

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET



Nataša D. Vlahović

ROBUSNO PRAĆENJE POKRETNIH OBJEKATA NA TERMALNOJ SLICI

doktorska disertacija

Beograd, 2021

UNIVERSITY OF BELGRADE

SCHOOL OF ELECTRICAL ENGINEERING



Nataša D. Vlahović

**ROBUST TRACKING OF MOVING OBJECTS
IN THERMAL IMAGES**

Doctoral Dissertation

Belgrade, 2021

PODACI O MENTORU I ČLANOVIMA KOMISIJE

Mentor:

dr Željko Đurović, redovni profesor
Univerzitet u Beogradu, Elektrotehnički fakultet

Članovi komisije:

dr Branko Kovačević, profesor emeritus
Univerzitet u Beogradu, Elektrotehnički fakultet

dr Zoran Banjac, naučni saradnik
Institut Vlatakom

dr Dragomir El Mezeni, docent
Univerzitet u Beogradu, Elektrotehnički fakultet

Datum odbrane: _____

ZAHVALNICA

Pre svega bih želela da izrazim iskrenu zahvalnost mentoru prof. dr Željku Đuroviću na inspiraciji, motivaciji, kao i na nesebičnoj podršci. Profesor dr Željko Đurović mi je bio inspiracija za upis studija, jer veliko znanje i iskustvo na veoma jednostavan način ume da predstavi i približi. Tokom procesa rada na disertaciji sam imala veliku čast i zadovoljstvo da od njega naučim kako jedan inženjer razmišlja i daje maksimum u svom radu. Takođe, veliku zahvalnost dugujem i prof. dr Branku Kovačeviću, dr Zoranu Banjcu, kao i doc. dr Dragomiru El Mezeniju na veoma zanimljivim diskusijama i konstruktivnim komentarima koji su dali poseban pečat ovoj disertaciji.

Zatim bih želela da se zahvalim mojoj porodici, bez koje ove teze ne bi ni bilo. Neizmernu zahvalnost na bezuslovnoj podršci i osloncu svake vrste tokom celog školovanja dugujem mojim roditeljima Svetlani i Draganu Kljajiću, kao i bratu Milanu Kljajiću. Na nesebičnoj podršci, osloncu, ramenu za plakanje, strpljenju i vremenu da se rad privede kraju zahvaljujem suprugu Nemanji Vlahoviću, a na inspiraciji i efikasnosti ćerki Jani Vlahović, kao i sinu koji je na putu.

Veliku zahvalnost dugujem upravi, kolegama i koleginicama iz Instituta Vlatakom na podršci tokom izrade disertacije. Pre svega se zahvaljujem kolegici dr Branki Stojanović na strpljenju u rešavanju mnogobrojnih dilema tokom rada na disertaciji. Posebnu zahvalnost dugujem i kolegi koji je poslužio kao model u eksperimentima koji su sprovedeni sa termalnom kamerom, Milanu Stojanoviću MSc. Zahvaljujem se i kolegi dr Iliji Popadiću na konstruktivnim diskusijama, kao i mom timu na podršci, posebno dr Nikoli Stojkoviću i Kristini Matović. Šefu dr Miroslavu Periću se posebno zahvaljujem na podršci svake vrste, hardverskoj, moralnoj, kao i izlaženju u susret u svim prilikama kada je pomoć bila potrebna.

Zahvaljujem se mojim prijateljima koji su me ohrabivali i slušali kada je bilo najpotrebnije. Posebno se zahvaljujem kolegici, ali pre svega prijatelju, doc. dr Sanji Vujnović, ne samo na moralnoj podršci, već i na konstruktivnim komentarima koji su uticali na krajnji oblik ove teze. Na strpljenju, ohrabrenju i beskrajnim razgovorima o disertaciji sam zahvalna i doc. dr Mariji Boričić.

Iskrenu zahvalnost dugujem kolegama iz Ministarstva Odbrane, Vojnotehničkog Instituta i Vojske Srbije jer su podržali moju inicijativu i posvetili svoje vreme za diskusiju i odabir pravca mog istraživanja. Tom prilikom se posebno zahvaljujem šefovima kojima nikada nije bilo teško da izdvoje dodatno vreme za pomoć: prof. dr Dragoljubu Vujiću, puk dr. Bojanu Pavkoviću, Sredoju Subotiću MSc, kao i Nenadu Cakiću. Zahvaljujem se i prof. dr Stevici Graovcu na saradnji u početnim fazama istraživanja.

ROBUSNO PRAĆENJE POKRETNIH OBJEKATA NA TERMALNOJ SLICI

Sažetak:

Praćenje pokretnih objekata je tema koja je veoma aktuelna u današnje vreme kada postoji potreba za sve većim brojem sistema za nadzor i osmatranje. Termalne kamere su omogućile vidljivost tokom dana i noći, što je velika prednost u odnosu na vizuelne kamere. Bolja rezolucija i kvalitet termalne slike su dovele do sve veće upotrebe u brojnim civilnim aplikacijama. Međutim, drugačija svojstva termalnih kamera u odnosu na vizuelne kamere čine dodatni izazov u razvoju algoritama za praćenje.

Osnovni predmet istraživanja ove doktorske disertacije jeste analiza problema praćenja jednog pokretnog objekta na termalnoj slici, kao i razvoj algoritama za robusno praćenje objekata na termalnoj slici scene.

Analizom dostupne literature je uočeno da dobre rezultate daju algoritmi koji su bazirani na deskriptorima odlika, a posebno SURF (eng. *Speeded Up Robust Features*) algoritam. Međutim, usled lošijeg kvaliteta slike i nesavršenosti odabranog deskriptora, mogu se desiti greške prilikom uparivanja odlika. U tim situacijama je potrebno koristiti prediktore pozicije objekta od interesa, kako bi se praćenje nastavilo.

Još jedan zaključak, nakon analize dostupne literature i baza podataka kreiranih za problem praćenja na termalnoj slici, jeste da ne postoji detaljna statistička analiza greške koju pravi algoritam za praćenje baziran na SURF odlikama. Zbog toga je jedan od ciljeva doktorske disertacije bio da se napravi dovoljno dobra baza podataka za detaljnu statističku analizu. Ovakvom analizom je omogućeno da se analiziraju tipovi greške i posledice na algoritam za praćenje. Analiza je omogućila i uvid u činjenicu da se u merenjima često javljaju autlajeri (eng. *Outliers*), a da zbog njih možemo reći da rezidual merenja nema normalnu raspodelu. Ta činjenica za posledicu ima da se standardni Kalmanov filter, kao estimator, loše pokazuje u situacijama kada postoje autlajeri.

Sa druge strane, robusni estimatori su, u situacijama kada dolazi do pojave autlajera, dobro rešenje. Zato je još jedan od ciljeva ove disertacije dizajn robusnog sistema za praćenje koji nije osetljiv na autlajere u merenjima. Međutim, statistička analiza je otkrila da osim grešaka koje su posledica okluzija i zaustavljaju praćenje, postoji porast varijanse greške u slučaju manevra, odnosno promene režima kretanja. To su greške koje se robusnim metodama ne smeju odseći. Postoje dva rešenja ovog problema, opisana u disertaciji. Jedan se zasniva na formiranju ekspertskeg sistema, koji donosi odluku o korišćenju određene funkcije uticaja u zavisnosti od situacije na sceni. Drugo rešenje jeste adaptacija parametra robusne funkcije trenutnoj situaciji na sceni. Ovo rešenje se zasniva na trenutnoj proceni kontaminacije autlajerima. Prednost ovog rešenja se ogleda u postizanju balansa između robusnosti i efikasnosti, sa jedne strane, kao i postizanju balansa između toga koji tip greške je u pitanju. Rešenje koje se nameće kao sledeći korak u dizajnu jeste i korišćenje adaptivnih robusnih filtera, radi prilagođenja matrica kovarijansi šuma, merenja i ulaza trenutnoj situaciji na sceni. Kako proces podešavanja parametra funkcije uticaja zavisi od procenjenog faktora kontaminacije, dat je poseban osvrt na način računanja

faktora kontaminacije. Uveden je i adaptivni faktor zaboravljanja u račun faktora kontaminacije, kako bi se, na taj način, postigla veća tačnost i bolje prilagođenje situaciji na sceni.

Ključne reči:

praćenje pokretnih objekata, termovizija, robusna estimacija, Kalmanov filter, deskriptor odlika, funkcija uticaja, podesivi parametri, balans robusnosti i efikasnosti estimatora, autlajeri, statistička analiza.

Naučna oblast: elektrotehnika i računarstvo

Uža naučna oblast: digitalna obrada slike

ROBUST TRACKING OF MOVING OBJECTS IN THERMAL IMAGES

Abstract:

Moving objects tracking is currently a popular topic because of the growing demand for surveillance and monitoring systems. Thermal cameras enable visibility during the day as well as night, which is a great advantage over visual cameras. Better thermal image resolution and quality have led to increased usage in many civil applications. However, thermal cameras have different features compared to visual cameras, which is an additional challenge in the development of tracking algorithms.

The main research topic of this dissertation is analysis of a single moving object tracking problem, as well as the development of robust tracking algorithms for thermal images.

A review of available literature revealed that good results are obtained when feature descriptor-based algorithms are used, especially a SURF (*Speeded Up Robust Features*) algorithm. However, poor image quality or contrast, as well as any imperfection of the SURF algorithm itself and the presence of occlusions, can cause feature matching errors. These situations point out that there is a need for motion prediction and estimation.

Examination of literature sources, as well as of databases designed for the thermal image tracking problem, led to a more significant conclusion: there are no papers that analyze in detail the errors of a SURF algorithm in a thermal image. That is why one of the goals of this dissertation is to create a database good enough for detailed statistical analysis. This analysis uncovers typical errors and their impact on the tracking algorithm. On the other hand, the statistical analysis shows that there are outliers in the data, so the distribution of the measurement residual is not normal. Because of the outliers, the standard Kalman filter estimator does not provide good tracking results.

Robust estimators are a good solution if there are outliers. Consequently, an additional goal of this doctoral dissertation is to design a robust tracking system not sensitive to outliers in the measured data. The statistical analysis shows that, apart from the outliers that are a direct consequence of occlusions and result in a total loss of the target, there are also errors due to maneuvering, which increase the error variance. Maneuvering errors are not outliers and must not be cut by robust methods. Achieving balance in this case is not an easy task. There are two possible solutions to this problem, as described in this dissertation. One solution is based on expert system design where, depending on the particular situation on the scene, the system itself decides which influence function can be used. The second solution is robust function parameter tuning, based on the current situation on the thermal scene. This solution is based on outlier contamination estimation. The advantage of the latter solution is the fact that it is possible to achieve a balance between estimator efficiency and robustness, as well as separation of the two types of errors. The next design step is to use adaptive robust filters, in order to adjust the state and measurement noise covariance matrices to the current situation in the thermal image. Since tuning of the influence function parameters depends on the estimated contamination factor, the calculation of this factor is also analyzed. The use of an adaptive forgetting factor to estimate the contamination factor results in higher precision and better adaptation to the conditions on the scene.

Keywords: moving object tracking, thermal imagery, robust estimation, Kalman filter, feature descriptor, influence function, tunable parameters, robustness and efficiency balance, outliers, statistical analysis.

Scientific area: electrical engineering and computer science

Specific scientific area: digital image processing

SADRŽAJ:

1. UVOD	1
1.1 Predmet rada i cilj istraživanja	1
1.2 Opis sadržaja disertacije	3
2. TERMALNA SLIKA	5
2.1 Termalne kamere	5
2.2 Mogućnosti i ograničenja termalnih kamera	6
2.3 Analiza termalne slike	10
3. OBRADA SLIKE.....	14
3.1 Osnove obrade slike	14
3.2 Pretprocesiranje slike	16
3.3 Odlike na slici.....	19
3.3.1 Detektori i deskriptori odlika	19
3.3.2 Upporedna analiza osetljivosti detektora odlika na termalnoj slici	20
3.3.3 SURF deskriptor	27
4. PRAĆENJE POKRETNIH OBJEKATA	29
4.1 Obrada video signala	30
4.2 Analiza savremenih algoritama za praćenje pokretnih objekata	32
4.3 Praćenje objekata SURF deskriptorom	35
4.3.1 SURF deskriptor – greška praćenja	35
4.3.2 Tehnike estimacije funkcije gustine verovatnoće	37
4.4 Uzroci greške praćenja objekata SURF deskriptorom na termalnoj slici	41
4.5 Analiza greške praćenja SURF deskriptora na termalnoj slici.....	45
5. ESTIMACIJA STANJA STOHAŠTIČKIH SISTEMA	46
5.1 Linearna estimacija stanja stohastičkih sistema	47
5.1.1 Standardni Kalmanov filter	47
5.1.2 Ograničenja kod klasičnih metoda i pojam autlajera	48
5.2 Robusna estimacija stanja stohastičkih sistema	50
5.2.1 Razvoj teorije robusne estimacije i različiti pristupi.....	50
5.3 Robusni estimatori stanja	52

5.3.1	Robusni Kalmanov filter sa fiksnim parametrima	52
5.3.2	Funkcije uticaja	55
5.3.3	Robusni Kalmanov filter sa promenljivim parametrima	58
5.4	Adaptivni robusni estimatori stanja.....	61
5.5	Procena kontaminacije autlajerima	62
5.5.1	Adaptivni faktor zaboravljanja	62
6.	DIZAJN ROBUSNOG SISTEMA ZA PRAĆENJE POKRETNIH OBJEKATA NA TERMALNOJ SLICI I EKSPERIMENTALNI REZULTATI	65
6.1	Standardni Kalmanov filter	66
6.2	SURF i KLT odlike i standardni Kalmanov filter u praćenju objekata na termalnoj slici	67
6.3	Robusni Kalmanov filter sa fiksnim parametrima	71
6.4	Ekspertski sistem sa različitim funkcijama uticaja u zavisnosti od kretanja objekta na slici	74
6.4.1	Usporedna analiza SKF i RKF sa različitim funkcijama uticaja	74
6.4.2	Analiza primene različitih funkcija uticaja na sekvencama sa različitim režimima kretanja	76
6.4.3	Dizajn ekspertskog sistema na bazi promene funkcije uticaja u slučaju različitih režima kretanja	79
6.5	Robusni Kalmanov filter sa promenljivim parametrima.....	80
6.5.1	Poređenje rada RKF sa promenljivim Δ i savremenih trepera.....	83
6.6	Adaptivni Robusni Kalmanov filter sa promenljivim parametrima.....	86
6.7	Procena kontaminacije podataka autlajerima.....	89
6.7.1	Adaptivni faktor zaboravljanja	92
7.	ZAKLJUČAK	96
	LITERATURA	99

1. UVOD

U okviru Uvoda je izložen pregled problema koji se razmatra u doktorskoj disertaciji, kao i cilj istraživanja uz detaljan opis sadržaja doktorske disertacije.

1.1 PREDMET RADA I CILJ ISTRAŽIVANJA

Praćenje pokretnih objekata na sceni predstavlja problem koji se dugo godina izučava, pogotovo u domenu vizuelnih kamera. Ovo je problem koji je još uvek u fokusu naučnih istraživanja, što dokazuju mnoga takmičenja i konferencije na ovu temu koji se svake godine organizuju sa ciljem da se postignu što bolje performanse i efikasnost algoritama za praćenje [1], [2]. Savremena tehnološka dostignuća su omogućila sve veću komercijalnu upotrebu tehnologija koje su nekada bile rezervisane samo za vojni sektor, poput termalnih kamera. One su interesantne iz mnogo razloga: omogućavaju vidljivost tokom dana i noći (jer ne zavise od izvora svetlosti), pasivni su senzori (primaju zračenje, a ne emituju, kao na primer radari), vide kroz kamuflažne folije, vide ono što se očima ne može videti (opasni gasovi, vatra, kvarovi u električnim instalacijama, i bilo koje povećanje temperature), ne narušavaju privatnost tokom nadzora (kao što je slučaj kod vizuelnih kamera). Zbog toga se sve više i koriste u komercijalnim aplikacijama. Sve veća komercijalna dostupnost termalnih kamera je omogućila popularizaciju problema praćenja pokretnih objekata na termalnoj slici.

Osnovni predmet istraživanja ove doktorske disertacije jeste analiza problema praćenja jednog pokretnog objekta na termalnoj slici, dok je cilj doktorske disertacije dizajn robusnog sistema za praćenje pokretnog objekta na termalnoj slici koji se prilagođava različitim uslovima scene.

Analizom dostupne literature je uočeno da SURF („*Speeded Up Robust Features*“) deskriptori daju dobre rezultate u praćenju objekata u termalnom domenu [3], [4], pa predstavljaju i dobro rešenje za odabrani zadatak. Dakle, SURF detektor i deskriptor uz uparivanje odlika na dva sukcesivna frejma čine algoritam koji je vrlo često korišćen u realnim aplikacijama zbog brzine rada i robusnosti [5].

Iako SURF algoritam generalno daje dobre rezultate u termalnom domenu, usled lošijeg kvaliteta slike ili manjeg kontrasta na samoj termalnoj slici mogu se desiti greške prilikom uparivanja. Dakle, zbog nesavršenosti same termalne slike, SURF deskriptora, ali i prisustva različitih okluzija u slici, merenja pozicije objekta koji se prati nisu uvek tačna i precizna, pa je potrebno vršiti predikciju i estimaciju kretanja objekta. Takva estimacija podrazumeva korišćenje neke vrste prediktora radi predikcije pozicije objekta od interesa zbog situacija u kojima SURF deskriptor ne daje dobre rezultate, ili kada odlike uopšte ne mogu biti pronađene u slici.

Uočena mana metoda koje opisuju praćenje objekta od interesa korišćenjem SURF algoritma jeste da ne postoje istraživanja koja se odnose na detaljnu analizu greške SURF algoritma na termalnoj slici. Takvom analizom greške se može otkriti prisustvo tipičnih grešaka koje kvare performansu sistema, a dešavaju se u određenim situacijama promene režima kretanja, ali i onih koji utiču na potpuni gubitak praćenja objekta od interesa i predstavljaju autlajere u podacima. Najčešći uzrok prestanka rada algoritma za praćenje jesu autlajeri u podacima. Međutim, nije lako unapred predvideti kada će se desiti niti koliku će vrednost imati. Zbog toga je, za problem praćenja pokretnog objekta na termalnoj slici, vrlo značajno ispitati prirodu grešaka koje se javljaju u podacima.

U slučaju pojave autlajera u podacima korišćenje linearnog estimatora, poput standardnog Kalmanovog filtra, nije dobro rešenje, jer je osetljiv na njih. Ukoliko se sam uzrok pojave autlajera, za dati slučaj ispita, Kalmanov filter se može unaprediti i učiniti robusnim u slučaju njihove pojave, što svakako može dati rešenje koje štedi procesorsko vreme i daje bolje performanse sistema. Zbog toga je, u okviru ove disertacije, odabran robusni estimator na bazi robusnog Kalmanovog filtra.

Pre samog projektovanja robusnog estimatora, posebnu pažnju je potrebno obratiti na činjenicu da robusnost na autlajere dolazi sa cenom koja se plaća smanjenjem efikasnosti estimatora. Još jedan problem prilikom dizajna robusnog Kalmanovog filtra za analizirani slučaj jeste prisustvo dva najčešća tipa grešaka. To su greške usled manevra koje utiču na porast varijanse greške sistema i greške usled okluzija, koje su autlajeri. I dok se autlajeri u podacima uspešno otklanjaju robusnim metodama, greške usled promene režima kretanja, odnosno manevra objekta, zavise od situacije na sceni i nisu autlajeri, pa se nikako ne smeju odseći. Robusni Kalmanov filter se zato mora projektovati na način da toleriše greške manevra, dok autlajere uklanja. Teško je napraviti jasnu razliku između ova dva tipa greške. Takođe, teško je i napraviti balans između robusnosti i efikasnosti estimatora.

Međutim, postoje načini za dizajn rešenja koje se prilagođava situaciji. Jedan od načina jeste ispitivanje rada različitih funkcija uticaja u raznim režimima kretanja i dizajn ekspertskeg sistema koji se, u zavisnosti od situacije na sceni, prilagođava uslovima birajući pogodnu funkciju uticaja za taj slučaj. Drugi način jeste korišćenje podesivih parametara funkcija uticaja. Naime, kako funkcije uticaja sadrže podesive parametre koji zavise od procenjenog stepena, odnosno varijanse kontaminacije autlajerima, oni se mogu prilagoditi uslovima scene u zavisnosti od podataka koje imamo na raspolaganju i na taj način možemo postići kompromis između oprečnih zahteva.

Dakle, neki od doprinosa ove doktorske disertacije jesu: 1) formiranje nove baze podataka za potrebe statističke analize problema praćenja jednog pokretnog objekta na termalnoj slici; 2) statistička analiza podataka sa termalne kamere i greške odabranog SURF algoritma za praćenje; 3) dizajn robusnog sistema za praćenje koji u toku rada vrši procenu trenutne kontaminacije autlajerima i automatski podešava parametre nelinearne robusne funkcije, 4) dizajn adaptivnog robusnog sistema za praćenje, 5) testiranje i uvođenje adaptivnog faktora zaboravljanja u proračun kontaminacije autlajerima. Rešenja predložena u ovoj disertaciji opisuju novi pristup dizajnu algoritma za praćenje sa SURF deskriptorom, koji nije do sada poznat u literaturi, jer mane SURF algoritma otklanja uz pomoć robusnog Kalmanovog filtra, a ne dodatnim popravkama samog algoritma koji prati objekat od interesa.

1.2 OPIS SADRŽAJA DISERTACIJE

Pored prvog, uvodnog poglavlja, doktorska disertacija sadrži još sedam poglavlja:

Drugo poglavlje je podeljeno na tri osnovne celine: termalne kamere, mogućnosti i ograničenja termalnih kamera i analizu termalne slike. U delu koji se odnosi na termalne kamere je opisan generalni princip rada termalnih kamera, kao i način formiranja termalne slike. Iznete su i osnovne podele kamera, na osnovu talasne dužine, kao i na osnovu tehnologije izrade. Termalne slike se razlikuju od slika sa kamera u vizuelnom domenu, a glavne razlike su izložene u delu koji se odnosi na mogućnosti i ograničenja termalnih kamera. Takođe je, u ovom delu, dat odgovor na pitanje koliko daleko možemo videti sa termalnom kamerom, objašnjen je pojam Džonsonovog kriterijuma, dat je pregled mera performanse koje govore o osetljivosti termovizijske kamere i kakve mogućnosti pruža. Poslednja sekcija ovog poglavlja predstavlja analizu termalne slike, uz analizu šuma koji se javlja na konkretnoj analiziranoj sekvenci i predstavlja važan korak u postavljanju početnog modela potrebnog u daljem razvoju algoritma za praćenje pokretnog objekta.

Treća glava predstavlja teorijski osvrt na oblast obrade slika, a podeljena je na dve celine: osnove obrade slika i odlike na slici. Najpre su izložene osnove obrade slike, odnosno šta slika predstavlja, na koji način se mogu obrađivati i ispitivati informacije koje se dobijaju sa slike i koja su to ograničenja koja računari imaju u pogledu obrade slika. U ovom delu je dat prikaz različitih segmenata obrade slike (poput pretprocesiranja slike), a objašnjen je i tok obrade podataka u sistemima za obradu slike. Druga celina ovog poglavlja daje najpre detaljniji opis algoritama koji se baziraju na opisu odlika na slici i načinima na koji se te odlike mogu tretirati. Data je i uporedna analiza osetljivosti detektora odlika na termalnoj slici, na osnovu koje se mogu doneti zaključci o tome na koji način se detektori iz različitih familija mogu koristiti na termalnoj slici. Kao deskriptor odlika, za zadatak praćenja u ovom radu, je odabran SURF deskriptor, a teorijski pristup je opisan kao deo ove sekcije.

U četvrtoj glavi je, u pet celina, opisan zadatak praćenja objekata na termalnoj slici. Najpre je opisan problem praćenja objekata i izazovi sa kojima se susrećemo prilikom dizajna sistema za praćenje. Kao sastavni deo razmatranja problema praćenja objekata jeste i tema obrade video signala, pa je dat teorijski i praktični osvrt na uslove i ograničenja kvaliteta video signala koji se obrađuje sistemima za praćenje. Sledeća celina ovog poglavlja se odnosi na analizu rada savremenih algoritama za praćenje, kao i njihovu podelu. Kao odabrani algoritam za praćenje je usvojen algoritam sa SURF detektorom i deskriptorom, pa je izložena metodologija rada sa SURF deskriptorom. U okviru ove celine je predstavljen način za analizu greške posmatranog algoritma, korišćenjem tehnika estimacije gustine verovatnoće, a zatim je data i statistička analiza dobijenih podataka. Izvršena je osnovna podela uzroka grešaka kod SURF algoritma. Na kraju je izvršena sistematska analiza grešaka i predlog za njihovo otklanjanje. Ovo poglavlje je izuzetno važno jer, na osnovu statističke analize i sistematskog pristupa klasifikaciji grešaka, daje uvid u načine za poboljšanje rada sistema, a vodeći računa o balansu između nekada oprečnih zahteva sistema.

U petom poglavlju je izložena teorija estimacije stanja stohastičkih sistema u pet celina: linearna estimacija i robusna estimacija stanja stohastičkih sistema, robusni estimatori stanja, adaptivni robusni estimatori stanja i procena kontaminacije autlajerima. Najpre je dat teorijski osvrt na linearnu estimaciju, gde je izložen i način dizajna standardnog Kalmanovog filtra, kao

predstavnik klasične teorije estimacije, pa su i analizirana ograničenja kod linearnih sistema i estimatora. U sklopu ove celine objašnjena su ograničenja klasičnih metoda, kao i pojam autlajera. Sekcija robusna estimacija daje uvid u razvoj teorije robusne estimacije, kao i njene osnovne pristupe. Zatim su opisani načini za dizajn robusnih estimatora koji su opisani i korišćeni u ovom radu, a zatim i način za adaptivnu robusnu estimaciju. Na kraju je dat teorijski osvrt na procenu kontaminacije autlajerima, kao i način za adaptaciju procene kontaminacije uslovima scene uz pomoć adaptivnog faktora zaboravljanja.

Eksperimentalni rezultati i celokupan postupak dizajna različitih tipova estimatora prikazani su u šestom poglavlju. Najpre je opisan način za postavljanje modela standardnog Kalmanovog filtra, kao i njegova ograničenja. Zatim je izloženo rešenje problema klasičnih metoda kombinovanjem dve vrste algoritama za praćenje, uz analizu nedostataka ovakve metode. U sledećoj sekciji je pokazano da je robusni Kalmanov filter u stanju da se izbori sa problemima koje standardni Kalmanov filter nije bio u mogućnosti da prevaziđe. Međutim, radi postizanja optimalnog balansa između oprečnih zahteva sistema, potrebno je stalno prilagođavati estimator trenutnoj situaciji. Rešenje tog problema ide u dva pravca, gde je jedan pravac dizajn ekspertskeg sistema, koji na osnovu trenutnih parametara scene menja korišćenu funkciju uticaja robusnog Kalmanovog filtra, a drugi pravac je adaptacija promenljivog parametra funkcije uticaja na osnovu procenjene kontaminacije greškama tipa autlajera, a oba pristupa su opisana u ovom poglavlju. Još jedno poboljšanje rada algoritma za praćenje je opisano u sekciji koja opisuje način rada adaptivnog robusnog filtra sa promenljivim parametrima. Na kraju ovog poglavlja je dat eksperimentalni prikaz rezultata procene faktora kontaminacije autlajerima, uz rezultate primenom adaptivnog faktora zaboravljanja radi postizanja procene koja se više prilagođava uslovima na sceni.

Sedmo poglavlje predstavlja sumiranje rezultata, analizu i zaključak koji se može izvesti o izloženoj metodologiji rada, kao i predlog za dalja istraživanja.

Na kraju su date reference koje su korišćene prilikom izlaganja teme ove disertacije.


2. TERMALNA SLIKA

2.1 TERMALNE KAMERE

U cilju boljeg razumevanja principa rada termalnih kamera, najpre ćemo objasniti pojam elektromagnetnog spektra i različitih tipova elektromagnetnog zračenja. Elektromagnetni spektar zračenja, na slici 1, prikazuje sve vrste zračenja u zavisnosti od njihove talasne dužine i frekvencije. Infracrveni opseg talasnih dužina, vidljivih infracrvenim, odnosno termalnim kamerama se deli na više podopsega prema svojstvima: blisko infracrveno (NIR - „*Near Infrared*“, talasne dužine 0,7–1 μm), kratko-talasno infracrveno (SWIR - „*Shortwave Infrared*“, 1–3 μm), srednje infracrveno (MWIR - „*Midwave Infrared*“, 3–5 μm), daleko infracrveno (LWIR - „*Longwave Infrared*“, 7,5-12 μm). Podela ovih talasnih opsega infracrvenog zračenja je izvršena na osnovu razlike regija gde je atmosferska transmisija veoma niska, odnosno na regione gde postojeći senzori imaju svoja ograničenja. LWIR, a ponekad i MWIR, obično se u literaturi nazivaju termalnim infracrvenim zračenjem. Termalne kamere mogu biti hladene i nehladene, a biraju se u zavisnosti od raspoloživih resursa i potreba aplikacije ili sistema gde se koriste. Hladene kamere, osim što omogućavaju snimanje velikog broja frejmova u sekundi, daju sliku boljeg kvaliteta, uz veći dinamički opseg i bolju temperaturnu osetljivost na male razlike u temperaturi. Sa druge strane, nehladene kamere su tiše, manje su cene i veličine, ali daju sliku lošijeg kvaliteta sa većim prisustvom šuma i imaju mogućnost snimanja manjeg broja frejmova u sekundi u odnosu na hladene kamere [6].

Radi boljeg objašnjenja rada i primene termalnih kamera, upoređićemo ih sa vizuelnim kamerama. Na slici 1, koja je dizajnirana po ugledu na slike [7] i [8] se može videti koji deo elektromagnetnog spektra možemo videti našim očima. Kako naše oči u stvari vide reflektovanu svetlost i na taj način se u mozgu formira slika sveta oko nas, vrlo je lako razumeti koncept vizuelnih kamera. Vizuelne kamere formiraju sliku na osnovu reflektovane svetlosti, ali im je zato potreban i izvor svetlosti kako bi mogle formirati sliku. Zbog toga nije moguće koristiti vizuelne kamere u mraku.

Sa druge strane, termalne kamere snimaju temperaturnu raspodelu posmatrane scene tako što detektuju zračenje objekata na sceni, odnosno temperaturu i emisivnost objekata. Temperatura objekta je široko poznat pojam, dok je emisivnost objekta karakteristika materijala od kojeg je objekat sačinjen. Razlika u odnosu na vizuelne i bliske infracrvene (NIR) kamere, gde celokupno detektovano zračenje potiče od refleksije od objekata na sceni, jeste ta što je najveći deo izmerenog zračenja posledica emisije samih objekata. Dakle, termalne kamere imaju mogućnost detekcije malih temperaturnih razlika koje se na termalnoj slici prikazuju najčešće različitim nivoima sive boje, ali i u paletama boja po izboru (u zavisnosti od korisničkog interfejsa i mogućnosti same kamere) [9], [10].



1. Slika – Elektromagnetni spektar zračenja

Jedna značajna podela senzora jeste i na aktivne i pasivne senzore [11]. Aktivni senzori zavise od emitovane energije (primer: slika sa vizuelne kamere zavisi od količine svetlosti) i mogu biti otkriveni lako (što u vojnim primenama znači da neprijateljske snage mogu biti upozorene na to da se posmatraju, na primer radarskim sistemima). Sa druge strane, za termalne kamere možemo reći da su pasivni senzori, kojima nisu potrebni dodatni izvori zračenja da bi mogli formirati sliku, a omogućavaju vidljivost u bilo koje doba dana ili noći. Zbog specifičnih potreba u sofisticiranim sistemima za nadzor i osmatranje, praćenje pokretnih ciljeva, raketnim sistemima itd. termalne kamere su najpre bile korišćene samo za vojne primene. Međutim, kako je napredovala tehnologija razvoja i kako se poboljšavao kvalitet slike samih kamera, tako su nalazile sve veću ulogu i u civilnim aplikacijama. U današnje vreme imaju primenu u raznim granama industrije, ekologije, građevinarstva, medicine, robotike, elektronike itd [3]. Koriste se u aplikacijama za praćenje meta, kontrole kvaliteta, aplikacijama nedestruktivnog testiranja, nadzora, inspekcije toplote i gasova u objektima, za temperaturna merenja [12] itd.

2.2 MOGUĆNOSTI I OGRANIČENJA TERMALNIH KAMERA

Prilikom rada sa termalnim slikama važno je imati na umu da se termalne slike ne mogu tretirati kao crno bele slike sa vizuelne kamere. Termalne slike imaju različite karakteristike u odnosu na slike sa vizuelnih kamera. Osnovna razlika jeste da u termalnom domenu ne postoje senke, niti različiti šabloni u zavisnosti od boja na sceni, kao što je to slučaj sa slikama sa kamera u vizuelnom domenu. Šabloni na termalnim slikama potiču od razlika u materijalima od kojih su objekti sačinjeni, kao i od njihove različite temperature. Još jedna važna činjenica, koju treba imati u vidu prilikom dizajna sistema u kojima se koriste termalne kamere, jeste da je promena emitovanog zračenja proces koji je sporiji od promene reflektovanog zračenja. To znači da se

promene koje se dešavaju na termalnoj slici dešavaju sporije nego promene na slikama sa vizuelnih kamera. Takođe, karakteristike šuma koji se javlja na termalnoj slici su sasvim drugačije od šuma koji se javlja u vizuelnom domenu [6], [10], [3]. Kako je za uspešan dizajn sistema ili aplikacija potrebno dobro poznavati mogućnosti i performanse korišćenih senzora i aktuatora koji diktiraju uslove rada sistema, isto važi i za korišćenje termovizijskih sistema.

Za početak je neophodno upoznati se sa karakteristikama šuma na termalnoj slici, jer je to faktor koji najviše utiče na kvalitet termalne slike. Šum u termalnoj slici se javlja kao posledica tehnologije izrade same kamere, odnosno termovizijskog sistema ili kao posledica same prirode posmatrane scene. Jako je teško napraviti jasnu razliku između vrsta šuma i odrediti dominantan tip šuma za konkretan slučaj. Izvori šuma u termalnim sistemima su razni i ima ih jako veliki broj: 1) 3-D šum koji je prostorno – vremenski šum, a obuhvata šum fotona, Džonsonov šum, šum pojačavača, šum digitalizacije; 2) 2-D vremenski šum koji obuhvata vremenski šum vrste ili kolone; 3) 2-D prostorni šum koji obuhvata beli šum matričnih skenera, korelisani šum vrste, korelisani šum kolone, šum greške normalizacije, šum niskih učestanosti. Jako je teško odrediti dominantan tip šuma za bilo koji sistem i generalan način za njegovo otklanjanje.

Neke od mera performanse koje govore o osetljivosti termovizijske kamere i kakve mogućnosti pruža jesu temperaturna razlika ekvivalentna šumu (NETD – „*Noise Equivalent Temperature Difference*“) koja predstavlja objektivnu meru osetljivosti sistema, dok je jedna od subjektivnih mera minimalno razloživa temperaturna razlika (MRTD – „*Minimum Resolvable Temperature Difference*“). Naravno, karakteristike sistema daje proizvođač i obuhvataju podatke o kameri (tip detektora, NETD, spektralni odziv, operabilnost, itd.), kao i o objektivu kamere (kontinualno ili fiksno zumiranje, širina vidnog polja, itd.).

Još jedno važno pitanje, kada se radi o izboru termalne kamere u zavisnosti od njene primene, jeste koliko daleko vidi kamera. Kako bismo mogli dati odgovor na ovo pitanje, korišćemo Džonsonov kriterijum koji definiše šta to znači videti termalnom kamerom [13], [14].

Džonsonov kriterijum predstavlja metodu za predikciju verovatnoće diskriminacije objekta od interesa, a služi za karakterizaciju termalnih kamera i davanje procene dometa kamere. Po ovom kriterijumu postoje tri stepena mogućnosti da kamera vidi:

1. Detekcija:

Predstavlja mogućnost detekcije prisustva objekta na slici. Za ovu vrstu diskriminacije objekta je potreban najmanji broj piksela po kritičnoj dimenziji - bar oko 1.5 ili više piksela kritične dimenzije.

2. Prepoznavanje

Predstavlja mogućnost razlikovanja, odnosno prepoznavanja razlika između tipova objekata (pešak, kamion, automobil, avion, itd.). Za prepoznavanje je potrebno bar 6 piksela po kritičnoj dimenziji.

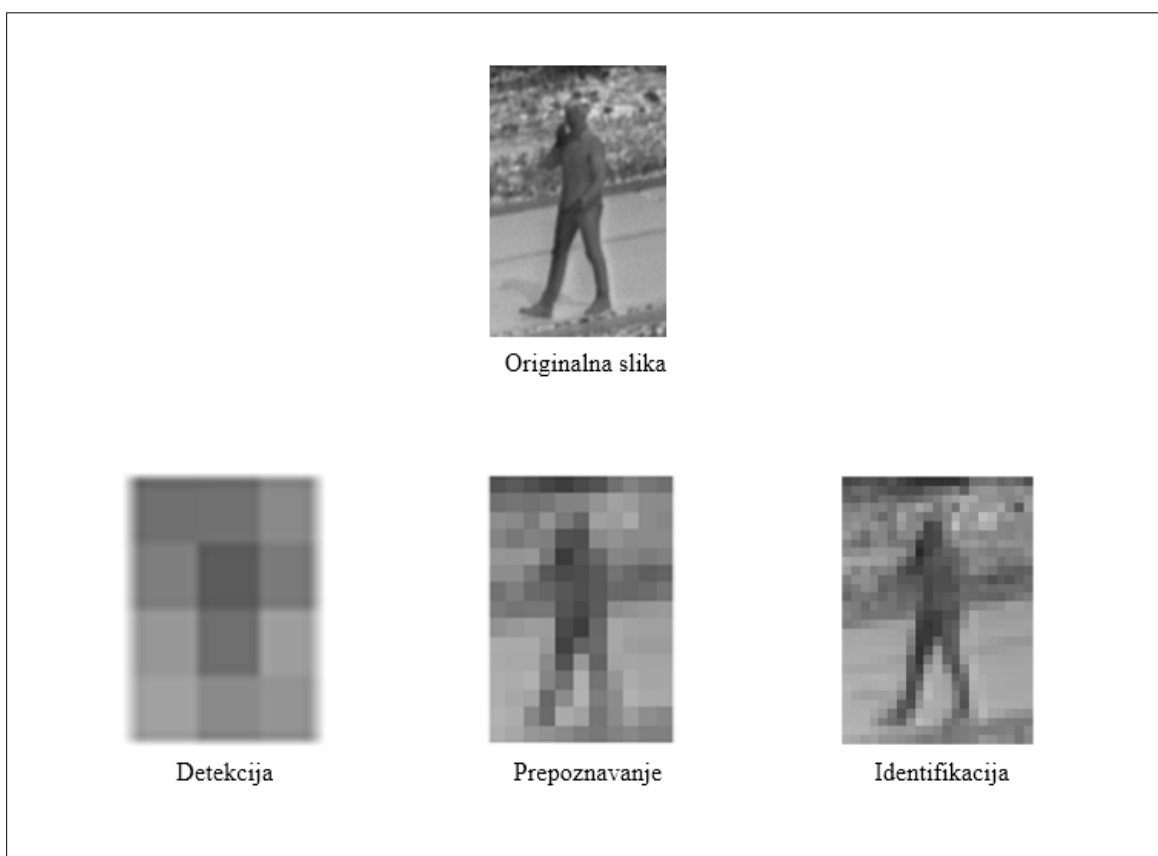
3. Identifikacija

Predstavlja mogućnost jasne identifikacije u vojnom kontekstu, da li je meta prijateljska ili nije. Za ovu mogućnost je potrebno bar 12 piksela po kritičnoj dimenziji.

Očekivani rezultat kamere jeste da se objekti na sceni uoče, odnosno detektuju (da li je objekat na sceni ili nije), prepoznaju (koji je tip objekta u pitanju automobil, pešak, avion ili bilo koji drugi tip objekta) ili identifikuju (obično se koristi za vojne primene, kako bi definisali da li je prijateljski ili neprijateljski objekat na sceni). Naravno, minimalan broj piksela potreban za

detekciju, prepoznavanje ili identifikaciju objekta od interesa zavisi i od vrste objekta koji se posmatra, dakle na primer, da li se očekuje pešak ili autobus. Na osnovu toga se posebno specificiraju kriterijumi detekcije, prepoznavanja ili identifikacije za ljude i vozila standardnih veličina, i daju se procene daljine u zavisnosti od objektiva koji se koristi uz kameru. Svakako, ono što proizvođač ne može da garantuje jeste rad u svim atmosferskim prilikama, jer sneg, magla i kiša imaju veliki uticaj na sliku termalne kamere. Takođe, u zavisnosti od toga da li je objekat statičan ili se kreće zavisi njegova vidljivost.

Jedan primer Džonsonovog kriterijuma u slučaju pešaka je ilustrovan na slici 2, koja se bazira na primeru iz [13], ali predstavljenom na jednom frejmu iz sekvence koja je kreirana za potrebe ove disertacije.



2. Slika – Džonsonov kriterijum primer na frejmu iz sekvence koja se analizira u disertaciji

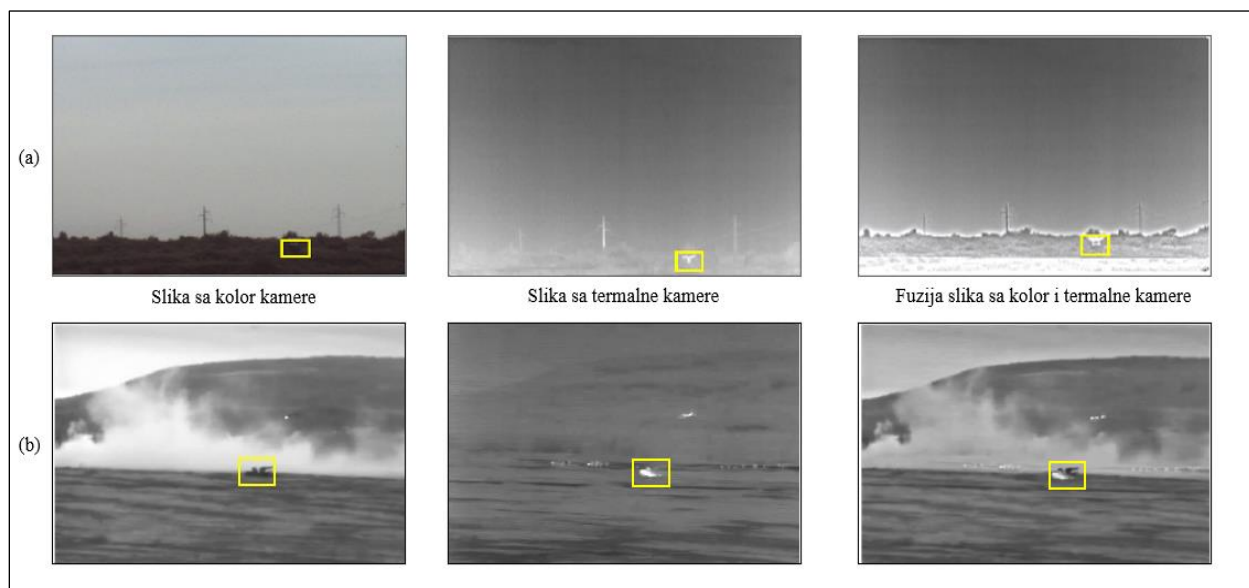
Dakle, Džonsonov kriterijum pretpostavlja da je kritična dimenzija za čoveka 0.75 metara. Kako bi se dobio kriterijum za detekciju, prepoznavanje i identifikaciju potrebno je imati 1.5 piksela, 6 piksela i 12 piksela na 0.75 metara kritične dimenzije.

Ukoliko pretpostavimo da je tipična dimenzija čoveka 1.8x0.5 metara, dobijamo kriterijum za čoveka:

- **Detekcija** (dovoljno 3.6x1 piksel), sa slike 2 se vidi da je dovoljno da se proceni da je nešto na slici prisutno,
- **Prepoznavanje** (dovoljno 14.4x4 piksela), sa slike 2 se vidi da je čovek na slici,
- **Identifikacija** (dovoljno 28.8x8 piksela), sa slike 2 se vidi da je osoba bez naoružanja, odnosno prijateljska.

Termalne kamere pružaju različite mogućnosti korisniku, ali imaju i svoja ograničenja. Prilikom izbora termalne kamere za određenu primenu, potrebno je razmotriti sve aspekte i karakteristike koje su potrebne za rad konkretnog sistema. Nije isto definisati karakteristike termalne kamere za potrebe sistema za praćenje objekata i sistema za detekciju gasova. Na kraju, i nakon izbora kamere, neophodno je izvršiti analizu slike koja se dobija kada je kamera u najčešće korišćenom radnom režimu aplikacije za koju se koristi.

Mogućnosti termalnih kamera su velike, a mogu se koristiti u velikom broju aplikacija u različitim granama industrije, biologije, poljoprivrede, u sistemima za nadzor i naravno u vojnim aplikacijama. U sistemima za nadzor se mogu samostalno koristiti za detekciju i praćenje, ali i kao sastavni deo multisenzorskih sistema, koji daju mogućnost spajanja, odnosno fuzije više slika u jednu, poput termalne slike i slike sa vizuelne kamere. Na taj način se mogu poboljšati performanse algoritama za detekciju i praćenje objekata od interesa [15]. Na slici 3 se mogu videti dva primera fuzije slike sa kolor i termalne kamere [15]. Objekat od interesa je na svim slikama obeležen.



3. Slika – Primer fuzije slike sa kolor i termalne kamere: (a) situacija 1: (levo) slika sa kolor kamere, (sredina) slika sa termalne kamere, (desno) fuzija slika sa kolor i termalne kamere; (b) situacija 2: (levo) slika sa kolor kamere, (sredina) slika sa termalne kamere, (desno) fuzija slika sa kolor i termalne kamere

Iz priloženog primera sa slike 3 se može primetiti da se u slučaju situacije 1 na kolor slici objekat uopšte ne vidi, dok se na termalnoj slici bolje vidi, a samim tim i fuzija ove dve slike daje bolju predstavu o sceni koja se posmatra. Sa druge strane, u slučaju situacije 2 se objekat od interesa vidi slabije, ali se ipak vidi, dok se sama scena i pozadinski dim na kolor slici jasno mogu razaznati, a na termalnoj ne. U oba slučaja se primećuje poboljšanje dobijeno fuzijom slika. Korišćenjem fuzije slika se, dakle, dobija poboljšanje u smislu vidljivosti objekata na sceni, ali se zato mora voditi računa o povećanju računске zahtevnosti algoritma, a samim tim i o brzini rada na realnim platformama.

2.3 ANALIZA TERMALNE SLIKE

Kao što smo već pomenuli, termalne kamere predstavljaju senzore koji u zavisnosti od temperature i zračenja objekata na sceni formiraju sliku i obezbeđuju istu vidljivost tokom noći, kao i na dnevnoj svetlosti, pa se zato dosta razlikuju u odnosu na slike dobijene pomoću vizuelnih kamera koje sliku formiraju na osnovu osvetljenosti scene. Ono što predstavlja prvi korak u dizajnu svakog sistema jeste analiza podataka koji se dobijaju sa korišćenih senzora i šuma koji taj senzor pravi. U našem slučaju je zato potrebno statistički analizirati sliku koja se dobija sa termalne kamere. U ovom radu su analizirane karakteristike slike i šuma termalne MWIR kamere rezolucije 640x480 sa brzinom rada od 60 fps („frames per second“ – frejmova u sekundi).

Kako bismo mogli izvršiti statističku analizu ponašanja SURF deskriptora u različitim situacijama, analizirane su javno dostupne baze podataka: *OTCBVS*, *LITIV*, *ASL-TID*, *BU-TIV*, *LTIR*, *ADAS FLIR*, *LSOTB-TIR*. Baze *ASL-TID*, *BU-TIV* i *ADAS* („Advanced Driver Assistance Systems“) *FLIR dataset* [16] nisu specijalno dizajnirane za problem praćenja objekata, dok su baze *OTCBVS* i *LITIV* zastarele baze, pa se ne mogu se primeniti za nove izazovne probleme praćenja. Dakle, samo dve javno dostupne baze su odgovarajuće za analizirani problem: *LTIR* („Linköping Thermal InfraRed dataset“) [17] i *LSOTB-TIR* [17] *dataset*. Međutim, kako je jedan od glavnih doprinosa ovog rada i statistička analiza greške odabranog algoritma, baze podataka na raspolaganju nisu odgovarajuće za taj zadatak. Glavne mane su: 1) nedovoljan broj frejmova za detaljnu statističku analizu 2) ne postoji više različitih scenarija kretanja u istim uslovima.


Dakle, nakon analize javno dostupnih baza, zaključak je da je potreban novi skup podataka za deo rada koji se odnosi na statističku analizu. Metodologija za kreiranje ove baze jeste da ispuni neke predefinisane kriterijume, kao što su da sadrži neke tipične uzroke pojave greške kod praćenja u termalnom domenu (okluzije i različiti tipovi promene dinamike kretanja objekata), ali pod istim uslovima kamere i pozadine za svaku situaciju. Sa druge strane, postojeći evaluacioni skup *LSOTB-TIR* [17] sadrži dovoljan broj sekvenci koje su napravljene specijalno za praćenje pešaka, pa se može iskoristiti za poređenje rezultata različitih algoritama, za šta je u ovom radu i korišćen u okviru sekcije 6.5.1.

Radi temeljne statističke analize termalne slike, za potrebe izrade što boljeg modela koji se koristi u daljem radu, odnosno u zadatku praćenja pokretnog cilja, veći set podataka od 2300 uzoraka je napravljen. Za ovaj skup podataka, izvršeno je ručno obeležavanje pozicije pokretnog objekta od interesa za aplikaciju praćenja, što predstavlja stvarne pozicije („ground truth“) podatke za ovaj slučaj. Za poziciju objekta je uzet centar objekta koji se prati. Skup obuhvata sekvencu kretanja pešaka koji hoda ulicom (slika 4). Prvi korak jeste analiza slike koju dobijamo sa termalne kamere, odnosno analiza šuma na termalnoj slici.

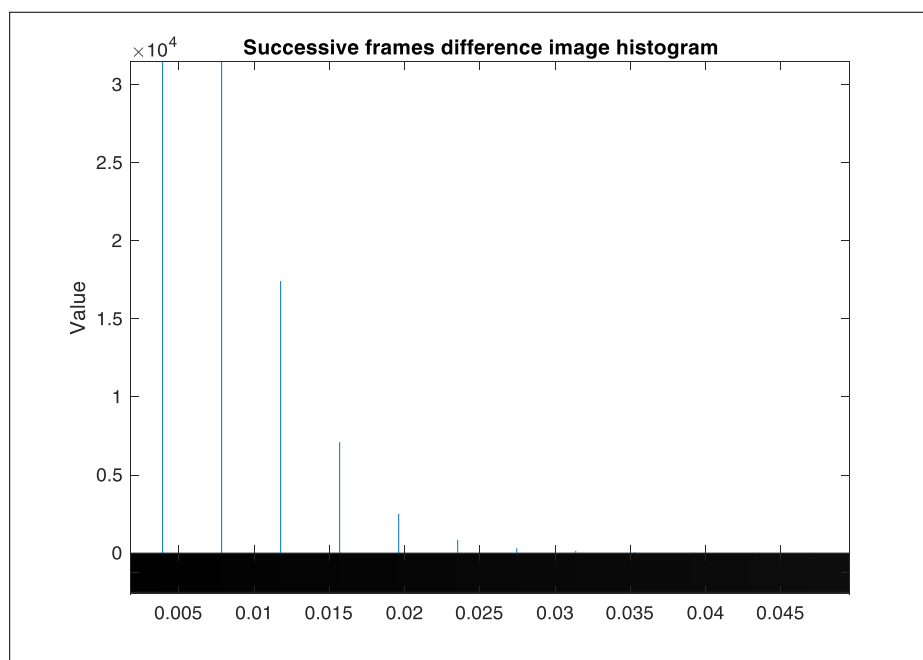


4. Slika - Skup podataka za statističku analizu i objekat od interesa

Za početnu analizu termalne slike je potrebno analizirati histogram slike koju očekujemo sa termalne kamere i uporediti sa histogramom dela slike gde se nalazi objekat od interesa za praćenje. Dakle, histogram slike koju analiziramo (prikazan na normalizovanom opsegu [0-1]), kao i histogram regiona od interesa, gde se nalazi naš objekat od interesa su prikazani na slici 5. Ono što sa histograma možemo dobiti kao informaciju jeste raspodela zračenja na sceni, izražena u nivoima sivog. Ove informacije su od značaja, pogotovo za obrade slike poput segmentacije ili popravke kvaliteta slike, koje predstavljaju deo predobrade slike svakog sofisticiranog sistema za praćenje objekata. Sa histograma koji su prikazani na slici 5 se može zaključiti, po širini opsega histograma cele slike (levo), da je dinamički opseg širok, što znači da je i kontrast na slici dobar, dok se sa slike regiona od interesa (desno) može videti raspodela nivoa sivog piksela objekta od interesa.



5. Slika - Histogram slike koja se analizira (levo) i regiona od interesa (desno)



6. Histogram slike razlike sukcesivnih frejmova kada se objekat od interesa ne pomera

Kako je brzina rada kamere 60 fps, to znači da se slika osvežava na 16,67 ms. Radi analize promene scene između sukcesivnih frejmova, kada se objekat od interesa ne pomera na slici, odnosno analize šuma koji se javlja između dva sukcesivna frejma, gde nije došlo do promene temperature ni zračenja na slici, analiziramo sliku razlike i njen histogram (slika 6). Ono što možemo saznati iz analize slike razlike sukcesivnih frejmova jeste koliki je eksperimentalno izmeren šum koji pravi sam detektor termalne kamere. To zapravo znači da je ovo šum za koji svakako znamo da ga ne unosi algoritam za praćenje, već da je šum koji unosi sam sistem, odnosno termalna kamera.

U posmatranom slučaju je to mala vrednost, jer je termalna kamera dobre rezolucije, ali u slučajevima lošije rezolucije ova analiza može biti značajna prilikom određivanja šta je šum merenja, a šta šum samog sistema [3]. Svakako, dobijeni podaci se koriste za dizajn početnog modela Kalmanovog filtra, što će biti opisano u narednim poglavljima.

3. OBRADA SLIKE

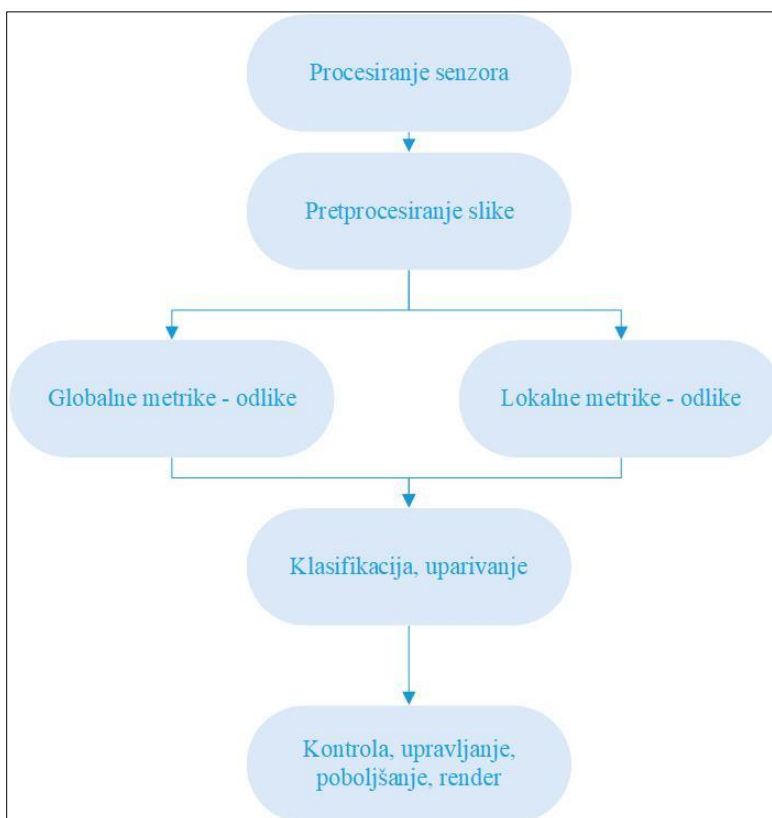
3.1 OSNOVE OBRADNE SLIKE

Savremenom čoveku čulo vida pruža najviše informacija o svetu koji ga okružuje. Osim očiju, koje šalju sliku mozgu o svetu neverovatnom brzinom, takođe je neverovatna brzina i lakoća obrade tih informacija. Dakle, ljudsko oko je složen aparat koji omogućava ljudima da vide, razumeju i izvuku informacije o svetu koji ih okružuje. Na osnovu naučenih šablona, ljudski mozak obrađuje informacije, raspoznaje objekte koje vidi, a sposoban je i da vrši generalizaciju šablona. Međutim, zadatak davanja sposobnosti računarima da vide nije nimalo lak. Od samog formiranja slike koju računar vidi, pa do njene obrade na željeni način je dug put. Neke od teškoća jesu gubitak informacija prilikom prebacivanja iz 3D u 2D prostor, kreiranje modela i interpretacija, šum na slici, brzina obrade, način dobijanja slike, lokalna i globalna obrada slike, itd. Najpre, sama činjenica da mi živimo u 3D svetu, a da senzori koji primaju i prosleđuju sliku (kamere) kreiraju 2D matricu piksela koju potom prosleđuju računarima, jasno govori da sigurno ima gubitka informacija u tom prenosu. Zatim, sledeći problem jeste to što ljudi imaju sposobnost rezonovanja i generalizacije informacija, i na taj način, na osnovu prethodnog znanja formiraju svoju predstavu o svetu. Računarima se takva vrsta interpretacije predstavlja modelom, sa kojim se poredi dobijena slika scene. Od preciznosti modela i informacija koje se mogu obraditi i dobiti sa slike zavisi i rezultat automatskih analiza računara. Sledeći problem koji se javlja jeste šum na slici, koji predstavlja jedan od faktora koji utiču na degradaciju slike, a samim tim i gubitak informacija zbog njegovog prisustva. Ukoliko obrada slike podrazumeva rad u realnom vremenu, onda se javlja i problem brzine obrade velikog broja informacija, jer slike koje imaju bolju rezoluciju imaju i veći broj piksela za obradu, a samim tim troše i više procesorskog vremena. Potrebno je voditi računa i o načinu dobijanja slike, odnosno sekvence frejmova, jer nedovoljan kontrast ili osvetljaj dovode do slika iz kojih se ne mogu izvući informacije. Na kraju, u zavisnosti od toga kakvu vrstu obrade podataka odaberemo, dobijamo i različitu vrstu informacija sa slike. Na primer, lokalne obrade podataka imaju znanje o nekim delovima slike, pa nekad teško mogu interpretirati sliku, dok globalne obrade podataka uzimaju u obzir celu sliku [18]. Kao i u svemu, primećujemo da je, u zavisnosti od konkretne aplikacije, potrebno postići balans između raznih komponenti, pa tako veća rezolucija slike daje više informacija, manje šuma, ali troši više procesorskog vremena za obradu.

Slika dobijena sa kamere predstavlja dvodimenzionalnu matricu koja sadrži vrednosti piksela. Svaka obrada slike podrazumeva rad sa informacijama koje se mogu dobiti iz ove matrice, što znači da svaka degradacija kvaliteta slike dovodi do smanjenja informacija koje se iz te slike mogu dobiti. Kako bi mašine primile i razumele dobijene slike potrebne su razne obrade slike u zavisnosti od konkretne aplikacije za koju se ta slika koristi. Algoritama i aplikacija za obradu slike na različite načine ima dosta, kao i njihovih podela. Može se reći da je najprostija podela algoritama na one niskog, srednjeg i višeg nivoa. Metode niskog nivoa koriste malo znanja o

samom sadržaju slike i to su metode kao što su kompresija slike, binarizacija slike, pa zatim filtriranje šuma, poboljšanje kontrasta, izoštravanje slike, morfološke obrade slike (erozija, dilatacija) segmentacija slike, izdvajanje odlika (regiona, uglova, interesnih tačaka). Sa druge strane, metode srednjeg nivoa su one koje na osnovu nekog poznavanja sadržaja slike obavljaju različite sofisticirane zadatke na osnovu zadatih modela i sposobnosti donošenja odluka na osnovu informacija. To su algoritmi koji se bave analizom oblika i šablona na slici, granica objekata i regiona, detekcije nekih posebnih predefinisanih oblika, uparivanje istih odlika. Metode najvišeg nivoa jesu one koje se bave 3D vizijom i kretanjem, a to su algoritmi koji se bave perspektivnom projekcijom, transformacijama slike, kalibracijama kamere, distorzijama slike, kretanjem na slici odnosno optičkim tokom odlika, estimatorima stanja poput Kalmanovog filtra itd. [19].

Kako bi se na lakši način predstavili algoritmi za obradu slike, dat je izgled toka obrade podataka u sistemima za obradu slike (slika 7). Dakle, prvi korak jeste početno procesiranje, odnosno prenos slike sa senzora do računara, a obuhvata razne procese vezane za to (kompresija slike, kvantizacija, digitalizacija, itd.). Faza pretprocesiranja predstavlja fazu pripreme slike za aplikaciju kojoj je slika namenjena, pa se, u zavisnosti od same aplikacije određuje koji će algoritmi biti korišćeni. Neki od algoritama koji se koriste u fazi pretprocesiranja jesu: korekcije osvetljaja, izoštravanje, poboljšanje kontrasta, filtracija šuma, poboljšanje kvaliteta slike („*enhancement*“), morfološke obrade, segmentacija, konverzije boja, statističke obrade slike, itd. Sledeća faza obuhvata detekciju odlika na slici. Postoje globalne i lokalne odlike, pa se u zavisnosti od toga biraju, po potrebi, i različiti algoritmi. Nakon detekcije i opisa odlika na slici, može se pristupiti zadacima klasifikacije i uparivanja odlika. Na kraju se rade i najsloženije obrade koje podrazumevaju poboljšanje slike ili upravljanje na osnovu podataka sa slike.



7. Slika - Tok obrade podataka u sistemima za obradu slike

Za opisivanje slika, odnosno 2D matrica piksela, se često koriste matematički modeli. Slika se obično predstavlja kao $f(x,y)$ ili $f(x,y,t)$, gde su x i y koordinate, a t je vreme. Vrednost slike koja se predstavlja funkcijom može biti temperatura, osvetljaj, pritisak, rastojanje od posmatrača, u zavisnosti od konkretne aplikacije. Prilikom predstavljanja kontinualne slike digitalnom vrši se i kvantizacija. Digitalnu sliku, dakle, čine pikseli koji nose informaciju o slici na određenoj lokaciji u slici. Na slici se mogu analizirati različite osobine i parametri. Kada govorimo o metričkim osobinama slike, možemo definisati razdaljinu i to na više različitih načina, na primer Euklidsko rastojanje, „City block“ rastojanje, kao i šahovska tabla rastojanje. Još jedna važna osobina kod digitalnih slika jeste susedstvo. Neki od osnovnih tipova susedstva u dvodimenzionalnom prostoru su 4-susedstvo i 8-susedstvo. Za piksel P sa koordinatama (p,q) 4-susedstvo se definiše kao:

$$D_4(P) = \{(p + 1, q), (p - 1, q), (p, q + 1), (p, q - 1)\} \quad (1)$$

8-susedstvo se definiše kao:

$$D_8(P) = D_4 \cup \{(p + 1, q + 1), (p + 1, q - 1), (p - 1, q + 1), (p - 1, q - 1)\} \quad (2)$$

gde \cup predstavlja uniju elemenata [20].

Slike se analiziraju i uz pomoć histograma koji predstavljaju frekvenciju vrednosti funkcije slike. Dakle, histogram osvetljaja $h_f(z)$ slike predstavlja frekvenciju osvetljaja vrednosti z u slici. Parametri koje se takođe uzimaju u razmatranje jesu fizički parametri tipa kontrasta, granica, oblika, teksture, boje itd. Još jedan od parametara koji se analiziraju jesu odlike na slici, što je detaljnije objašnjeno u sledećem delu.

3.2 PRETPROCESIRANJE SLIKE

Faza pretprocesiranja slike, kao što je već rečeno, obuhvata postupke koji za cilj imaju popravku kvaliteta slike koja se zatim šalje algoritmu za praćenje. U nekim situacijama, ovakav način prethodne obrade slike može poboljšati rezultat praćenja. Izbor filtera za poboljšanje kvaliteta slike zavisi od konkretne aplikacije. U nastavku je dat pregled metoda popravke kvaliteta termalne slike koji su dostupni u programskom paketu Matlab, kao i nekih savremenih metoda poput „fuzzy“ filtera [21] ili filtera baziranih na gustini piksela (BPDF filter [22]).

Efekti različitih filtera su testirani na više različitih slika [23]. Za početak, originalnoj slici je dodat veštački šum. Kako bi zašumljena analizirana slika odgovarala realnoj situaciji, korišćen

je šum tipa „so“ u kombinaciji sa Gausovim šumom. Testirani su Filtar 1 (medijan i Gausov filtar), Filtar 2 (fazi filtar) i Filtar 3 (BPDF filtar). Na slici 8 su prikazani neki od rezultata dobijenih kroršćenjem različitih filtara. Dakle, slika 8 sadrži originalnu sliku, zašumljenu (sa „so“ šumom i Gausovim šumom) sliku, kao i rezultate filtracije sa Filtrom 1, Filtrom 2 i Filtrom 3.

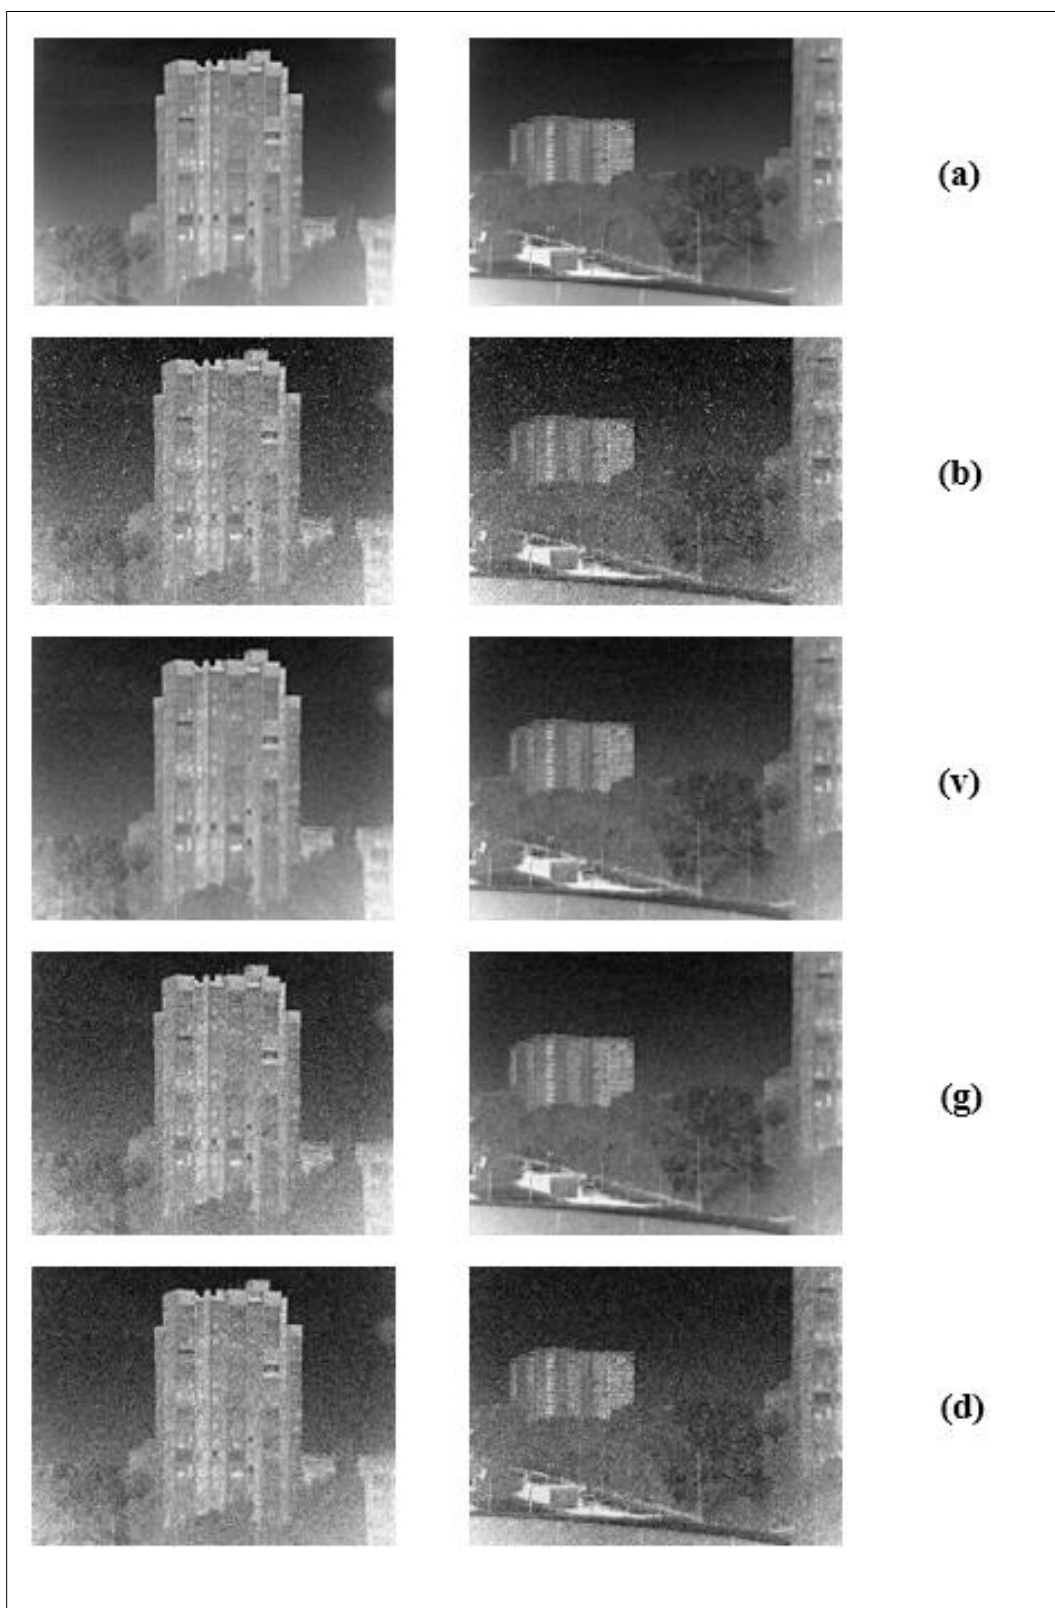
Osim samog vizuelnog testa potrebno je dodatno ispitati performanse različitih korišćenih filtara na još nekoliko sekvenci i dati rezultat poređenja različitih mera performansi odabranih za ovaj slučaj. Jedna od mera performanse koju koristimo u ovom slučaju je PSNR („*Peak Signal to Noise Ratio*“). PSNR se računa na osnovu sledeće relacije:

$$PSNR = 10 \log_{10} \frac{I_{max}^2}{MSE} \quad (3)$$

U tabeli 1 su predstavljeni rezultati dobijeni testiranjem PSNR na pet različitih termalnih slika.

1. Tabela – Prikaz PSNR za pet različitih testiranih slika

PSNR	Slika 1	Slika 2	Slika 3	Slika 4	Slika 5
Filtar 1	25.414	26.595	27.306	26.95	26.793
Filtar 2	20.356	20.364	20.417	20.287	20.384
Filtar 3	20.404	20.420	20.478	20.321	20.436



8. Slika - Prikaz: (a) Originalna slika 1, (b) Zašumljena slika 1 sa „so“ i Gausovim šumom, (v) Rezultat Filtar 1, (g) Rezultat Filtar 2, (d) Rezultat Filtar 3

U tabeli 2 je dat tabelarni prikaz brzine rada ispitanih filtara po frejmu.

2. Tabela – Brzina rada ispitanih filtara

Filtar	Vreme [s]
F1	0.06
F2	1.2
F3	2.3

Na osnovu prikazanih rezultata se može izvesti zaključak da jako dobre rezultate daju filtri koji se baziraju na kombinaciji medijan filtra i Gausovog filtra i to zbog toga što realni šum odgovara nekoj kombinaciji Gausovog šuma sa šumom tipa „so“. Što se tiče implementacije, brzina rada takvih filtara je dosta bolja od ostalih analiziranih filtara. Ono o čemu je potrebno dodatno voditi računa prilikom odabira algoritma za pretprocesiranje jeste koliko je vremena na raspolaganju po frejmu za pretprocesiranje, jer se nekada može desiti da je i sam algoritam za praćenje vrlo računski i vremenski zahtevan, pa ne ostavlja vremena za ovu fazu. Naravno, u zavisnosti od konkretne aplikacije se i bira odgovarajući algoritam.

3.3 ODLIKE NA SLICI

3.3.1 Detektori i deskriptori odlika

Postoji mnogo vrsta odlika slika koje se mogu analizirati: strukturne (tekstura, uglovi, linije, oblici, itd.), statističke (one koje se baziraju na opisivanje oblasti piksela statističkim momentima), bazirani na modelu (na osnovu frakcionih, stohastčkih idr. modela), bazirani na transformacijama (Furijeova transformacija, „wavelet“ itd.) [24]. Još jedna podela odlika jeste na globalne (odlike koje opisuju celu sliku) i lokalne (oblik - šablon slike („image pattern“) koji se razlikuje, odnosno odskače od svoje bliske okoline). Na osnovu detekcije, opisivanja i uparivanja ovih odlika se mogu dizajnirati različiti algoritmi obrade slike.

Kako bismo na pravi način objasnili tok rada algoritama za pronalaženje i uparivanje odlika na slici, objasnićemo osnovne pojmove, odnosno elemente ovih algoritama:

- **Detektori** se koriste za lociranje odlika na slici koje mogu biti od koristi, kao što su neke tačke koje označavaju lokacije uglova, ivica ili nekih drugih oblika ili šablona koji se javljaju na slici. Kada se pronađu tačke od interesa, odnosno lokacije nekih odlika na slici one se opisuju različitim vrstama deskriptora, radi lakšeg daljeg poređenja.

- **Deskriptori** služe za opisivanje regiona gde se nalaze određene odlike. Deskriptori mogu imati osobine, robusnosti i invarijantnosti odlika na skaliranje, rotaciju ili neke druge promene na slici.
- **Uparivanje odlika** se vrši upoređivanjem deskriptora na dva sukcesivna frejma, a služi u aplikacijama gde se prate promene lokacije odlika, kao što su na primer praćenje objekata ili stabilizacija slike.

U ovom radu je akcenat na algoritmu, odnosno deskriptoru odlika koji spada u grupu lokalnih deskriptora. Postoje različiti algoritmi za detekciju i deskripciju, a obično se grupišu zajedno detektor i deskriptor u jedan algoritam koji nalazi i opisuje odlike na slici.

Deskriptori odlika se, na osnovu načina detekcije i izdvajanja deskriptora, grupišu u različite familije: lokalni binarni deskriptori, deskriptori spektra, deskriptori bazičnog prostora i poligon oblik deskriptori.


U lokalne binarne deskriptore, spadaju algoritmi poput LBP („*Local Binary Pattern*“), FREAK („*Fast Retina Keypoint*“), ORB („*Oriented FAST and Rotated BRIEF*“), BRISK („*Binary Robust Invariant Scalable Keypoints*“), „*Census*“. Ovi deskriptori kreiraju vektor binarnih vrednosti na osnovu rezultata poređenja piksela. Deskriptori spektra su algoritmi poput SIFT („*Scale-invariant feature transform*“), SURF („*Speeded Up Robust Features*“), CenSurE („*Center Surround Extremas*“), „*HAAR*“, HOG („*Histogram of oriented gradients*“), „*Daisy, O-Daisy*“, i CARD („*Compact and Realtime Descriptor*“). Ovoj grupi deskriptora pripadaju algoritmi koji koriste razne vrste spektralnih vrednosti, gradijenata i proseka vrednosti regiona, a obično su vrlo zahtevni računski. Deskriptori baznog spektra obuhvataju Furijeove deskriptore, kao i metode „*Sparse Coding Methods*“. Na kraju, deskriptori poligonih oblika su metode poput MSER („*Maximally Stable Extremal Regions*“), metrike oblika objekta („*Object Shape Metrics*“), kao i metode konteksta oblika („*Shape Context*“). Vrlo popularne metode u zadacima praćenja jesu SIFT [25], [26] ili SURF [27], [28], [5], [29], [30] deskriptori iz familije deskriptora spektra, i to zbog robusnosti na parcijalne okluzije, skaliranje i rotacije.

Detektori i deskriptori odlika se uspešno koriste u raznim oblastima obrade slike: kao algoritmi za praćenje objekata [5], [29], [30], za detekciju kretanja u algoritmima za video stabilizaciju [31], u algoritmima za prepoznavanje lica [32], itd.

3.3.2 Uporedna analiza osetljivosti detektora odlika na termalnoj slici

U ovom odeljku je objašnjen odabir SURF algoritma za dalji rad na praćenju pokretnog objekta na slici. Najpre, kako bi se ispitao i uporedio rad deskriptora koji pripadaju različitim familijama deskriptora, iz svake familije je odabran po jedan predstavnik. Kao predstavnik familije deskriptora spektra je odabran SURF algoritam, FREAK („*Fast Retina Keypoint*“) [33] kao predstavnik familije lokalnih binarnih deskriptora i MSER („*Maximally Stable Extremal Regions*“) [34] kao predstavnik familije poligonih oblika.


Testiranje je vršeno na termalnim slikama koje sadrže objekat od interesa u različitim situacijama od interesa (translacija, rotacija, zamagljena slika, promena veličine, kao i zašumljena slika). U ovom slučaju je objekat od interesa dron na crnoj pozadini, kako bi se jasno analizirao rad deskriptora za posmatrani objekat bez uticaja objekata u pozadini. Testiranje je sprovedeno na način da se za dva frejma prikazuje broj ključnih tačaka i deskriptora za svaki od odabranih algoritama. Svi testirani algoritmi su dostupni u okviru Matlab softverskog paketa. Analizirane su dve sekvence, čiji je prvi frejm prikazan na slici 9.



9. Slika - Testiranje rada SURF, FREAK i MSER algoritama: (a) dron sekvenca 1, (b) dron sekvenca 2

Translacija

Najpre testiramo sva tri algoritma u slučaju translacije objekta od interesa, koja je sadržana u okviru dron sekvence 1. Rezultati su prikazani na slici 10 i u tabeli 3.



10. Slika - Poređenje frejmova za: (a) SURF, (b) FREAK i (c) MSER u slučaju translacije objekta od interesa

3. *Tabela – Broj uparenih odlika za analizirane algoritme, slučaj translacije*

Algoritam	SURF	FREAK	MSER
Broj uparenih odlika	20	12	10

Kao što se sa slike 10 i iz tabele 3 može videti, za slučaj translacije objekta od interesa, sva tri algoritma su uspešno našla i uparila veći broj odlika na dva frejma.

Rotacija

Sledeći korak je testiranje sva tri algoritma u slučaju rotacije objekta od interesa, koja je sadržana u okviru dron sekvence 1. Rezultati su prikazani na slici 11 i u tabeli 4.



11. Slika - Poređenje frejmova za: (a) SURF, (b) FREAK i (c) MSER u slučaju rotacije objekta od interesa

4. *Tabela – Broj uparenih odlika za analizirane algoritme, slučaj rotacije*

Algoritam	SURF	FREAK	MSER
Broj uparenih odlika	12	4	9

Testirani frejmovi nisu sukcesivni frejmovi, već su, sa namerom, testirani frejmovi koji sadrže dva frejma između. Razlog za to je ispitivanje u slučaju primetne rotacije, koja ipak nije toliko izražena na sukcesivnim frejmovima. Kao što se sa slike 11 i iz tabele 4 može videti, za slučaj rotacije objekta od interesa, sva tri algoritma nalaze odlike, međutim sa većim stepenom rotacije objekta od interesa, više ne bi bilo odlika na dva frejma koje se mogu upariti. U slučaju SURF algoritma, postoji 12 uparenih odlika, ali i 4 netačna uparivanja. Još jedan test, koji je u ovom slučaju izvršen, je određivanje maksimalnog broja frejmova između dva analizirana frejma na kojima je moguće upariti odlike u slučaju rotacije. Rezultati su prikazani u tabeli 5.

5. Tabela – Broj frejmova između dva analizirana za testirane algoritme, slučaj rotacije

Algoritam	SURF	FREAK	MSER
Broj frejmova između dva analizirana	8	3	10

Iz rezultata tabele 5 se može zaključiti da SURF i MSER algoritam daju dobre rezultate, dok FREAK pokazuje loše performanse u slučaju rotacije. To samo znači da SURF i MSER algoritam imaju manju osetljivost na rotaciju.

Zamagljenje – „blur“

Sledeći korak je testiranje sva tri algoritma u slučaju zamagljenih ivica objekta od interesa, koja je sadržana u okviru dron sekvence 2. Rezultati su prikazani na slici 12 i u tabeli 6.



12. Slika - Poređenje frejmova za: (a) SURF, (b) FREAK i (c) MSER u slučaju zamagljenih ivica objekta od interesa

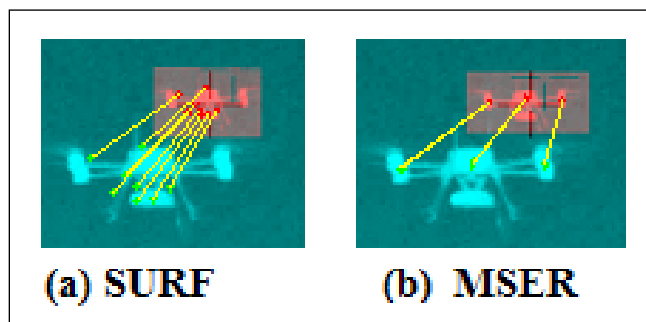
6. Tabela – Broj uparenih odlika za analizirane algoritme, slučaj zamagljenih ivica

Algoritam	SURF	FREAK	MSER
Broj uparenih odlika	6	3	2

Kao što se sa slike 12 i iz tabele 6 može videti, u slučaju da zamagljenje ivica objekta od interesa nije velikog intenziteta, algoritmi su uspešni u uparivanju odlika. Međutim, uspešnost uparivanja odlika se smanjuje povećanjem intenziteta zamagljenja.

Promena veličine

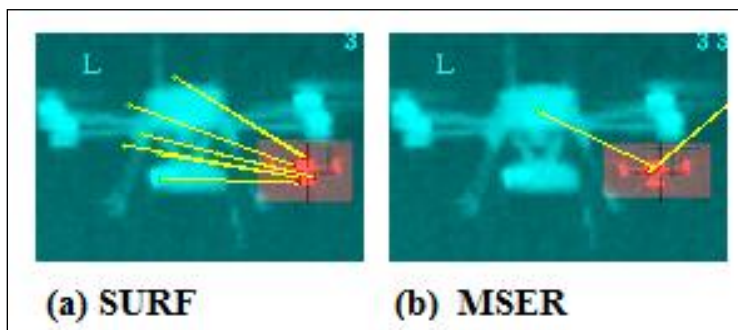
Sledeći korak je testiranje sva tri algoritma u slučaju promene veličine objekta od interesa, koja je sadržana u okviru dron sekvence 2. Rezultati su prikazani na slici 13 i u tabeli 7, za slučaj 1, kada se objekat od interesa povećava, dok su na slici 14 i tabeli 8 prikazani rezultati u slučaju 2 koji predstavlja smanjenje objekta od interesa.



13. Slika - Poređenje frejmova za: (a) SURF i (b) MSER u slučaju promene veličine objekta od interesa, slučaj 1

7. Tabela – Broj uparenih odlika za analizirane algoritme, slučaj promene veličine objekta od interesa, slučaj 1

Algoritam	SURF	MSER
Broj uparenih odlika	8	3



14. Slika - Poređenje frejmova za: (a) SURF i (b) MSER u slučaju promene veličine objekta od interesa, slučaj 2

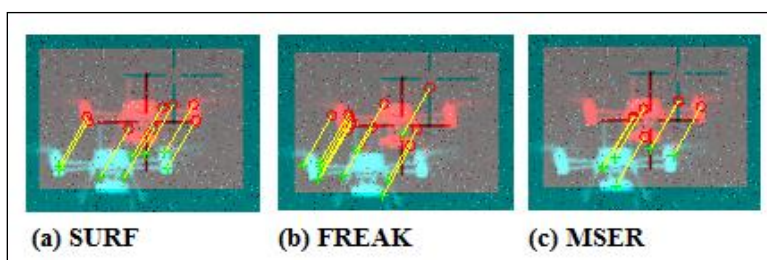
8. Tabela – Broj uparenih odlika za analizirane algoritme, slučaj promene veličine objekta od interesa, slučaj 2

Algoritam	SURF	MSER
Broj uparenih odlika	7	2

Kao što se sa slike 13 i iz tabele 7 može videti, u slučaju povećanja objekta od interesa SURF i MSER algoritam uspeavaju da upare odlike, dok FREAK algoritam nije uspešan, odnosno nema ni jednu uparenu odliku, pa nije ni prikazan u rezultatima poređenja. Sličan je rezultat i u slučaju 2, kada je objekat od interesa smanjen (slika 14 i tabela 8), SURF i MSER algoritam daju dobre rezultate, dok FREAK algoritam nema ni jednu uparenu odliku. U oba slučaja SURF algoritam pokazuje bolju performansu u odnosu na MSER algoritam.

Šum

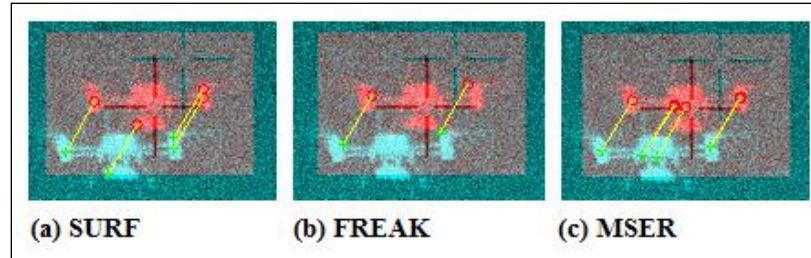
Sledeći korak je testiranje sva tri algoritma u slučaju šuma na slici. Analizirani su slučajevi „so i biber“ šuma varijanse 0.02 i Gausovog šuma varijanse 0.02, i to na sekvenci 2. Rezultati su prikazani na slici 15 i u tabeli 9, za slučaj „so i biber“ šuma, dok su na slici 16 i u tabeli 10 prikazani rezultati u slučaju Gausovog šuma.



15. Slika - Poređenje frejmova za: (a) SURF i (b) MSER u slučaju „so i biber“ šuma

9. Tabela – Broj uparenih odlika za analizirane algoritme, u slučaju „so i biber“ šuma

Algoritam	SURF	FREAK	MSER
Broj uparenih odlika	8	11	9



16. Slika - Poređenje frejmova za: (a) SURF i (b) MSER u slučaju Gausovog belog šuma

10. Tabela – Broj uparenih odlika za analizirane algoritme, u slučaju Gausovog belog šuma

Algoritam	SURF	FREAK	MSER
Broj uparenih odlika	4	2	7

Kao što se sa slika 15 i 16 i iz tabela 9 i 10 može videti, u slučaju šuma niske vrednosti varijanse, rezultati su prihvatljivi za svaku od ispitivanih metoda.

Na osnovu priloženih rezultata testiranja, može se zaključiti da:

- U slučaju translacije svi analizirani algoritmi daju dobre rezultate, što je i očekivano;
- U slučaju rotacije, približno slične rezultate daju algoritam MSER i SURF, dok je FREAK najlošiji;
- U slučaju zamagljenja ivica objekta, najbolje performanse ima SURF algoritam;
- U slučaju promene veličine objekta od interesa najbolje rezultate pokazuje SURF algoritam, dok FREAK algoritam ne uspeva da isprati promenu veličine uopšte;
- U slučaju pojave šuma na slici koja ne degradira vidno kvalitet slike, sva tri algoritma daju dobre rezultate;

Na kraju se može reći da je, nakon analize, zaključeno da FREAK algoritam daje najlošije rezultate, dok SURF i MSER algoritam daju veoma dobre rezultate. Za dalji rad je odabran SURF algoritam. Razlog odabira ove familije i deskriptora za pomenuti zadatak jeste to što odabrani deskriptor pokazuje bolje performanse od ostalih deskriptora [3]. SURF deskriptor predstavlja bržu verziju SIFT deskriptora, pa predstavlja bolju opciju jer postiže balans između dva najvažnija zahteva svakog sistema, a to su brzina računanja i performanse. SURF detektor se deklarise kao detektor otporan na skaliranje i rotaciju [35], a pokazuje i jako dobre rezultate u praćenju objekata u termalnom domenu [3], [4]. SURF odlike imaju sposobnost lakog razlikovanja svetlih i tamnih oblika zbog orijentacija gradijenata koji se koriste kako bi se opisale pojedinačne regije slike. To praktično znači da deskriptor svetlije regije na tamnoj pozadini nije isti kao tamni region na svetloj pozadini i obrnuto. Ovo je vrlo korisno svojstvo deskriptora, pogotovo za zadatak praćenja pešaka, jer su ljudi na slici tipično vidno svetliji ili tamniji od objekata u pozadini [35], [4]. SURF algoritam podrazumeva detektor odlika, deskriptor i uparivanje odlika na dva sukcesivna frejma.

Zbog svega toga, za zadatak praćenja pokretnih objekata na termalnoj slici, koji je opisan u ovom radu, odabran je SURF algoritam koji podrazumeva SURF detektor i deskriptor.

3.3.3 SURF deskriptor

Za zadatak praćenja pokretnih objekata, odabran je metod uparivanja odlika na sukcesivnim frejmovima. Odabrani deskriptor za ovaj zadatak je SURF („*Speeded Up Robust Features*“) deskriptor. SURF je i detektor i deskriptor odlika, a bazira se na dva koraka, ekstrakciji i deskripciji odlika. Kako bi se lakše objasnio tok rada SURF-a, najpre je potrebno objasniti pojam integralne slike. Ona se definiše kao suma vrednosti piksela na pravougaonom području koje je zadato:

$$I_{\Sigma}(p) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq y} I(i, j) \quad (4)$$

gde je $I_{\Sigma}(p)$ integralna slika u tački $p = (x, y)$ i predstavlja sumu svih piksela ulazne slike I iz pravougaonika sa temenima $(0, 0)$, $(x, 0)$, $(0, y)$ i (x, y) .

Prvi korak jeste ekstrakcija, odnosno izdvajanje odlika, za koju se koristi Hesijan matrica, odnosno njena determinanta, kao mera lokalne promene oko tačke. Tačke od interesa, odnosno odlike su tačke gde ova determinanta ima maksimalnu vrednost. Hesijan matrica se definiše, u tački $p(x, y)$ za faktor skaliranja σ kao:

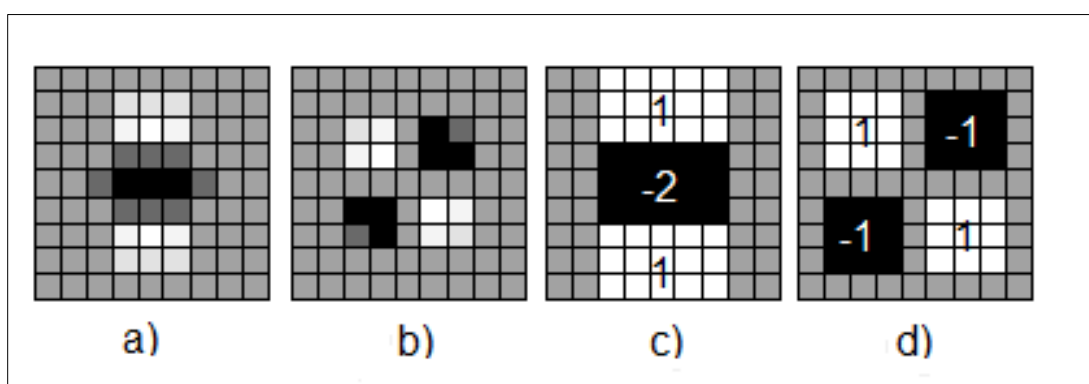
$$H(p, \sigma) = \begin{bmatrix} L_{xx}(p, \sigma) & L_{xy}(p, \sigma) \\ L_{xy}(p, \sigma) & L_{yy}(p, \sigma) \end{bmatrix} \quad (5)$$

gde $L_{xx}(p, \sigma)$ predstavlja konvoluciju Gausovog parcijalnog derivativa drugog reda sa slikom $I(x, y)$ u tački p , a slično je i za $L_{xy}(p, \sigma)$ i $L_{yy}(p, \sigma)$. Kako bi se izračunala determinanta Hesijan matrice, vrši se konvolucija sa Gausovim parcijalnim derivativom drugog reda. Za to se koristi aproksimacija Gausovog derivativa drugog reda takozvanim „*box filter*“. Velika prednost ovakvog načina računanja jeste da se konvolucija slike i „*box filter* -a“ može lako i brzo izračunati korišćenjem integralne slike (4). Ovaj postupak je opisan na slici 17, i to za slučaj korišćenja „*box filter*“ dimenzija 9×9 , za $\sigma = 1.2$ i predstavlja najveću prostornu rezoluciju, odnosno najnižu vrednost faktora skaliranja.

Sada se determinanta Hesijan matrice aproksimirana „*box filter*“ može računati kao:

$$\det(H_{approx}) = D_{xx}D_{yy} - (\omega D_{xy})^2 \quad (6)$$

gde su D_{xx}, D_{xy}, D_{yy} aproksimacije Gausovog parcijalnog derivativa drugog reda dobijene korišćenjem „*box filtera*“, dok $\omega = 0.9$ predstavlja vrednost koja je potrebna radi balansiranja relativnih težina u izrazu za Hesijan determinantu i koristi se za bilo koju veličinu filtera [35]. Na ovaj način se smanjuje vreme računanja, odnosno procesorsko vreme izvršavanja algoritma, pa je zato SURF algoritam brz za računanje. Integralne slike omogućavaju proračun pravougaonih „*box filtera*“ u približno konstantnom vremenu [3]. Obično se prostori skala („*scale spaces*“) implementiraju kao piramide slika rezolucija koje se smanjuju. Međutim, upotrebom „*box filtera*“ i integralnih slika se taj postupak skraćuje i slike se mogu paralelno filtrirati „*box filterima*“ različitih veličina (9x9, 15x15, 21x21...) za različite faktore skaliranja σ . Inicijalna veličina za $\sigma = 1.2$ jeste 9 x 9. Povećavanjem veličine filtera se postiže efekat smanjenja rezolucije, kao kod piramida slika [35]. Na ovaj način se lokalizuju odlike na slici.



17. Slika - SURF algoritam a)Gausov parcijalni derivativ drugog reda y pravac, b)Gausov parcijalni derivativ drugog reda xy pravac, c)Aproksimacija korišćenjem box filter ay pravac, d)Aproksimacija korišćenjem box filter axy pravac

Sledeći korak jeste opisivanje lokalizovanih odlika. Najpre se nalaze orijentacije odlika korišćenjem „*Haar-wavelet-a*“ u x i y pravcima. Orijetacije su predstavljene kao vektori u prostoru. Sama ekstrakcija deskriptora se sastoji u formiranju kvadratne regije sa centrom oko interesne tačke koja ima orijentaciju izračunatu u prethodnom koraku [35].

4. PRAĆENJE POKRETNIH OBJEKATA

Primene sistema za praćenje pokretnih objekata su brojne: od praćenja i osmatranja vazdušnog prostora, video osmatranja prostora, praćenja vremenskih prilika, u biologiji prilikom praćenja kretanja ćelija [36], zatim u vojnoj industriji za navođenje objekata prema meti, itd. Praćenje pokretnih objekata na slici predstavlja jedan od problema koji je veoma popularan u današnje vreme, pa se zbog toga svake godine organizuje veliki broj takmičenja kao što su Visual Object Tracking – VOT Challenge [37], [38], [39] Visual Object Tracking Thermal Infrared – VOT-TIR Challenge [1], [2] i konferencija na ovu temu. Dosta napretka je ostvareno u praćenju pokretnih objekata u vizuelnom domenu, dok je praćenje pokretnih objekata u termalnom domenu jedna od oblasti u kojoj i dalje ima prostora za usavršavanje algoritama. Razlog zbog kojeg je problem praćenja na termalnoj slici sve popularniji u civilnim aplikacijama (a ne samo u vojnim) jeste sve veća dostupnost komercijalnih termalnih senzora, visokog kvaliteta koji omogućavaju vidljivost u bilo koje doba dana i noći u uslovima kada nema dodatnih izvora zračenja, za razliku od vizuelnih senzora koji nemaju takve mogućnosti [40], [9].

Zadatak praćenja pokretnih objekata generalno obuhvata praćenje pozicije objekta od interesa i određivanje putanje kojom se taj objekat kreće, i to na osnovu podataka sa senzora. Senzor može biti bilo šta, od kamere, preko radara ili bilo kog drugog senzora koji daje podatke o željenom objektu. Objekti koji se prate mogu imati konstantnu brzinu, ali mogu i vršiti manevre. Izgled tipičnog sistema za praćenje je prikazan na slici 18.



18. Slika - Tipičan sistem za praćenje objekta od interesa

Odabrani senzor sistema za praćenje koji je opisan u ovom radu je termalna kamera, pa je emitovano zračenje objekta signal na osnovu kojeg se formira slika scene. Naravno, svako merenje podrazumeva i pojavu mernog šuma, koji degradira kvalitet merenja. Kontinualna slika scene se digitalizuje, i to najpre tako što se vrši kvantizacija signala. Sirovi podaci se zatim komprimuju i na taj način spremaju za prenos računaru koji procesira podatke i vrši estimaciju stanja objekta koji se prati. Podaci, odnosno parametri koji se prate prilikom dizajna sistema za praćenje jesu pozicija, brzina, ubrzanje, azimut, elevacija, itd. - u zavisnosti od konkretnog problema. Zadatak

praćenja može obuhvatati praćenje jednog ili više objekata na sceni, a za ovaj rad je odabran zadatak praćenja jednog pokretnog objekta na sceni.

Što se tiče izbora objekta koji se prati, može se pratiti bilo koji objekat od interesa, kao što je pešak, automobil, avion, itd., a u ovom slučaju je analizirano kretanje pešaka. Praćenje pešaka predstavlja poseban deo oblasti praćenja pokretnih objekata. Kada je zadatak praćenja definisan kao praćenje pešaka, zna se i relativna procena brzine kojom pešaci mogu da se kreću (manja nego brzina kretanja automobila ili aviona), kao i koje promene dinamike kretanja se mogu desiti na slici. Jedan od razloga zbog kojih su SURF odlike odabrane za zadatak praćenja pešaka jeste sposobnost lakog razlikovanja svetlih i tamnih oblika zbog orijentacija gradijenata koji se koriste kako bi se opisale pojedinačne regije slike. To praktično znači da deskriptor svetlije regije na tamnoj pozadini nije isti kao tamni region na svetloj pozadini i obrnuto. Ovo je vrlo korisno svojstvo deskriptora, pogotovo za zadatak praćenja pešaka, jer su ljudi na slici tipično svetliji od objekata u pozadini [35], [4]. Najpre, procena pozicije, brzine i ubrzanja se vrši na osnovu merenja sa senzora, koja su po svojoj prirodi zašumljena. U našem slučaju, vrednosti pozicije tačaka u x i y koordinatama koje su dobijene SURF-om predstavljaju merenje senzora. SURF algoritam koji je objašnjen u prethodnom poglavlju obuhvata detektor i deskriptor odlika, kao i uparivanje istih odlika na dva sukcesivna frejma. Na osnovu uparivanja odlika na sukcesivnim frejmovima se daje informacija o lokaciji objekta od interesa.

Sam zadatak praćenja željenog objekta nije nimalo lak, jer postoje razni uticaji spoljašnje sredine, ili načini kretanja objekta koji mogu uticati da merenja sa senzora daju loše podatke. U generalnom slučaju problemi koji se javljaju prilikom praćenja jedne pokretne mete su razni: šum na termalnoj slici koji je posledica termalnog detektora, manje rezolucije, mrtvih piksela, vremenskih uslova (magla, sneg, kiša, izuzetno topao dan); nedovoljan kontrast između pozadine i objekta od interesa; promena smera kretanja objekta od interesa; promena pravca kretanja objekta od interesa; rotacija objekta od interesa; okluzije na slici, nedovoljan broj tačaka za dovoljno dobru procenu pozicije, itd. U narednom delu su svi nabrojani problemi analizirani, kao i njihov uticaj na algoritam praćenja.

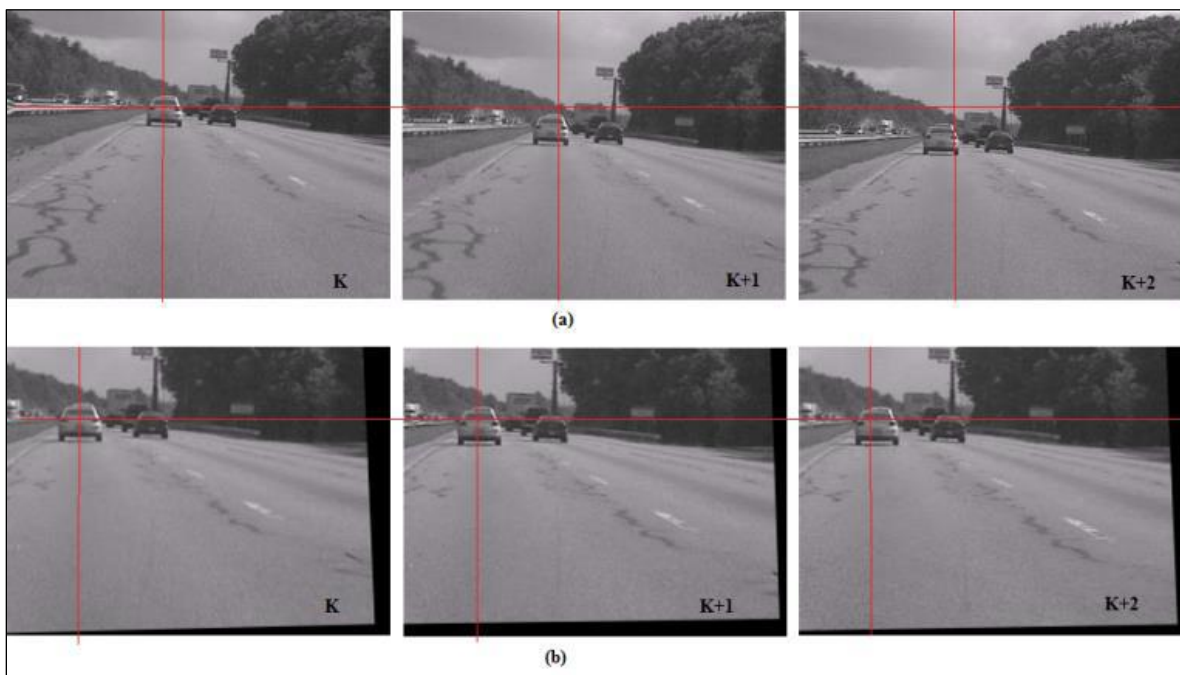
4.1 OBRADA VIDEO SIGNALA

Tema praćenja objekata na slici spada u oblast obrade video signala, odnosno praćenja kretanja objekta od interesa na sukcesivnim frejmovima jedne video sekvence. Samim tim je bitno upoznati se sa nekim ograničenjima kvaliteta samog video signala, kao i preduslovima koji je potrebno da budu ispunjeni da bi se stvorili uslovi da praćenje objekata na sukcesivnim frejmovima bude moguće.

U prethodnoj sekciji 3 su iznete osnove obrade slike i načini da se kvalitet slike poboljša algoritmima za preprocesiranje. Sa druge strane, jako je bitno poboljšati i kvalitet video signala pre pristupa praćenju objekata, u smislu otklanjanja neželjenih kretanja sa slike, usled pomeranja

kamere tokom snimanja video snimka. Ovo je veoma važan korak pogotovo prilikom dizajna komercijalnih rešenja za nadzor, jer ukoliko se neželjena kretanja ne uklone mogu predstavljati problem prilikom praćenja objekata od interesa. Neželjena kretanja predstavljaju kretanja nastala usled podrhtavanja kamere koja se drži u ruci, pomeranja kamere usled vetra ukoliko je montirana na fiksnu platformu, ili pomeranja kamere zbog pomeranja vozila na koje je fiksirana. Način da se taj problem otkloni jeste korišćenje video stabilizacije. Postoje dve vrste rešenja za digitalnu video stabilizaciju: softverska (digitalna video stabilizacija) i hardverska (mehanička, tj optička video stabilizacija, žirostabilizacija sistema sa kamerama, itd.). Hardverska rešenja za video stabilizaciju se obično montiraju na same kamere i sisteme za nadzor, tako da rade nezavisno od algoritama za obradu slike unutar samih sistema. Savremene kamere i telefoni obično imaju opcije za uključivanje ovog tipa video stabilizacije. Digitalna video stabilizacija je takođe jedan od načina uklanjanja ovakvih neželjenih kretanja [41], ali je i sastavni deo softvera sistema za nadzor.

Najvažniji koraci prilikom dizajna algoritma za video stabilizaciju jesu estimacija kretanja na slici i kompenzacija neželjenog kretanja usled podrhtavanja kamere. U tom smislu, u algoritmima video stabilizacije se koriste različiti algoritmi bazirani na optičkom toku [41], deskriptorima odlika [31], a u poslednje vreme i metode zasnovane na dubokom učenju [42] za estimaciju kretanja i razdvajanje željenog od neželjenog kretanja. Primer rada video stabilizacije je prikazan na slici 19.



19. Slika – Prikaz rada digitalne video stabilizacije (a) originalna slika, (b) stabilisana slika

Dakle, kako raste potreba za ugradnjom video kamera za nadzor na fiksne ili pokretne platforme, bitno je naglasiti da se savremeni sistemi za praćenje dizajniraju na način da se video stabilizacija uključi u proces snimanja same video sekvence, ili u fazi post procesiranja sekvence. Ovakav pristup omogućava da se neželjeno kretanje razdvoji od željenog kretanja objekta od interesa, a samim tim se i omogućava bolja performansa algoritama za praćenje.

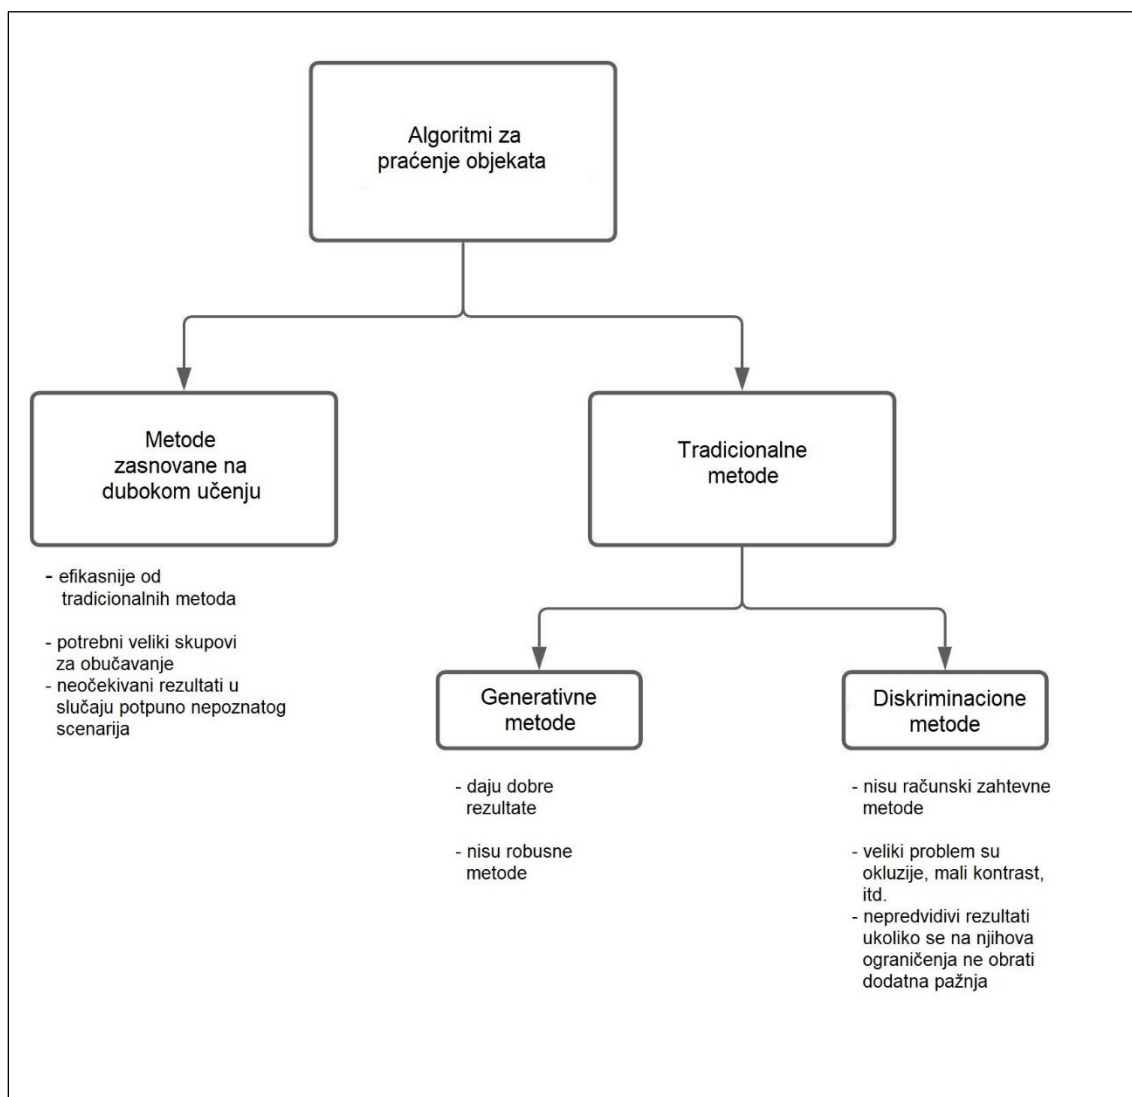
Još jedno ograničenje koje je bitno razmotriti jeste način obrade video signala. Naime, bitna je informacija o tome da li nam u sistem dolazi komprimovana slika (ili video sekvenca), ili pak dobijamo sirovi signal direktno sa izlaza kamere. U zavisnosti od načina kompresije [43] se neke informacije iz same slike, odnosno video signala gube, ali se šteti na prostoru za smeštanje. Implikacije na algoritam za praćenje jesu da se može smanjiti kvalitet slike, odnosno video signala, što, u nekim slučajevima može dovesti do pogoršanja performanse sistema. Međutim, sa druge strane, obrada komprimovanog signala može uticati na smanjenje vremena potrebnog za obradu slike. U praktičnim implementacijama je ipak mali uticaj kompresije na performanse algoritma za praćenje, veći je uticaj na algoritme koji služe za popravku kvaliteta slike.

4.2 ANALIZA SAVREMENIH ALGORITAMA ZA PRAĆENJE POKRETNIH OBJEKATA

Najčešće korišćeni algoritmi u poznatim takmičenjima na temu praćenja u termalnom domenu uključuju korelacione filtre [44], razne verzije Kanade-Lukas-Tomasi filtera [45], algoritme koji koriste više vrsta deskriptora odlika [25], praćenje na osnovu optičkog toka [46], algoritme zasnovane na dubokom učenju [47], kao i kros-korelacione metode [48]. Algoritmi za praćenje objekata mogu se podeliti u dve grupe: na tradicionalne metode i na metode bazirane na dubokom učenju. Tradicionalne metode takođe se mogu podeliti u dve grupe: generativne metode praćenja (zasnovane na modelu cilja) i diskriminativne metode (razlikuju objekat od pozadine). U nastavku je, za svaku grupu metoda, dat pregled najvažnijih karakteristika, dok slika 20 predstavlja pregled i podelu algoritama sa najvažnijim karakteristikama.

Algoritmima za praćenje koji se baziraju na dubokom učenju se posvećuje dosta pažnje u poslednje vreme. Motivisani uspehom dubokog učenja u oblasti praćenja u vizuelnom domenu, nekoliko novih trekera za termalni domen koriste istu ideju. Konvolucione neuralne mreže su imale veliki uspeh u rešavanju problema praćenja [47] u termalnom domenu. Postoji dosta pristupa koji se baziraju na dubokom učenju, ali jedan od najpopularnijih je baziran na Sijamskim mrežama. Sijamske mreže su uspešno primenjene na zadatke praćenja u vizuelnom domenu [49], dok je performansa trekera baziranih na Sijamskim mrežama postigla brzinu realnog vremena sa *DSiam* („*Dynamic Siamese network*“) pristupom [50]. Pomenuti treker je napravljen za zadatke vizuelnog praćenja, ali neki od savremenih trekera koriste njegove mogućnosti za praćenje objekata u termalnom domenu [17]. Treker koji je poslednja reč tehnologije u oblasti termalnog praćenja objekata od interesa baziran je na Sijamskim mrežama i to je *HssNet* („*Hierarchical Spatial-aware Siamese Convolutional Neural Network*“) treker. Glavna ideja jeste da se problem praćenja tretira ne kao klasifikacioni zadatak, već kao zadatak verifikacije. To je realizovano uz pomoć *HssNet*

algoritma. Glavna ideja ovog pristupa jeste učenje sličnosti između objekata i lociranje kandidata koji je najbliži praćenju. Korišćenjem metode hijerarhijske konvolucione fuzije, treker je u stanju da postigne bogatu prostornu i semantičku reprezentaciju odlika i da ima poboljšanu sposobnost diskriminacije. Pristup baziran na *HssNet* pokazuje dobre performanse u poređenju sa drugim najsavremenijim metodama [51]. Još jedan novi algoritam u okviru Sijamskog framework-a jeste *MLSSNet* („*Multi Level Similarity Model*“) [52]. Kako je i navedeno u radu [52] savremeni trekeri koriste samo semantičke odlike, pa im i fali robusnost u slučaju distrakcija. *MLSSNet* treker računa različite sličnosti između oblika korišćenjem mreže sličnosti sa više nivoa, gde se jedan nivo fokusira na globalne semantičke sličnosti, a drugi računa lokalne strukturne sličnosti *TIR* objekata. Dakle, *MLSSNet* treker postiže robusno praćenje objekata, dok eksperimentalni rezultati pokazuju dobru performansu u odnosu na savremene algoritme [52]. Iako metode zasnovane na dubokom učenju jesu dosta efikasnije od tradicionalnih metoda, njihove glavne mane jesu: potreba za velikim skupovima podataka za obučavanje mreže, kao i neočekivani rezultati u slučaju potpuno nepoznatog scenarija.



20. Slika – Podela algoritama za praćenje objekata

Tradicionalne diskriminativne metode su, takođe, vrlo često korišćene za problem praćenja u termalnom domenu. U poslednje vreme, veoma dobre rezultate pokazuju diskriminativne metode koje se baziraju na korelacionim filtrima korišćenim sa različitim tipom odlika [53], [54], [44], [55], [56]. Nisu računski zahtevni, što je svakako prednost, ali se susreću sa svim problemima sa kojima se bore i drugi algoritmi poput okluzija, spajanja pozadine, malog kontrasta i slično. Glavna ideja korelacionih algoritama je razlaganje problema praćenja na estimaciju translacije i skaliranje. Iako su veoma efikasni kod praćenja, algoritmi mogu dati i nepredvidive rezultate ukoliko se na njihova ograničenja ne obrati dodatna pažnja.

Tradicionalni generativni trekeri kombinuju neke metode mašinskog učenja sa ručno podešenim odlikama za prevazilaženje problematičnih scenarija. Ovakvi trekeri daju dobre rezultate, ali njihov glavni problem jeste što nisu robusni. Za generalne zadatke praćenja, jako dobro su se pokazali algoritmi koji omogućavaju da se objekat opiše nekom vrstom deskriptora, poput *SIFT* [25], [26] ili *SURF* [27], [28], [5], [29], [30] deskriptora, koji su vrlo popularni u domenu praćenja, jer su robusni na parcijalne okluzije, skaliranje i rotacije [3]. Međutim, ne mogu se svi deskriptori sa istom efikasnošću koristiti i u vizuelnom i u termalnom domenu, jer se karakteristike samih slika dosta razlikuju. Termalne slike nemaju senke, imaju mnogo drugačije karakteristike šuma nego slike u vizuelnom domenu [57], [58], a kako nemaju boju, različiti oblici i obrasci slike se javljaju na osnovu varijacija u materijalu i temperaturi objekata na sceni. *SURF* („*Speeded Up Robust Features*“) deskriptori daju dobre rezultate u praćenju objekata u termalnom domenu [3], [4], pa predstavljaju i dobro rešenje za zadatak praćenja objekta u termalnom domenu.

SURF detektor i deskriptor uz uparivanje odlika na dva sukcesivna frejma čine algoritam koji je vrlo često korišćen u realnim aplikacijama zbog brzine rada i robusnosti [5]. Iako *SURF* algoritam generalno daje dobre rezultate u termalnom domenu, usled lošijeg kvaliteta slike ili manjeg kontrasta na samoj termalnoj slici mogu se desiti greške prilikom uparivanja. Dakle, zbog nesavršenosti same termalne slike, *SURF* deskriptora, ali i prisustva različitih okluzija u slici, merenja pozicije objekta koji se prati nisu uvek tačna i precizna, pa je potrebno vršiti predikciju i estimaciju kretanja objekta. Takva estimacija podrazumeva korišćenje neke vrste prediktora radi predikcije pozicije objekta od interesa zbog situacija u kojima *SURF* deskriptor ne daje dobre rezultate, ili kada odlike uopšte ne mogu biti pronađene u slici. Analizom dostupne literature i radova na ovu temu su uočeni osnovni problemi i nedostaci primenjenih metodologija. U [29] algoritam obrađuje sliku u boji, koja se pretvara u sliku u nivoima sivog i na osnovu poboljšanog *SURF* algoritma i Kalmanovog filtra se vrši praćenje objekta. Takav pristup, opisan u [29], predstavlja ideju na osnovu koje se može dizajnirati algoritam za praćenje na termalnoj slici, uz kombinovanje *SURF* algoritma i Kalmanovog filtra. U [27] je opisan algoritam koji koristi *SURF* odlike i Kalmanov filter za praćenje objekata na slici u boji, gde je standardni Kalmanov filter korišćen radi predikcije pozicije „*bounding box-a*“ oko objekta u sledećem koraku (gde će se tražiti *SURF* odlike u sledećem koraku), kako bi se smanjilo vreme procesiranja. Ukoliko dođe do grešaka (zbog okluzija ili pogrešnog uparivanja), taj problem se rešava algoritmom „*histogram re-match*“. Ovakav pristup, opisan u [27], daje dobre rezultate, međutim „*histogram re-match*“ algoritam, kao dodatni algoritam, troši procesorsko vreme. U [28] je opisan algoritam koji kombinuje više algoritama, „*CamShift*“, *SURF* i optički tok, dok se matrice Kalmanovog filtra podešavaju u zavisnosti od greške koju algoritam daje.

Kao što je već rečeno, na osnovu analize radova dostupnih u literaturi koji opisuju praćenje objekta od interesa korišćenjem *SURF* algoritma, je primećeno da nema radova koji se bave detaljnom analizom grešaka koje pravi *SURF* algoritam na termalnoj slici. Samim tim je i dodatna

predikcija pozicije vršena bez uzimanja u obzir statistike greške SURF algoritma. Takvom analizom greške se može otkriti prisustvo tipičnih grešaka koje kvare performansu sistema, a dešavaju se u određenim situacijama promene režima kretanja, ali i onih koji utiču na potpuni gubitak praćenja objekta od interesa i predstavljaju autlajere u podacima. Najčešći uzrok prestanka rada algoritma za praćenje jesu autlajeri u podacima. Međutim, kako nije lako unapred predvideti kada će se desiti niti koliku će vrednost imati, za problem praćenja pokretnog objekta na termalnoj slici je vrlo značajno ispitati prirodu grešaka koje se javljaju u podacima. Ukoliko ima autlajera, standardni Kalmanov filter nije dobro rešenje za takav slučaj, jer je osetljiv na njih. Pristupom koji se zasniva na statističkoj analizi podataka mogu se izbeći metode koje kombinuju više različitih algoritama za praćenje [28], jer se na taj način model Kalmanovog filtra može podesiti tako da odgovara posmatranoj vrsti problema. Zbog toga je naredni korak analiza rada i greške SURF algoritma.

4.3 PRAĆENJE OBJEKATA SURF DESKRIPTOROM


4.3.1 SURF deskriptor – greška praćenja

SURF algoritam, koji je objašnjen u poglavlju 3.3.3, obuhvata detektor i deskriptor odlika, kao i uparivanje istih odlika na dva sukcesivna frejma. Iako se SURF algoritam pokazao kao odličan algoritam za praćenje u termalnom domenu [3], ipak nijedan algoritam nije nepogrešiv. Zbog toga je predmet analize ovog poglavlja greška koju SURF algoritam pravi na obrađenom skupu podataka. Greške SURF algoritma, u termalnom domenu, se uglavnom dešavaju zbog lošeg kontrasta na slici, promena u kontrastu koja nije afina promena, kao i zbog velikih distorzija [59]. U našem slučaju se greške uglavnom događaju zbog nedovoljnog kontrasta na slici, i tada se može desiti da SURF algoritam može da prepozna istu tačku na nekom drugom objektu, umesto na objektu od interesa, ili se može desiti da nema dovoljan broj tačaka za tačnu procenu. Kako bismo detaljno statistički ispitali rad SURF algoritma i kako se ponaša u različitim situacijama praćenja pokretne mete, na raspolaganju imamo skup podataka od 2300 sukcesivnih frejmova termalne slike koji prate pešaka koji se kreće. Kako bi se rezultati praćenja mogli porediti sa stvarnim vrednostima, ručno su obeleženi centri pokretnog objekta, koji predstavljaju stvarnu poziciju, odnosno „*ground truth*“. Kako bi se izračunala pozicija centra objekta od interesa, u regionu gde se nalazi objekat od interesa se detektuju SURF odlike i kreiraju deskriptori. Pozicija centra objekta je tačka sa x i y koordinatama, i predstavlja središte pronađenih SURF deskriptora. Kada se pronađu SURF tačke i deskriptori za dati objekat, greška SURF algoritma se onda računa kao razlika stvarne pozicije i one koju je dao SURF algoritam. Na ovaj način se ispituju greške koje SURF algoritam pravi na termalnoj slici koju analiziramo, što predstavlja značajne podatke za projektovanje estimatora, u cilju poboljšanja performansi rada odabranog algoritma.

Slika 21 prikazuje vrednosti greške SURF algoritma za x i y koordinatu zajedno, za dati skup podataka. Pre same analize podataka bitno je istaći da, za dati skup podataka, samostalno

korišćen SURF algoritam (bez pomoći predikcije estimatora), čim se pojavi veća greška u proceni pozicije objekta od interesa gubi metu i praćenje prestaje. Zbog toga, kako bi se omogućio prikaz na celom skupu podataka, i nakon pojave greške koja dovodi do prestanka praćenja, vrši se reinicijalizacija algoritma. Reinicijalizacija predstavlja ponovno obeležavanje regiona od interesa i kreiranje SURF deskriptora u tačkama od interesa.

Ova analiza je omogućila dobijanje opsega u kojem se prosečno kreću greške SURF-a po osama, u slučaju uspešnog praćenja. Sa druge strane, mogu se analizirati i situacije kada se javljaju velike greške koje dovode do prestanka praćenja. Baš takve situacije koje dovode do prestanka praćenja, ili samo velike greške praćenja jesu one koje zahtevaju dodatnu analizu, ali i neku vrstu robusne predikacije položaja objekta u sledećem koraku. Sama slika 21 govori o raspodeli mernog šuma, koji je, kao što se vidi, lociran u okviru jednog klastera. Međutim, iz podataka se ne može doneti zaključak o raspodeli mernog šuma, pogotovo kada imamo u vidu da su u skupu podataka od 2300 odbiraka snimljeni različiti režimi kretanja, da bi se na što bolji način ispitao odabrani algoritam. Još jedan zaključak koji je upečatljiv sa slike 21 jeste da postoje loša merenja, odnosno autlajeri u podacima. Dakle, dalja analiza podrazumeva da se ispita uticaj različitih režima kretanja na grešku SURF algoritma, kao i da se ispituju situacije koje dovode do velikih grešaka, odnosno autlajera u podacima. Pojam autlajera je bolje objašnjen u narednom poglavlju, jer je usko povezan sa pojmom robusne estimacije.




21. Slika - Greška SURF algoritma po koordinatama

4.3.2 Tehnike estimacije funkcije gustine verovatnoće

Postoji više načina za procenu raspodele ili funkcije gustine verovatnoće iz dostupnih podataka, ali je glavna podela na parametarske, neparametarske i polu parametarske metode. Dok se parametarske metode baziraju na „*a priori*“ znanju o raspodeli i proceni pretpostavljenih parametara modela raspodele, neparametarske metode ne polaze od takvih početnih znanja, već omogućavaju estimaciju raspodele bez ikakvih početnih informacija o tipu raspodele.

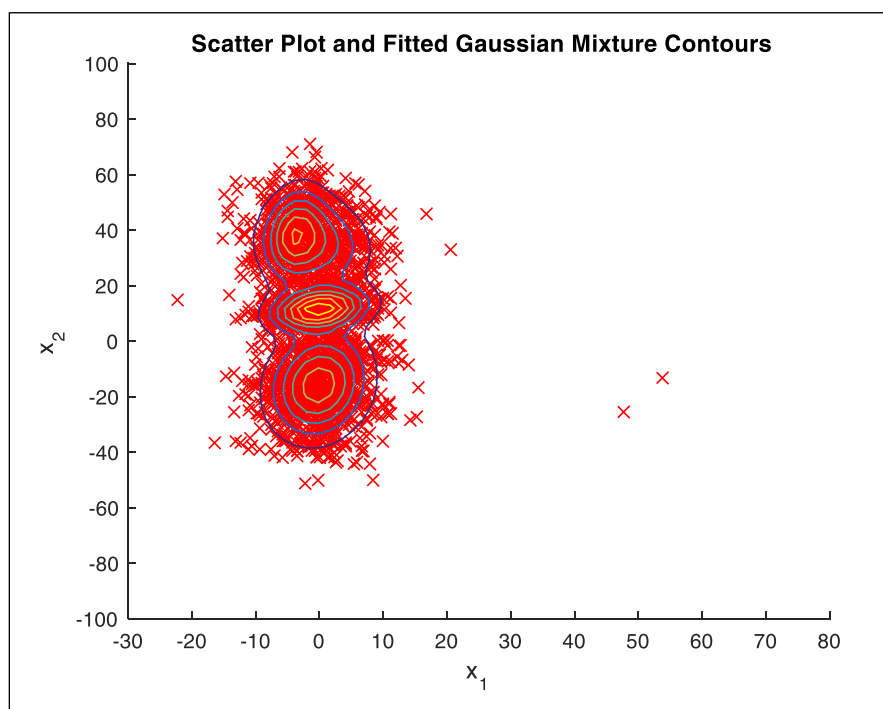
Prvi korak u analizi rezultata jeste pokušaj da se podaci uklape u parametre neke od postojećih raspodela. Najlakši način za to jeste korišćenjem *Matlab* funkcije „*allfitdist*“, koja uklapa, odnosno fituje veliki broj postojećih raspodela sa poznatim parametrima u dobijene podatke. Na raspolaganju je veliki broj raspodela: Gama, Rejljeva, Normalna, Vejbulova, itd. Grafik koji je prikazan na slici 22 prikazuje uklapanje sa četiri raspodele čiji parametri najviše odgovaraju zadatim podacima. Na grafiku se vidi da su najbolja uklapanja sa četiri različite raspodele, međutim vidi se i da ni jedna ne odgovara u potpunosti našim podacima.



22. Slika – Parametarski pristup estimaciji funkcije gustine verovatnoće greške SURF algoritma

Nakon parametarskog pristupa estimaciji funkcije gustine verovatnoće greške SURF algoritma se može zaključiti da ovo nije pristup koji se može koristiti u posmatranoj situaciji.


Polu-parametarske metode estimacije funkcije gustine verovatnoće (u literaturi „*semi-parametric*“) jesu takozvani modeli Gausove mešavine, odnosno „*Gaussian Mixture Models*“ [60]. Suština pristupa koji se zasniva na Gausovim mešavinama jeste da se pretpostavlja da podaci, čija se raspodela estimira, u stvari predstavljaju skup nekoliko različitih Gausovih, odnosno normalnih raspodela, ali sa različitim parametrima. Najlakši način za estimaciju funkcije gustine verovatnoće jeste korišćenjem Matlab funkcije „*fitgmdist*“ za fitovanje modela Gausove mešavine u podatke. Naravno, potrebno je na početku pretpostaviti koliko je komponenti Gausovih mešavina, što nekada i nije lak zadatak. Na slici 23 je grafički prikaz kontura Gausove mešavine za ulazne podatke koji predstavljaju grešku SURF algoritma, ukoliko je pretpostavljeno pet komponenti.



23. Slika – Gausove mešavine


Međutim, pet komponenti nije dovoljno za predstavljanje podataka Gausovim mešavinama, a dalje povećanje broja komponenti ne dovodi do rešenja, tako da se može zaključiti da se podaci ne mogu na ovaj način statistički predstaviti. Osim čisto Gausovskih mešavina, podatke je moguće predstaviti i drugim tipovima mešavina, poput, na primer Gaus-Košijevih mešavina [61], itd.

Sledeći korak jeste neparametarski pristup estimaciji parametara funkcije gustine verovatnoće greške. Među nekim od najpoznatijih neparametarskih pristupa se smatraju Parzenova estimacija [62], estimacija pomoću kernel funkcija [63], [64], kros-validacija [65]. Pristupom koji se bazira na adaptivnom kernel estimatoru baziranom na procesu linearne difuzije [64] je izvršena estimacija funkcije gustine verovatnoće greške (slika 24).



24. Slika – KDE estimacija funkcije gustine verovatnoće 2D

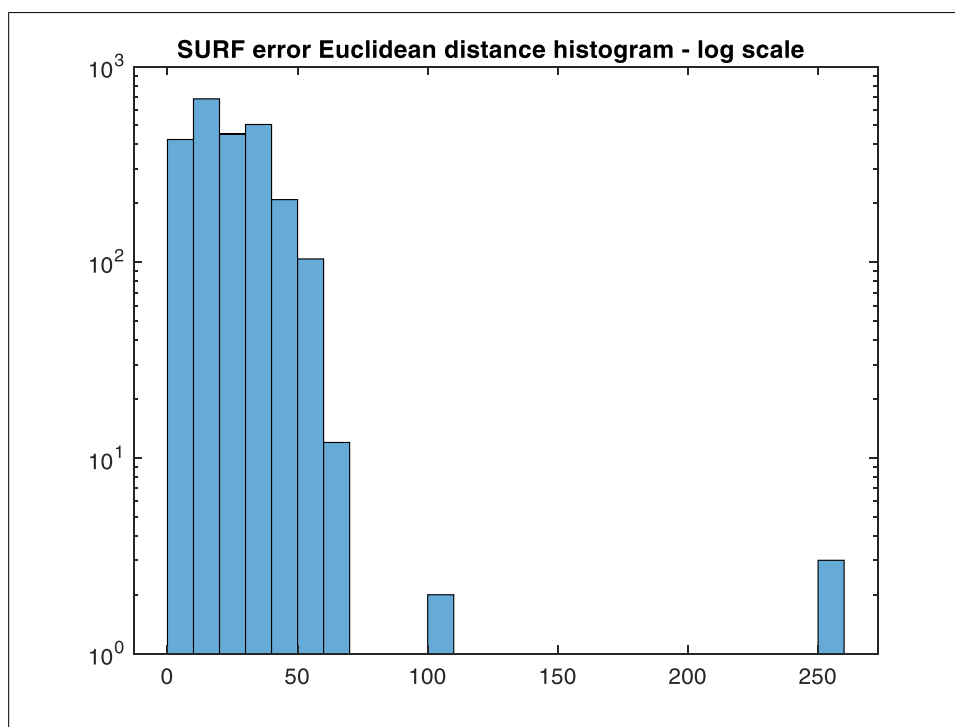
Nakon estimacije funkcije gustine verovatnoće pristupom koji se zasniva na kernel funkcijama u 2D je zaključeno da se i dalje ne može dovoljno zaključiti o samoj raspodeli, i da je bolje videti rezultate u 1D, koji su prikazani na slici 25.



25. Slika – KDE estimacija funkcije gustine verovatnoće 1D

Nakon formiranja estimacije u 1D je već jasnije na koji način se podaci mogu bolje statistički analizirati. Možda i najbolje rešenje, za zadati problem, predstavlja predstavljanje greške histogramom i to na način koji je opisan u daljem tekstu.

Dalja analiza, dakle, uključuje i analizu histograma greške SURF algoritma, gde je kao greška označeno Eukidsko odstojanje pozicije tačke koju SURF algoritam daje kao poziciju centra objekta od interesa u odnosu na „*ground truth*“ poziciju. Kako su na oordinati najupečatljivije velike greške, odnosno autlajeri, oordinata je prikazana na slici 26. Oordinata je predstavljena logaritamskom skalom, kako bi se bolje videli autlajeri, kojih ima mali broj (jer smo kada se praćenje izgubi vršili reinicijalizaciju), ali imaju veliki uticaj na praćenje (zaustavljaju ga).



26. Slika - Histogram greške SURF algoritma u log skali

Na prikazanom histogramu (slika 26) su vidne velike greške algoritma kao repovi na velikim vrednostima. Velika vrednost ovih grešaka je uzrok prestanka praćenja objekta od interesa. Sa ove slike je još jasnije da su velike greške u merenjima te koje dovode do loših rezultata algoritma za praćenje i odstupaju od raspodele većine populacije.

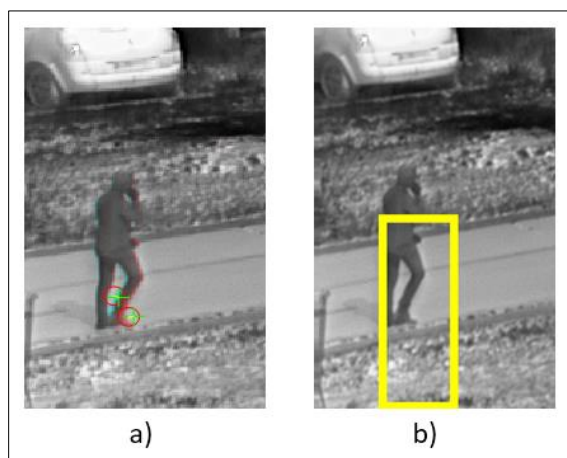
Na osnovu predstavljene analize možemo zaključiti da je raspodela greške najpribližnija Gausovoj raspodeli u centralnom delu, dok postoje i autlajeri, koji predstavljaju takozvane zadebljale ili otežale repove koji se mogu predstaviti nekom drugom funkcijom raspodele. Takođe, ovako procenjene statistike su stacionarne. Bitno je naglasiti da se, u okviru ove analize, posmatra dominantno kretanje objekta od interesa duž jedne ose (x ose). Korelacija između x i y koordinate postoji, ali zavisi i od tipa same greške, što će biti i prikazano u narednom poglavlju.

4.4 UZROCI GREŠKE PRAĆENJA OBJEKATA SURF DESKRIPTOROM NA TERMALNOJ SLICI

Na osnovu dugotrajnog iskustva u analizi termovizijskih slika, što je potvrđeno i na analiziranom skupu podataka, uočeno je da su kritični delovi praćenja objekta SURF algoritmom sledeće situacije:

- Promene smera i pravca kretanja objekta od interesa
- Rotacije objekta od interesa
- Situacije kada je objekat od interesa zaklonjen nekim drugim objektom (parcijalna ili potpuna okluzija)
- Degradacija kvaliteta slike (nedovoljan kontrast zbog uslova na sceni, izražen šum na slici, itd)
- Situacije kada se iste tačke, sa istim deskriptorima upare na dva potpuno različita mesta

Analiziraćemo, u okviru odabranog skupa podataka, ove kritične situacije i videti njihov uticaj na praćenje. Na osnovu toga se greške mogu podeliti u različite tipove, na osnovu uticaja na performansu algoritama za praćenje. Pre same analize situacija potrebno je naglasiti da algoritam, na osnovu svih pronađenih tačaka, daje informaciju o koordinatama centra objekta koji posmatramo. Vrlo često se desi da su tačke koje se nađu po y osi, u toku uparivanja istih tačaka u nekim situacijama koje analiziramo, skoncentrisane u gornjem ili donjem delu objekta koji posmatramo. Odatle je veća greška po y osi nego po x osi, zbog same prirode kretanja objekta koji posmatramo. Ta situacija je ilustrovana na slici 27.

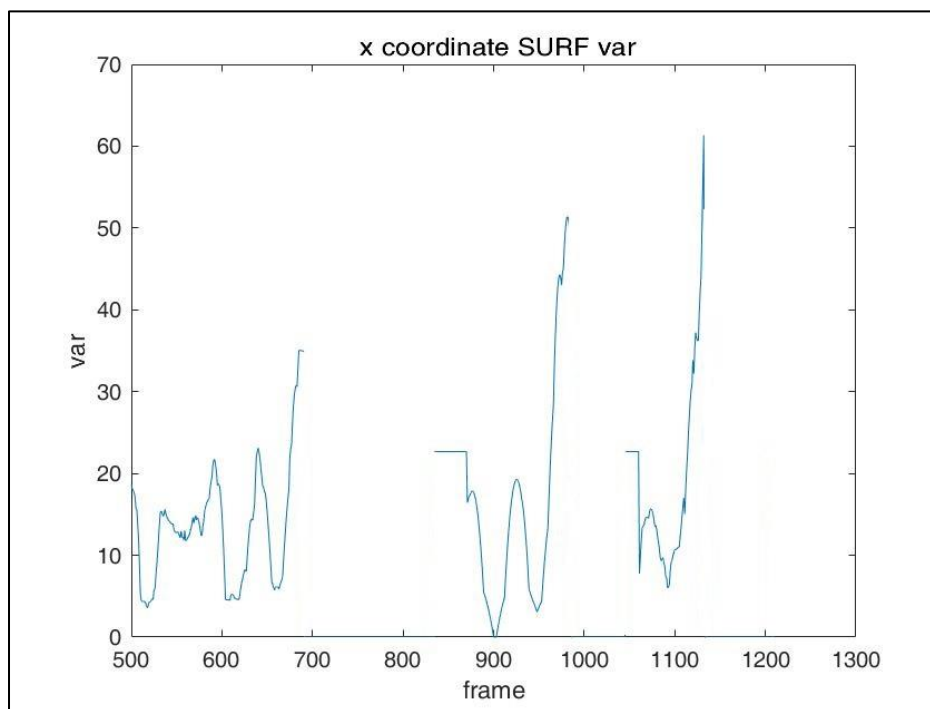


27. Slika - Ilustracija razloga veće greške po y osi a) pronađene tačke SURF algoritmom, b) bounding box pozicija

Ovde vidimo da su tačke koje je SURF detektor našao skoncentrisane oko stopala pešaka, pa se i sam prozor praćenja pomerio. To ne znači da je došlo do prestanka praćenja ili velike greške, već da su tačke koje su pronađene skoncentrisane u jednom delu, pa nije moguće precizno

naći centar objekta koji pratimo. U ovom trenutku je izračunata greška (odstupanje od „ground truth“ pozicije) po y osi 40 piksela, dok je po x osi 3.5 piksela.

Na slici 28 je prikazana varijansa greške u proceni kretanja pešaka na odabranom skupu podataka. Na ovoj slici su prekidi praćenja prikazani kao prekidi na grafiku varijanse, a to su tačke kada je, zbog velike greške, došlo do prekida praćenja. Sa druge strane, sa grafika je primetno da postoje delovi sekvence gde dolazi do porasta varijanse, ali ne prestaje praćenje objekta od interesa.




28. Slika - Varijansa greške SURF algoritma na odabranom delu sekvence

Na osnovu analiziranih rezultata, a i na osnovu iskustva u obradi termalne slike, može se zaključiti koje situacije na koji način utiču na promenu varijanse greške SURF algoritma i kakav tip grešaka daju:

- (1) **Porast varijanse greške bez gubitka praćenja** usled promene dinamike kretanja objekta od interesa obično podrazumeva situacije manevra, odnosno promene smera i pravca kretanja, kao i rotaciju objekta od interesa.
- (2) **Nepredvidive velike greške koje dovode do prestanka praćenja ili autlajeri** su situacije koje su obično posledica okluzija na slici. Dakle, okluzije uglavnom dovode do prestanka praćenja objekta od interesa, zbog toga što SURF algoritam daje veliku grešku u proceni pozicije mete. Neke od takvih situacija su i prikazane na slici 29. Tu je prikazano par situacija okluzija iz posmatranog skupa podataka. Manje okluzije mogu, ali i ne moraju pokvariti

rezultate praćenja. To sve zavisi od toga koliko tačaka SURF algoritam uspe da nađe. U konkretnom slučaju su okluzije prikazane na slici 29 imale veliki uticaj na praćenje, odnosno zaustavile su praćenje.



29. Slika - Situacije okluzija

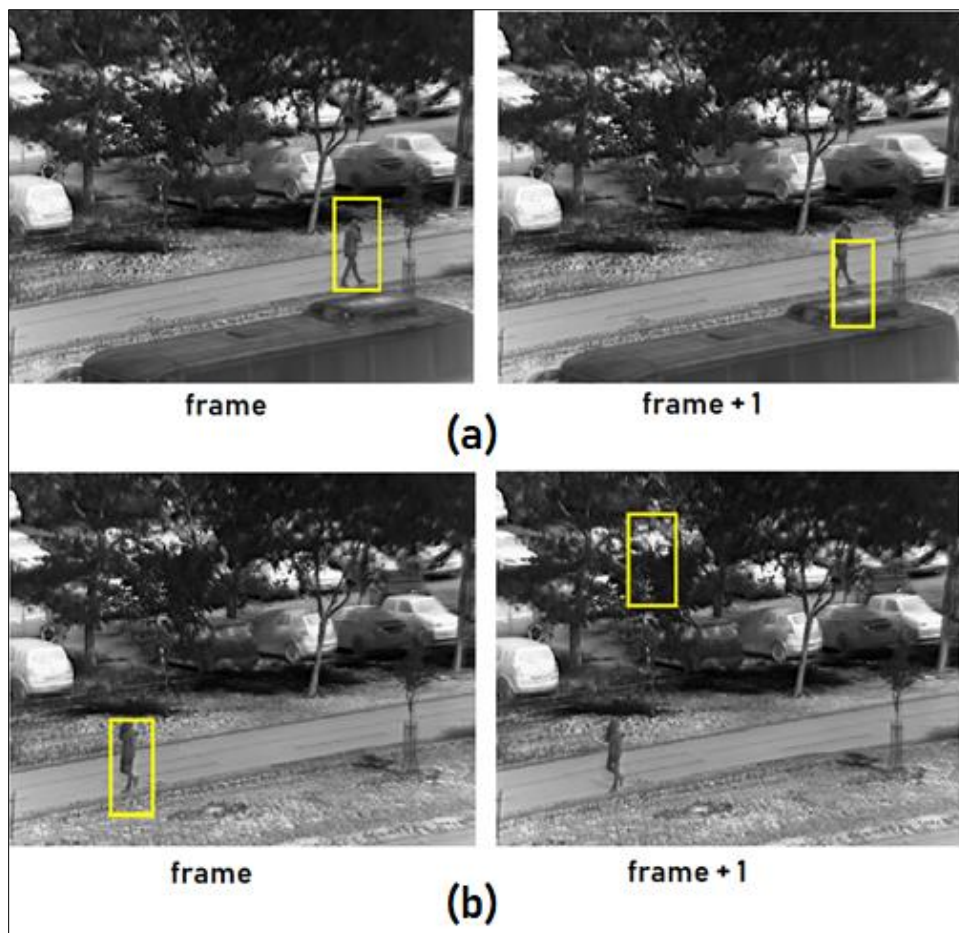
Problem okluzija je vrlo ozbiljan i opasan, jer se dešava da se na objektu koji je zaklonio naš objekat od interesa greškom nađu tačke koje se podudaraju sa tačkama sa objekta koji želimo da pratimo. Tada se praćenje nastavlja, ali praćenje pogrešnog objekta. To je upravo situacija koja je prikazana na slici 30. Po x osi greška raste, a po y se neznatno menja. Objekti su po y osi na sličnom položaju i zbog toga se po y osi ne vidi da je objekat izgubljen. Dakle, oba objekta se po y osi nalaze na sličnom mestu i y koordinata više nije merodavna.



30. Slika - Ilustracija situacije kada se po y koordinati ne vidi da je objekat izgubljen

Još jedna od situacija koja se može svrstati u greške koje dovode do prestanka praćenja, ili nepredvidive velike greške praćenja jesu pogrešno prepoznate SURF odlike. To je situacija kada su odlike pogrešno prepoznate na nekom mestu gde se uopšte ne nalazi naš objekat od interesa, niti neki objekat koji oblikom liči na objekat koji pratimo, već se samo može dogoditi pogrešno prepoznavanje odlika. Na slici 31 se nalaze neke od situacija u kojima se dogodilo pogrešno

prepoznavanje. Naravno, ova pogrešna prepoznavanja u jednom ili par frejmova mogu u potpunosti poremetiti rezultat praćenja, pa zato imaju veliki uticaj na performansu.



31. Situacije pogrešnog prepoznavanja mete, sukcesivni frejmovi, (a) Situacija 1, (b) Situacija 2

- (3) **Greške usled degradacije kvaliteta slike**, kao što je u slučaju magle, snega, kiše ili previše zagrejane okoline mogu dovesti do lošije performanse algoritma za praćenje, jer je njihova posledica nedovoljan kontrast na slici ili nemogućnost izdvajanja odlika SURF algoritmom. To su situacije koje zahtevaju dodatnu obradu i poboljšanje kvaliteta slike, radi praćenja mete. Ovakve greške, ili situacije dovode do toga da se odlike ni ne mogu pronaći na slici, tako da zahtevaju predobrade podataka kako bi praćenje bilo omogućeno. U analiziranom skupu podataka nije bilo ovakvih grešaka, ali se na njih mora obratiti pažnja prilikom dizajna sistema za praćenje.

4.5 ANALIZA GREŠKE PRAĆENJA SURF DESKRIPTORA NA TERMALNOJ SLICI

Na osnovu statističke analize rada SURF algoritma u zadatku praćenja pešaka na termalnoj slici koja je obrađena u ovom poglavlju, možemo videti da je problem sa kojim se susrećemo vrlo složen. Vidimo da se klasične statističke mere poput varijanse značajno menjaju u zavisnosti od analizirane situacije, što pokazuje da u podacima ima dosta vrednosti koje odskaču od očekivanih. Dakle, postoje različiti tipovi grešaka koji se javljaju prilikom rada algoritma, a samim tim su i različiti uticaji na performanse praćenja. Vidimo da su greške mogle da se svrstaju u tri osnovne grupe, a to su (1) greške usled promene dinamike, odnosno manevra objekta od interesa, (2) nepredvidive, velike greške, odnosno autlajeri (3) greške usled degradacije kvaliteta slike. Greške usled degradacije kvaliteta slike se uspešno rešavaju algoritmima za predobradu slike (kada je to moguće), poput onih za filtraciju, izoštravanje ili poboljšanje kontrasta. One nisu predmet istraživanja ovog rada, jer postoji veliki broj algoritama za njihovo rešavanje, a ti algoritmi uglavnom nemaju uticaj na ostale greške koje se javljaju.

Ono što je predmet istraživanja ove disertacije jeste na koji način možemo smanjiti uticaj grešaka usled manevra i autlajera. Kao rešenje ovog problema se nameće dizajn estimatora za predikciju pozicije objekta od interesa, kao prvi korak. Kada dođe do pojave autlajera, ili grešaka koje odstupaju od podrazumevane raspodele, klasične statističke mere poput srednje vrednosti i varijanse više ne opisuju problem na dobar način, a ni linearni estimatori poput Standardnog Kalmanovog filtra neće rešiti problem. Kao rešenje usled pojave autlajera u podacima jeste odbacivanje autlajera nekom od tehnika odbacivanja autlajera, kao što je opisano u [66]. Sa druge strane, jedno od rešenja za greške usled autlajera jeste robusni estimator. Ali sa druge strane, javlja se dilema kako napraviti razliku između dva tipa grešaka: autlajera i grešaka kada dođe do manevra, a dešava se prilikom promene režima kretanja. Dakle, glavno pitanje jeste kako koristiti robusne estimatore na način da se postigne kompromis između dva tipa grešaka. U sledećem poglavlju je dat teorijski osnov pristupa koji se zasniva na robusnoj estimaciji, sa posebnom pažnjom usmerenom ka postizanju kompromisa između dva tipa greške i balansa između robusnosti i efikasnosti.

5. ESTIMACIJA STANJA STOHAŠTIČKIH SISTEMA

Estimacija predstavlja procenu određenih parametara sistema na osnovu raspoloživih merenja senzora. Kako su merenja sa senzora obično zašumljena, što vodi do grešaka koje narušavaju performanse sistema, estimatori na osnovu podataka na raspolaganju i statističkih pretpostavki o tim podacima, procenjuju vrednosti parametara sistema. Dakle, ukoliko je potrebno proceniti nepoznati parametar $X\{x_1, \dots, x_n\}$, a na raspolaganju je skup od n podataka $Y\{y_1, \dots, y_n\}$, tada je estimacija, odnosno procena nepoznatog parametra data sa:

$$\hat{X}\{\hat{x}_1, \dots, \hat{x}_n\} = f(y_1, \dots, y_n), \quad (7)$$

gde je $f(\cdot)$ izabrana funkcija, koja može biti linearna ili nelinearna, u zavisnosti od konkretnog problema. Estimatori se mogu projektovati na različite načine, ali postoje dva osnovna pristupa estimaciji, a to su klasičan i Bajesov pristup estimaciji. Kod klasičnog pristupa je vektor X koji je potrebno proceniti nepoznata deterministička konstanta, dok se kod Bajesovog pristupa X posmatra kao slučajna promenljiva, a estimiraju se realizacije slučajnog vektora. Kod klasičnog pristupa informacije o podacima su sadržane u funkciji gustine verovatnoće, koja zavisi od parametra koji se procenjuje (funkcija verodostojnosti). Sa druge strane, kod Bajesovog pristupa postoji „*a priori*“ funkcija gustine verovatnoće pre dobijanja samih podataka na osnovu kojih se vrši procena ($f_{gv}(X)$), kao i „*posterior-na*“ združena funkcija gustine verovatnoće za procenjivani parametar kada se desi merenje podatka ($f_{gv}(X, Y)$).

Svaki estimator je slučajna promenljiva, pa se performanse estimatora opisuju statistički preko funkcije gustine verovatnoće (FGV). Naravno, performanse estimatora zavise u potpunosti od pretpostavljenih funkcija gustine verovatnoće, odnosno raspodela slučajnih promenljivih. Prilikom dizajna bilo kojeg estimatora, uvek je potrebno postići kompromis između performanse i brzine računanja. Kvalitet estimacije je određen poređenjem stvarne i procenjene vrednosti nepoznatog parametra [67]. Neke od mera performanse estimatora su nepomerenost (prosečna estimacija teži stvarnoj vrednosti), kao i minimalna varijansa (minimizacija varijanse po nekom unapred određenom kriterijumu). Pristup kojim se omogućava dobar kvalitet estimacije jeste da je estimator nepomeren, a minimalne varijanse [67].

Kako bi se bolje objasnio Bajesov pristup estimaciji, definišemo grešku estimacije slučajne promenljive X za jednu realizaciju merenja Y , kao :

$$e_k = x_k - \hat{x}_k = x_k - f(y_k) \quad (8)$$

gde $x_k \in X\{x_1, \dots, x_n\}$, $\hat{x}_k \in \hat{X}[x_1, \dots, x_n]$, a $y_k \in Y\{y_1, \dots, y_n\}$. Težnja prilikom dizajna estimatora je, naravno, da greška estimacije bude što manja. Zbog toga se uvodi pojam Bajesove funkcije cene, koja govori o tome koliko se značaja pridaje pojedinačnoj vrednosti greške estimacije. Funkcija cene $c(e)$ može biti kvadratna, apsolutna, itd. Na taj način se može definisati optimalni estimator, koji minimizira rizik (a rizik je očekivana cena). Minimizacija rizika predstavlja minimalno matematičko očekivanje funkcije $c(\cdot)$ u zavisnosti od greške estimacije:

$$\hat{x}_k = f(y_k) = \arg_{\hat{x}} \min E\{c(e_k)\} \quad (9)$$

U zavisnosti od usvojene funkcije cene se i definišu različiti estimatori, pa je tako za kvadratnu funkciju optimalan estimator minimalne srednje kvadratne greške, dok je za apsolutnu funkciju cene optimalan estimator minimalne medijane [67].

5.1 LINEARNA ESTIMACIJA STANJA STOHAŠTIČKIH SISTEMA

Kako je zadatak određivanja nepomerenog estimatora minimalne varijanse generalno veoma težak zadatak, jedan od načina da se uprosti jeste da se problem svede na linearan. Ukoliko se za kriterijum optimalnosti usvoji minimalna srednje kvadratna greška, a usvoji se i pretpostavka o linearnom modelu, tada je optimalno rešenje linearni estimator minimalne srednje kvadratne greške. Generalizacija ovog estimatora za dinamičke modele u prostoru stanja jeste Kalmanov filter.

5.1.1 Standardni Kalmanov filter

Jedno od najvažnijih dostignuća dvadesetog veka u oblasti linearne estimacije jeste Kalmanov filter koji predstavlja algoritam široko primenjen u oblasti praćenja objekata [68]. Standardni Kalmanov filter (SKF), opisan u ovoj glavi je optimalno rešenje linearnog kvadratnog problema, odnosno optimalni linearni estimator koji minimizira srednje kvadratnu grešku estimiranih parametara. Da bi se Standardni Kalmanov filter uspešno koristio u estimaciji stanja sistema, model važi pod nekim pretpostavkama. Među njima su i pretpostavke da je sistem linearan, a da celokupan šum sistema ima Gausovu raspodelu. U ovom radu, Kalmanov filter se koristi za modelovanje dinamike centra objekta koji se prati, pod pretpostavkom konstantne brzine. Sistem je predstavljen modelom u prostoru stanja:

$$x(k+1) = F(k)x(k) + G(k)w(k) \quad (10)$$

$$y(k) = H(k)x(k) + v(k) \quad (11)$$

gde $x(k)$ predstavlja vektor stanja, a $y(k)$ vektor opsevacija, dok su $w(k)$ i $v(k)$ šum stanja i merenja, respektivno. Pretpostavka koja važi za usvojen model jeste da su šum stanja i merenja beli šumovi sa nultom srednjom vrednosti:

$$E\{w(k)\} = 0; E\{w(k)w(k)^T\} = Q(k)\delta_{kj}; \quad (12)$$

$$E\{v(k)\} = 0; E\{v(k)v(k)^T\} = R(k)\delta_{kj}; \quad (13)$$

gde je δ_{kj} Kronecker-ov delta simbol, a $E\{.\}$ matematičko očekivanje. $F(k)$ je matrica prelaza stanja, a $H(k)$ matrica opservacija. Ukoliko je $\hat{x}(k/k-1)$ linearna estimacija najmanjih kvadrata veličine $x(k)$, a $P(k/k-1)$ odgovarajuća kovarijaciona matrica, onda su standardne rekurzije Kalmanovog filtra date izrazima:

$$\hat{x}_p(k) = F(k-1)\hat{x}(k-1) \quad (14)$$

$$P_p(k) = F(k-1)P(k-1)F^T(k-1) + G(k-1)Q(k-1)G^T(k-1) \quad (15)$$

$$K(k) = P_p(k/k-1)H^T(k)[H(k)P_p(k/k-1)H^T(k) + R(k)]^{-1} \quad (16)$$

$$\hat{x}(k/k) = \hat{x}_p(k/k-1) + K(k)(y(k) - H(k)\hat{x}(k/k-1)) \quad (17)$$

$$P(k/k) = [I - K(k)H(k)]P_p(k/k-1) \quad (18)$$

Početno stanje $x(0)$ je slučajna promenljiva, nezavisna od budućih realizacija šumova $w(k)$ i $v(k)$ sa nultom srednjom vrednosti i kovarijacionom matricom $P(0)$ [69].

5.1.2 Ograničenja kod klasičnih metoda i pojam autlajera

Kako bismo na bolji način objasnili koja su ograničenja klasičnih metoda estimacije, poput Standardnog Kalmanovog filtra predstavljenog u sekciji 5.1.1, najpre ćemo objasniti pojam autlajera. Kada nam je na raspolaganju određeni skup podataka, statistički definisano, autlajeri u tom skupu su tačke čije vrednosti značajno odskakuju od vrednosti ostalih podataka u skupu. Autlajeri su podaci koji se javljaju usled grešaka prilikom merenja, netačnih merenja, ili usled nedovoljno preciznog modelovanja problema kojim se bavimo. Dakle, uzroci autlajera, kao i njihova priroda su raznorodni. Zbog toga je i teško predvideti kada će se javiti i kolike će njihove vrednosti biti. Autlajeri u podacima mogu biti vrlo opasni jer menjaju procene klasičnih statističkih mera podataka posmatranog sistema, što naravno utiče i na performanse sistema koji projektujemo. Dakle, kada se klasičke statističke mere značajno menjaju u zavisnosti od situacije, znači da se javljaju vrednosti koje odskakuju, odnosno autlajeri. Zato je jako bitno, prilikom početnog dizajna konkretne aplikacije, upoznati se sa podacima koji se dobijaju, kao i videti da li je moguće proceniti raspodelu tih podataka, pa na osnovu toga izvesti zaključke o pojavi autlajera.

Kako klasične statističke mere u slučaju pojave autlajera nisu dobri pokazatelji stanja sistema, sa autlajerima u podacima se možemo izboriti tako što formiramo neka pravila za njihovo odbacivanje, uključimo apriori znanja u novi model, ili da se korišćenjem teorije robusne statistike njihov uticaj smanji [70]. Ukoliko su u pitanju aplikacije koje ne zahtevaju procesiranje u realnom vremenu, intuitivno je moguće pomisliti da je za nijansu jednostavnije analizirati podatke koji su na raspolaganju i odstraniti autlajere putem određivanja pravila za odbacivanje. Ali, i u ovom jednostavnijem slučaju se postavlja pitanje opravdanosti izbora koji će se podatak izbaciti, kako se ne bi desilo da se kao autlajer klasifikuje podatak koji je validan. Čak i ukoliko se izbace autlajeri iz seta podataka, nije sigurno da će ostatak podataka zadovoljavati početne pretpostavke o normalnoj raspodeli, koje su neophodne da bi se klasične statističke mere koristile. I na kraju, da li se ovakve metode mogu izboriti sa višestrukom pojavom autlajera, gde je moguće da postoje neki autlajeri koji su zamaskirani drugim autlajerima, pa ih pravila za odbacivanje neće tretirati. Opet, procena i klasifikacija nekog podataka kao autlajera zavisi od „*apriori*“ znanja o očekivanim vrednostima podataka [71]. Naravno, problem se dodatno usložnjava kada su u pitanju sistemi koji vrše procesiranje u realnom vremenu, gde se samo na osnovu prethodnih podataka može dati statistička procena podataka. Tada se autlajeri moraju tretirati odmah ili mogu pogoršati performanse sistema, a u slučaju sistema za praćenje i zaustaviti praćenje objekta od interesa. Zbog svega navedenog, pristupi bazirani na robusnoj estimaciji imaju prednost u odnosu na pristupe koji se baziraju na formiranju pravila odbacivanja. Još jedan od pristupa koji se pominju u literaturi jeste i korišćenje Kalmanovog filtra za odstranjivanje autlajera iz opservacija, gde se Kalmanov filter koristi za učenje težina svakog novog merenja [72], [73]. Tim pristupom se može izbeći podešavanje kovarijacione matrice šuma. Međutim, ovakav pristup, za posmatrani slučaj ne bi mogao da reši problem razdvajanja grešaka usled autlajera i usled manevra. Takođe, neki od novijih pristupa koriste i duboko učenje za rešavanje problema autlajera, kao na primer u identifikaciji parametara sistema [74], međutim, ovo rešenje nije još primenjeno na problem praćenja i problem procene tačnog stepena kontaminacije.

U konkretnom zadatku praćenja pokretnog objekta, podaci koje dobijamo od senzora (slike sa termalne kamere) predstavljaju stvarno stanje sistema kroz vreme. Na osnovu SURF algoritma se vrši merenje pozicije objekta od interesa. Međutim, kao što smo već naglasili u prethodnim poglavljima, ta merenja nisu uvek precizna, jer sadrže šum merenja. Sa druge strane, može se desiti da neki podatak koji smo dobili, odnosno neko merenje potpuno odskače od uobičajenih vrednosti. U delu gde je analizirana greška SURF algoritma (sekcija 4.3) na slici 21 je vidno da u podacima postoje neke velike vrednosti koje značajno odskaču od ostalih. Baš te vrednosti koje odskaču su autlajeri i imaju veliki uticaj na klasične statističke mere, poput varijanse i srednje vrednosti jer ih menjaju čim se pojave. Takođe, jedna od klasičnih metoda estimacije je i standardni Kalmanov filter, čiji model se zasniva na određenim pretpostavkama, među kojima su da je model dobar u slučaju da je posmatrani sistem linearan sa združenim Gausovskim procesima i da su raspodele mernog šuma poznatih definisanih statistika. U realnim situacijama, funkcija gustine verovatnoće šuma odudara od Gausovske, pa na taj način pravi standardni Kalmanov filter osetljivim na autlajere u podacima. Dakle, kada dođe do pojave autlajera, klasične metode za rešavanje linearnog problema estimacije, kao što je standardni Kalmanov filter nisu dobro rešenje, jer više ne važe neke početne pretpostavke o usvojenom klasičnom modelu. Zato je kao rešenje ovog problema izabrana robustifikacija sistema primenom teorije robusne estimacije [71].

5.2 ROBUSNA ESTIMACIJA STANJA STOHAISTIČKIH SISTEMA

Samo u idealnom svetu nema izuzetaka koji odskaču od pravila. Međutim, u tehnici se često koriste neke veoma idealistične pretpostavke kao što je pretpostavka Gausove raspodele podataka, ili linearni modeli. Razlog za ovakvo uprošćeno modeliranje realnih sistema je najpre to što realni modeli mogu biti jako kompleksni za računanje, a samim tim i vremenski zahtevni. Potrebno je postići balans između svih performansi sistema. Nekada je važnija preciznost u radu sistema, a nekada brzina rada, pa se u zavisnosti od konkretne aplikacije vrše prilagođavanja stvarnim potrebama.

Jedno od rešenja kojim se uticaj autlajera na performanse sistema može smanjiti jeste korišćenjem teorije robusne estimacije, koja se pokazala kao superiorna u odnosu na klasične metode kao što su određivanja pravila odbacivanja [71]. Osnovni cilj robustifikacije jeste smanjenje uticaja autlajera na performanse sistema. Robusna estimacija podrazumeva korišćenje robusnih statističkih mera umesto klasičnih, pa se tako umesto srednje vrednosti i standardne devijacije mogu koristiti medijana i medijan apsolutna devijacija („*MAD – Median Absolute Deviation*“), respektivno. Međutim, svaki pristup ima mane, a prilikom korišćenja robusnih mera, umesto klasičnih uvek treba imati u vidu da robusnost dolazi sa cenom, a to je smanjenje efikasnosti. To je razlog zbog kojeg se robusna statistika koristi u slučajevima kada postoje autlajeri u podacima [75], jer kada ih nema, robusni sistemi imaju manju efikasnost od klasičnih (koji su optimalna rešenja). Za slučaj koji je analiziran u ovom radu je jasno iz analize date u sekciji 4.3 da postoje autlajeri i zbog toga se kao rešenje problema predlaže dizajn robusnog estimatora.

5.2.1 Razvoj teorije robusne estimacije i različiti pristupi

Pojam robusnosti označava neosetljivost sistema na neočekivane velike greške, odnosno autlajere. Osnovni zadatak robusnih estimatora je zato zaštita sistema od uticaja velikih nepredvidivih grešaka, koje prete da potpuno ugroze performanse sistema. Postoji više definicija robusnosti: rezistentna robusnost (označava neosetljivost estimacione procedure na prisustvo pojedninačnih autlajera); efikasna robusnost (pretpostavlja se da estimator ima veliku efikasnost u odnosu na minimalnu moguću grešku estimacije); mini-maksna robusnost i kvalitativna robusnost. Kako su definicije mini-maksne robusnosti i kvalitativne robusnosti jako složene u matematičkom smislu, u praksi se projektuje estimator koji je efikasno i rezistentno robusan [68]. Neka od ograničenja teorije robusne estimacije jesu da ovaj pristup zahteva veći skup podataka za temeljnu statističku analizu podataka, gde se ipak moraju uključiti neke ekspertske i iskustvene procene u sam proces dizajna robusnog sistema. Još jedna bitna mana pristupa baziranih na robusnoj estimaciji jeste da se povećanjem robusnosti smanjuje efikasnost estimatora, pa je potrebno postići balans između ove dve komponente. Robusne procedure moraju imati određene osobine, a to su efikasnost (dobra efikasnost koja teži optimalnoj za posmatrani model), stabilnost (male devijacije

od početnih pretpostavki ne utiču mnogo na performansu), granice izdržljivosti (velike devijacije od modela ne uzrokuju totalni krah sistema) [71].

Sama istorija razvitka robusne statistike je stara koliko i statistika kao nauka, jer se je pojava autlajera vrlo uobičajena u realnom svetu, ali se se ipak radovi iz 1960-tih godina uzimaju kao fundamentalna otkrića u teoriji robusne estimacije. To su radovi Tukija, Hubera i Hampela. Rad P.J.Hubera iz 1964. godine [76] se uzima kao jedna od baza teorije robusne estimacije. Huber uvodi posebnu klasu estimatora koji su poznati kao M-estimatori. Takođe, modelira i pojam „*gross-error*“ koji označava pojavu velike nepredvidive greške, odnosno autlajera, pretpostavljajući njihovu pojavu na određenom delu podataka ε sa nepoznatom raspodelom, dok je ostatak podataka $(1 - \varepsilon)$ poznate raspodele. Dalji razvoj podrazumeva i pristup koji se bazira na funkcijama uticaja [77], a doprinos daju osim Hampela i Hubera, Elvecio i Rončeti [71].

Postoji više pristupa estimaciji u teoriji robusne statistike, a tri glavne klase estimatora robusne statistike su:

- M-robusni estimatori – Estimatori maksimalne verodostojnosti, koji se zasnivaju na kriterijumu maksimalne verodostojnosti.
- L-estimatori – Zasnivaju se na linearnoj kombinaciji redne statistike (tipičan primer je medijana).
- R-estimatori – Zasnivaju se na rang testovima za rangiranje reziduala [71].

Razmatrajući prirodu problema koji se izučava kao predmet ove disertacije, može se reći da je najprostije rešenje za dizajn efikasnog i rezistentnog estimatora pristup koji je opisan u [78], [79], [80]. U ovom radu su korišćeni M-robusni estimatori.

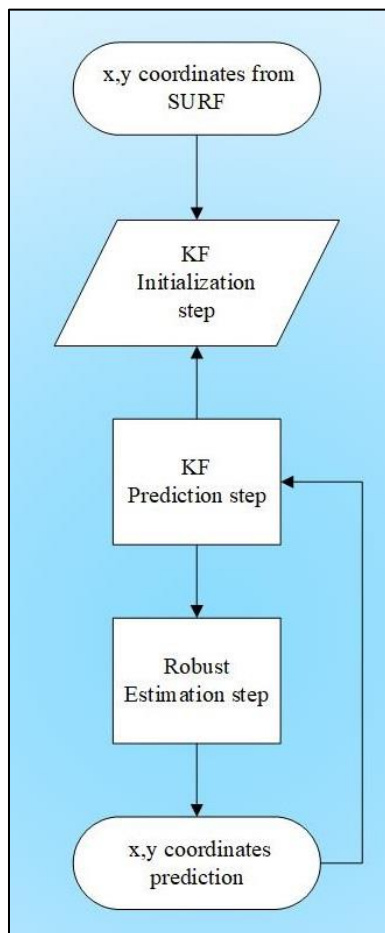
Kao što je navedeno, kod korišćenja robusnih estimatora mora se voditi računa o kompromisu između efikasnosti i robusnosti. Takođe, u konkretnom slučaju, iz analize greške koja se javlja korišćenjem SURF algoritma (sekcija 4.4), videli smo da se greške javljaju usled autlajera u podacima, ali mogu biti i posledica manevra objekta od interesa. Dakle, osim autlajera, usled nemodelirane dinamike sistema, tokom promene režima kretanja dolazi do velike greške merenja, međutim, to su greške koje se nikako ne smeju odseći jer bi se cilj izgubio. Kada dođe do pojave autlajera, ili grešaka koje odstupaju od podrazumevane raspodele, klasične statističke mere poput srednje vrednosti i varijanse više ne opisuju problem na dobar način. Takođe se, standardni Kalmanov filter, kao klasičan statistički metod, zasniva na nekim pretpostavkama pod kojima važi model. Kada su početne pretpostavke za standardni Kalmanov filter tačne, što podrazumeva da su raspodele šuma podataka koje opserviramo Gausovske, tada usvojen model važi. U realnim situacijama, funkcija gustine verovatnoće odudara od Gausovske, pa na taj način pravi standardni Kalmanov filter osetljivim na autlajere u podacima. Kao što smo videli, u analizi podataka praćenja sa SURF algoritmom, u ovom slučaju pojava autlajera i grešaka usled nemodelirane dinamike je neminovna. Zato estimator koji se projektuje za ovakav sistem mora biti robusan. Ali sa druge strane, nikako nije moguće jasno napraviti razliku između dva tipa grešaka: autlajera i grešaka kada dođe do nepoznate promene u samom modelu, a dešava se prilikom promene režima kretanja. Zbog toga se u okviru teorije robusne estimacije traži kompromis. Taj kompromis se može postići podešavanjem promenljivog parametra robusne funkcije, ili korišćenjem različitih robusnih funkcija uticaja u zavisnosti od režima kretanja, što je opisano u narednim sekcijama.

5.3 ROBUSNI ESTIMATORI STANJA

5.3.1 Robusni Kalmanov filtar sa fiksnim parametrima

Kalmanov filtar predstavlja algoritam koji se široko primenjuje u oblasti praćenja objekata, dok predstavlja i jedno od najvažnijih dostignuća oblasti estimacije [68]. U ovom radu, Kalmanov filtar se koristi za modelovanje dinamike centra objekta koji se prati, pod pretpostavkom konstantne brzine.

Kao što smo i naglasili u prethodnoj sekciji, korišćenjem teorije robusne estimacije, efekat autlajera može biti minimiziran. Ukoliko podaci ne sadrže autlajere, robusni metod zadržava praćenje pokretnog objekta, ali na račun performanse [81], dok ukoliko postoji deo podataka koji predstavljaju autlajere robusni metod ima prednost što je na njih otporan i praćenje se, u velikom broju slučajeva, ne zaustavlja. Zbog toga robusne metode predstavljaju pouzdan metod detekcije autlajera u podacima [75]. U ovom radu koristimo robusni Kalmanov filtar (RKF) opisan sledećim dijagramom (slika 32):



32. Slika - Robusni Kalmanov filtar dijagram toka

Ako sistem predstavimo modelom u prostoru stanja jednačinama procesa i merenja jednačinama istim kao i u slučaju standardnog Kalmanovog filtra (10) i (11):

$$x(k+1) = F(k)x(k) + G(k)w(k)$$

$$y(k) = H(k)x(k) + v(k)$$

gde $x(k)$ predstavlja vektor stanja, a $y(k)$ predstavlja vektor merenja, dok su $w(k)$ i $v(k)$ šum stanja i merenja, respektivno, tada je robusni Kalmanov filter opisan sledećim koracima:

1) Korak inicijalizacije se poklapa sa korakom inicijalizacije standardnog Kalmanovog filtra.

Za šum merenja i stanja važi:

$$E\{w(k)\} = 0; E\{w(k)w(k)^T\} = Q(k)\delta_{kj}; \quad (19)$$

$$E\{v(k)\} = 0; E\{v(k)v(k)^T\} = R(k)\delta_{kj}; \quad (20)$$

gde je δ_{kj} Kroneker-ov delta simbol, a $E\{.\}$ je matematičko očekivanje. $F(k)$ predstavlja tranzionu matricu stanja, a $H(k)$ matricu merenja.

2) Sledeći korak jeste korak predikcije:

Ako sa $\hat{x}(k/k-1)$ označimo estimaciju $x(k/k)$, a sa $P(k/k-1)$ označimo odgovarajuću kovarijacionu matricu, onda je predikcija:

$$\hat{x}_p(k) = F(k-1)\hat{x}(k-1) \quad (21)$$

$$P_p(k) = F(k-1)P(k-1)F^T(k-1) + G(k-1)Q(k-1)G^T(k-1) \quad (22)$$

Jedan od načina da se Kalmanov filter robustifikuje jeste da se standardni Kalmanov filter izmeni u koraku estimacije. Dakle, korak estimacije u robusnom Kalmanovom filteru u stvari predstavlja korak gde se vrši robustifikacija [81], odnosno primena nelinearne funkcije uticaja na rezidual merenja $\varepsilon(k)$ u Kalmanovom filteru.

3) Korak robusne estimacije

Kovarijaciona matrica reziduala $S(k)$ služi za računanje transformacije beljenja nad rezidualom. Na osnovu toga se može izračunati i skalirani rezidual $v(k)$, na koji se primenjuje robusna funkcija uticaja $\psi(k)$ i dalje računa $\omega(k)$ robusni težinski faktor, koji se koristi za računanje robusnog Kalmanovog pojačanja. Sledeće jednačine opisuju korak estimacije:

$$\varepsilon(k) = y(k) - H(k)\hat{x}_p(k) \quad (23)$$

$$S(k) = H(k)P(k)H(k)^T + R(k) \quad (24)$$

gde je $\varepsilon(k)$ rezidual, a $S(k)$ kovarijaciona matrica reziduala.

Pre nego što pristupimo robustifikaciji vrši se beljenje reziduala korišćenjem transformacije beljenja [82]:

$$v(k) = \Lambda^{-\frac{1}{2}} \Phi^T \varepsilon \quad (25)$$

gde je Λ dijagonalna matrica sopstvenih vrednosti λ_i , a Φ matrica odgovarajućih sopstvenih vektora matrice $S(k)$. Kako je $v(k)$ vektor, označićemo sa $v_n(k)$ jedan njegov element. Konačno, implementaciju Huberove nelinearne funkcije vršimo kroz sledeću relaciju:

$$\psi(k) = \psi(v_n(k)) = \min(|v_n(k)|, \Delta) \operatorname{sgn}(v_n(k)) \quad (26)$$

$$\omega(k) = \begin{cases} \frac{\psi(v_n(k))}{v_n(k)} & , v_n(k) \neq 0 \\ 1 & , v_n(k) = 0 \end{cases} \quad (27)$$

gde je $\psi(k)$ robusna funkcija uticaja, a $\omega(k)$ robusni težinski faktor.

Dakle, robustifikacija Kalmanovog filtra se bazira na primeni nelinearne funkcije uticaja na rezidual merenja u Kalmanovom filtru. Na osnovu teorije „*Robust dynamic stochastic approximation estimator theory*“ [83], što je pristup baziran na definiciji vremenski promenljivog funkcionala („*time-varying functional*“), dobijamo i jednačine za robusno pojačanje koje se koristi u poslednjem koraku predikcije stanja za sledeći korak:


$$K(k) = \omega(k) P_p(k/k-1) H^T(k) [H(k) P_p(k/k-1) H^T(k) + R(k)]^{-1} \quad (28)$$

Odatle dobijamo novu estimaciju stanja i kovarijacionu matricu:

$$\hat{x}(k) = \hat{x}_p(k/k-1) + K(k) \varepsilon(k) \quad (29)$$

$$P(k) = [I - K(k) H(k)] P_p(k-1) \quad (30)$$

Funkcija uticaja, koja predstavlja ključni korak u robustifikaciji Kalmanovog filtra mora biti odabrana tako da se na najbolji mogući način izbori sa autlajerima koji postoje u podacima. Za ovaj slučaj, robusnog Kalmanovog filtra sa fiksnim parametrima odabrana je Huber-ova funkcija uticaja, prikazana na slici 33:



33. Slika - Huber-ova funkcija uticaja

$$\psi(x) = \begin{cases} x & , |x| \leq \Delta \\ \Delta \operatorname{sgn}(x) & , |x| > \Delta \end{cases} \quad (31)$$


gde je Δ odabrana vrednost parametra [84]. Veoma je važno na pravi način podesiti parametar Δ na osnovu zadatih kriterijuma performanse. U ovom radu je parametar Δ u stvari promenljivi parametar koji podešavamo u zavisnosti od situacije na sceni.

5.3.2 Funkcije uticaja

Prilikom dizajna robusnog Kalmanovog filtra sa fiksnim parametrima, iz prethodne sekcije, kao odabrana funkcija uticaja se koristi Huber-ova funkcija uticaja. Međutim, to nije jedina funkcija uticaja koja se može koristiti. Njena mana jeste to što raspodele koje nose najmanje informacija imaju tendenciju da imaju eksponencijalne repove koji mogu biti tanji od očekivanog u praksi [71]. Dakle, osim pomenute Huber-ove funkcije, takozvane „*redescending*“ M funkcije su analizirane i testirane takođe, jer se definišu kao malo efikasnije od Huber estimatora za neke simetrične raspodele šireg repa. Ove funkcije imaju sposobnost potpunog odbijanja velikih i uticajnih autlajera, što nije slučaj sa Huber-ovom funkcijom koji ih tretira isto kao i manje autlajere.

Neke od funkcija uticaja čiji se rad u konkretnom slučaju analizira su:

(1) Hampel-ova funkcija uticaja – slika 34




34. Slika – Hampel-ova funkcija uticaja

Hampel-ova funkcija uticaja se definiše kao:

$$\psi(x) = \text{sgn}(x) \begin{cases} |x| & , 0 < |x| \leq a \\ a & , a < |x| \leq b \\ a \frac{c-|x|}{c-b} & , b < |x| \leq c \\ 0 & , |x| < c \end{cases} \quad (32)$$

gde su a, b , and c definisane konstante.

(2) Tuki-jeva funkcija uticaja – slika 35



35. Slika – Tuki-jeva funkcija uticaja


Tuki-jeva funkcija uticaja se definiše kao:

$$\psi(x) = \begin{cases} x(1 - \frac{x^2}{c^2})^2 & , |x| \leq c \\ 0 & , |x| > c \end{cases} \quad (33)$$

gde je c definisana konstanta.

Za ovu robusnu funkciju se obično koristi vrednost konstante $c = 4.685$ što obezbeđuje asimptotsku efikasnost od 95% linearne regresije za normalnu raspodelu.

(3) Endrjus-ova funkcija uticaja – slika 36



36. Slika – Endrjus-ova funkcija uticaja

Endrjus-ova funkcija uticaja se definiše kao:

$$\psi(x) = \begin{cases} \sin\left(\frac{x}{c}\right) & , |x| \leq c\pi \\ 0 & , |x| > c\pi \end{cases} \quad (34)$$

gde je c definisana konstanta.

5.3.3 Robusni Kalmanov filter sa promenljivim parametrima

Prilikom projektovanja Huber-ovog robusnog Kalmanovog filtra, potrebno je pravilno postaviti vrednost parametra Δ u Huber-ovoj funkciji uticaja koja je opisana jednačinom (31). Ovaj korak je veoma važan jer je to konstanta koja reguliše nivo robusnosti, odnosno efikasnosti estimatora. Naime, kako šum merenja u realnim situacijama, pa tako i u posmatranom slučaju, nije Gausove raspodele, već imamo autlajere u podacima koji kontaminiraju nominalnu raspodelu, moramo dizajnirati naš estimator tako da bude robusan na pojavu autlajera. Sa slike 26 u sekciji 4.3 se može videti da rezidual nema Gausovu raspodelu i autlajeri svakako za to nisu jedini krivci. Međutim, zanemarićemo tu činjenicu u ovom trenutku i pretpostavićemo da imamo u pitanju najčešći slučaj. Najčešći slučaj jeste da je šum merenja Gausovski raspodeljen u centralnom delu, dok autlajeri predstavljaju takozvane zadebljale ili otežale repove koji se mogu predstaviti nekom drugom funkcijom raspodele. Dakle, podaci u sebi sadrže uvek i neki stepen kontaminacije autlajerima, koji ćemo označiti sa ε . Ti autlajeri imaju drugačiju raspodelu od pretpostavljene raspodele šuma. Ostatak podataka, njih $(1 - \varepsilon)\%$ ima normalnu raspodelu. Robusna funkcija uticaja, koja je nelinearna, se uvodi kako bi se estimator robustifikovao, odnosno napravio neosetljivim na autlajere. Izbor konstante Δ dakle reflektuje pretpostavku o stepenu kontaminiranosti podataka autlajerima. Međutim, sa jedne strane je neophodno estimator učiniti robusnim na autlajere u merenjima, a sa druge strane je potrebno da taj estimator bude i efikasan, odnosno da prihvatljivo funkcioniše pod idealnim uslovima. Većom robustifikacijom estimator gubi na efikasnosti i obrnuto, pa je potreban balans između ove dve komponente performanse. Taj balans unosi konstanta Δ . U zavisnosti od stepena kontaminacije autlajerima određujemo vrednost ove konstante, a da pri tome ne ugrozimo efikasnost, pa je i Huber dao vrednosti Δ za različite procenat efikasnosti [71], [75]. Međutim, u zavisnosti od režima kretanja, i statistike šuma se menjaju, pa je tako i kontaminacija autlajerima različita u zavisnosti od situacije na sceni. Ukoliko je stepen kontaminacije autlajerima unapred poznat, najbolji izbor vrednosti Δ (za slučaj kontaminirane Gausovske raspodele) dao je Huber [71], [76]. Međutim, u većini realnih situacija stepen kontaminacije se menja i nije unapred poznat.

Možemo reći da je, u slučaju normalne raspodele greške kada nema kontaminacije autlajerima, kao izbor Δ konstante najbolje odabrati što veću vrednost. Sa druge strane, ukoliko raspodela greške ima otežale repove najbolji izbor je što manja vrednost Δ konstante. Zbog toga se kao rešenje nameće podešavanje konstante Δ u zavisnosti od stepena kontaminacije podataka autlajerima, što može da poveća efikasnost i do 40% u odnosu na slučaj fiksne konstante [85].

Do veze između faktora kontaminacije i parametra Huber-ove funkcije uticaja Δ se može doći ukoliko usvojimo pretpostavku da podaci $x = \{x_i\}, i = 1, 2, \dots, n$ imaju zajedničku raspodelu i da je raspodela svih podataka data u formi ε -kontaminirane normalne raspodele:

$$F(z_i) = (1 - \varepsilon)\Phi(z_i) + \varepsilon H(z_i), \quad (35)$$

gde je $z_i = \frac{x_i - \mu}{\sigma}$, dok je Φ standardna normalna kumulativna funkcija raspodele, sa lokacijom μ i skalom σ , H je nepoznata raspodela kontaminacije, a ε predstavlja procenjeni faktor kontaminacije. Huber je posebno opisao problem estimacije lokacije u ovom slučaju kada postoji kontaminacija podataka autlajerima. Huber baš za takvu vrstu problema uvodi pojam M-estimacije lokacije. Definiše se kao problem minimizacije dat u formi:

$$\min_{\mu} \sum \rho(z_i) \quad (36)$$

$$\rho(z_i) = \begin{cases} \frac{z_i^2}{2} & , z_i^2 \leq \Delta^2 \\ \Delta|z_i| - \frac{k^2}{2} & , \text{za ostale slučajeve} \end{cases} \quad (37)$$

Vrednost Δ je, kao što je već i rečeno konstanta koja se podešava u zavisnosti od kontaminacije podataka autlajerima. Ukoliko varijansa nije unapred poznata, Huber sugerise da se koristi MAD („Mean Absolute Deviation“) procena, jer takva procena daje bolje rezultate pod uslovom da ima kontaminacije autlajerima. Sada se problem minimizacije, koji je predstavljen jednačinom (36), može predstaviti kao rešenje jednačine:

$$\sum \psi(z_i) = 0 \quad (38)$$

$$\sigma \psi(z_i) = \sigma \frac{d\rho}{d\mu} = \begin{cases} -\Delta & , \text{ako } z_i < -\Delta \\ z_i & , \text{ako } |z_i| < \Delta \\ \Delta & , \text{ako } z_i > \Delta \end{cases} \quad (39)$$

Analitičko rešenje za procenu lokacije je dato kao:


$$\hat{\mu} = \tilde{y} + \frac{\Delta \sigma (n_3 - n_1)}{n_2} \quad (40)$$

gde su n_1, n_2, n_3 brojevi opservacija u intervalima.

Vežu između ove dve komponente (Δ konstante i stepena kontaminacije autlajerima ε) definisao je Huber [71], [86] sledećom relacijom:

$$\frac{2\varphi(\Delta)}{\Delta} - 2\Phi(-\Delta) = \frac{\hat{\varepsilon}_k}{1 - \hat{\varepsilon}_k} \quad (41)$$

gde je sa $\hat{\varepsilon}_k$ označena procena stepena kontaminacije autlajerima, dok je $\varphi = \Phi'$ funkcija raspodele za normalnu Gausovu slučajnu promenljivu. Zavisnost Δ od procenjenog stepena kontaminacije autlajerima je prikazana na slici 37.



37. Slika - Zavisnost parametra Δ od procenjenog stepena kontaminacije

Ono što se javlja kao problem jeste procena stepena kontaminacije autlajerima. Kako koristimo Huber-ovu robusnu funkciju nad rezidualima za izračunavanje težinskog faktora, odnosno za odsecanje autlajera, ovaj podatak možemo iskoristiti za procenu stepena kontaminacije [87]. U [87] je za određivanje težinskog faktora korišćena procena na osnovu Mahalanobis rastojanja ili Projekcione statistike. Po toj ideji, a na osnovu izračunatih težinskih faktora, korišćenjem Huber-ove funkcije uticaja procenjujemo stepen kontaminacije na osnovu n odbiraka merenja na sledeći način [87]:

$$\hat{\epsilon}_k = 1 - \frac{1}{n} \sum_{i=1}^n \omega_i \quad (42)$$

gde je $\hat{\epsilon}_k$ procena kontaminacije za prethodnih n odbiraka, dok je ω_i robusni težinski faktor za svaki i -ti odbirak izračunat preko jednačine (27). Sada na osnovu jednačine (41) i procenjenog faktora kontaminacije (42) možemo odrediti konstantu Δ . Ono što je važno naglasiti jeste da se robustifikacija Huber-ovom funkcijom uticaja vrši nad izbeljenim rezidualom ($v_n(k)$). Neophodno je postaviti i granice za vrednost koju Δ može da ima [85], što je u našem slučaju: $\Delta \in [1, 2.63]$. Ove vrednosti su u skladu sa vrednostima koje je Huber predložio [71], a za konkretan slučaj empirijski određene. Broj odbiraka n za koji se vrši procena kontaminacije autlajerima je vrlo značajan. Ukoliko je ovaj broj veće vrednosti, onda je kašnjenje u računanju kontaminacije izraženo, ali je preciznija njena procena. Sa druge strane, manja vrednost n daje grublju procenu, ali i manje kašnjenje u računanju kontaminacije. Empirijski je utvrđena vrednost parametra n za konkretan slučaj iznosi 25 odbiraka.

5.4 ADAPTIVNI ROBUSNI ESTIMATORI STANJA

Kako nije uvek moguće imati na raspolaganju veliku bazu podataka na osnovu koje se mogu „*a priori*“ izračunati statistike potrebne za modelovanje šuma u Kalmanovom filtru, potrebno je dizajnirati rešenje koje bi bilo adaptivno na način da se potrebne statistike šuma računaju iz dobijenih podataka u toku rada samog filtra i adaptivno podešavaju. Kako bismo postigli adaptivnost rešenja, na osnovu procene ovih matrica možemo prilagoditi naš Kalmanov filter datoj situaciji. Sledeći i poslednji korak, jeste dizajn adaptivnog rešenja koje se na osnovu M-robustnih estimacija Q i R matrica šuma u Kalmanovom filtru prilagođava situacijama na slici, dok se konstanta Huber-ove funkcije uticaja takođe adaptira uslovima scene na način objašnjen u prethodnoj sekciji. Procena šuma se vrši na osnovu dobijenih odbiraka procene šuma merenja $r(i)$ i stanja $q(i)$ [68]:

$$r(i) = y(i) - H(i)\hat{x}(i) \quad (43)$$

$$q(i) = (G^T(i)G(i))^{-1}G^T(i)[\hat{x}(i) - F\hat{x}(i-1)], \quad (44)$$

gde je $i = k - N + 1, \dots, k$, dok N predstavlja vrednost prozora u kojem računamo statistike šuma. Ukoliko koristimo M-robustnu procenu šuma merenja i stanja, procena parametra lokacije $\hat{r}(k)$ (robustna alternativa srednjoj vrednosti) je definisana sa:

$$\sum_{i=k-N+1}^k \Psi\left(\frac{r(i) - \hat{r}(k)}{\hat{d}(k)}\right) = 0 \quad (45)$$

gde je $\Psi(\cdot)$ robustna funkcija uticaja, u našem slučaju Huber-ova funkcija. Estimacija faktora skaliranja podataka je faktor $\hat{d}(k)$. Ovaj faktor se računa u robustnoj statistici kao:

$$\hat{d}(k) = \text{median} \frac{|r(i) - \text{median}(r(i))|}{0.6745}, \quad (46)$$

gde je $i = k - N + 1, \dots, k$.

Na kraju, računamo M-robustnu procenu varijanse šuma merenja i stanja kao:

$$\hat{V}(k) = \frac{\hat{d}^2(k) \left\{ \frac{1}{N} \sum_{i=k-N+1}^k \Psi^2 \left[\frac{r(i) - \hat{r}(k)}{\hat{d}(k)} \right] \right\}}{\left\{ \frac{1}{N} \sum_{i=k-N+1}^k \Psi' \left[\frac{r(i) - \hat{r}(k)}{\hat{d}(k)} \right] \right\}^2} \quad (47)$$

Odatle se šum merenja i stanja procenjuju kao:

$$\hat{R}(k) = \hat{V}_r(k) - HP(k)H^T \quad (48)$$

$$\hat{Q}(k) = \hat{V}_q(k) - (G^T(k)G(k))^{-1}[F(k)P(k-1)F^T(k) - P(k)] \quad (49)$$

Na kraju je potrebno dodati da se nekad dešava da estimatori daju negativnu vrednost, pogotovo na početku, pa se zbog toga izračunate vrednosti uvek resetuju na apsolutne vrednosti [68].

5.5 PROCENA KONTAMINACIJE AUTLAJERIMA

Kao što je već rečeno u sekciji 5.3.3, početna pretpostavka od koje se, u ovom slučaju, polazi jeste da je šum merenja Gausovski raspodeljen u centralnom delu, dok autlajeri predstavljaju takozvane zadebljale ili otežale repove koji se mogu predstaviti nekom drugom funkcijom raspodele. To znači da podaci u sebi sadrže uvek i neki stepen kontaminacije autlajerima, koji se označava sa ε . Baš ti autlajeri imaju drugačiju raspodelu od pretpostavljene raspodele šuma, dok ostatak podataka, njih $(1 - \varepsilon)\%$ ima normalnu raspodelu. U sekciji koja se bavi podešavanjem promenljivog parametra funkcije uticaja (5.3.3) je formulom 42 dat način procene kontaminacije podataka autlajerima. Za analizirani slučaj u toj sekciji su uzete eksperimentalno određene vrednosti parametra n , koji i figuriše u datoj formuli. Međutim, zanimljivo je ispitati u kojoj meri parametar n utiče na procenu kontaminacije autlajerima, kao i tačnost ovakvog načina procene kontaminacije.

5.5.1 Adaptivni faktor zaboravljanja

Memorija sistema predstavlja svojstvo da pamti i izvlači informacije iz prethodnih odbiraka. Faktor zaboravljanja, sa druge strane predstavlja težinski faktor zaboravljanja starijih podataka, u odnosu na novije. Termin faktor zaboravljanja se javlja u teoriji identifikacije, odnosno estimacije i modelovanja parametara sistema, kod dizajna adaptivnih filtara, odnosno rekurzivnog metoda najmanjih kvadrata [88], [89]. Vrednost faktora zaboravljanja se kreće u opsegu: $f_f \in (0,1]$ [88]. Ukoliko je $f_f = 1$, tada možemo reći da podrazumevamo da su podaci stacionarni, odnosno da je njihova dinamika promene spora. To važi za sve vrednosti faktora zaboravljanja bliske jediničnoj vrednosti. Sa druge strane, ukoliko su vrednosti faktora zaboravljanja bliže nultoj

vrednosti, onda će biti omogućeno praćenje brze dinamike u podacima. Naravno, i tada je potrebno voditi računa da ukoliko je faktor zaboravljanja jako blizak nultoj vrednosti, onda sistem može previše pratiti dinamiku šuma u podacima [90]. Samim tim, adaptacija ovog faktora, u zavisnosti od podataka i dinamike promene u podacima predstavlja dobro rešenje za posmatrani slučaj.

Adaptacija faktora zaboravljanja predstavlja temu koja se dugo godina unazad izučava. Najviše radova koji se bave adaptivnim faktorom zaboravljanja je napisano u oblasti hemijske industrije i hemijskih postrojenja [90]. Uglavnom se većina pristupa koja koristi adaptivni težinski faktor bazira na eksponencijalnim težinskim modelima. U radu [90] je dat pregled dotadašnjih metoda za adaptaciju faktora zaboravljanja korišćenog za identifikaciju putem rekurzivne metode najmanjih kvadrata, kao i novi predlog za adaptaciju. Taj predlog se bazira na eksponencijalnom pristupu, gde figuriše dodatni predefinisani parametar α , na način da faktor zaboravljanja bude u opsegu $f_f \in (0.95, 1)$, kao i faktor veličine prozora N , koji predstavlja u stvari memoriju faktora zaboravljanja. Iako pristup daje dobre rezultate, bazira se na pretpostavci uvođenja novog parametra α , ali i varijabilnosti faktora samo u jednom delu opsega vrednosti. Još jedan način računanja faktora zaboravljanja, koji podrazumeva uvođenje dodatnog parametra, se zasniva na proceni odnosa snage korisnog signala i šuma [91]. Noviji radovi u ovoj oblasti podrazumevaju različite načine za proračun faktora zaboravljanja, poput metoda zasnovanih na gradijentu [92], [93]. Formula za gradijent ima svojstvo da je pozitivan u slučaju kada je greška velika, a kada je sistem u stabilnom stanju, gradijent je negativan. Na tome se i zasniva proračun faktora zaboravljanja [92]. Jedan od pristupa su i algoritmi bazirani na matičnom zaboravljanju, čija je mana računaska kompleksnost [94]. Još jedan od načina za računanje faktora zaboravljanja jeste preko estimiranih vrednosti varijansi apriori i aposteriori greške, na način opisan u [95]. Mana ovog pristupa se zasniva na činjenici da se varijanse dobijaju direktno, dakle celokupan proračun se zasniva na estimiranim parametrima. Jedan od interesantnih načina proračuna jeste baziran na uvođenju novih parametara, poput parametra α koji odražava uticaj greške, kao i određivanje minimalnog faktora zaboravljanja, koji takođe figuriše u izrazu za proračun faktora zaboravljanja [96]. Još jedna zanimljiva ideja se zasniva na proračunu faktora zaboravljanja na način da se uvrste informacije o rezidualu, kao i minimalnim i maksimalnim vrednostima koje faktor zaboravljanja može da ima [97].

Na osnovu ideje o usrednjavanju vrednosti faktora kontaminacije autlajerima [87] korišćenjem faktora zaboravljanja kojim se množi prethodna procena faktora kontaminacije je formiran i novi, pristup koji se bazira na adaptivnom faktoru zaboravljanja. Faktor zaboravljanja se računa na način sličan kao u [97], sa tom razlikom da smo za proračun faktora zaboravljanja umesto greške uzeli težinski faktor. Formula po kojoj se računa faktor zaboravljanja je:

$$F_f = \begin{cases} F_f^{max}, & \omega_k = 1 \\ F_f^{min} + (F_f^{max} - F_f^{min}) * \omega_k, & \omega_k < 1 \\ F_f^{max}, & \omega_k > 1 \end{cases} \quad (50)$$

U odnosu na početnu ideju, gde se usrednjava trenutna vrednost faktora zaboravljanja korišćenjem trenutne i prethodne vrednosti. U našem slučaju, formiramo adaptivni faktor zaboravljanja i računamo srednju vrednost za prethodnih N_{mem} odbiraka, na sledeći način:

$$\tilde{\epsilon}_k = \frac{1}{N_{mem}} \sum_{i=1}^{N_{mem}} F_f \hat{\epsilon}_i \omega_i, \quad (51)$$

gde je $\hat{\epsilon}_i$ izračunato pomoću formule za računanje faktora kontaminacije

6. DIZAJN ROBUSNOG SISTEMA ZA PRAĆENJE POKRETNIH OBJEKATA NA TERMALNOJ SLICI I EKSPERIMENTALNI REZULTATI

Početna tačka u dizajnu sistema za praćenje, u ovom radu jeste korišćenje SURF odlika i standardnog Kalmanovog filtra za podešavanje osnovne verzije sistema, modela i potrebnih parametara. Algoritam se zasniva na izdvajanju SURF odlika iz prethodno obeleženog regiona od interesa („ROI“). Sledeći korak jeste računanje centra pozicije objekta od interesa, što predstavlja ulazno merenje u Kalmanovom filtru. Dakle, x i y pozicije centra, dobijene SURF deskriptorom, su vektor merenja za Kalmanov filter koji zatim vrši predikciju pozicije objekta koji se prati na osnovu usvojenog modela. U slučajevima kada nema pronađenih SURF tačaka, Kalmanov filter je od krucijalnog značaja za performansu praćenja. Ukoliko šum merenja i procesa nisu pažljivo izračunati i postavljeni, Kalmanov filter neće imati dobar model na osnovu kojeg može da vrši korektnu predikciju položaja centra mete [69].

Radi preciznog računanja statistika šuma merenja i procesa koristimo rezultate dobijene statističkom analizom podataka koje očekujemo da dobijemo. Kako je naš problem praćenja definisan kao praćenje jednog pokretnog objekta na termalnoj slici, algoritam je prilagođen ovom specifičnom slučaju. Dakle, za ovaj slučaj praćenja su izračunati šum merenja i procesa.

Statistička analiza šuma procesa se vrši na sukcesivnim frejmovima slike razlike, koja je objašnjena u sekciji 2.3. Šum merenja je izračunat na osnovu greške merenja SURF algoritma u odnosu na „ground truth“ podatke analiziranog skupa podataka. Na osnovu statističke analize izvršene u sekciji 2.3 mogu se pravilno postaviti vrednosti srednje vrednosti i varijanse šuma merenja i procesa u modelu Kalmanovog filtra:

$$Q = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & q_{22} & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & q_{44} \end{bmatrix} \quad (52)$$

$$R = \begin{bmatrix} r_x & 0 \\ 0 & r_y \end{bmatrix} \quad (53)$$


Radi ispitivanja rada Kalmanovog filtra pripremljena su tri skupa podataka: *DS 1*, *DS 2* i *DS 3*, opisani i analizirani u sledećoj sekciji.

6.1 STANDARDNI KALMANOV FILTAR

Na osnovu Standardnog Kalmanovog filtra (SKF), možemo videti vrednosti u okvirima kojih se kreću reziduali, izbeljeni reziduali, zatim kovarijansa reziduala, kao i srednja vrednost i to na osnovu različitih načina za računanje istih (klasičnih i robusnih). Na osnovu toga se može ispitati dizajn robusnih filtara sa različitim funkcijama uticaja. Takođe, pokazano je kako različite situacije kod kojih se javlja greška prilikom računanja SURF odlika utiču na rezultate koji se dobijaju i zbog čega je važno koristiti robusne metode prilikom rada sa Kalmanovim filtrom.

Radi ispitivanja rada Kalmanovog filtra najpre ispitujemo skup podataka pod imenom *DS 1*. Za ovaj skup podataka je karakteristično da se meta kreće u jednom smeru bez menjanja brzine kretanja, kao i da nema okluzija niti loših merenje SURF-a koji mogu ugroziti praćenje standardnim Kalmanovim filtrom. Ono što nam je značajno jeste analiza reziduala dobijenih praćenjem SURF deskriptorom i standardnim Kalmanovim filtrom.

Praćenje standardnim Kalmanovim filtrom je uspešno na ovom skupu podataka, što se može videti iz priloženih rezultata na slikama 38 gde je prikazana apsolutna vrednost greške estimacije, koja predstavlja apsolutnu razliku pozicije SKF i „ground truth“ merenja pozicije objekta.



38. Slika - Standardni Kalmanov filtar apsolutna greška po x (levo) i y (desno) koordinati

Sledeći skup podataka koji se obrađuje jeste *DS 2*. Za ovaj skup podataka je karakteristično da se meta kreće u jednom smeru bez menjanja brzine kretanja, kao i da nema okluzija. Međutim, u ovom skupu podataka dolazi do greške u uparivanju odlika na dva sukcesivna frejma, zbog sličnosti deskriptora. Loša merenje SURF deskriptora daju pogrešnu informaciju o položaju objekta po y osi i zbog toga SKF daje lošije rezultate. Praćenje sa SKF nije uspešno na ovom skupu podataka.

Još jedan skup podataka koji se obrađuje jeste *DS 3*. Za ovaj skup podataka je karakteristično da se meta kreće u jednom smeru bez menjanja brzine kretanja, u prisustvu okluzija u vidu drugog objekta sa kojim se objekat koji se prati preklopi u nekom trenutku. Standardni Kalmanov filter daje lošije rezultate, jer ne može da se izbori sa autlajerima u podacima koji nastaju zbog okluzija. Praćenje sa SKF nije uspešno na ovom skupu podataka.

Situacije koje predstavljaju probleme za SKF u skupovima podataka *DS 2* i *DS 3* su prikazane na slici 39.



39. Slika - SKF – greška estimacije zbog autlajera: (a) situacija 1 – pogrešno upravljanje, (b) okluzija

Kao što se i sa slika može videti, analizom skupova *DS 1*, *DS 2*, *DS 3* je primećeno da je standardni Kalmanov filter dobar kada u podacima nema autlajera. Međutim, čim se dese autlajeri u podacima, SKF više nije dobar estimator stanja jer je na njima osetljiv. Prvenstveno je to i razlog zbog kojeg je odlučeno da se koriste robusni filter i u daljem dizajnu sistema za praćenje.

6.2 SURF I KLT ODLIKE I STANDARDNI KALMANOV FILTER U PRAĆENJU OBJEKATA NA TERMALNOJ SLICI

Kako bismo poboljšali performansu algoritma za praćenje, u slučaju okluzija na slici, kada standardni Kalmanov filter ne daje dobre rezultate, najpre je testirano poboljšanje algoritma dodavanjem još jednog deskriptora odlika u proces praćenja [69]. Dakle, kombinacijom SURF deskriptora odlika, kao i KLT („*Kanade Lucas Tomasi*“) trepera [98] uz korišćenje standardnog

Kalmanovog filtra kao prediktora dobijamo algoritam koji je u stanju da se izbori sa određenim vrstama okluzija na slici 40.

Testiranje je izvršeno za test sekvencu iz LTIR seta podataka [6] čiji je prvi frejm prikazan na slici. Karakteristika ove sekvence jeste da sadrži parcijalnu okluziju, dva objekta na slici se delimično preklapaju.



40. Slika – Test sekvencu iz LTIR seta podataka, prvi frejm

U ovoj sekvenci se javljaju dve vrste okluzija, preklapanje dva pešaka, što predstavlja situaciju 1 i preklapanje više pešaka, što predstavlja situaciju 2. Situacije okluzija su prikazane na slici 41.




41. Slika – Situacije okluzija u sekvenci: (a) Situacija 1, (b) Situacija 2

Algoritam za praćenje koji je baziran na SURF deskriptoru i standardnom Kalmanovom filtru uparuje iste odlike na dva sukcesivna frejma. Inicijalna pozicija pravougaonika za praćenje u kojem se traže SURF odlike se postavlja na prvom frejmu u sekvenci, a zatim se na sukcesivnom frejmu traže i uparuju iste odlike. Kalmanov filter vrši predikciju položaja pravougaonika za praćenje u sledećem koraku, na osnovu merenja centra objekta SURF algoritmom. U sledećem koraku se SURF odlike traže unutar pravougaonika praćenja i uparuju sa narednim frejmom. U svakom koraku dolazi do uparivanja novih odlika, i ukoliko je treker podešen da radi na takav način, greši kada se dogode okluzije u sekvenci. Primer greške je prikazan na slici 42.



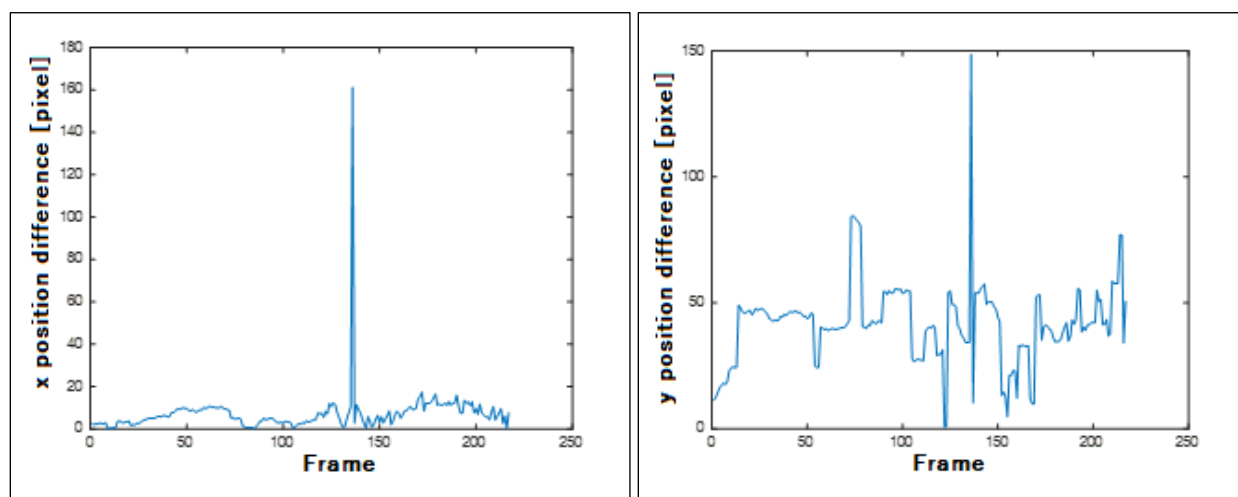
42. Slika – Pogrešno uparivanje SURF odlika na dva sukcesivna frejma, situacija 1

Kako bi odabrani algoritam radio bolje u slučaju okluzija, najpre je treker modifikovan na način koji doprinosi brzini i memoriji odabranog algoritma. Naime, ukoliko se u svakoj iteraciji ponovo računaju SURF odlike za područje regiona pravougaonika za praćenje, vreme se nepotrebno gubi na računanje. Zbog toga se, samo u slučaju da je broj uparenih odlika manji od dve SURF odlike, pravi novi referentni frejm i nove SURF odlike u njemu. Na taj način algoritam dobija memoriju i uspeva da se izbori sa nekim okluzijama na slici, i to u slučaju situacije 1 na konkretnoj sekvenci. Rezultat greške praćenja je prikazan na slici 43.



43. Slika – Greška SURF algoritma u slučaju prve modifikacije trekera

Prva okluzija, za situaciju 1 se dogodila oko frejma 30, a druga okluzija počinje oko frejma 120. U slučaju prve okluzije je modifikovana verzija trekera uspevala da nastavi praćenje u toku situacije 1, što ranije nije bio slučaj. Međutim, ostaje i dalje slučaj okluzija situacije 2, kada algoritam ne uspeva da zadrži praćenje objekta od interesa. Zbog toga se uvode i KLT odlike, koje se koriste na način da se SURF odlike koriste prilikom inicijalizacije KLT trekera. Ukoliko dolazi do odskakanja merenja SURF pozicija i predikcije Kalmanovog filtra iz okvira vrednosti koje su logične za kretanje pešaka na slici, vrši se reinicijalizacija trekera opet sa SURF odlikama i tačkama. Na ovaj način se postiže da se problem situacija okluzija kada SURF algoritam i standardni Kalmanov filter ne uspevaju da prate objekat od interesa prevaziđe korišćenjem KLT trekera dodatno. Rezultati ovako koncipiranog rešenja su prikazani na slici 44.



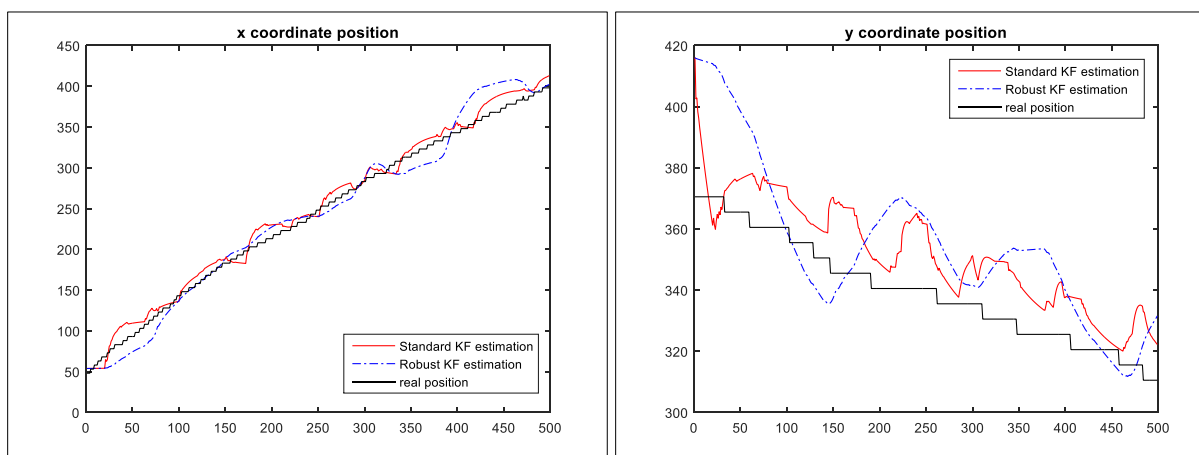
44. Slika – Greška SURF algoritma u slučaju druge modifikacije trekera

Kao što se sa priloženih grafika može i primetiti, ovako koncipiran treker je uspešno održao praćenje objekta od interesa u slučaju situacije 1 i u slučaju situacije 2. Međutim, opisano rešenje ima dosta nedostataka. Osim toga što se statistike šuma standardnog Kalmanovog filtra moraju računati za svaku situaciju posebno, kombinacija više algoritama za praćenje, poput uklapanje SURF i KLT trekera dovodi do velikog uvećanja složenosti algoritma za praćenje. Još jedna mana ovog pristupa jeste što je i dalje potrebno manualno ograničiti skok pozicije objekta od interesa, u skladu sa mogućnostima kretanja pešaka. Takvo rešenje nije primenjivo na različite uslove scene, niti različit način kretanja objekta na slici. Zaključak jeste da bi rešenje zasnovano na robustifikaciji i adaptaciji estimatora, uz korišćenje samo jedne vrste deskriptora – SURF deskriptora moglo doprineti boljoj performansi algoritma za praćenje. Na taj način bi se moglo postići automatsko prilagođavanje trenutnim uslovima scene. Sledeća poglavlja su zato posvećena eksperimentalnim rezultatima testiranja robusnih rešenja. Naravno, još jedna mogućnost poboljšanja rezultata praćenja, u slučaju multisenzorskih sistema, jeste korišćenje fuzije slike sa termalne i vizuelne kamere [99], ali ova tema prevazilazi okvire ovog rada.

6.3 ROBUSNI KALMANOV FILTAR SA FIKSNIM PARAMETRIMA

Kako se u mnogim situacijama pokazuje da je veliki uticaj pogrešnih merenja, okluzija i drugih faktora na rezultate praćenja sa SKF, sledeći korak jeste dizajn robusnog Kalmanovog filtra (RKF), radi smanjenja uticaja takvih autlajera. Najpre je testiran rad robusnog Kalmanovog filtra sa Huber-ovom funkcijom uticaja, pa upoređen sa rezultatima SKF za iste situacije, kako bi se pokazala prednost robusnog filtra u situacijama kada ima autlajera u merenjima, kao što je slučaj sa *DS 2* i *DS 3*.


Najpre analiziramo *DS 1*, radi poređenja rada SKF i RKF sa Huber-ovom funkcijom uticaja u slučaju sekvence u kojoj nema autlajera. Rezultati su prikazani na slici 45.



45. Slika – Uporedni prikaz rada SKF i RKF na *DS 1*, za *x* i *y* koordinate

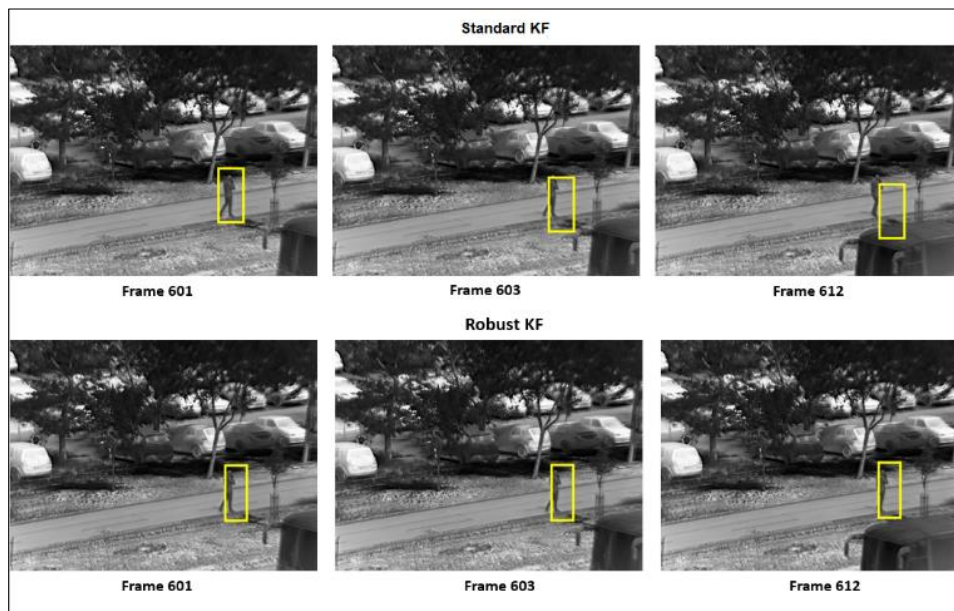
Kao što se i vidi sa grafika za x i y koordinate, SKF i RKF sa Huber-ovom funkcijom uticaja daju slične rezultate, osim što je greška RKF u nekim trenucima veća, što je i očekivan rezultat.

Sledeći analizirani skup je DS 2, gde je došlo do pogrešnog uparivanja i autlajera u podacima merenja za y koordinatu. Uporedni prikaz rezultata za SKF i RKF sa Huberovom funkcijom uticaja u ovom slučaju su prikazani na slici 46.




46. Slika – Uporedni prikaz rada SKF i RKF na DS 2, za y koordinatu

Kao što se i vidi sa grafika, RKF ignoriše grešku u merenjima i uspešno nastavlja praćenje, što nije slučaj kod SKF. Rezultat praćenja je prikazan i na frejmovima iz date sekvence i prikazan na slici 47.




47. Slika – Uporedni prikaz rada SKF i RKF na DS 2, frejmovi sekvence

Na kraju, upoređujemo rezultate rada SKF i RKF sa Huber-ovom funkcijom uticaja i na DS 3, koji sadrži okluzije. Autlajeri se javljaju u merenjima x koordinate, pa je prikazan rezultat za tu koordinatu.



48. Slika – Uporedni prikaz rada SKF i RKF na DS 3, za x koordinatu

Sa grafika se može videti da je opet vidna prednost RKF u odnosu na SKF u slučaju okluzija, a taj rezultat je prikazan i na konkretnim frejmovima iz sekvence (Slika 49).



49. Slika – Uporedni prikaz rada SKF i RKF na DS 3, frejmovi sekvence


Sa prikazanih grafika se vidi da je robusni Kalmanov filter uspešno nastavio praćenje i uprkos autlajerima u podacima, tako da se sada može i detaljnije ispitati na drugim sekvencama, u različitim režimima rada.

6.4 EKSPERTSKI SISTEM SA RAZLIČITIM FUNKCIJAMA UTICAJA U ZAVISNOSTI OD KRETANJA OBJEKTA NA SLICI

U ovoj sekciji se ispituje rad različitih funkcija uticaja koje su opisane u 5.3.2. Najpre je dat prikaz rada različitih funkcija uticaja na već ispitivanim skupovima podataka DS 1, DS 2, DS 3, kako bi se uporedio njihov rad u odnosu na SKF. Zatim je urađena dublja analiza kada ispitivane sekvence podataka sadrže i različite režime kretanja, a na kraju je dat i predlog konačnog sistema koji u zavisnosti od režima rada koristi robusnu funkciju koja je dala najbolje rezultate za taj režim rada.

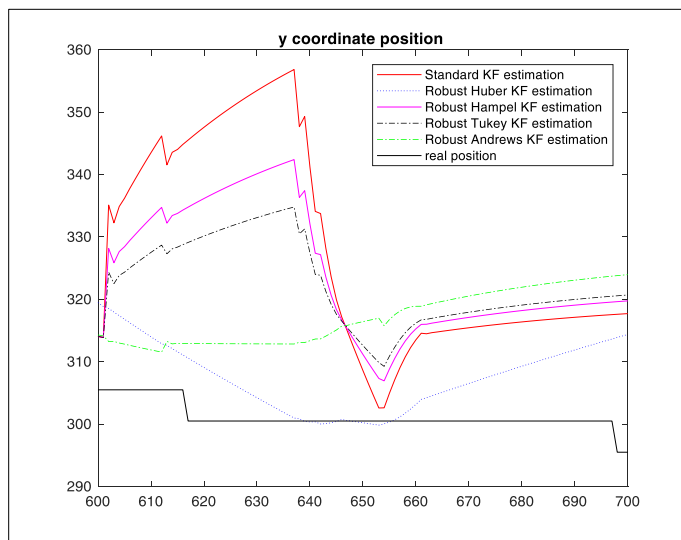
6.4.1 Uporedna analiza SKF i RKF sa različitim funkcijama uticaja

Testirane su različite funkcije uticaja, kako bi se video njihov uticaj na rezultate praćenja. Rezultati praćenja robusnim Kalmanovim filtrom, sa različitim funkcijama uticaja (koje su opisane u sekciji 5.3.2) su upoređeni sa rezultatima koje daje SKF na različitim skupovima podataka. Najpre analiziramo DS 1 gde i standardni Kalmanov filter daje dobre rezultate, kako bismo uporedili sa rezultatima koje daju robusni filteri, ali sa različitim funkcijama uticaja (slika 50).




50. Slika – Uporedni prikaz pozicije SKF i RKF sa Huber-ovom, Hampel-ovom, Tuki-jevom i Endrjus-ovom funkcijom uticaja za DS 1

Sa ovih grafika je jasno da robusni filtri daju istu ili malo veću grešku u odnosu na SKF, a da dobre rezultate daju sve analizirane robusne funkcije, u ovom slučaju. Sledeće analizirane situacije jesu za $DS 2$ i $DS 3$, i to su prikazane koordinate gde je dolazilo do pojave autlajera u podacima (slike 51 i 52).



51. Slika – Usporedni prikaz pozicije SKF i RKF sa Huber-ovom, Hampel-ovom, Tuki-jevom i Endrjus-ovom funkcijom uticaja za $DS 2$, koordinata y




52. Slika – Usporedni prikaz pozicije SKF i RKF sa Huber-ovom, Hampel-ovom, Tuki-jevom i Endrjus-ovom funkcijom uticaja za $DS 3$, koordinata x

6.4.2 Analiza primene različitih funkcija uticaja na sekvencama sa različitim režimima kretanja

Različite funkcije uticaja imaju i različite rezultate u zavisnosti od situacije na sceni. Zbog toga je, u ovoj sekciji, izvršeno ispitivanje rada različitih funkcija uticaja u zavisnosti od režima kretanja. Dakle, dati su uporedni grafici greške RKF sa Huber-ovom, Hampel-ovom, Tuki-jevom i Endrjus-ovom funkcijom uticaja, kako bi se izveo zaključak o njihovom radu. Bitne situacije koje su analizirane su promena smera i pravca objekta od interesa, rotacija, pogrešno prepoznate odlike, okluzije i nedovoljan kontrast.

1) Promena smera kretanja objekta od interesa

Prva situacija koja se ispituje jeste promena smera kretanja objekta od interesa. Cilj jeste ispitati koja funkcija uticaja daje najmanju grešku procene pozicije. Zbog toga je prikazana uporedno greška za Huber-ovu, Hampel-ovu, Tuki-jevu i Endrjus-ovu funkciju uticaja na slici 53.




53. Slika - Promena smera kretanja – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate

Na osnovu rezultata možemo primetiti da Huber-ova i Hampel-ova robusna funkcija daju najveće vrednosti greške u nekim segmentima, tako da izbor za ovu situaciju pada na Tuki-jevu ili Endrjus-ovu funkciju, koje su u pomenutim situacijama dale najbolje rezultate.

2) Rotacija objekta od interesa

Sledeća situacija koju ćemo ispitati jeste rotacija objekta od interesa, a komparativna predstava greške je prikazana na slici 54.




54. Slika - Rotacija – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate

Analizom skupova podataka sa rotacijom zaključujemo da je za ovaj slučaj najbolja primena Tuki-jeve robusne funkcije.

3) Autlajeri - pogrešno prepoznate odlike objekta od interesa na nekom drugom mestu

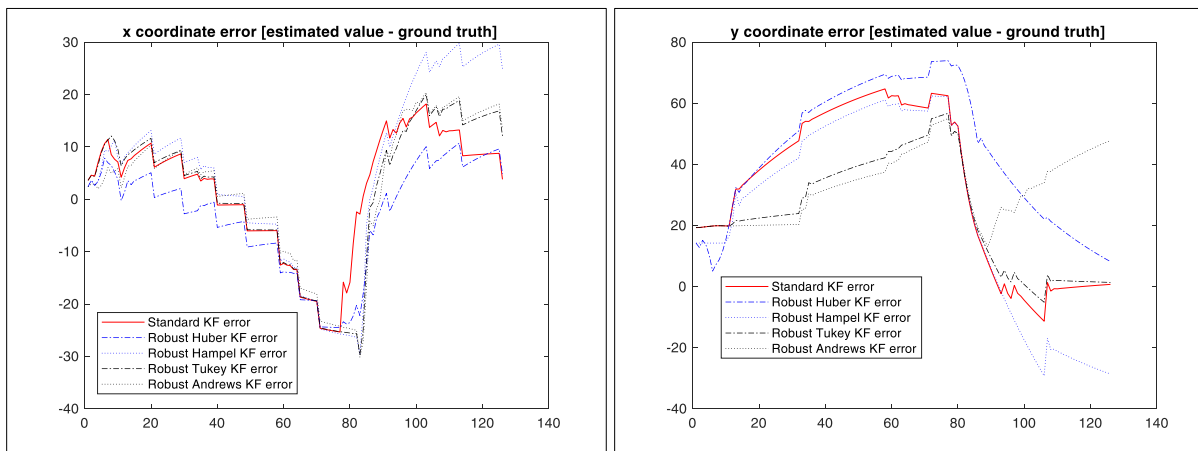
Sledeća situacija koju ćemo ispitati jeste kada su pogrešno prepoznate odlike objekta od interesa. Na slici 55 prikazani su rezultati, ali ne za ceo ispitani set podataka, jer je na primer Hampel-ova funkcija uticaja izdivergirala već na 235 odbirku od ukupno 300. U ovom slučaju je najbolji izbor Huber-ova funkcija uticaja.



55. Slika – pogrešno prepoznate odlike – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate

4) Okluzije


Sledeća situacija koju ćemo ispitati jesu okluzije objekta od interesa. Obradeno je pet skupova podataka sa okluzijama različitih vrsta, ali ćemo prikazati jedan reprezentativan primer na slici 56. Endrjus-ova funkcija divergira u svakom obrađenom primeru, a Hampel-ova u jednom. Kao najbolje rešenje uzima se Tuki-jeva funkcija.



56. Slika – okluzije – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate

5) Nedovoljan kontrast

Sledeća situacija koju ispitujemo jeste nedovoljan kontrast između objekta od interesa i pozadine. Huber-ova funkcija uticaja je najbolji izbor, jer Endrjus-ova divergira još na početku, dok Hampel-ova i Tuki-jeva pred kraj divergiraju – slika 57.



57. Slika – nedovoljan kontrast – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate


6.4.3 Dizajn ekspertskog sistema na bazi promene funkcije uticaja u slučaju različitih režima kretanja

Na osnovu rezultata iz prethodne sekcije, može se dati predlog konačnog sistema za praćenje pokretne mete na termalnoj slici sa RKF. Kao osnovna funkcija uticaja, na osnovu rezultata je odabrana Huber-ova funkcija. U slučaju da dolazi do promene smera kretanja objekta od interesa, koristi se Endrjus-ova funkcija, kod rotacije Tuki-jeva, dok je kod okluzija problem podeljen na dve grane Tuki-jeva, Hampel-ova funkcija uticaja. Za ostale analizirane slučajeve (pogrešno prepoznavanje objekta od interesa na nekom drugom mestu, kao i za nedovoljan kontrast) koristi se Huber-ova funkcija koja je svakako osnovna funkcija, tako da se ovi slučajevi ne moraju izdvajati posebno.

Dakle, ono što je potrebno da naš sistem prepozna kao situacije kada je potrebno postaviti neku drugu funkciju uticaja koja nije Huber-ova (koja je osnovna) jesu:

- **Promena smera kretanja**, koju možemo preko „*Optical Flow*“ algoritma [100] primetiti po promeni znaka brzine kretanja objekta,
- **Rotacija**, koju takođe preko „*Optical Flow*“ algoritma možemo detektovati,
- **Okluzija**, koju ćemo prepoznavati na osnovu „*Background subtraction*“ [101] algoritma, gde dobijenu sliku obradimo morfološkim obradama (dilatacija i erozija), a onda preko procenta popunjenosti slike razlike određujemo da li je došlo do okluzija.

Na kraju dajemo rezultat za 1520 odbiraka na kojem je ovako dizajniran sistem pratio objekat od interesa, a sve pomenute situacije koje utiču na pojavu autlajera su uspešno prevaziđene. Na slici 58 je prikazan rezultat greške robusnog Kalmanovog filtra za x i y koordinatu. Ono što je bitno naglasiti jeste da su „*ground truth*“ pozicije manualno obeležavane, tako da je malo odstupanje vrlo moguće prilikom obeležavanja.




58. Slika – okluzije – komparativni prikaz greške RKF sa više funkcija uticaja, x i y koordinate

6.5 ROBUSNI KALMANOV FILTAR SA PROMENLJIVIM PARAMETRIMA

U ovom poglavlju je opisan još jedan pristup dizajnu robusnog Kalmanovog filtra koji uz pomoć promenljivog parametra Δ u Huber-ovoj funkciji uticaja uspeva da postigne kompromis između efikasnosti i robusnosti, kao i između različitih tipova greške (odseći autlajere, a ostaviti promene usled promene režima kretanja) [102]. Analiziran je rad samog SURF algoritma i rad robusnog Kalmanovog filtra sa promenljivim parametrom Δ kroz varijansu greške tog algoritma. Pre same analize statistika, potrebno je naglasiti da algoritam na osnovu svih pronađenih tačaka daje informaciju o koordinatama centra objekta koji posmatramo. Dominantno kretanje se dešava duž x ose i iz tog razloga su prikazani rezultati za tu osu.

Kao što smo već rekli, situacije delimične ili potpune okluzije imaju veliki uticaj na praćenje objekta korišćenjem SURF deskriptora. Grafik vremenske promene varijanse praćenja SURF algoritmom na sekvenci koja sadži tri okluzije za koordinatu x je prikazan na slici 59, uporedo sa grafikom promene varijanse robusnog Kalmanovog filtra koji ima promenljivu vrednost Δ .




59. Slika - Uporedna varijansa greške algoritma SURF samostalno i RKF sa podesivim Δ

Na ovom intervalu je SURF algoritam izgubio metu zbog okluzije tri puta, a na grafiku su ovi prekidi praćenja označeni prekidom grafika varijanse i sivom površinom. Usled okluzija se javljaju greške koje su loša merenja, odnosno autlajeri u podacima. Ostale promene varijanse, odnosno povećanje vrednosti varijanse greške, gde se nastavlja praćenje objekta od interesa potiču od nemodelirane promenljive dinamike usled manevra. Sa druge strane, korišćenjem robusnog Kalmanovog filtra sa promenljivim parametrom Δ vidimo sa grafika da nema prekida u radu,

odnosno praćenje ne prestaje zbog pojave okluzija na slici. Sa datog grafika se može videti da varijansa greške ima slične vrednosti na delu sekvence gde nema mnogo autlajera u podacima. Sa druge strane, tamo gde je bilo prekida u praćenju prilikom korišćenja samog SURF algoritma, zbog pojave okluzija, uvođenjem robusnog Kalmanovog filtra je to izbegnuto.


Na grafiku na slici 60 je prikazana promena parametra Δ tokom vremena.



60. Slika - Promena parametra Δ tokom vremena

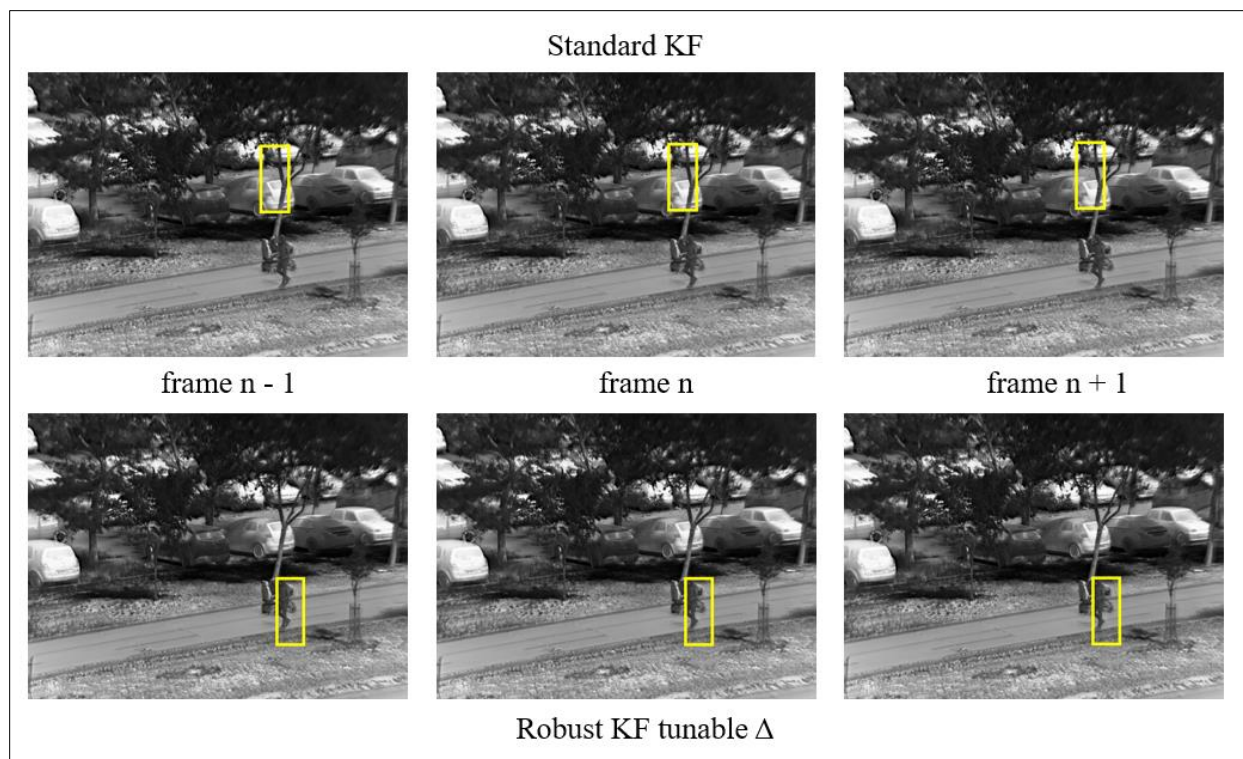
Na ovom grafiku se vidi da se vrednost parametra menjala tokom vremena i to u odnosu na procenu stepena kontaminacije autlajerima u obrađenim podacima. Kao inicijalna vrednost za Δ je postavljena vrednost 2, što znači da se pretpostavlja mala kontaminacija autlajerima. Δ se uglavnom menja u zavisnosti od kontaminacije autlajerima, a sa grafika vidimo i da se uglavnom pad Δ poklapa sa porastom varijanse greške na grafiku 59. Naravno, i ostali tipovi greške opisani u sekciji 2, takođe utiču na procenu kontaminacije autlajerima, jer nikako nije moguće napraviti strogu granicu između različitih tipova greške. Međutim, ono što jesmo postigli je da se uglavnom situacija na sceni prati promenom parametra Δ , što i omogućava postizanje bolje performanse nego što je slučaj kada je Δ fiksni parametar.

U tom smislu je zanimljivo videti uporedni prikaz rezultata tri tipa Kalmanovog filtra, što je i prikazano na slici 61. Na ovom grafiku je predstavljena greška standardnog Kalmanovog filtra (SKF), robusnog Kalmanovog filtra sa fiksnim Δ („Fixed delta RKF“) i robusnog Kalmanovog filtra sa promenljivim Δ („Tunable delta RKF“). Predstavljen je deo sekvence sa okluzijom gde je standardni Kalmanov filter zadržao praćenje objekta, iako sa velikom greškom u nekim delovima.



61. Slika - Uporedna greška za SKF, RKFsa fiksnim Δ i RKF sa promenljivim Δ , koordinata x

Ono što se grafika može videti jeste da je u slučaju korišćenja robusnog KF, bilo sa fiksnom, bilo sa promenljivom vrednošću Δ vidno manja greška praćenja, odnosno RKF ne gubi objekat od interesa, kao što je sličaj sa SKF. Velike vrednosti greške SKF se javljaju i zbog pogrešnog uparivanja SURF deskriptora, ali i zbog okluzija na slici i označavaju delove gde je rezultat praćenja bio potpuno pogrešan. Sa druge strane, poređenjem rada dve vrste robusnog Kalmanovog filtra, sa grafika se vidi da je greška koju pravi robusni Kalmanov filter sa promenljivom vrednošću Δ manja nego ukoliko je vrednost Δ fiksna. Na ovaj način je pokazano koliko je RKF sa podesivim Δ parametrom neophodan u ovakvim realnim situacijama praćenja, a superioran u odnosu na standardni Kalmanov filter. Slika 62 predstavlja komparativni prikaz rezultata u situacijama okluzije dobijenih korišćenjem SKF i RKF sa promenljivim Δ .

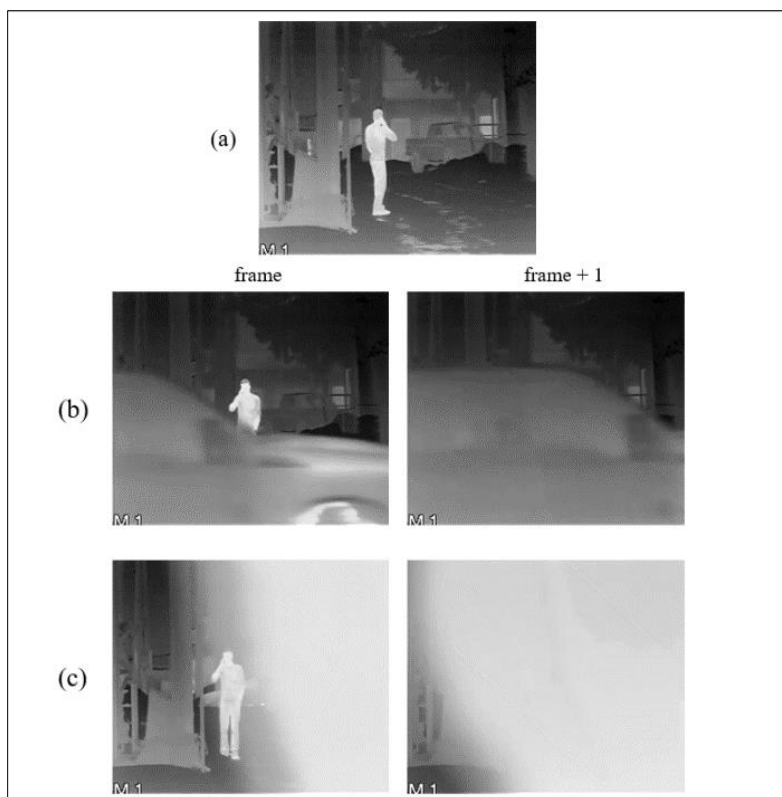


62. Slika – Paralelni prikaz greške SKF i RKF sa promenljivim Δ

6.5.1 Poređenje rada RKF sa promenljivim Δ i savremenih trekera

Kako bi se testirala robusnost na okluzije novog RKF sa promenljivim Δ trekera, u različitim scenarijima praćenja, njegova performansa je upoređena sa dva tipa savremenih trekera: 1) trekera baziranih na dubokom učenju (*DSiam* [50], *HssNet* [51], *MLSSNet* [52]) i 2) tradicionalni diskriminacioni treker (*KCF HOG* [44]). Novi algoritam (RKF sa promenljivim Δ) je testiran na sekvencama iz *LSOTB-TIR* [17] evaluacionog skupa. Testirane sekvence sadrže različite tipove okluzija, koje su prikazane na slikama 63 i 64. Za sekvencu 1, karakteristično je duže trajanje potpune okluzije objekta od interesa, dok je za sekvencu 2 karakteristična parcijalna okluzija.

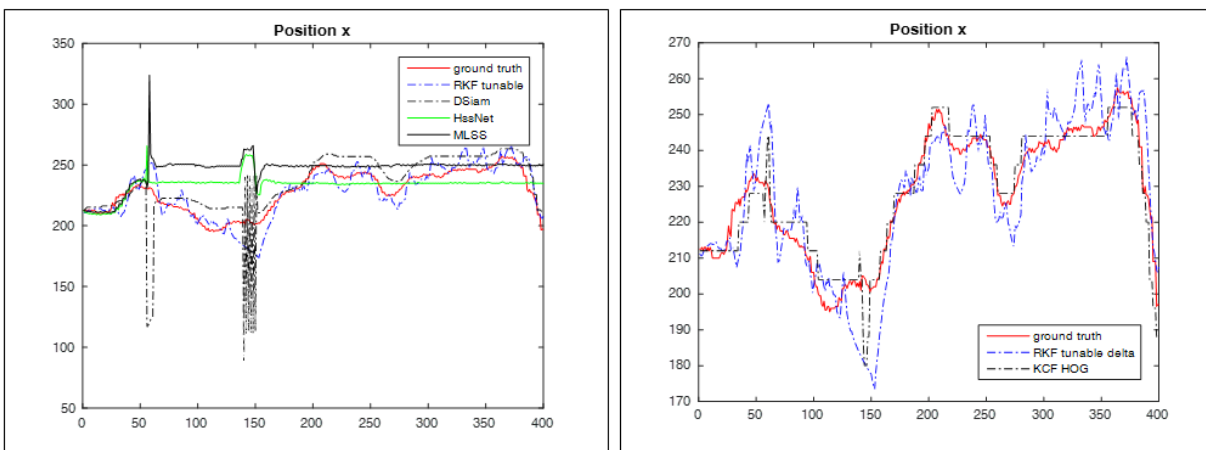
Najpre su prikazani rezultati poređenja različitih trekera za sekvencu 1, koja sadrži dva tipa dužih potpunih okluzija (slika 63). Na slici 65 je prikazan rezultat praćenja različitih algoritama za praćenje, uz prikaz stvarnih pozicija objekta od interesa. Kako bi se rezultati mogli jasnije predstaviti, grafik na slici levo prikazuje rezultat poređenja metoda zasnovanih na dubokom učenju i novog RKF sa promenljivim Δ trekera, dok grafik desno prikazuje rezultate poređenja tradicionalnog diskriminacionog trekera *KCF HOG*-a i RKF sa promenljivim Δ , za sekvencu 1.



63. Slika – Evaluaciona sekvenca 1 – (a) početni frejm, (b) okluzija 1 sukcesivni frejmovi, (c) okluzija 2 sukcesivni frejmovi



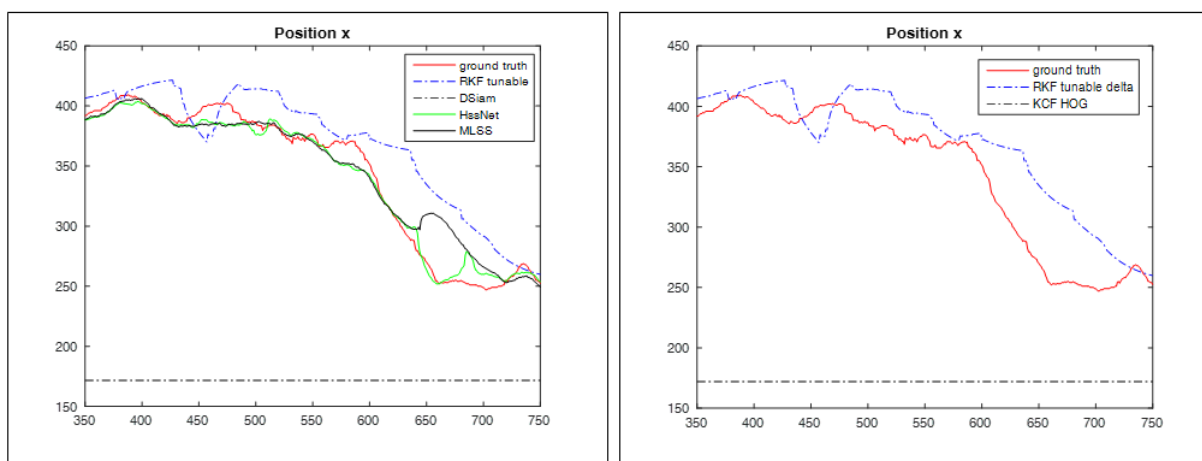
64. Slika – Evaluaciona sekvenca 2 – (a) početni frejm, (b) okluzija



65. Slika – Paralelna reprezentacija: (levo) stvarne pozicije, RKF sa promenljivim Δ , DSiam, HSSNet i MLSSNet treker; (desno) stvarne pozicije, RKF sa promenljivim Δ , KCF HOG; x koordinata, sekvenca 1

Okluzije u sekvenci 1 (slika 63) su se dogodile oko frejma 50 i 140. Sa slike 65 se može videti da je treker RKF sa promenljivim Δ robustan na okluzije iz sekvence. DSiam treker uspeva da prati objekat od interesa, iako je greška bila značajna u situacijama okluzija. Sa druge strane, HSSNet i MLSSNet algoritmi ne prate dinamiku objekta od interesa uopšte u ovom slučaju. KCF HOG algoritam takođe pokazuje dobre rezultate praćenja u ovom slučaju.

Sledeća analizirana situacija jeste sekvenca 2, gde se okluzija dogodila oko frejma 450. Rezultati poređenja rada različitih trekera su prikazani na slici 66. Kako bi se rezultati mogli jasnije predstaviti, grafik na slici levo prikazuje rezultat poređenja metoda zasnovanih na dubokom učenju i novog RKF sa promenljivim Δ trekera, dok grafik desno prikazuje rezultate poređenja tradicionalnog diskriminacionog trekera KCF HOG-a i RKF sa promenljivim Δ , za sekvenca 2.



66. Slika – Paralelna reprezentacija: (levo) stvarne pozicije, RKF sa promenljivim Δ , DSiam, HSSNet i MLSSNet treker; (desno) stvarne pozicije, RKF sa promenljivim Δ , KCF HOG; x koordinata, sekvenca 2

DSiam i *KCF HOG* treker nisu uspešno pratili objekat od interesa u ovoj situaciji. Sa druge strane, *HssNet*, *MLSSNet* i *RKF* sa promenljivim Δ su uspeli da isprate dinamiku kretanja objekta od interesa. Dakle, u slučaju sekvence 2 se može zaključiti da tradicionalna diskriminativna metoda nije dala dobar rezultat, dok je većina metoda zasnovanih na dubokom učenju (osim *DSiam*), kao i *RKF* sa promenljivim Δ dala dobre rezultate.

Svi trekeri su pokrenuti na PC računaru sa *i73.4 GHz CPU* i *NVIDIA GeForce GTX 650 GPU*. Prosečna brzina po frejmu je korišćena kao metrika za brzinu. Rezultati su predstavljeni u Tabeli 11.

11. Tabela – Performansa trekera – brzina

Algoritam	Brzina [fps]
RKF promenljivo Δ	9
DSiam	12
HssNet	15
MLSSNet	25
KCF HOG	272


Na osnovu rezultata koji su prikazani u Tabeli 11, očigledno je da je *RKF* sa podesivim Δ numerički najviše zahtevan algoritam u odnosu na druge analizirane metode. To znači da se može koristiti za praćenje objekata koji se sporije kreću. Sa druge strane, za razliku od metoda koje su zasnovane na dubokom učenju, kojima je potrebno dosta vremena za početno obučavanje mreže, predloženi algoritam ne zahteva dodatno vreme za obučavanje.

Zaključak koji se može doneti, na osnovu prethodne analize rada algoritama na testnim sekvencama, jeste da predloženi algoritam *RKF* sa podesivim Δ pokazuje robusnost na okluzije u različitim scenarijima okluzija. Takođe, iako performanse predloženog algoritma nisu najbolje u poređenju sa drugim savremenim metodama za konkretnu sekvencu, *RKF* sa podesivim Δ ipak u obe testirane situacije daje dobar rezultat praćenja. Za razliku od toga, za sekvencu 1 metode zasnovane na dubokom učenju ne prate dinamiku kretanja mete dobro, a za sekvencu 2 korelacioni filter ne daje dobre rezultate.

6.6 ADAPTIVNI ROBUSNI KALMANOV FILTAR SA PROMENLJIVIM PARAMETRIMA


U ovoj sekciji je ispitan rad adaptivnog robusnog Kalmanovog filtra (*ARKF*) na različitim sekvencama. Cilj je da se ispita rad i ponašanje *ARKF* u poređenju sa *SKF*, *RKF* sa promenljivim parametrima, kao i da se ispita ponašanje *ARKF* kada statistike šuma nisu unapred poznate, odnosno na sekvencama dobijenim sa različitim kamerama, i različitim scenama. Najpre je prikazana uporedna performansa rada *SKF*, *RKF* i *ARKF* koja je prikazana na slici 67.

Predstavljen je deo sekvence sa okluzijom gde je standardni Kalmanov filter zadržao praćenje objekta, iako sa velikom greškom u nekim delovima, dok *RKF* sa promenljivim Δ , kao i *ARKF* imaju znatno manju grešku. Takođe, vidi se i prednost *ARKF* u odnosu na *RKF* i to na način da *ARKF* u nekim delovima ipak ima manji porast vrednosti greške nego *RKF*.

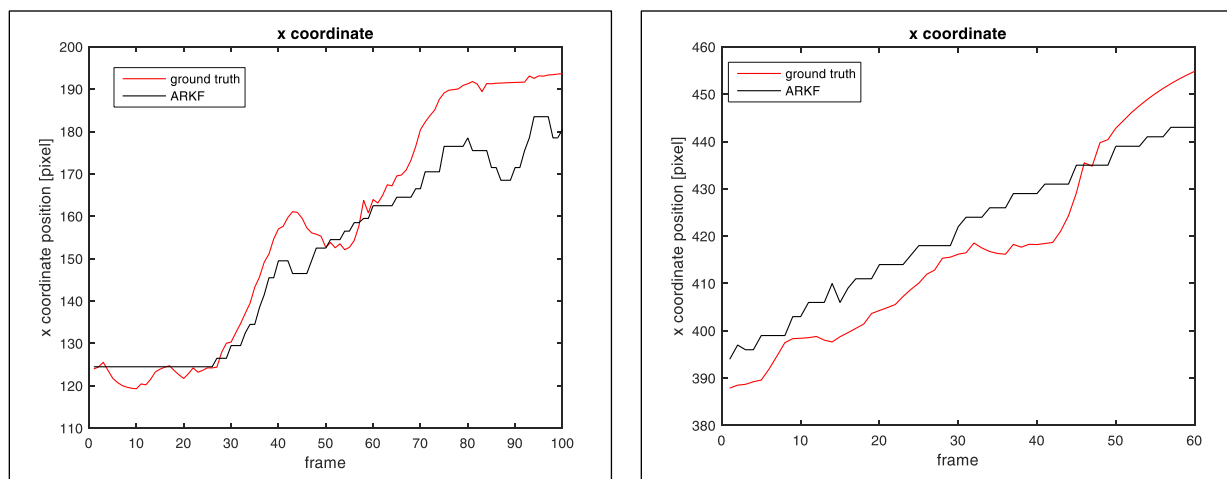


67. Slika – Uporedna greška za SKF, RKF sa promenljivim Δ i ARKF, koordinata x

Kako bismo ispitali ponašanje ARKF u situacijama za koje nemamo „*apriori*“ određene statistike šuma za Kalmanov filter, koristićemo dve sekvence snimane različitim kamerama, koje imaju i različite rezolucije. Na slici 68 su prikazani frejmovi iz ispitivanih sekvenci 1 i 2, koje su dobijene sa različitih kamera. Prva adaptivna sekvenca 1 je rezolucije 263x210, dok adaptivna sekvenca 2 ima rezoluciju 640x480. Cilj je ispitati uspešnost praćenja korišćenjem ARKF u slučaju potpuno novih sekvenci, kada statistike šuma nisu unapred poznate, a to je, kao što je poznato, veliki problem za standardni Kalmanov filter.



68. Slika – Sekvence snimane različitim kamerama za potrebe ispitivanja rada ARKF: (a) adaptivna sekvenca 1, (b) adaptivna sekvenca 2




69. Slika – Prikaz rada ARKF: (levo) ground truth i ARKF pozicija za adaptivnu sekvencu 1, (desno) ground truth i ARKF pozicija za adaptivnu sekvencu 2, koordinata x

Na graficima na slici 69 su prikazani rezultati rada ARKF na adaptivnim sekvencama 1 i 2 za koordinatu x . Sa grafika levo se vidi da je praćenje održano u slučaju korišćenja ARKF koji sadrži adaptivno podešavanje šuma, kao i adaptivno podešavanje robusne konstante Δ . Kao što se i može primetiti sa grafika desno, ARKF za sekvencu 2 gde takođe nisu unapred određene statistike šuma uspešno prati metu, što znači da su statistike šuma merenja i procesa potrebne za i ovaj slučaj pravilno izračunate. Dakle, za slučajeve kada statistike šuma nisu unapred poznate ARKF se pokazao uspešnim u praćenju objekta od interesa, što smo i hteli da postignemo.

U sekciji 6.5.1 je izvršeno poređenje rada RKF sa promenljivim Δ i savremenih trekera. Zbog toga bi bilo interesantno videti i uporedni prikaz rada ARKF i drugih trekera na jednoj evaluacionoj sekvenci. Za taj prikaz je odabrana evaluaciona sekvencu 2 prikazana na slici 64. Grafik na slici 70 daje uporedni prikaz „ground truth“ pozicija, kao i pozicija estimiranih sa RKF sa promenljivim Δ , ARKF, *DSiam*, *MLSSNet* i *HSSNet* trekera.

Sa grafika 70 se može videti da ARKF, u slučajevima kada se dogodi skok greške RKF sa promenljivim Δ , ima bolje performanse od RKF. To je posledica prilagođavanja vrednosti šuma stanja i merenja na osnovu trenutne situacije.



70. Slika – Paralelna reprezentacija pozicije ground truth, RKF sa promenljivim Δ , ARKF, Dsiam, MLSSNet, HssNet za evaluacionu sekvencu 2

6.7 PROCENA KONTAMINACIJE PODATAKA AUTLAJERIMA

Za potrebe ispitivanja procene kontaminacije autlajerima u podacima napravljena je baza podataka koja se sastoji od par veštački generisanih sekvenci sa unapred poznatim faktorom kontaminacije. Ono što je važno naglasiti jeste da je maksimalni procenat autlajera koji se može javiti u podacima 10%. Sve vrednosti preko 10% kontaminacije se smatraju za sistemske greške. Međutim, u slučaju veštačkog skupa, a radi procene tačnosti odabrane metode za procenu kontaminacije je korišćena vrednost 10% i 15%.

Veštački skupovi podataka se formiraju tako da sadrže pozicije centra objekta od interesa i to na način da se formira skup pozicija gde se kretanje vrši po obe ose. Za takav vid kretanja je formiran skup pozicija bez autlajera u podacima, sa 10% autlajera i sa 15% autlajera u podacima. Nakon toga su izvršena računanja prosečne kontaminacije autlajerima na celom skupu podataka, a radi lakšeg prikaza su rezultati tabelarno predstavljeni u Tabeli 12.

12. Tabela – Procena srednje vrednosti estimirane kontaminacije autlajerima, koordinata x

	ϵ_{est} mean, $n=25$	ϵ_{est} mean, $n=20$	ϵ_{est} mean, $n=10$
1.1. x, y motion, 0% contamination	0 %	0 %	0 %
1.2. x, y motion, 10% contamination	15 %	15 %	21 %
1.3. x, y motion, 15% contamination	22 %	24 %	27 %

Sledeći korak jeste proračun kontaminacije autlajerima za iste podatke, gde su data zašumljena merenja pozicije, i to belim Gausovim šumom sa [Matlab funkcija awgn, sa SNR = 40dB]. Rezultati su tabelarno prikazani u Tabeli 13.

13. Tabela – Procena srednje vrednosti estimirane kontaminacije autlajerima, zašumljena merenja, koordinata x

	$\epsilon_{est} \text{ mean, } n=25$	$\epsilon_{est} \text{ mean, } n=20$	$\epsilon_{est} \text{ mean, } n=10$
1.4. x, y motion, 0% contamination	0.12 %	0.08 %	0.09 %
1.5. x, y motion, 10% contamination	16 %	22 %	21 %
1.6. x, y motion, 15% contamination	23 %	24 %	27 %


Na osnovu rezultata dobijenih testiranjem veštačkog skupa podataka može se zaključiti da procena faktora kontaminacije autlajerima u velikoj meri odgovara stvarnim podacima. Naravno, u zavisnosti od vrednosti samih autlajera se menja težinski faktor robusne funkcije koji figuriše u formuli za proračun, pa samim tim veća vrednost autlajera (a ne samo veći broj odbiraka koji su autlajeri) dovodi do povećanja faktora kontaminacije i obrnuto. Kada nema kontaminacije autlajerima, vrednost faktora kontaminacije je, u slučaju kada nema dodavanja šuma, jednaka nuli, dok je u slučaju dodavanja šuma oko 1%. Sa druge strane, može se primetiti da tačnost procene raste povećanjem faktora n , koji figuriše u formuli za proračun kontaminacije. Ovom početnom analizom je potvrđena tačnost predloženog načina procene faktora kontaminacije.

Sledeći korak je testiranje na skupovima stvarnih podataka koji su korišćeni i za testiranje predloženih rešenja u ovoj disertaciji.


Najpre analiziramo skup podataka sa okluzijama, gde se okluzije javljaju oko frejma 100 i oko frejma 300. Na grafiku 71 su prikazane vrednosti greške pozicije i procene faktora kontaminacije ϵ za koordinatu x .

Kao što se sa grafika i može videti, u delovima gde dolazi do blagog porasta greške pozicije se i procenjena vrednost faktora kontaminacije povećava na oko $\epsilon = 8.5\%$ u slučaju prve okluzije, i $\epsilon = 9.3\%$ u slučaju druge okluzije. Okluzije su u ovom slučaju bile kratkotrajne parcijalne okluzije, što se i ogleda u rezultatima procenjenog faktora kontaminacije.

Rezultati procene faktora kontaminacije ϵ na evaluacionim sekvencama 1 i 2, na kojima je testiran robusni Kalmanov filter sa promenljivim parametrima iz sekcije 6.5.1 su prikazani na slici 72. Zanimljivo je videti i razliku koja se pravi u proceni faktora kontaminacije, između dva različita tipa okluzija, koja su predstavljena evaluacionim sekvencama 1 i 2.



71. Slika – Uporedni prikaz: (slika gore) greške pozicije i (slika dole) procene faktora kontaminacije ε , koordinata x , sekvenca sa okluzijama



72. Slika – Uporedni prikaz procene ε : (slika levo) evaluaciona sekvenca 1 i (slika desno) evaluaciona sekvenca 2, koordinata x

U sekciji 6.5.1 na slikama 63 i 64 su prikazani frejmovi iz evaluacionih sekvenci, respektivno. Kao što je već rečeno, oko frejma 50 i 140, u evaluacionoj sekvenci 1 se javljaju okluzije. Pojavu okluzija prati i povećanje vrednosti procene faktora kontaminacije autlajerima, kao što se i može videti sa grafika na slici 72 levo. Okluzije na ovoj sekvenci su dugotrajne potpune okluzije, što se i ogleda u proceni faktora kontaminacije, koji ima visoku vrednost. Sa druge strane, na evaluacionoj sekvenci 2 se okluzije javljaju oko frejma 450 i predstavljaju parcijalne okluzije kraćeg trajanja. I ta činjenica se ogleda u rezultatima procene faktora kontaminacije ϵ , i to nižim vrednostima procene faktora kontaminacije. Na osnovu ove analize se može zaključiti da odabrani način računanja procene trenutne kontaminacije autlajerima daje veoma dobre rezultate te procene. Samim tim, je i procena parametra Huber-ove funkcije uticaja adekvatna u slučaju promenljivih uslova na sceni.

Trenutni način računanja faktora kontaminacije podrazumeva proračun na bazi prozora od prethodnih n odbiraka. Na taj način ovaj faktor određuje tačnost procene faktora kontaminacije ϵ . Naravno, iz priloženih podataka se može videti da, što je veći uzorak na kojem se procenjuje tačnost procene, raste i tačnost procene. Sa druge strane, porastom veličine prozora u kojem se računa kontaminacija dolazi do smanjenja sposobnosti sistema da reaguje brzo na promene u podacima. Međutim, postoji jednostavna tehnika pomoću koje se ovaj problem može rešiti, a to je uvođenje faktora zaboravljanja [87]. Uvođenjem adaptivnog faktora zaboravljanja je moguće postići vrednost parametra koja se prilagođava datoj situaciji na sceni.


6.7.1 Adaptivni faktor zaboravljanja

Testiraćemo najpre odabrani metod sa adaptivnim faktorom zaboravljanja na veštački generisanoj sekvenci.

14. Tabela – Procena srednje vrednosti estimirane kontaminacije autlajerima sa adaptivnim faktorom zaboravljanja, koordinata x

	$\epsilon_{est\ mean} - no\ no\ added\ noise$	$\epsilon_{est\ mean},$
1.7. x, y motion, 0% contamination	0 %	0 %
1.8. x, y motion, 10% contamination	11 %	12 %
1.9. x, y motion, 15% contamination	15 %	15 %


Na primeru veštački generisane sekvence, koja je zašumljena i ima 15% kontaminacije autlajerima je prikazano na koji način adaptivni faktor zaboravljanja prati promenu situacije na sceni, zajedno sa procenom faktora kontaminacije (slika 73).



73. Slika – Uporedni prikaz: (slika gore) stvarna pozicija, (slika sredina) estimacija ε , (slika dole) adaptivni Ff, veštačka zašumljena sekvenca sa kontaminacijom 15%, koordinata x


Na datom grafiku se može videti da adaptivni faktor kontaminacije prati situaciju koja se događa, odnosno, vrednost opada u slučaju kada dođe do pojave autlajera u podacima. Sa druge strane, i tabela 14 pokazuje da je procena kontaminacije sada preciznija, nego u slučaju da nije korišćen adaptivni faktor zaboravljanja.

Sledeća situacija predstavlja test na sekvenci sa okluzijama, gde je na Slici 74 prikazana greška u odnosu na stvarnu poziciju, kao i procena kontaminacije autlajerima i promena faktora zaboravljanja.



74. Slika – Uporedni prikaz: (slika gore) stvarna pozicija, (slika sredina) estimacija ε , (slika dole) adaptivni F_f , sekvenca sa okluzijama, koordinata x

Na grafiku se može videti da procena faktora kontaminacije autlajerima prati blage poraste greške usled okluzija. Takođe, i vrednost faktora zaboravljanja se menja u zavisnosti od situacije na sceni. Još jedan zanimljiv primer jeste poređenje rada RKF sa podesivim Δ i RKF sa podesivim Δ i adaptivnim F_f , što je i prikazano na slici 75, i to za slučaj evaluacione sekvence 1 (prikazane na Slici 63).



75. Slika – Uporedni prikaz: stvarne pozicije, RKF sa podesivim Δ i F_f i RKF sa podesivim Δ , evaluaciona sekvenca 1, koordinata x

Upoređivanjem rada RKF sa podesivim Δ i F_f i RKF sa podesivim Δ se može doći do zaključka da RKF sa podesivim Δ i F_f ipak pravi manju grešku prilikom praćenja, što je u velikoj meri i posledica usrednjavanja vrednosti faktora kontaminacije korišćenjem adaptivnog faktora zaboravljanja.

7. ZAKLJUČAK

Praćenje objekata na slici predstavlja aktuelan problem današnjice, uz razne izazove koji se nameću kao posledica promene situacije na posmatranoj sceni. U termalnom domenu se izazovi praćenja dodatno usložnjavaju zbog same prirode termalne slike. Potrebe za sistemima za praćenje su velike, od sistema za nadzor u vojnim primenama, tako i u sve većem broju civilnih primena (nadzor granica, obala, objekata od interesa, itd.). Zato i postoji potreba za razvojem i praktičnom implementacijom algoritama za praćenje. Analizom dostupne literature je uočeno da postojeće tehnike praćenja pokretnih ciljeva i dalje ne obezbeđuju zadovoljavajuće performanse. Takođe je uočeno da ne postoji baza podataka koja bi se mogla iskoristiti za detaljnu statističku analizu rada algoritma za praćenje. Baš zbog toga je i tema ove disertacije poboljšanje načina za dizajn sistema za praćenje, koji se baziraju na povećanju robusnosti i adaptivnosti sistema, i to uvođenjem faktora koji se prilagođavaju nekim uslovima scene.

Istraživanja sprovedena u prvoj fazi rada na ovoj doktorskoj disertaciji, koja se bavi analizom dostupne literature, kao i prednosti i nedostataka javno dostupnih i opisanih metoda za praćenje, su dovela do formiranja osnovnog koncepta dizajna sistema za praćenje. U ovoj disertaciji je opisan problem praćenja pokretnog objekta na termalnoj slici uz pomoć SURF deskriptora i Kalmanovog filtra. Iako se SURF deskriptor opisuje kao metoda koja je dobra za problem praćenja u termalnom domenu, što je i eksperimentalno ispitano u okviru disertacije, ipak se često dešava da ni jedna odlika nije pronađena na slici, ili se dogodi pogrešno prepoznavanje, u slučaju nekih situacija u kojima je prepoznavanje i uparivanje odlika otežano. Zbog toga se koristi Kalmanov filter, koji vrši predikciju, kako bi se praćenje nastavilo i kada SURF algoritam daje pogrešnu procenu pozicije. Međutim, standardni Kalmanov filter se može koristiti samo kada je model dobro postavljen i u skladu sa specifičnim problemom kojim se bavimo. Dakle, kada u merenjima nema velikih odstupanja koji dovode do gubitka praćenja objekta od interesa, odnosno kada nema autlajera može se koristiti standardni Kalmanov filter. Međutim, kako u realnim situacijama to nije slučaj, SURF algoritam i standardni Kalmanov filter ipak nisu dovoljni za uspešno praćenje.

Zbog toga je neophodna detaljnija analiza šuma koji se javlja prilikom praćenja objekta SURF deskriptorom na termalnoj slici. Preduslov za vršenje takve analize jeste formiranje nove baze podataka koja ima jasno definisane kriterijume za formiranje, a koji podrazumevaju dovoljnu dužinu trajanja sekvence, dovoljan broj različitih režima kretanja i situacija koje su izazovne u domenu praćenja objekata, kao i da sve situacije budu snimljene pod istim uslovima. Jedino sa takvom bazom podataka se može na pravi način vršiti statistička analiza podataka. Formiranjem greške praćenja SURF algoritma se može pristupiti detaljnoj analizi podataka, radi dobijanja informacija koje će se kasnije koristiti u robustifikaciji i adaptaciji sistema za praćenje.

Analizom greške odabranog SURF algoritma se došlo do zaključaka koji su najčešći uzroci greške i koje su njihove posledice. Okluzije koje se javljaju u podacima dovode do prestanka rada sistema za praćenje, dok promena režima kretanja, odnosno manevra dovodi do povećanja

varijanse greške, ali ne i do prestanka praćenja. Pitanje koje se nameće jeste kako je moguće razdvojiti ova dva tipa greške.

Rezultati dobijeni statističkom analizom govore da u podacima ima autlajera koji kontaminiraju nominalnu raspodelu, pa da samim tim ni šum merenja u posmatranom slučaju, nije Gausove raspodele. Zbog toga se, u daljem razmatranju, pretpostavlja najčešći slučaj, a to je da je šum merenja Gausovski raspodeljen u centralnom delu, dok autlajeri predstavljaju takozvane zadebljale ili otežale repove koji se mogu predstaviti nekom drugom funkcijom raspodele. Dakle, zaključeno je da podaci u sebi sadrže uvek i neki stepen kontaminacije autlajerima ε . Ti autlajeri imaju drugačiju raspodelu od pretpostavljene raspodele šuma. Ostatak podataka, njih $(1 - \varepsilon)\%$ ima normalnu raspodelu.

Robusni pristup dizajnu algoritma za praćenje se zasniva na rešenju koje je manje osetljivo na autlajere u podacima od standardnih metoda, a ima mogućnost automatskog se prilagođavanja uslovima scene. Novi dizajn se bazira na uvođenju nelinearne funkcije uticaja koja se primenjuje na rezidual merenja u koraku estimacije Kalmanovog filtra. Jedan od načina da se dizajnira rešenje koje se može prilagođavati uslovima scene jeste promena funkcije uticaja u zavisnosti od toga kakav tip kretanja je u pitanju. Ovaj način podrazumeva formiranje ekspertskeg sistema koji prepoznaje različite tipove kretanja, pa na osnovu toga, donosi odluku o tome koja funkcija uticaja se koristi. Na ovaj način se postiže prilagođenje uslovima scene, ali se nivo robusnosti ne menja. Drugi način, koji ima mogućnost postizanja balansa između robusnosti i efikasnosti, na način da se poveća robusnost prilikom pojave autlajera, a smanji kada ih nema, postiže još bolje performanse. Značajna informacija, koja je i osnova ideje o konceptu robusnog dizajna, je dobijena statističkom analizom greške algoritma za praćenje, jer je uočeno da se procenom kontaminacije autlajera na sceni može i regulisati nivo robusnosti estimatora. Ova informacija je dala polaznu osnovu za dizajn sistema koji ima sposobnost automatskog prilagođavanja situacijama scene, a na osnovu procene stepena kontaminacije autlajerima. Novi dizajn, formiran korišćenjem ove informacije, se zasniva na uvođenju nelinearne Huber-ove funkcije uticaja koja se primenjuje na rezidual merenja u koraku estimacije Kalmanovog filtra. Stepen robustifikacije, određen konstantom u korišćenoj Huber-ovoj funkciji uticaja, može da se podesi u zavisnosti od pretpostavljene kontaminacije autlajerima. Međutim niti je stepen kontaminacije „*apriori*“ poznat, niti je isti tokom vremena. Zbog toga se sistem projektuje tako da, na osnovu analize pristiglih podataka, vrši proračun ovog parametra. Na taj način, korišćenjem već postojećih metoda robustifikacije, a uz pomoć statističke analize podataka, dat je predlog novog sofisticiranog sistema za praćenje koji se adaptira na procenjeni stepen kontaminacije autlajerima. Pokazano je da sistem uspešno održava praćenje objekta od interesa tamo gde SURF algoritam to nije mogao da uradi, dok predloženo rešenje pokazuje značajno manju grešku u odnosu na standardni Kalmanov filter, kao i u odnosu na robusni Kalmanov filter sa fiksnim parametrom Δ . Novi sistem predstavlja odličnu polaznu osnovu za dalje usavršavanje sistema za praćenje na termalnoj slici, jer u većini slučajeva, otklanja probleme pojave autlajera tokom pojave okluzija na slici. To je naravno u slučaju da okluzije ne traju preterano dugo, jer ukoliko su okluzije duge, praćenje svakako prestaje jer objekta i njegovih odlika dugo nema na sceni, pa algoritam nema šta da prati. Međutim, i promene dinamike kretanja, odnosno manevri objekta od interesa unose porast varijanse greške sistema za praćenje. Kao sledeći korak se nameće rešenje koje se adaptivno prilagođava tim promenama dinamike kretanja na sceni. Jedan od načina je prikazan u ovoj disertaciji, ali se mogu koristiti razni drugi tipovi adaptivnih filtera poput [103] , [104]. Još jedan od doprinosa ove disertacije se odnosi na procenu kontaminacije autlajerima i uvođenje adaptivnog

faktora zaboravljanja u proračun kontaminacije. Na taj način se postiže rešenje koje adaptivno menja faktor zaboravljanja prilikom procene kontaminacije i daje njenu precizniju procenu. Dalja rešenja se svakako mogu razmatrati u vidu korišćenja nekog drugog algoritma za praćenje mete, koji se na isti način može robustifikovati i prilagoditi postojećoj kontaminaciji autlajerima.

LITERATURA

- [1] M. Felsberg, „The thermal infrared visual object tracking VOT-TIR2015 challenge results,“ u: *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 2015.
- [2] M. Felsberg et al. (2016) , „The Thermal Infrared Visual Object Tracking VOT-TIR2016 Challenge Results. u: Hua G., Jégou H. (eds),“ u *Computer Vision – ECCV 2016 Workshops. ECCV 2016. Lecture Notes in Computer Science*, Springer, 2016, p. vol 9914..
- [3] N. Vlahović i S. Graovac, „Sensibility analysis of the object tracking algorithms in thermal image,“ *Scientific Technical Review*, t. 67, br. 1, 2017.
- [4] K. Jungling i M. Arens, „Feature based person detection beyond the visible spectrum,“ u *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, 2009.
- [5] H. Shuo, W. Na i S. Huajun, „Object tracking method based on surf,“ u: *AASRI Procedia*, t. 3, pp. 351-356, 2012.
- [6] A. Berg, J. Ahlberg i M. Felsberg, „A Thermal Object Tracking Benchmark,“ u: *Advanced Video and Signal Based Surveillance (AVSS), 12th IEEE International Conference*, 2015.
- [7] „https://www.miniphysics.com/electromagnetic-spectrum_25.html,“ [Na mreži].
- [8] „<http://jeanbont.pbworks.com/w/page/37624610/Infrared%20Spectroscopy>,“ [Na mreži].
- [9] I. FLIR Systems, „What’s The Difference between Thermal Imaging and Night Vision,“ 2019. [Na mreži]. Available: <https://www.flir.com/discover/ots/thermal-vs-night-vision/>.
- [10] N. Vlahović, Ž. Barbarić, L. Tomić i P. Tomić, „Analiza šuma na termalnoj slici scene,“ u *Zbornik 61. Konferencije za elektroniku, telekomunikacije, računarstvo, automatiku i nuklearnu tehniku ETRAN 2017*, Kladovo, Srbija, 2017.
- [11] B. Samuel i P. Robert , *Design and Analysis of Modern Tracking Systems*, Norwood, USA: Artech House, 1999.
- [12] G. C. Holst, „Common sense approach to thermal imaging,“ u *SPIE Optical Engineering Press, Vol. 1*, Washington, DC, USA, 2000.

-
- [13] F. Systems, „Thermal Imaging: How far can you see with it?“, 2018. [Na mreži]. Available: https://www.flirmedia.com/MMC/CVS/Tech_Notes/TN_0002_EN.pdf. [Poslednji pristup 2018].
- [14] T. Sjaardema, S. Collin i G. Birch, „History and evolution of the Johnson criteria“, SANDIA Report, 2015.
- [15] R. Pavlović, N. Vlahović i V. Petrović, „Comparative analysis of feature descriptor algorithms in multisensors systems“, u *Proceedings of Papers – 5th International Conference on Electrical, Electronic and Computer Engineering IcETRAN*, Palić, Serbia, 2018.
- [16] FLIR, „<https://www.flir.com/oem/adas/adas-dataset-form/>“, FLIR, 2020. [Na mreži].
- [17] Q. Liu, X. Li, Z. He, C. Li, J. Li, Z. Zhou i F. Zheng, „LSOTB-TIR: A Large-Scale High-Diversity Thermal Infrared Object Tracking Benchmark“, u: *arXiv preprint arXiv:2008.00836*, 2020.
- [18] M. Sonka, V. Hlavac i R. Boyle, *Image processing, analysis, and machine vision*, Cengage Learning, 2014.
- [19] E. Davies, *Computer and machine vision: theory, algorithms, practicalities*, Academic Press, 2012.
- [20] „Image Processing Learning Resources, Pixel Connectivity“, [Na mreži]. Available: <https://homepages.inf.ed.ac.uk/rbf/HIPR2/connect.htm>.
- [21] M. Nachtegaele, D. Van der Weken, D. Van De Ville i E. Kerre, *Fuzzy filters for image processing*, Springer, 2013.
- [22] U. Erkan i L. Gökrem, „A new method based on pixel density in salt and pepper noise removal“, u: *Turkish Journal of Electrical Engineering & Computer Sciences*, t. 26, br. 1, pp. 162-171, 2018.
- [23] N. Vlahović, M. Stojanović, L. Tomić, K. Mišković, B. Stojanović i A. Kovačević, „Thermal Image Noise Reduction Post-Processing Techniques“, u *8th International Conference on Defensive Technologies OTEH 2018*, Belgrade, SERbia, 2018.
- [24] S. Krig, *Computer vision metrics: Survey, taxonomy, and analysis*, Springer Nature, 2014.
- [25] F. Jabar, S. Farokhi i U. Sheikh, „Object tracking using SIFT and KLT tracker for UAV-based applications“, u: *IEEE International Symposium on Robotics and Intelligent Sensors (IRIS)*, 2015.
- [26] H. Zhou, Y. Yuan i C. Shi, „Object tracking using SIFT features and mean shift“, u: *Computer vision and image understanding*, t. 113, br. 3, pp. 345-352, 2009.

-
- [27] Y. Hongpeng, P. Chao, C. Yi i F. Qu, „A robust object tracking algorithm based on surf and kalman filter,“ u: *Intelligent Automation & Soft Computing*, t. 19(4), pp. 567-579, 2013.
- [28] S. Xu i A. Chang, „Robust object tracking using Kalman filters with dynamic covariance,“ Cornell University, 2014.
- [29] D. Hu i J. Nan, „Research on target tracking based on improved SURF algorithm and Kalman prediction,“ u: *First International Workshop on Pattern Recognition, International Society for Optics and Photonics*, 2016.
- [30] D. Ta, W. Chen, N. Gelfand i K. Pulli, „Surfrac: Efficient tracking and continuous object recognition using local feature descriptors,“ u: *IEEE Conference on Computer Vision and Pattern Recognition*, 2009.
- [31] X. Zheng, S. Cui, G. Wang i J. Li, „Video Stabilization System Based on Speeded-up Robust Features,“ u: *International Industrial Informatics and Computer Engineering Conference*, Atlantis Press, 2015.
- [32] M. Pavlović, B. Stojanović, N. Vlahović i S. Stanković, „Comparison of feature descriptors for visible and thermal face recognition,“ u: *18th International Symposium Infoteh-Jahorina (Infoteh) IEEE*, Jahorina, Bosnia and Herzegovina, 2019.
- [33] A. Alahi, R. Ortiz i P. Vandergheynst, „Freak: Fast retina keypoint,“ u: *IEEE Conference on Computer Vision and Pattern Recognition*, 2012.
- [34] R. Kimmel, C. Zhang, A. Bronstein i M. Bronstein, „Are MSER features really interesting,“ u: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, t. 33, br. 11, pp. 2316-2320, 2011.
- [35] H. Bay, T. Tuytelaars i L. V. Gool, „SURF: Speeded Up Robust Features,“ u: *Computer Vision and Image Understanding*, 2008.
- [36] C. Subhash, R. M. Mark, M. Darko i J. E. Robin, *Fundamentals of Object Tracking*, Cambridge, UK: Cambridge University Press, 2011.
- [37] M. Kristian, „The visual object tracking vot2017 challenge results,“ u: *Proceedings of the IEEE International Conference on Computer Vision. 2017*, 2017.
- [38] M. Kristan, „The sixth visual object tracking vot2018 challenge results,“ u: *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018.
- [39] M. Kristan i et al., „The seventh visual object tracking vot2019 challenge results,“ u: *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*, 2019.

-
- [40] R. Gade i T. B. Moeslund, „Thermal Cameras and Applications: A Survey,“ u: *Machine Vision and Applications*, t. 25(1), pp. 245-262, 2014.
- [41] N. Vlahović, M. Stojanović, M. Stanković i S. Stanković, „Adaptive Video Stabilization using Kalman filtering,“ u *5th International Conference on Electrical, Electronic and Computing Engineering, IcETRAN 2018*, Palić, Serbia, 2018.
- [42] N. Vlahović, N. Ilić i S. Stanković, „Deep Learning in Video Stabilization Homography Estimation,“ u *14th Symposium on Neural Networks and Applications (NEUREL)*, Belgrade, Serbia, 2018.
- [43] A. C. Bovik, *Handbook of image and video processing*, Academic press, 2010.
- [44] J. F. Henriques, R. Caseiro, P. Martins i J. Batista, „High-speed tracking with kernelized correlation filters,“ u: *IEEE transactions on pattern analysis and machine intelligence*, t. 37(3), pp. 583-596, 2014.
- [45] J. Suhr, „Kanade-lucas-tomasi (klt) feature tracker,“ u: *Computer Vision (EEE6503)*, 2009.
- [46] A. Chauhan i P. Krishan, „Moving object tracking using gaussian mixture model and optical flow,“ u: *International Journal of Advanced Research in Computer Science and Software Engineering*, t. 3, br. 4, 2013.
- [47] Q. Liu, X. Lu, Z. He, C. Zhang i W. Chen, „Deep convolutional neural networks for thermal infrared object tracking,“ u: *Knowledge-Based Systems*, t. 134, pp. 189-198, 2017.
- [48] K. Lebeda, S. Hadfield i R. Bowden, „The Thermal Infrared Visual Object Tracking VOT-TIR2016 Challenge Results,“ 2016.
- [49] L. Bertinetto, J. Valmadre, J. Henriques, A. Vedaldi i P. Torr, „Fully-convolutional siamese networks for object tracking,“ u: *European conference on computer vision. Springer*, 2016.
- [50] Q. Guo, W. Feng, C. Zhou, R. Huang, L. Wan i S. Wang, „Learning dynamic siamese network for visual object tracking,“ u: *Proceedings of the IEEE international conference on computer vision*, pp. 1763-1771, 2017.
- [51] X. Li, Q. Liu, N. Fan, Z. He i H. Wang, „Hierarchical spatial-aware siamese network for thermal infrared object tracking,“ u: *Knowledge-Based Systems*, t. 166, pp. 71-81, 2019.
- [52] Q. Liu, X. Li, Z. He, N. Fan, D. Yuan i H. Wang, „Learning deep multi-level similarity for thermal infrared object tracking,“ u: *arXiv preprint arXiv:1906.03568*, 2019.
- [53] M. Stojanović, N. Vlahović, M. Stanković i S. Stanković, „Object tracking in thermal imaging using kernelized correlation filters,“ u *17th International Symposium Infoteh-Jahorina (Infoteh)*, Jahorina, 2018.

-
- [54] M. Stojanović, N. Vlahović, M. Stanković i S. Stanković, „Deep Features in Correlation Filters for Thermal Image Tracking,“ u: *14th Symposium on Neural Networks and Applications (NEUREL)*, Belgrade, 2018.
- [55] M. Danelljan, G. Hager, F. Shahbaz Khan i M. Felsberg, „Learning spatially regularized correlation filters for visual tracking,“ u: *Proceedings of the IEEE international conference on computer vision*, 2015.
- [56] E. Gundogdu, A. Koc, B. Solmaz, R. Hammoud i A. Aydin, „Evaluation of feature channels for correlation-filter-based visual object tracking in infrared spectrum,“ u: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2016.
- [57] R. G. Driggers, M. H. Friedman i J. M. Nichols, *Introduction to Infrared and Electro-Optical Systems*, Artech House, 2012.
- [58] M. Vollmer i K.-P. Möllmann, *Infrared thermal imaging _ fundamentals, research and applications*, Second Edition ur., Weinheim, Germany, 2018.
- [59] E. Oyallon i J. Rabin, „An Analysis of the SURF Method,“ u: *Image Processing On Line*, t. 5, pp. 176-218, 2015.
- [60] T. Kadir i M. Brady, „Non-parametric estimation of probability distributions from sampled signals,“ Technical report, OUEL, 2005.
- [61] C. Karlgaard i H. Schaub, „Comparison of several nonlinear filters for a benchmark tracking problem,“ u: *AIAA Guidance, navigation, and control conference and exhibit*, 2006.
- [62] E. Parzen, „On estimation of a probability density function and mode,“ u: *The annals of mathematical statistics*, t. 33(3), pp. 1065-1076, 1962.
- [63] P. D. Hill, „Kernel estimation of a distribution function,“ u: *Communications in Statistics-Theory and Methods*, t. 14(3), pp. 605-620, 1985.
- [64] Z. Botev, J. Grotowski i D. Kroese, „Kernel density estimation via diffusion,“ u: *The annals of Statistics*, t. 38(5), pp. 2916-2957, 2010.
- [65] M. Sugiyama, T. Suzuki i T. Kanamori, *Density ratio estimation in machine learning*, Cambridge University Press, 2021.
- [66] K. Lee i E. N. Johnson, „Robust Outlier-Adaptive Filtering for Vision-Aided Inertial Navigation,“ u: *Sensors*, t. 20, br. 7, pp. 2007-2036, 2020.
- [67] S. Kay, *Fundamentals of statistical signal processing*, Prentice Hall PTR, 1993.

-
- [68] Ž. Đurović i B. Kovačević, „Robust Estimation with Unknown Noise Statistics,“ u: *IEEE Transactions On Automatic Control*, t. 44, br. 6, pp. 1292-1296, 1999.
- [69] N. Vlahović i Ž. Đurović, „Object Tracking in Thermal Images based on SURF and KLT features,“ u: *5th International Conference IcETran 2018*, Palić, 2018.
- [70] V. Barnett i T. Lewis, *Outliers in Statistical Data*, Belfast, UK: John Wiley and Sons Ltd, 1978.
- [71] P. J. Huber i E. M. Ronchetti, *Robust Statistics*, Second Edition, John Wiley & Sons, Inc., Hoboken, New Jersey, 2009.
- [72] J.-A. Ting, E. Theodorou i S. Schaal, „Learning an outlier-robust Kalman filter,“ u: *European Conference on Machine Learning*, Berlin, Heidelberg, 2007.
- [73] J. Ting, E. Theodorou i S. Schaal, „A Kalman filter for robust outlier detection,“ u: *International Conference on Intelligent Robots and Systems, IEEE*, San Diego, USA, 2007.
- [74] C. Mattos, Z. Dai, A. Damianou, G. Bareto i N. Lawrence, „Deep recurrent Gaussian processes for outlier-robust system identification,“ u: *Journal of Process Control*, t. 60, pp. 82-94, 2017.
- [75] R. Maronna, R. Douglas Martin i V. Yohai, *Robust Statistics: Theory and Methods*, John Wiley & Sons, Ltd., 2006.
- [76] P. J. Huber, „Robust Estimation of a Location Parameter,“ u: *The Annals of Mathematical Statistics*, pp. 73-101, 1964.
- [77] F. Hampel, E. Ronchetti, P. Rousseeuw i W. Stahel, *Robust Statistics: The Approach Based on Influence Functions*, Wiley, 1986.
- [78] L. Chang, B. Hu, G. Chang i A. Li, „Robust derivative-free Kalman filter based on Huber’s M-estimation,“ u: *Journal of Process Control*, pp. 155-1561, 2013.
- [79] M. Zorzi, „Robust Kalman filtering under model perturbations,“ u: *IEEE Transactions on Automatic Control*, t. 6, br. 62, pp. 2902-2907, 2016.
- [80] Z. Changliang, „Adaptive m-estimation for robust cubature kalman filtering,“ u: *Sensor Signal Processing for Defence (SSPD), IEEE*, pp. 1-5, 2016.
- [81] N. Vlahović i Ž. Đurović, „Robust Object Tracking based on SURF in Thermal Images,“ u: *6th International Conference IcETran 2019*, Srebrno Jezero, Serbia, 2019.
- [82] M. Hossain, „Whitening and Coloring Transforms for Multivariate Gaussian Random Variables,“ Project Rhea, 2016.

-
- [83] B. Kovačević, Ž. Đurović i S. Glavaški, „On robust Kalman filtering,“ u: *International Journal of Control*, t. 56:3 , pp. 547-562, 2007.
- [84] V. K. Pamula, S. R. Vempati i T. A. Kumar, „A Robust Technique For Multiuser Detection In The Presence Of Signature Uncertainties,“ u: *International Conference on Pervasive and Embedded Computing and Communication Systems PECCS*, 2012.
- [85] Y. Wang, X. Lin, M. Zhu i Z. Bai, „Robust estimation using the Huber function with a data-dependent tuning constant,“ u: *Journal of Computational and Graphical Statistics*, t. 16, br. 2, pp. 468-481, 2007.
- [86] R. Gilchrist i G. Portides, „Using GLIM4 to Estimate the Tuning Constant for Huber’s M-estimate of Location,“ u: *Proceedings in Computational Statistics 11th Symposium*, Vienna, Austria, 1994.
- [87] C. Karlgaard i H. Schaub, „Adaptive huber-based filtering using projection statistics: Application to spacecraft attitude estimation,“ u: *AIAA Guidance, Navigation and Control Conference and Exhibit*, 2008.
- [88] A. Vahidi, A. Stefanopoulou i H. Peng, „Recursive least squares with forgetting for online estimation of vehicle mass and road grade: theory and experiments,“ u: *Vehicle System Dynamics*, t. 43, br. 1, pp. 31-55, 2005.
- [89] E. C. Ifeachor i B. W. Jervis, *Digital signal processing: a practical approach*, USA: Prentice Hall, Pearson education Limited, 2002.
- [90] J. Cooper i K. Worden, „On-line physical parameter estimation with adaptive forgetting factors,“ u: *Mechanical Systems and Signal Processing*, t. 14, br. 5, pp. 705-730, 2000.
- [91] C. Paleologu, J. Benesty i S. Ciochina, „A robust variable forgetting factor recursive least-squares algorithm for system identification,“ u: *IEEE Signal Processing Letters*, t. 115, pp. 597-600, 2008.
- [92] S.-H. Leung i C. So, „Gradient-based variable forgetting factor RLS algorithm in time-varying environments,“ u: *IEEE Transactions on Signal Processing*, t. 53, br. 8, pp. 3141-3150, 2005.
- [93] M. Badoni, A. Singh i B. Singh, „Variable forgetting factor recursive least square control algorithm for DSTATCOM,“ u: *IEEE Transactions on Power Delivery*, t. 30, br. 5, pp. 2353-2361, 2015.
- [94] A. Bruce, A. Goel i D. S. Bernstein, „Recursive Least Squares with Matrix Forgetting,“ u: *2020 American Control Conference (ACC). IEEE*, 2020.

-
- [95] L. Lu, H. Zhao i B. Chen, „Improved-variable-forgetting-factor recursive algorithm based on the logarithmic cost for Volterra system identification,“ u: *IEEE Transactions on Circuits and Systems II: Express Briefs*, t. 63, br. 6, pp. 588-592, 2016.
- [96] Z. Lao, B. Xia, W. Wang, W. Sun, Y. Lai i M. Wang, „A novel method for lithium-ion battery online parameter identification based on variable forgetting factor recursive least squares,“ u: *Energies*, t. 11, br. 6, p. 1358, 2018.
- [97] Y. Liao, D. Tingpeng i J. Quanquan , „Model-free adaptive control method with variable forgetting factor for unmanned surface vehicle control,“ u: *Applied Ocean Research*, t. 93, 2019.
- [98] C. Tomasi i T. Detection Kanade, „Tracking of point features,“ u: *Int. J. Comput. Vis.*, pp. 137-154, 1991.
- [99] R. Pavlović i N. Vlahović, „Uav Tracking On Fused Thermal And Color Image,“ u *8th International Scientific Conference on Defensive Technologies OTEH 2018* , Belgrade, Serbia, 2018.
- [100] K. Ying-Che, T. Cheng-Tao i C. Chih-Hao, „Fast Estimation of Pedestrian Movement,“ u: *Sensors and Materials* 29.6 (2017): 713-726., t. 29(6), pp. 713-726, 2017.
- [101] M. S. Youssef, A. H. Meer i F. F. Arige , „Detection and tracking of multiple moving objects with occlusion in smart video surveillance systems,“ u *5th IEEE International conference intelligent systems*, 2010.
- [102] N. Vlahović i Z. Djurovic, „Robust tracking of moving objects using thermal camera and speeded up robust features descriptor,“ u: *International Journal of Adaptive Control and Signal Processing*, t. 35, br. 4, pp. 549-566, 2021.
- [103] Y. Yang i T. Xu, „An adaptive Kalman filter based on Sage windowing weights and variance components,“ u: *The Journal of Navigation* , t. 56, br. 2, pp. 231-240, 2003.
- [104] Y. Yang, *Adaptively robust kalman filters with applications in navigation*, Sciences of Geodesy-I, Berlin, Heidelberg: Springer, 2010, pp. 49-82.

BIOGRAFIJA

Kandidat Nataša (devojačko prezime Kljajić) Vlahović je rođena 09.06.1987. godine u Beogradu, Republika Srbija. Osnovne studije je upisala na Elektrotehničkom fakultetu u Beogradu 2006. godine, a diplomirala 2010. godine nakon 8 semestara, na smeru Signali i sistemi sa ocenom 10 (deset). Prosek ocena u toku studija je bio 8,62. Diplomski rad pod nazivom: „Vizuelizacija sistema upravljanja pozicionim servo sistemom na platformi Simens Simatic PCS7” odbranila je na Elektrotehničkom fakultetu u Beogradu 2010. godine. Nakon osnovnih upisala je i master studije na Elektrotehničkom fakultetu u Beogradu, 2010. godine, a završila 2011. godine, na smeru Signali i sistemi. Prosek ocena na master studijama je bio 10. Master rad pod nazivom: „Optičko prepoznavanje karaktera bazirano na Hopfildovim neuralnim mrežama” odbranila je na Elektrotehničkom fakultetu u Beogradu 2011. godine. Posедуje zvanje diplomirani inženjer-master elektrotehnike i računarstva. 2015. godine upisuje doktorske akademske studije na Elektrotehničkom fakultetu na modulu Upravljanje sistemima i obrada signala.

Odmah po završetku master studija, započela je praksu u firmi Microsoft Development Center Serbia, gde je provela mesec dana na poziciji za labeliranje i akviziciju podataka. Zatim prelazi u firmu Termovent Komerc, kao inženjer automatike, i tamo ostaje do juna 2012. godine. Od juna 2012. godine do novembra 2017. godine radila je na Vojnoteničkom institutu (Ministarstvo Odbrane Republike Srbije - Uprava za Odbrambene Tehnologije). Za to vreme radi na poziciji istraživač – saradnik, a zatim i viši istraživač, u Sektoru za raketno naoružanje. Tokom rada u Vojnotehničkom institutu angažovana je i kao sekretar Naučnog veća, osim redovne pozicije istraživača u okviru laboratorije za vođenje i upravljanje. U novembru 2017. godine počinje sa radom u Vlatakom institutu, na poziciji sistem inženjera.

Oblast istraživanja Nataše Vlahović obuhvata upravljanje sistemima, obradu signala, digitalnu obradu slike. Autor je i koautor radova koji su publikovani u međunarodnim naučnim časopisima (1 rad), domaćim časopisima (4 rada), kao i radova saopštenih na međunarodnim konferencijama (16 radova) i domaćim konferencijama (1 rad).

Прилог 1.

Изјава о ауторству

Име и презиме аутора: Наташа Влаховић

Број индекса: 2015/5030

Изјављујем

да је докторска дисертација под насловом

Робусно праћење покретних објеката на термалној слици

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршила ауторска права и користила интелектуалну својину других лица.

У Београду, дана _____.

Потпис аутора



Прилог 2.

**Изјава о истоветности штампане и електронске верзије
докторског рада**

Име и презиме аутора: Наташа Влаховић
Број индекса: 2015/5030
Студијски програм: Електротехника и рачунарство
(модул Управљање системима и обрада сигнала)
Наслов рада: Робусно праћење покретних објеката на термалној слици
Ментор: проф. др Жељко Ђуровић

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предала ради похрањена у Дигиталном репозиторијуму Универзитета у Београду.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

У Београду, дана _____.

Потпис аутора

Vlahovića

Прилог 3.

Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

Робусно праћење покретних објеката на термалној слици

која је моје ауторско дело.

Дисертацију са свим прилозима предала сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучила.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
6. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци.

Кратак опис лиценци је саставни део ове изјаве).

У Београду, дана _____.

Потпис аутора

