

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA

Krešimir Romić

**DETEKCIJA STEPENICA I PJEŠAČKIH
PRIJELAZA MORFOLOŠKOM OBRADOM I
ANALIZOM SLIKE U SVRHU USMJERAVANJA
SLIJEPIH I SLABOVIDNIH OSOBA**

Doktorski rad

Osijek, 2018.

Doktorski rad izrađen je na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Mentor: Izv. prof. dr. sc. Irena Galić

Sumentor: Izv. prof. dr. sc. Krešimir Nenadić

Doktorski rad ima: 125 stranica.

Doktorski rad br.: 67

Povjerenstvo za ocjenu doktorske disertacije:

1. Dr.sc. Snježana Rimac-Drlje, redovita profesorica u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednica
2. Dr.sc. Irena Galić, izvanredna profesorica, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentorica
3. Dr.sc. Sonja Grgić, redovita profesorica u trajnom zvanju, Fakultet elektrotehnike i računarstva u Zagrebu, članica
4. Dr.sc. Krešimir Nenadić, izvanredni profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član
5. Dr.sc. Časlav Livada, docent, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član

Povjerenstvo za obranu doktorske disertacije:

1. Dr.sc. Snježana Rimac-Drlje, redovita profesorica u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, predsjednica
2. Dr.sc. Irena Galić, izvanredna profesorica, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, mentorica
3. Dr.sc. Sonja Grgić, redovita profesorica u trajnom zvanju, Fakultet elektrotehnike i računarstva u Zagrebu, članica
4. Dr.sc. Krešimir Nenadić, izvanredni profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član
5. Dr.sc. Časlav Livada, docent, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, član

Datum obrane doktorske disertacije: 11. prosinca 2018. g.

Zahvaljujem mentorici izv. prof. dr. sc. Ireni Galić koja me uvela u znanstveno-istraživačko područje računalne obrade slike i pomogla da zakoračim u svijet znanosti odlascima na brojne konferencije i pisanjem znanstvenih radova. Svojim znanjem, iskustvom i savjetima uvijek je bila spremna pomoći i uvelike je doprinijela izradi ovog doktorskog rada.

Zahvaljujem sumentoru i voditelju na poslijediplomskom studiju izv. prof. dr. sc. Krešimiru Nenadiću koji je uvijek bio na raspolaganju za savjete i pomoć tijekom poslijediplomskog studija. Hvala kolegi Hrvoju Leventiću s kojim sam dijelio ured, ali i sve probleme i radosti koje je pred nas donio poslijediplomski studij. Hvala i ostalim kolegama te prijateljima koji su mi primjerima iz svog iskustva i riječima ohrabrenja olakšali put do završetka ovog doktorskog rada.

Na kraju, najveća hvala mojim najdražima. Mojim roditeljima i sestri hvala na bezgraničnoj podršci i vjeri u mene, ne samo na poslijediplomskom studiju, već tijekom cijelog mog školovanja. Mojoj supruzi hvala na razumijevanju za sve moje duge ostanke na poslu te za bezuvjetnu podršku i motivaciju u dobrim i lošim trenucima studiranja na poslijediplomskom studiju. Moja radost potpuna je tek kada ju mogu podijeliti s vama.

SADRŽAJ

1. UVOD	1
2. SUSTAVI ZA POMOĆ SLIJEPIM I SLABOVIDNIM OSOBAMA. 4	
2.1. Problemi pri kretanju slijepih i slabovidnih osoba.....	4
2.2. Koncept sustava.....	5
2.3. Pristupi za razvoj pomoćnih sustava za slijepe i slabovidne	9
2.3.1. Metode obrade 2D slike	10
2.3.2. Metode obrade 3D slike	13
2.3.3. Ostale metode.....	14
3. MORFOLOŠKA OBRADA I ANALIZA SLIKE	15
3.1. Binarna slika.....	15
3.2. Osnovne morfološke operacije.....	18
3.3. Morfološka analiza slike	23
4. METODA ZA DETEKCIJU STEPENICA ZASNOVANA NA VERTIKALNOJ I HORIZONTALNOJ ANALIZI SLIKE	26
4.1. Predobrada.....	26
4.2. Vertikalna analiza.....	29
4.3. Horizontalna analiza.....	32
4.4. Eksperimentalni rezultati.....	35
4.4.1. Analiza odabira rezolucije	35
4.4.2. Uspješnost detekcije.....	40
4.4.3. Brzina izvođenja	46

5. MULTIREZOLUCIJSKA METODA ZA DETEKCIJU PJEŠAČKIH PRIJELAZA ZASNOVANA NA MORFOLOŠKOJ ANALIZI I ENERGIJI LINIJA	49
5.1. Multirezolucijski pristup	49
5.2. Predobrada	51
5.3. Morfološka analiza	54
5.4. Energija linija	59
5.5. Eksperimentalni rezultati.....	63
5.5.1. Uspješnost detekcije.....	63
5.5.2. Količina obrađenih piksela	68
5.5.3. Brzina izvođenja	69
6. METODA ZVUČNOG USMJERAVANJA SLIJEPIH I SLABOVIDNIH OSOBA ODREĐIVANJEM PROSTORA ZA SIGURNO KRETANJE	72
6.1. Lokalizacija na temelju rubnih točaka	72
6.2. Smjer kretanja.....	75
6.3. Usmjereni zvučni signali	79
6.4. Primjeri i brzina usmjeravanja	83
6.5. Korekcija odluke na temelju više uzastopnih slika.....	89
7. OKVIR ZA EVALUACIJU METODA USMJERAVANJA SLIJEPIH I SLABOVIDNIH OSOBA NA STEPENICAMA I PJEŠAČKIM PRIJELAZIMA.....	92
7.1. Testno okruženje	92
7.2. Baza slika i video isječaka.....	94

7.3. Ocjenjivanje točnosti odluka.....	95
8. ZAKLJUČAK.....	104
LITERATURA	107
POPIS SLIKA.....	114
POPIS TABLICA	118
SAŽETAK	119
ABSTRACT.....	120
ŽIVOTOPIS.....	121
PRILOZI	122
Prilog P.1. Značajke kamere s uređaja HTC One A9s.....	122
Prilog P.2. Značajke kamere SJCAM SJ4000.....	123
Prilog P.3. Značajke računala Lenovo V310-15ISK.....	124
Prilog P.4. Značajke računala Lenovo Ideacentre Stick 300-01IBY	125

1. UVOD

Prema navodima Svjetske zdravstvene organizacije (engl. *World Health Organization*) na svijetu živi 285 milijuna ljudi s nekom vrstom oštećenja vida dok je 39 milijuna od njih potpuno slijepo [1]. Ono što iznenađuje jest činjenica da se velika većina njih još ne koristi naprednim digitaliziranim sustavima za pomoć pri kretanju. Najrasprostranjenije je sredstvo za pomoć pri kretanju slijepih i slabovidnih bijeli štap [2], koji možda još dugo neće biti u potpunosti zamjenjiv, ali napredak tehnologije omogućuje značajni prostor za razvoj naprednijih automatiziranih sustava za navođenje i orijentaciju slijepih i slabovidnih. Ovo se odnosi na kretanje u poznatim, ali i nepoznatim okolinama, gdje se osobe susreću s raznim vrstama prepreka u slobodnom kretanju. Kako bi kretanje i percepcija okoline bili što jednostavniji, razvijaju se sustavi za detekciju najčešćih vrsta potencijalnih prepreka i ostalih objekata važnih za kretanje slijepih i slabovidnih osoba. Osim problematike detekcije prepreka i drugih objekata prilikom kretanja, važna je i problematika informiranja slijepe osobe o okolini i pronalaska odgovarajućeg načina usmjeravanja u pokretu.

U ovom radu dan je pregled istraživačkog područja i opisane su različite vrste spomenutih sustava s posebnim naglaskom na sustave koji koriste slike s kamere kao ulazne podatke te obradom tih slika u realnom vremenu daju potrebnu informaciju o detektiranom objektu i predloženom smjeru kretanja s obzirom na situaciju sa slike. Izložena je problematika koja se javlja pri razvoju takvog sustava te rješenja za moguće probleme pri izradi. Analizirani su i pristupi rješavanju spomenutih problema prema postojećim radovima u ovom znanstvenom području. Razvijene su nove metode primarno temeljene na računalnoj obradi slike kao glavnoj okosnici ovog rada. Predložene su nove metode za specifične probleme detekcije stepenica i pješačkih prijelaza temeljene na morfološkoj obradi i analizi binarne slike. Kao nastavak na metode za detekciju stepenica i pješačkih prijelaza razvijena je i metoda za zvučno navođenje slijepih osoba u pokretu primjenjiva na takve situacije. S obzirom na visoke zahtjeve pouzdanosti i performansi ovakvih sustava predložen je i okvir za evaluaciju metoda usmjeravanja slijepih i slabovidnih osoba na stepenicama i pješačkim prijelazima koji uključuje bazu video isječaka te postupak za usporedbu računalne i subjektivne odluke.

Primarni je cilj ovog rada razviti nove metode koje će potencijalno olakšati kretanje slijepim i slabovidnim osobama, a pritom otkloniti neke nedostatke postojećih metoda. Cilj je metode za detekciju stepenica izbjeći nedostatke postojećih metoda uzrokovane uzorcima ili oštećenjima na površini stepenica te djelomično zaklonjenim stepenicama. Nadalje, cilj je razviti metodu za

detekciju pješačkih prijelaza koja će maksimalno skratiti vrijeme izvođenja i omogućiti rad u stvarnom vremenu čak i na uređajima slabijih performansi. Obje metode kao ulazni podatak koriste slike izdvojene iz video isječaka dok je za izlazni podatak potrebno dobiti predloženi smjer kretanja za korisnika. Iz tog razloga cilj je na temelju predloženog postupka detekcije stepenica i pješačkih prijelaza daljnjom analizom odrediti prostor sigurnog kretanja te na odgovarajući način informirati slijepu osobu o preporučenom smjeru kretanja. S obzirom na malu zastupljenost ovakvih metoda u znanstvenim istraživanjima cilj je stvoriti i opisati referentnu bazu slika i video isječaka te razviti okvir za evaluaciju ovakvih i sličnih metoda usmjeravanja. Ciljevi ovog rada trebali bi u konačnici doprinijeti tome da stvarna primjena automatiziranih sustava za pomoć slijepim i slabovidnim osobama temeljenim na računalnoj obradi slike bude bliža i izglednija.

Ovaj rad podijeljen je u poglavlja prema sljedećem redoslijedu. U drugom poglavlju opisani su sustavi za pomoć slijepim i slabovidnim osobama. Ovdje su uz probleme koje takve osobe susreću u svakodnevnom kretanju predstavljeni i dosadašnji pristupi u rješavanju ovakvih problema što uključuje i kratak pregled njihovih prednosti i nedostataka. Treće poglavlje opisuje morfološku obradu i analizu slike općenito te uvodi glavne pojmove vezane za morfologiju u računalnoj obradi slike. Objasnen je pojam binarne slike i osnovnih morfoloških operacija te dane smjernice za korištenje istih prilikom razvijanja novih metoda. U četvrtom poglavlju opisana je nova metoda za detekciju stepenica koja u prvi plan stavlja vertikalnu analizu strukture stupaca binarne slike. Objasneni su pojedini koraci ove metode te je na konkretnim primjerima prikazan postupak predobrade, analize i konačne detekcije. Testirana je uspješnost predložene metode i brzina izvođenja, a dobiveni podaci uspoređeni su sa sličnim metodama. Peto poglavlje predstavlja novu multirezolucijsku metodu za detekciju pješačkih prijelaza zasnovanu na morfološkoj analizi slike. Opisani su koraci ove metode i uveden pojam energije linija kao parametar za donošenje odluke o detekciji. Na primjerima je prikazan svaki korak metode za detekciju, a predstavljena je i konačna uspješnost razvijene metode te usporedba sa sličnim metodama. Ovdje je izvršena i analiza brzine izvođenja na različitim uređajima te su dani podaci o mogućnosti rada u stvarnom vremenu. U šestom poglavlju opisana je nova metoda za zvučno usmjeravanje slijepih i slabovidnih osoba određivanjem prostora za sigurno kretanje na temelju rubnih točaka dobivenih u prethodne dvije metode. Opisan je postupak određivanja područja sigurnog kretanja na slici i princip zvučnog informiranja korisnika o pojednostavljenom smjeru kretanja. Sedmo poglavlje predstavlja okvir za evaluaciju metoda usmjeravanja slijepih i slabovidnih osoba. Okvir uključuje testno okruženje te bazu slika i video isječaka koja je opisana u ovom poglavlju. Predložen je i postupak za usporedbu računalne i subjektivne odluke kako bi se što lakše ocijenila uspješnost

odluka. Zaključak ovog doktorskog rada i ostvareni znanstveni doprinosi dani su u osmom poglavlju.

2. SUSTAVI ZA POMOĆ SLIJEPIM I SLABOVIDNIM OSOBAMA

U ovom poglavlju bit će izloženi problemi i potencijalne prepreke s kojima se slijepe i slabovidne osobe mogu susresti u kretanju. Osim prepreka koje je moguće detektirati u ovom poglavlju bit će predstavljen i koncept sustava za detekciju i usmjeravanje slijepih temeljen na računalnoj obradi slike s kamere. Također, ovdje su predstavljeni pristupi i metode u razvoju ovakvih pomoćnih sustava za slijepe i slabovidne.

2.1. Problemi pri kretanju slijepih i slabovidnih osoba

Prema pregledu istraživanja i inovacija u području mobilnih sustava pomoći za slijepe i slabovidne osobe [3] postoje mnogi objekti koje je moguće detektirati pri kretanju i na taj način pomoći u samostalnom kretanju slijepih i slabovidnih. Potencijalni problemi pri slobodnom kretanju slijepih i slabovidnih osoba mogu se podijeliti u tri kategorije s obzirom na udaljenost s koje je potrebno izvršiti zadatak: velike, srednje i male udaljenosti.

Pod zadatke velike udaljenosti (engl. *Far distance tasks*) ubrajamo navigaciju slijepih od jedne do druge točke [4] i sam pronalazak puta do točaka interesa [5]. Ovakvi zadaci uglavnom se odnose na kretanje i navigaciju u vanjskim prostorima. Glavnu problematiku kod ovakvih sustava predstavlja definiranje rute za slijepu osobu i usmjeravanje u stvarnom vremenu. Stoga su ovakvi zadaci manje vezani uz korištenje kamere, a više uz tehnologije poput GPS-a (engl. *Global Positioning System*).

Zadaci srednje udaljenosti (engl. *Intermediate distance tasks*) obuhvaćaju najviše problema s kojima se slijepi i slabovidni susreću pri slobodnom kretanju. Ovdje je najčešće riječ o raznim statičnim ili pokretnim preprekama u neposrednoj blizini ispred osobe [6]. Preprekom možemo smatrati bilo koji objekt povezan s tlom koji se nalazi na putu [7],[8] ili neki specifičan objekt koji želimo detektirati kao što su stepenice [9], pješački prijelazi [10],[11],[12] ili neki važni znakovi [13]. Iz navedenog se može zaključiti da je za rješavanje zadataka srednje udaljenosti prikladno koristiti kameru kao sredstvo prikupljanja informacija iz okoline.

Zadaci male udaljenosti (engl. *Near distance tasks*) predstavljaju one zadatke koje korisnik obavlja s iznimno male udaljenosti, u što se prvenstveno ubraja čitanje i prepoznavanje objekata koje osoba drži u ruci [14]. U ovom kontekstu često se spominje i samostalna kupovina koja povlači nekoliko problema kao što su kretanje po trgovini, pronalazak proizvoda i plaćanje [15]. Ova skupina zadataka male udaljenosti najdulje je zastupljena u znanstvenim istraživanjima s


obzirom na to da je računalno prepoznavanje znakova (engl. *Optical Character Recognition – OCR*) već desetljećima razvijano i unapređivano, pa su sustavi koji rješavaju problem samostalnog čitanja bili jedan od prvih izazova za znanstvenike u ovom području. U posljednje vrijeme komercijalno su dostupni uređaji za pomoć slijepima pri čitanju poput sustava *OrCam* [16].

Ovaj doktorski rad vezan je uz rješavanje problematike zadataka srednje udaljenosti, točnije, riječ je o detekciji stepenica i pješačkih prijelaza gdje slijepi i slabovidne osobe trebaju obratiti posebnu pozornost prilikom kretanja. Prema tome, u nastavku ovog pregleda bit će naglasak na sustavima za automatsku detekciju stepenica i pješačkih prijelaza te usmjeravanje na istima.


2.2. Koncept sustava

Automatizirana digitalna pomagala za slijepi i slabovidne osobe zamišljena su kao prenosivi sustavi u kojima glavni dio predstavlja uređaj za obradu podataka. Odabir glavnog uređaja za obradu podataka je vrlo važan zbog korištenja u pokretu, nužno je da uređaj bude što manjih dimenzija, ali istovremeno s dovoljno računalne snage za zahtjevne računalne radnje kao što je obrada digitalne slike. Kod ovakve primjene kao rješenje se nameću uređaji čija je upotreba već široko rasprostranjena kao što su laptopi, mobiteli i tableti. Također, u posljednje vrijeme porasla je i dostupnost osobnih računala iznimno malih dimenzija (engl. *Mini PC*) čija računalna snaga otprilike odgovara današnjim mobilnim telefonima. Smatra se da su takvi uređaji dosegili tehnološku razinu na kojoj se mogu koristiti kako bi se osobama s posebnim potrebama omogućila lakša integracija u društvo i veća kvaliteta života [17]. Pojam „mobilnih pomoćnih tehnologija“ [3] odnosi se na tehnologije koje se mogu integrirati u široko rasprostranjene mobilne uređaje kako bi pomogle osobama s posebnim potrebama, ali pritom vodeći računa o diskretnosti, suptilnosti i neoznačavanju takvih osoba. Mobilnim uređajima ovdje se smatraju svi uređaji koji su prenosivi i mogu se koristiti u pokretu, te kao takvi predstavljaju nenametljiv način upotrebe pomoćnih sustava za osobe s posebnim potrebama [18].

Uz spomenute mobilne uređaje koji bi služili za obradu podataka, sustav za pomoć slijepima predložen u ovom radu upotpunjuju još dva dijela: dio za prikupljanje podataka (kamera) i dio sustava za informiranje korisnika (stereo slušalice). Vidljivo je kako ova dva dijela potencijalno mogu biti integrirana u jedan uređaj kao što je mobilni telefon, koji već posjeduje kameru te može reproducirati zvučne obavijesti. Ipak, koncept sustava predložen u ovom radu koristi računalo (laptop ili *mini PC*), posebnu odvojenu kameru i stereo slušalice za reprodukciju zvučnih obavijesti. Koncept takvog sustava prikazan je na modelu na slikama 2.1. (a)-(c) gdje osoba s instaliranom kamerom prilazi stepenicama kao potencijalnoj kritičnoj točki, na istoj slici vidi se



(a)



(b)



(c)



(d)



(e)



(f)



(g)


Slika 2.1. Prilazak osobe objektu i prikaz ulazne slike s kamere za: (a)-(c) stepenice; (d)-(g) pješački prijelaz

ulazni podatak s kamere koji se koristi za daljnju računalnu obradu i dobivanje informacije o

stepenicama i smjeru kretanja. Slično je prikazano i na slikama 2.1. (d)-(g) gdje osoba s kamerom prilazi pješačkom prijelazu.

Prema predloženom konceptu slijed koraka u automatiziranom sustavu za navođenje slijepih osoba prikazan je na slici 2.2. Slika s kamere koristi se kao ulazni podatak, a uređaj za obradu podataka pokušava u realnom vremenu dati informaciju o detektiranom objektu i predloženom smjeru kretanja što se korisniku javlja u obliku zvučnih poruka i signala.

Važna je stavka pri izradi ovakvog sustava pozicioniranje i odabir vrste kamere. Ona se najčešće postavlja na glavu korisnika kao neka vrsta naočala [19] ili na tijelo u visini prsa pomoću posebnih nosača. S obzirom na to da je u oba slučaja zajamčena trešnja i pomicanje kamere važno je očekivati nefokusirane slike s određenom količinom šuma i zamućenosti. Postupci iz računalne obrade slike koji se koriste pri otklanjanju ovih nedostataka navedeni su i detaljnije opisani u 4. i 5. poglavlju. Također, moguće je odabirom kamere s ugrađenim sustavima za stabilizaciju slike povećati kvalitetu ulazne slike. Danas su takve kamere prilagođene za korištenje u pokretu (engl. *action cameras*) lako dostupne, te uz male dimenzije najčešće daju širokokutnu sliku koja će omogućiti i širi pogled na korisnikovu okolinu. Nadalje, usmjeravanje kamere je bitno kako bi




Slika 2.2. Koraci u automatiziranom sustavu za pomoć slijepim i slabovidnim osobama

potencijalni objekt na vrijeme ušao u kadar i bio prepoznat s prihvatljive udaljenosti. Za objekte kao što su stepenice ili pješački prijelazi, udaljenost od 1 do 3 metra smatra se dovoljnom za pravovremeno informiranje korisnika. Ovakvi sustavi gdje se kamera koristi za prikupljanje informacija iz okoline koje su inače dobivene ljudskim osjetilom vida nazivaju se FPV sustavi (engl. *First-person vision systems*) [20].

Uređaj za obradu podataka kao centralni dio sustava može biti smješten u torbi ili džepu, ovisno o veličini. Ako se koristi kamera s mobilnog telefona, tada je i on sam postavljen na odgovarajuće mjesto pomoću posebnih nosača. Mobilni telefoni zbog malih su dimenzija praktični za ovakvu primjenu, ali su njihovi računalni resursi često raspodijeljeni i na druge radnje koje korisnik na istom uređaju obavlja. Stoga je robusnije rješenje koristiti prijenosno računalo posvećeno isključivo zadacima obrade slike i usmjeravanja. Na uređaju se izvršavaju napredni postupci računalne obrade slike i videa koji će biti detaljno opisani u ostatku rada. Važno je napomenuti da ti postupci moraju biti dobro optimizirani i što manje zahtjevni kako bi se mogli izvršavati na uređajima slabijih performansi. U [21] se opisuje obrada videa u realnom vremenu i problemi u provedbi takvih postupaka obrade.

Treći dio sustava koji je zadužen za informiranje korisnika o potencijalnim preprekama otvara jedno sasvim novo područje istraživanja i razvoja odgovarajućeg i neinvazivnog sustava za informiranje osobe s nedostatkom osjetila vida. Kod ovog problema najčešće se spominju zvučni i taktilni signali kao djelomična zamjena za osjetilo vida [22]. Preporuča se smanjivanje prekomjerne upotrebe zvučnih upozorenja jer su istraživanja pokazala da se slijepi osobe brže prilagođavaju i lakše upotrebljavaju uređaje koji koriste dodirne aktuatora i vibracije kao sredstvo prikupljanja informacija u pokretu [23], [24]. U ovom radu će se zbog jednostavnosti koristiti zvučni signali, jer bi za taktilne signale bio potreban razvoj dodatnog specijaliziranog uređaja s vibracijskim aktuatorima. Zvučni signali će biti prilagođeni za što jednostavnije i intuitivnije korištenje, a koncept usmjerenih zvučnih signala predložen u ovom radu bit će jednostavno primjenjiv i na dodirne signale.


U sklopu ovog istraživanja izrađen je jednostavan prototip sustava za pomoć slijepima koji se sastoji od ranije spomenuta tri dijela. Prototip je korišten prilikom razvoja novih metoda i testiranja njihove uspješnosti i brzine. Prototip je korišten u dvije izvedbe, s laptopom ili *mini PC*-jem kao glavnim uređajem za obradu podataka. Prototip sustava prikazan je na slici 2.3. s naznačenim glavnim komponentama.



Slika 2.3. Prototip sustava za pomoć slijepim i slabovidnim osobama

2.3. Pristupi za razvoj pomoćnih sustava za slijepe i slabovidne

Radi stjecanja šire slike o ovom problemu bilo je potrebno istražiti radove u časopisima iz nekoliko znanstvenih područja što je vidljivo na slici 2.4. Stoga će biti spomenuti radovi iz područja računalne obrade slike i videa, mobilnih sveprisutnih računalnih sustava (engl. *Ubiquitous computing*) [25] i medicine (oftalmologije). U ovom pregledu najviše se govori o radovima iz područja računalne obrade slike s potencijalnom primjenom u pomoćnim sustavima za slijepe i slabovidne osobe. Općenito, relativno mali broj znanstvenih istraživanja usmjeren je na rješavanje problema za slijepe i slabovidne osobe, stoga i dosadašnji pristupi imaju određene manjkavosti i otvaraju prostor za unapređenje i razvoj. Ovo je posebno vidljivo kada se promatra usko znanstveno područje detekcije specifičnih objekata poput stepenica ili pješačkih prijelaza obradom slike.



Slika 2.4. Znanstveno-istraživačka područja i časopisi

U nastavku ovog potpoglavlja bit će opisani primjeri metoda razvijenih za potrebe sustava za pomoć slijepim i slabovidnim osobama. Primjeri uključuju metode detekcije stepenica i pješačkih prijelaza obradom 2D slike s klasičnih monokularnih kamera i 3D slike dobivene stereo kamerama. Ukratko su navedene i ostale metode koje ne koriste kamere.

2.3.1. Metode obrade 2D slike


Prva skupina metoda odnosi se na one metode koje koriste klasičnu kameru kojom se dobiva dvodimenzionalna slika. Može se reći da su ovakve metode najzastupljenije u znanstveno-istraživačkom području pomoćnih sustava za slijepe i slabovidne osobe temeljenih na obradi slike s kamere. Metode predložene u ovoj disertaciji pripadaju ovoj skupini metoda. U nastavku su ukratko opisani slični radovi iz ovog područja kako bi se predstavili dosadašnji pristupi i pojmovi važni za razumijevanje ovakvih metoda.

Postupak koji se najčešće pojavljuje u znanstvenim istraživanjima vezanim za detekciju objekata poput stepenica i pješačkih prijelaza je Houghova transformacija. Ova transformacija u svom osnovnom obliku iznimno je pogodna za detekciju linija na slici [26]. U radu [27] koristi se Houghova transformacija kako bi se detektirali približno paralelni horizontalni rubovi koji su

karakteristični za područje stepenica. Spominju se značajno lošiji rezultati za detekciju vanjskih stepenica zbog sjena, objekata na njima i varijacija osvjetljenja. Ukupna uspješnost ove metode na testnom uzorku od 227 slika bila je 83 %. Mnoge metode prvo rade predobradu slike gdje se najčešće vrši binarizacija i detekcija rubova. U radu [28] osim detekcije rubova korišteni su i Gabor filteri [29] kojima se naglašavaju paralelne linije određenog smjera, a uklanjaju drugi uzorci u slici. Sličan princip koristi se i u radu [30] prilikom navigacije autonomnog robota. S obzirom na to da se na slici stepenice postupno smanjuju od dolje prema gore, pomoću dobivenih horizontalnih linija traži se točka nestajanja (engl. *Vanishing point*). Točka nestajanja čest je pojam u metodama za detekciju stepenica [31] i koristi se za konačnu detekciju stepenica uz ranije detektirane linije. Glavne smjernice za ovaj postupak prikazane su na slici 2.5. S obzirom na strukturnu sličnost stepenica i pješačkih prijelaza na 2D slikama sličan princip koristi se i za detekciju pješačkih prijelaza u radu [32].

Zbog ranije spomenutih problema metode su često prilagođene za upotrebu u određenim uvjetima. Tako se metoda [33] zasniva samo na detekciji stepenica u unutrašnjim prostorima, slično kao i u radu [34] gdje se u unutrašnjim prostorima detektiraju vrata i natpisi uz njih. S obzirom na to da se kao čest problem kod metoda s 2D kamerama navodi detekcija stepenica koje idu prema dolje, neki radovi bave se isključivo rješavanjem tog problema [35].

Osim detekcije linija i geometrijskih karakteristika stepenica, neki radovi kao [36] baziraju se na korištenju Haarovih svojstava i Ada-Boost učenju gdje su moguće višestruke detekcije na



Slika 2.5. Približno paralelne linije i točka nestajanja

istoj slici. Razvijen je i sustav vrednovanja pojedinih detekcija za razliku od klasičnog pristupa gdje postoje samo dva moguća stanja (pronađen/nepronađen).

Kao osnovni pristup detekcije pješćkih prijelaza može se istaknuti rad [37] gdje je korištena jeftina monokularna kamera, metoda podudaranja s predloškom i metoda normalizirane korelacije. *Mean shift* segmentacija i morfološka obrada slike koriste se u radu [12] kao metode detekcije pješćkih prijelaza gdje je glavni nedostatak detekcija u slučaju djelomično osvjetljenih ili sjenom zaklonjenih dijelova slike. Ovi nedostaci djelomično su otklonjeni drugim pristupom, predloženim u [38] i [39], gdje je algoritam za detekciju pješćkih prijelaza zasnovan na bipolarnosti.

U [10] i [11] segmentacija pješćkih prijelaza vrši se izdvajanjem pozadine od promatranog objekta (engl. *figure-ground segmentation*). Ovo se pokazalo znatno robusnije u slučajevima lokalnih deformacija na rubnim linijama pješćkog prijelaza. Nedostaci ovakvih metoda prvenstveno se odnose na slabiju detekciju rubova pješćkih prijelaza koji su preblizu ili predaleko od kamere što kasnije negativno utječe na pronalazak točke nestajanja i usmjeravanje pješćaka.

Metode s klasičnim kamerama također su pogodne za implementaciju na mobilnim telefonima koji pretežno posjeduju takve kamere što je predloženo u radovima [40],[41]. Dodatne funkcionalnosti mogu se dobiti iskorištavanjem drugih senzora mobilnih telefona poput GPS-a [42]. Korištenje mobilnih telefona ponajviše je zagovarano u radovima objavljenim u sklopu projekta *Crosswatch* koji vodi James Coughlan. Ovaj projekt još je aktivan, a naglasak je općenito na pomoći pri kretanju slijepih na raskrižjima što uključuje i detekciju samih raskrižja i pješćkih prijelaza na unaprijed snimljenim kartama. Također, ovdje se važnost stavlja na orijentaciju slijepih pješćaka u odnosu na raskrižje i prepoznavanje mogućih smjerova kretanja na istima [43]. Ovakvi pristupi koji koriste mobilne telefone također istražuju mogućnost korištenja panoramskih slika u kombinaciji sa satelitskim slikama za detekciju raskrižja i pješćkih prijelaza što za sada zahtjeva značajno više vremena za izvođenje, ali ima potencijal za ubrzanje i primjenu u stvarnom vremenu [44], [45].

Metode za detekciju pješćkih prijelaza često su prikazane u kontekstu sigurnosnih sustava u automobilima i autonomnim vozilima [46]. Ipak, važno je uočiti razliku u položaju i orijentaciji pješćkog prijelaza promatranog iz vozila i iz perspektive pješćaka. Sigurnosni sustavi u vozilima imali bi za cilj obavijestiti vozača o potrebi za dodatnom pozornosti zbog potencijalnih pješćaka na pješćkom prijelazu dok bi se pješćacima trebalo pomoći da bez poteškoća prijeđu preko pješćkog prijelaza. Očekivana je i određena razlika u video isječcima snimljenim iz vozila i onih snimljenih hodajući jer vozila se kreću brže od pješćaka, a s druge strane podrhtavanje i trešnja kamere su

intenzivniji kod pješaka. Prema tome, algoritmi za pomoć slijepim osobama razlikuju se od onih namijenjenih vozilima.

2.3.2. Metode obrade 3D slike

Korištenjem stereo kamera, gdje se osim intenziteta piksela na 2D području slike dobiva i informacija o dubini, značajnije se olakšava pronalazak prepreka kao što su stepenice. Glavni je nedostatak ovakvih metoda veličina i oblik današnjih stereo kamera, samim time i teža instalacija na slijepu osobu i korištenje u pokretu te veća cijena takvih kamera. Ovdje je također isključeno korištenje samo mobilnih telefona u koje se u velikoj većini ugrađuju klasične kamere. Stoga je logično da se stereo kamere često ugrađuju u autonomne robote, dok je primjena u sustavima za pomoć slijepim i slabovidnim osobama nešto rjeđa.

U radovima [47] i [48] koriste se stereo kamere za detekciju nekoliko vrsta prepreka, a između ostalog i stepenica i pješačkih prijelaza. Metoda koristi Houghovu transformaciju za detekciju paralelnih horizontalnih linija te informaciju o dubini pomoću koje detektira i razlikuje stepenice i pješački prijelaz kao vizualno slične objekte. Ovom metodom postignuta je velika uspješnost detekcije od čak 97 %, ali testiranje je izvršeno na malom skupu ulaznih podataka koje su prikupili sami istraživači. Općenito, kao i kod metoda obrade 2D slike, i kod 3D slika izrazito je popularna Houghova transformacija za detekciju paralelnih linija [49].

U radu [50] koristi se *Microsoft Kinect* senzor [51] kojim je također moguće dobiti podatak o dubini. Metoda je temeljena na detektiranju gornjih površina stepenica kao ravnina koje su za određenu vrijednost udaljene od tla kao početne ravnine. Ovaj pristup omogućava osim detekcije stepenica i izračun njihovog nagiba. Metoda je testirana na manjem skupu podataka te je polučila uspješnost detekcije od gotovo 95 % uz iznimno mali postotak slučajnih pogrešnih detekcija.

Slučajne detekcije stepenica u slučajevima kada istih nema na slikama velik su problem, što je prikazano u radu [52] gdje se slično kao u [36] za detekciju koriste Haarova svojstva i Ada-Boost učenje.

Dok se neki istraživači baziraju isključivo na dobivanju informacije nalaze li se na slici stepenice, u nekim radovima kao što je [53] daje se pozornost i lokalizaciji istih te točnom određivanju područja slike u kojem se nalaze stepenice. S obzirom na to da stereo kamere omogućuju podatak o dubini, u slučaju stepenica to olakšava dobivanje dodatnih informacija kao što je udaljenosti do stepenica i njihov smjer (prema gore ili dolje).

Kod detekcije pješačkih prijelaza korištenjem RGB-D kamere i informacije o dubini ističe se rad S. Wanga [48] gdje je dobivena točnost od oko 79 %, ali bez ijedne slučajne pogrešne detekcije. Također, postoje i noviji pristupi koji koriste RGB-D slike i strojno duboko učenje (engl. *deep learning*) za detekciju pješačkih prijelaza [54]. Nedostatak metoda koje koriste strojno učenje je nepostojanje opsežne baze ulaznih podataka potrebnih za treniranje te sama računalna i vremenska zahtjevnost procesa treniranja.

2.3.3. Ostale metode

Iako metode koje ne koriste kamere nisu u fokusu ovog rada, takve metode moguće je kombinirati s onima koje koriste kamere, te na taj način dobiti složeniji sustav koji pri detekciji objekata koristi nekoliko vrsta ulaznih podataka. U nastavku su izdvojeni radovi u kojima se spominju metode koje ne koriste isključivo kamere prilikom detekcije objekata za slijepo i slabovidne.

U radu [55] spominju se ultrazvučni senzori, laseri i infracrveni primopredajnici kao tehnološka rješenja za detekciju različitih prepreka za slijepo osobe. Razmatra se i opcija ugradnje takvih tehnologija u postojeće bijele štapove kao kompleksnija pomagala koja bi pomoću vibracijskih aktuatora informirala korisnike o fizičkim preprekama. Slično kao u prethodnom radu, pomoću ultrazvučnih senzora postavljenih na remen korisnika moguće je detektirati prepreke te se korisnika obavještava zvučnim signalima [2]. Izvedba sustava koja objedinjuje prethodna dva sustava koristi bijeli štap s ugrađenim ultrazvučnim sensorima i kotačima kojima je moguće upravljati [56]. Isti kotači koriste se i za navođenje slijepo osobe tako da sustav sam zakreće štap kako bi se izbjegla prepreka.

Glavni je nedostatak ovakvih sustava taj što, iako detektiraju prepreke, ne mogu osigurati informaciju o kakvoj je prepreci riječ [57]. Stoga je razumljiva potreba i mogućnost objedinjenja nekoliko vrsta sustava spomenutih u ovom poglavlju.

3. MORFOLOŠKA OBRADA I ANALIZA SLIKE

U ovom radu glavnu okosnicu čini morfološka obrada i analiza slike na kojoj su zasnovane predložene metode. Morfologija u obradi slike podrazumijeva niz radnji povezanih s oblicima i geometrijskim strukturama u slici [58]. Često se koristi kao oblik predobrade slike za isticanje traženih oblika i pripremu za daljnje radnje što će biti slučaj i u ovom radu. U ovom poglavlju najprije je opisana binarna slika kakva se najčešće koristi za primjenu morfoloških operacija. Potom su opisane osnovne morfološke operacije koje su ujedno i korištene u postupcima predloženim u ovoj disertaciji. Posljednje potpoglavlje opisuje postupak morfološke analize slike i inicijalnu ideju za daljnje postupke detekcije zasnovane na morfološkoj analizi slike.


3.1. Binarna slika

Morfološke operacije uglavnom se primjenjuju na binarnim slikama gdje se njihov učinak zasniva na relativnom redoslijedu i prostornom rasporedu crnih ili bijelih piksela. Moguće je morfološke operacije izvoditi i na slikama u sivim tonovima (engl. *grayscale*) gdje bi onda učinak morfoloških operacija osim o prostornom rasporedu određenih piksela ovisio i o vrijednostima njihovih intenziteta [59]. S obzirom na to da će se u ovom radu morfološke operacije izvoditi isključivo na binarnim slikama, u nastavku su detaljnije opisane takve slike i postupci dobivanja takvih slika.

Postupak dobivanja binarne slike ili binarizacija smatra se najjednostavnijim oblikom segmentacije, tj. podjele slike na više izdvojenih područja interesa. Binarna slika predstavlja onu sliku u kojoj vrijednosti piksela mogu poprimiti samo dvije vrijednosti koje najčešće predstavljaju crna i bijela boja. Binarna slika najčešće se dobiva iz slike u sivim tonovima. Ako je slika u sivim tonovima 8-bitna, tj. ako je intenzitet svakog piksela označen vrijednošću od 0 do 255, onda će u binarnoj slici pikseli poprimiti krajnje vrijednosti 0 (crna boja) i 255 (bijela boja). U standardnom najosnovnijem postupku binarizacije vrijednost koju će poprimiti piksel binarne slike ovisit će o tome je li intenzitet promatranog piksela slike u sivim tonovima manji ili veći od praga (engl. *threshold*). Kada se koristi jedna vrijednost praga za cijelu sliku, riječ je o metodama globalne binarizacije. Osim postavljanja statičnih vrijednosti za prag, postoje različite metode određivanja odgovarajuće vrijednosti praga od kojih je jedna od najpoznatijih i najčešće korištenih Otsu metoda [60]. Također, često se za vrijednost praga uzima i srednja vrijednost svih intenziteta piksela u slici, što je posebno dobro u slučajevima kada objekti koje se želi segmentirati na slici zauzimaju približno jednako prostora kao i ostatak slike. Osim metoda globalne binarizacije,

postoje i metode lokalne binarizacije, odnosno adaptivne metode koje su nastale kako bi se smanjio utjecaj varijacija osvjetljenja u različitim dijelovima slike. Kod ovakvih metoda određuju se lokalne vrijednosti praga za manje segmente slike, pa će prag varirati ovisno o tome u kojem se dijelu slike promatrani piksel nalazi.

Slika 3.1. prikazuje postupak binarizacije korištenjem statičnih vrijednosti praga. Za ulaznu sliku 3.1. (a) korištenjem različitih vrijednosti praga (T) dobivaju se binarne slike prikazane na slikama 3.1. (b)-(e). Na slikama je vidljivo da se za konkretan primjer slike s pješačkim prijelazom korištenjem praga $T = 160$ i $T = 200$ dobivaju najpovoljniji rezultati izdvajanja pješačkog



Slika 3.1. Postupak binarizacije: (a) Ulazna slika; (b) Binarna slika ($T = 120$); (c) Binarna slika ($T = 160$); (d) Binarna slika ($T = 200$); (e) Binarna slika ($T = 240$)

prijelaza. Za vrijednosti praga $T = 240$ na binarnoj slici ostaje premalo sačuvanih podataka, dok za vrijednost praga $T = 120$ slika ostaje zasićena bijelim pikselima koji ometaju vidljivost pješačkog prijelaza.

Slika 3.2. prikazuje binarne slike dobivene korištenjem Otsu metode i adaptivne metode. Slika 3.2. (b) dobivena Otsu metodom za konkretan primjer daje dobre rezultate isticanja pješačkog prijelaza, iako zasićenost bijelim pikselima u gornjem dijelu pješačkog prijelaza ukazuje na mogućnost pogreške kod različitih uvjeta osvjetljenja. Slika 3.2. (c) dobivena je korištenjem adaptivne metode gdje se vrijednost praga mijenja za različite dijelove slike. Pokazalo se da korištenje adaptivnih metoda nije prikladno za slučaj izdvajanja pješačkog prijelaza jer će se ovom metodom nastojati sačuvati što je više moguće informacija u svakom dijelu slike što se odnosi i na one dijelove u okolini pješačkog prijelaza. Previše izdvojenih nevažnih detalja u slici otežava daljnju analizu slike i prepoznavanje pješačkog prijelaza.

Osim opisanim standardnim postupcima binarizacije, binarne slike mogu biti i rezultat drugih operacija nad slikama u sivim tonovima ili nad slikama u boji. Primjerice, rezultat algoritama za detekciju rubova mogu biti binarne slike gdje će rubovi biti prikazani bijelom bojom, a ostatak slike crnom. Upravo takav postupak dobivanja binarne slike bit će korišten u 4. poglavlju



(a)



(b)



(c)

Slika 3.2. Postupak binarizacije: (a) Ulazna slika; (b) Binarna slika (Otsu metoda); (c) Binarna slika (adaptivna metoda)

kod postupka predobrade slike za detekciju stepenica, dok će se u 5. poglavlju za detekciju pješačkih prijelaza koristiti standardni postupci binarizacije uz manje prilagodbe.

3.2. Osnovne morfološke operacije

U kontekstu prepoznavanja objekata kao što su stepenice i pješački prijelazi morfološka obrada slike omogućit će pojednostavljenje binarizirane ulazne slike i pripremiti istu za analizu. Cilj je uklanjanje nepotrebnih detalja u slici dok će se pritom nastojati zadržati što je više moguće korisnih informacija. S obzirom na karakterističan oblik stepenica i linija pješačkog prijelaza morfološkim operacijama moguće je takve oblike istaknuti, a one druge, za detekciju nebitne, prikriti.

Osnovne morfološke operacije na binarnim slikama su:

- Eroziija (engl. *erosion*)
- Dilatacija (engl. *dilation*)
- Otvaranje (engl. *opening*)
- Zatvaranje (engl. *closing*)

Od navedenih morfoloških operacija, erozija i dilatacija smatraju se primarnim jer mnoge druge složenije morfološke operacije, uključujući otvaranje i zatvaranje, izvedene su upravo iz njih. Operacijom erozije postiže se učinak prostornog smanjivanja područja bijele boje na binarnoj slici. Glavna je primjena ove operacije prilikom uklanjanja nepotrebnih detalja na slici u pogledu njihove veličine. Tako će primjenom erozije sve male nakupine bijelih piksela jednostavno nestati, dok će pri tome velika bijela područja ostati na slici, ali će biti smanjene površine. Učinak erozije prikazan je na slici 3.3. na ulaznoj binarnoj slici pješačkog prijelaza. Morfološke operacije često se izvode u nekoliko iteracija kako bi se pojačao njihov učinak. Tako su na slikama 3.3. (b)-(e) prikazani učinci nekoliko iteracija izvođenja operacije erozije. Vidljivo je da su već nakon primjene jedne iteracije erozije manji detalji iznad pješačkog prijelaza nestali, dok su bijele linije pješačkog prijelaza postale površinom manje. S većim brojem iteracija bijela područja gotovo u potpunosti iščezavaju sa slike.

Morfološka operacija dilatacije ima suprotan učinak od erozije. Ovom se operacijom bijela područja na slici šire i postaju površinom veća. Učinak dilatacije prikazan je na slikama 3.4. (a)-(f) gdje je vidljivo da manja crna područja na linijama pješačkog prijelaza postepeno nestaju, a površina bijelih linija sve je veća. Tako će nakon nekoliko iteracija dilatacije prostori između linija pješačkih prijelaza postati sve uži ili u potpunosti nestati.



(a)




(b)



(c)



(d)



(e)

Slika 3.3. Morfološka operacija erozije: (a) Ulazna binarna slika; (b) 1 iteracija erozije; (c) 2 iteracije erozije; (d) 3 iteracije erozije; (e) 4 iteracije erozije

Na konkretnim primjerima izvođenja erozije i dilatacije jasno su vidljivi pozitivni učinci eliminacije nepotrebnih detalja iz perifernih dijelova slike, te neutralizacije nepravilnosti na linijama pješačkih prijelaza izazvanih pukotinama ili istrošenom bojom. S druge strane, lako je uočiti i negativne učinke kao što je narušavanje strukture pješačkog prijelaza. Kod erozije postoji mogućnost potpunog nestajanja sa slike, a kod dilatacije može doći do pretvaranja pješačkog prijelaza u veću površinu bijele boje gdje više nisu jasne njegove karakteristične horizontalne linije. Zbog ovih negativnih učinaka, za konkretnu primjenu kod metoda razvijanih u ovoj disertaciji bit će više koristi od morfoloških operacija otvaranja i zatvaranja koje su opisane u nastavku.



(a)




(b)



(c)



(d)



(e)

Slika 3.4. Morfološka operacija dilatacije: (a) Ulazna binarna slika; (b) 1 iteracija dilatacije; (c) 2 iteracije dilatacije; (d) 3 iteracije dilatacije; (e) 4 iteracije dilatacije

Morfološka operacija otvaranja izvedena je iz primarnih operacija erozije i dilatacije i može se opisati kao postupak erozije nakon kojeg slijedi dilatacija dobivenog međurezultata. Ovime je smanjen destruktivni učinak erozije kojim se često gube početni oblici objekata na slici [61]. Glavni je učinak otvaranja zaglađivanje konture objekata i uklanjanje tankih izbočenja na bijelim konturama. Pri tome se ne gubi početni oblik i veličina takvih objekata, ali istovremeno je otvaranjem moguće eliminirati sitne objekte bijele boje. Kod izvođenja operacije otvaranja važan je strukturni element kojim se provodi. Strukturni element može biti različitih veličina i oblika, ali najčešće se koristi oblik pravokutnika ili elipse. Odabirom strukturnog elementa određuje se oblik i veličina objekata kakve želimo zadržati na slici. Tako će, recimo, odabirom kvadrata dimenzija

3×3 kao strukturnog elementa nakon otvaranja slika izgledati kao da su svi bijeli objekti izgrađeni od takvih elemenata, ali će biti zastupljeni samo oni dijelovi bijelih područja u koje stane odabrani strukturni element. Iz spomenutog razloga objekti manji od strukturnog elementa bit će eliminirani. Primjeri na slikama 3.5. (a)-(e) prikazuju primjenu operacije otvaranja s različitim veličinom strukturnog elementa. Za odabir odgovarajuće veličine strukturnog elementa važna je i rezolucija slike, a pokazalo se da je za manje rezolucije poput 640×360 piksela, kakva je korištena u ovom primjeru, bolje koristiti manje strukturne elemente (3×3 ili 5×5).




(a)




(b)



(c)



(d)



(e)

Slika 3.5. Morfološka operacija otvaranja: (a) Ulazna binarna slika; (b) Otvaranje (strukturni element 3×3); (c) Otvaranje (strukturni element 5×5); (d) Otvaranje (strukturni element 7×7); (e) Otvaranje (strukturni element 9×9);

Suprotno od otvaranja, morfološka operacija zatvaranja izvedena je kao primjena dilatacije na sliku nakon koje slijedi erozija međurezultata. Zatvaranjem se postiže učinak širenja bijelih područja tako da se popunjavaju manje praznine unutar istih ili manji procijepi na rubovima bijelih područja [61]. Kod zatvaranja je također moguće podešavati veličinu i oblik strukturnog elementa kao i kod otvaranja. Na slikama 3.6. (a)-(e) nalaze se primjeri izvođenja morfološke operacije zatvaranja sa strukturnim elementima različitih veličina. Pokazuje se da je korištenje operacije zatvaranja idealno za popunjavanje praznina uzrokovanih oštećenjima na pješačkim prijelazima. Na konkretnom primjeru slike u rezoluciji 640×360 pokazalo se da oblik pješačkog prijelaza ostaje




(a)




(b)



(c)



(d)



(e)

Slika 3.6. Morfološka operacija zatvaranja: (a) Ulazna binarna slika; (b) Zatvaranje (strukturni element 3×3); (c) Zatvaranje (strukturni element 5×5); (d) Zatvaranje (strukturni element 7×7); (e) Zatvaranje (strukturni element 9×9);

istaknut i pri korištenju većih strukturnih elemenata. Ipak, kada pješački prijelaz zauzima manji dio slike, većim strukturnim elementom može se narušiti oblik pješačkog prijelaza popunjavanjem prostora između bijelih linija. Stoga će se za slike rezolucije 640×360 koristiti kvadratni strukturni elementi do veličine 5×5 . Kod isticanja objekata pravokutnog oblika s oštrim linijama rubova, kao što su bijele linije pješačkog prijelaza, preporučljivo je koristiti i strukturni element kvadratnog ili pravokutnog oblika [61]. S druge strane, kada se na slici želi istaknuti kružne oblike zaobljenih rubova, tada će se za otvaranje ili zatvaranje koristiti strukturni elementi u obliku kruga ili elipse.

Osim opisane četiri osnovne morfološke operacije postoje i druge morfološke operacije i složeniji algoritmi kao što su: *top-hat* transformacija, *hit-or-miss* transformacija, stanjivanje (engl. *thinning*), zadebljavanje (engl. *thickening*), skeletonizacija (engl. *skeletonization*) i drugi. Ovi morfološki algoritmi neće biti opisani u ovom radu jer se neće koristiti u predloženim metodama i postupcima koji će biti predstavljeni u daljnjim poglavljima.

3.3. Morfološka analiza slike

Primjena morfologije u analizi digitalne slike često se spominje u kontekstu sustava temeljenih na računalnom vidu [62], [63], ali i u drugim srodnim područjima poput fizike [64]. Morfološka analiza slike definira se kao analiza slike u pogledu geometrije i prostornih zavisnosti među objektima na slici. Objekti su ovdje najčešće predstavljeni bijelim površinama na crnoj podlozi binarne slike. Kod morfološke analize naglasak je na strukturnim karakteristikama takvih objekata što uključuje parametre kao što su: površina, visina, širina objekta, međusobna udaljenost među objektima, oblik objekta te njegova globalna ili relativna pozicija i orijentacija na slici. Mjerenjem, usporedbom i uočavanjem zavisnosti među navedenim parametrima moguće je izlučiti informacije korisne za rješavanje brojnih problema u sustavima zasnovanim na računalnom vidu.

Za rješavanje problema vezanih za stepenice i pješačke prijelaze postoje mnogi karakteristični parametri vezani za njihovu strukturu i oblik. Ovdje je važno promatrati njihovu strukturu i oblik kakvi će se pojaviti na dvodimenzionalnoj slici. Jedna stepenica može se opisati kao par uzastopnih horizontalnih pravokutnih oblika nastalih od gornje i prednje plohe stepenice. Skup ponavljajućih parova ovakvih oblika čine stepenište. U pravilu je svaka pojedinačna stepenica unutar istog skupa jednakih dimenzija, što će olakšati njihov pronalazak. Tako će na binarnim slikama ponavljajući uzorak u području slike gdje se nalaze stepenice biti prepoznatljiv. Upravo analizom dimenzija objekata i pojavljivanja uzoraka karakterističnih za stepenice pokušat će se izlučiti korisna informacija sa slike. Kod pješačkih prijelaza u „zebra“ obliku također se na binarnim slikama može uočiti ponavljajući uzorak kojeg čine horizontalne bijele linije

pravokutnog oblika s jednakim međusobnim razmacima. S obzirom na ustaljene dimenzije i oblike ovakvih linija pješačkog prijelaza opet će se analizom binarne slike moći dobiti korisne informacije. Kako bi se lakše pratili svi pojmovi i parametri vezani za strukturu i oblik traženih objekata, na slici 3.7. prikazani su takvi parametri s nazivima koji će biti korišteni u ostatku rada.



(a)



(b)

Slika 3.7. Pojmovi i parametri važni za morfološku analizu stepenica (a) i pješačkih prijelaza (b)

Na slici 3.7. (a) prikazani su pojmovi i parametri vezani za stepenice, a na slici 3.7. (b) za pješačke prijelaze. Oba primjera uključuju prikaz na slici u boji i na binarnoj slici.

4. METODA ZA DETEKCIJU STEPENICA ZASNOVANA NA VERTIKALNOJ I HORIZONTALNOJ ANALIZI SLIKE


U nastavku je opisana predložena metoda za detekciju stepenica [65] te su prikazani eksperimentalni rezultati u pogledu uspješnosti detekcije i brzine izvođenja. Predložena metoda za detekciju stepenica može se podijeliti na tri glavna koraka. Prvi je korak predobrada (engl. *preprocessing*), potom slijedi vertikalna analiza i na kraju horizontalna analiza nakon koje se donosi odluka o detekciji stepenica. Na kraju poglavlja dani su eksperimentalni rezultati gdje se testirala odgovarajuća rezolucija ulazne slike, uspješnost i performanse metode.

4.1. Predobrada

Prije same predobrade važno je, s obzirom na problem koji se rješava, utvrditi treba li se koristiti ulazna slika u boji ili je dovoljno koristiti sliku u sivim tonovima (engl. *grayscale*). Obrada slike u sivim tonovima bit će vremenski manje zahtjevnija, pa se u slučajevima gdje boja nije presudna za samu detekciju preporuča korištenje takve ulazne slike. S obzirom na to da se stepenice i njihova okolina mogu pojaviti u različitim bojama, na temelju boje ne možemo dobiti nikakve dodatne informacije koje bi olakšale daljnju detekciju. Stoga će se kao ulazni podaci za predobradu koristiti slike u sivim tonovima.


Predobrada je često početni korak za probleme detekcije i prepoznavanja objekata na digitalnoj slici. Predobrada se najčešće odnosi na poboljšanje kvalitete ulazne slike ili naglašavanje objekata koje je potrebno detektirati. Naglašavanje objekata za njihovu lakšu prepoznatljivost moguće je izvršiti i degradacijom slike kao što je recimo binarizacija kojom dobivamo sliku koja se sastoji od piksela čiji intenzitet isključivo mogu biti dvije krajnje vrijednosti (0 i 255). Cilj je ovog koraka pojednostaviti reprezentaciju objekata u slici i prikazati ih isključivo crnom i bijelom bojom. Pritom je važno ukloniti što je više moguće nepotrebne detalje iz okoline, a istovremeno sačuvati glavne karakteristike područja interesa na slici. Kod stepenica će biti važno sačuvati obrise približno paralelnih horizontalnih ploha koje čine stepenice, dok će detalji s ostatka slike biti svedeni na minimum.

Primjer ulazne slike u sivim tonovima koja sadrži stepenice prikazan je na slici 4.1. (a) i takva slika prolazi predobradu koja se ovdje izvodi pomoću dva postupka. Prvi je postupak predobrade primjena Canny detektora rubova koji se često koristi za dobivanje binarne slike s istaknutim rubovima objekata na slici [59]. Uz Canny detektor rubova najčešće su korišteni Sobel i Prewitt detektori. Glavna je prednost Canny detektora rubova u odnosu na ove algoritme manja



Slika 4.1. Predobrada: (a) Ulazna slika sa stepenicama; (b) Canny detektor rubova; (c) Operacija zatvaranja

osjetljivost na šum u slici što će u konačnici rezultirati jasnijim binarnim prikazom objekata [66]. Pri tome će Canny detektor rubova zadržati glavne detalje i učiniti ih prepoznatljivim na slici. Istovremeno, odabirom ove vrste detektora gubi se potreba za primjenom algoritama za smanjivanje šuma u procesu predobrade i uvođenja dodatnih parametara u tu svrhu. Eksperimentalno su određeni odgovarajući parametri [67] koje je potrebno postaviti prilikom primjene Canny detektora rubova. Prvi parametar koji treba postaviti prag je za pronalazak ruba koji je ovdje postavljen na vrijednost 30. O ovom će parametru ovisiti kakav će prijelaz u




Slika 4.2. Predobrada: (a) Ulazna slika bez stepenica; (b) Canny detektor rubova; (c) Operacija zatvaranja

intenzitetu piksela biti tretiran kao rub. Drugi je parametar prag za spajanje rubova koji je postavljen na 80 i o njemu će ovisiti u kojoj će se mjeri detektirani rubovi spajati u neprekinute nizove. Iako je detekcijom rubova iz slike uklonjen dobar dio nevažnih detalja, i dalje su prisutni neki nepoželjni rubovi koji mogu omesti kasniju detekciju, što je vidljivo na slici 4.1. (b). Stoga se provodi drugi postupak predobrade, a to je primjena morfološke operacije zatvaranja (engl. *closing*) [68]. Operacijom zatvaranja popunjavaju se uski prolazi između bijelih kontura dobivenih prethodnim korakom te se nakon tri iteracije ovog postupka dobiva slika kakva je vidljiva na slici

4.1. (c). Za operaciju zatvaranja korišten je strukturni element kvadratnog oblika veličine 5×5 što će nakon tri iteracije rezultirati pojavljivanjem kvadratnih i pravokutnih oblika na slici. Na takvoj predobrađenoj slici ostaju sačuvani pravokutni oblici karakteristični za područje stepenica. Takvi pravokutni oblici, bilo crne ili bijele boje, predstavljaju gornju i prednju plohu pojedine stepenice. Nepotrebni detalji iz okoline nakon predobrade također poprimaju pravokutne oblike, ali njihovo pojavljivanje i raspored u prostoru razlikuje se od onog u području stepenica i upravo će ta razlika u nastavku biti iskorištena za detekciju. Osim što je postupkom predobrade na slici istaknuto sve važno za detekciju, istovremeno su pojednostavljivanjem eliminirani i negativni utjecaji različitih uvjeta osvjetljenja, slabog kontrasta i neizoštrenih slika. Binarna slika dobivena predobradom prosljeđuje se na sljedeći korak - vertikalnu analizu. Primjer procesa predobrade na slici koja ne sadrži stepenice prikazan je na slikama 4.2. (a)-(c). Ulazne i predobrađene slike mogu se također vidjeti i na pozitivnom primjeru sa stepenicama na slikama 4.4. (a) i (b) te na negativnom primjeru bez stepenica na slikama 4.5. (a) i (b).

4.2. Vertikalna analiza


Područje stepenica okarakterizirano je uzastopnim približno horizontalnim i paralelnim linijama koje predstavljaju rubove. Iz tog razloga, većina znanstvenih istraživanja u području detekcije stepenica temelji se na detektiranju paralelnih linija kao rubova stepenica. Glavni su



Slika 4.3. Promjena visina gornjih i prednjih ploha stepenica s obzirom na perspektivu snimanja

nedostaci ovakvog pristupa mogućnost pojavljivanja drugih horizontalnih linija na stepenicama uslijed uzoraka na materijalu kojim su stepenice izrađene. Također, ovakve metode počivaju na pretpostavci da će rubovi biti dobro detektirani, iako to često nije slučaj. Detektirani rubovi često su isprekidani, a ponekad i u većoj mjeri zaklonjeni drugim objektima na stepenicama. Kako bi se izbjegle pogreške uzrokovane ovakvim horizontalnim pristupom, u ovom radu predlaže se metoda u kojoj je naglasak na vertikalnoj analizi. U vertikalnom pristupu cilj je iskoristiti zavisnosti u svakom stupcu slike koje se pojavljuju u području stepenica zbog perspektive snimanja. Tako će stepenice koje su dalje od kamere na slici izgledati manje, a one bliže kameri veće kao što to prikazuje slika 4.3. Točnije, visine gornjih (y_2 , y_4 i y_6) i prednjih (y_1 , y_3 , y_5 i y_7) ploha stepenica postepeno će se povećavati od vrha prema dnu.

Vertikalna analiza izvodi se na binarnoj slici dobivenoj predobradom. Za razliku od traženja horizontalnih paralelnih linija, ovdje se vrši analiza piksela u svakom stupcu takve binarne slike. Računaju se duljine nizova piksela iste boje unutar stupca te se uspoređuju duljine susjednih nizova




Slika 4.4. Vertikalna analiza slike sa stepenicama: (a) ulazna slika; (b) predobrađena slika; (c) graf izmjenjivanja crnih i bijelih duljina nizova u stupcu (BCC); (d) graf potencijalnih stepenica po stupcu (SPC)

iste boje od vrha prema dnu slike. Ovi nizovi piksela crne ili bijele boje određuju visinu prednjih ili gornjih ploha stepenica. S obzirom na to da postoji mogućnost da nakon predobrade i gornje i prednje plohe na binarnoj slici poprime istu boju, osim susjednih uspoređivat će se i svaki drugi niz iste boje. Ako se duljina susjednih nizova crnih ili bijelih piksela povećala za 1 do 30 %, takav prijelaz u duljini računa se kao potencijalna stepenica. Ovaj uvjet prikazan je izrazom (4-1):

$$1.01 \leq k = \frac{y_i}{y_{i-1}} \leq 1.3 \quad (4-1)$$

gdje je k koeficijent uvećanja duljine niza jednakih piksela y_i u odnosu na prethodni od vrha prema dnu stupca, a i redni broj takvog niza. Slično je i s provjerom svakog drugog niza gdje se isti koeficijent k treba dobiti omjerom duljina svakog drugog niza piksela iste boje prema izrazu (4-2).

$$1.01 \leq k = \frac{y_i}{y_{i-2}} \leq 1.3 \quad (4-2)$$



Slika 4.5. Vertikalna analiza slike bez stepenica: (a) ulazna slika; (b) predobrađena slika; (c) graf izmjenjivanja crnih i bijelih duljina nizova u stupcu; (d) graf potencijalnih stepenica po stupcu (SPC)

Nakon usporedbe duljina svih susjednih bijelih ili crnih nizova dobiva se broj potencijalnih stepenica u pojedinom stupcu slike. Kao što je ranije spomenuto, ideja ovog postupka je u tome da će se na slici prednja i gornja ploha stepenice postupno povećavati što su bliže kameri [69]. Traženi postotak povećanja (1 – 30 %) dobiven je eksperimentalno, a graf na slici 4.4. (c) prikazuje kako se duljine nizova crnih i bijelih piksela izmjenjuju kroz jedan stupac slike od vrha prema dnu. Za ovaj prikaz odabran je stupac s najviše potencijalnih stepenica (engl. *BCC - best column case*). Na grafu su također brojevima označeni traženi prijelazi u duljinama nizova koji predstavljaju potencijalne stepenice. Ovakvi podnizovi izgledaju približno kao geometrijski nizovi [70] jer se postepeno povećavaju za određeni koeficijent koji ovdje nije fiksiran, ali varira u određenim granicama. Na primjeru slike bez stepenica (Slika 4.5. (c)) graf ne pokazuje takve nizove kojima se duljina postupno povećava što ukazuje da se radi o stupcu u kojem nema puno potencijalnih stepenica.

Ponavljajući ovaj proces uspoređivanja na svakom stupcu slike, dobiva se broj potencijalnih stepenica po stupcu koji je prikazan grafom na slici 4.4. (d). Graf prikazuje podatke za svih 640 stupaca slike i jasno je vidljivo da su povišene vrijednosti prisutne na onim područjima slike gdje se nalaze stepenice. Slika 4.5. (d) prikazuje graf potencijalnih stepenica po stupcu na primjeru slike koja ne sadrži stepenice. Ovdje krivulja rijetko prelazi vrijednost od tri potencijalne stepenice po stupcu i to će se smatrati nedostatnim za potvrdu postojanja stepenica na takvoj slici. Kako bi se stekao dojam na kojim su mjestima određene potencijalne stepenice na slikama 4.6. (a) i (b) točkama su prikazana mjesta gdje je na temelju vertikalne analize binarne slike uočen prijelaz karakterističan za stepenice.

Kako bi se vertikalnom analizom detektiralo više od tri potencijalne stepenice, potrebno je napraviti usporedbu barem četiri uzastopne plohe koje će u stvarnosti činiti barem dvije stepenice, pa se smatra da metoda može detektirati najmanje stepenište koje se sastoji od dvije stepenice. Za nastavak metode za detekciju stepenica broji se svaki stupac s više od tri potencijalne stepenice te se, ako slika sadrži barem deset takvih stupaca, prosljeđuje na daljnju analizu. U suprotnom se slika zbog nedovoljnog broja stupaca sa značajnijim brojem potencijalnih stepenica odbacuje, te se odmah donosi odluka da na slici nema stepenica.

4.3. Horizontalna analiza


Posljednji je korak metode horizontalna analiza koja se može smatrati nekom vrstom dodatne provjere. Ona se izvodi na slici koja je generirana upravo od spomenutih stupaca koji sadrže više od tri potencijalne stepenice kao odabrano područje interesa. Prema tome su generirane



Slika 4.6. Točke na mjestima gdje su vertikalnom analizom uočene potencijalne stepenice na slici: (a) sa stepenicama; (b) bez stepenica

slike uže od ulaznih slika, a dodatno su odrezane na vrhu i dnu kod najniže i najviše potencijalne stepenice. Primjeri takvih slika nalaze se na slici 4.7.

Generirane slike koje su nastale iz ulaznih slika sa stepenicama bit će okarakterizirane širokim pravokutnim oblicima kao što je vidljivo na slici 4.7. (a). Također, takva slika ne bi trebala imati puno horizontalnih prijelaza između crnih i bijelih piksela, ako su stupci koji tvore sliku potekli iz područja stepenica s ulazne slike. S druge strane, ako stepenice nisu bile prisutne na ulaznoj slici, to znači da su stupci od kojih je nova slika generirana slučajno prošli vertikalnu analizu zbog svojih karakteristika i oni su najčešće iz različitih područja slike kao što pokazuje




Slika 4.7. Generirane slike područja interesa iz ulazne slike: (a) sa stepenicama ($HE = 24,12$); (b) bez stepenica ($HE = 1,44$)

primjer na slici 4.7. (b). Kako bi se utvrdilo radi li se o slučajnim stupcima ili stupcima iz područja stepenica računa se parametar nazvan horizontalna energija (HE) prema formuli (4-3):

$$HE = \frac{\sum_{i=0}^h l_{max}(i)}{\sum_{i=0}^h tr(i)} \quad (4-3)$$

gdje je h visina slike, $l_{max}(i)$ duljina najdužeg niza uzastopnih bijelih ili crnih piksela u redu i , dok je $tr(i)$ broj prijelaza u svakom redu i . Na ovaj način može se odrediti jesu li stepenice dobro otkrivene nakon vertikalne analize ili je došlo do krive pretpostavke, jer će parametar HE imati značajno veće vrijednosti za slike koje su generirane iz onih koje na sebi sadrže stepenice, dok će u suprotnom vrijednost HE biti manja. Eksperimentalno je određen prag ($HE = 2$) te se konačna odluka o detekciji stepenica donosi ovisno je li HE manja ili veća od vrijednosti praga. Eksperimentalno određivanje praga prikazano je na slici 4.8. gdje se na grafu nalaze stvarne vrijednosti koje poprima HE na skupu ulaznih slika sa stepenicama i bez stepenica. Određeno je da kada se na slici dobije horizontalna energija veća od 2, stepenice su detektirane, dok u suprotnom slika ne sadrži stepenice.



Slika 4.8. Horizontalna energija na skupu slika sa stepenicama i bez stepenica

4.4. Eksperimentalni rezultati

Kako bi se testirala uspješnost predložene metode i mogućnost izvođenja u stvarnom vremenu, provedena su sljedeća ispitivanja: analiza odabira rezolucije ulazne slike, uspješnost detekcije stepenica i brzina izvođenja algoritma.

4.4.1. Analiza odabira rezolucije

U ovakvim zadacima računalne obrade slike gdje je cilj dobivati korisne informacije u stvarnom vremenu iznimno je važan odabir rezolucije ulazne slike. Iako nam današnje kamere omogućuju snimanje u visokim rezolucijama (1080×1920 i više), obrada takvih slika vremenski je zahtjevna pa je upitna mogućnost primjene u stvarnom vremenu. O rezoluciji ulazne slike ovisit će ukupna brzina izvođenja po slici, ali i uspješnost same detekcije. Stoga je važno pronaći odgovarajuću rezoluciju ulazne slike i postići kompromis između uspješnosti detekcije i brzine izvođenja. Prema sličnim istraživanjima [71], [47] i [49] u području računalne obrade slike za detekciju stepenica najčešće je korištena rezolucija 640×480 piksela. Ipak, neka istraživanja upućuju na mogućnost očuvanja korisnih vizualnih informacija i na slikama izrazito niske rezolucije za potrebe usmjeravanja slijepih osoba [72]. Slično je i kod primjene računalne obrade slike na drugim problemima poput prepoznavanja lica [73], gdje je dokazana mogućnost

smanjivanja rezolucije do 21×21 . Smanjivanje rezolucije često se razmatra u slučajevima gdje je prisutna velika količina šuma, kao što su medicinske slike [74]. Također, višerezolucijski pristupi nužni su u situacijama gdje se objekti koje treba prepoznati pojavljuju u različitim rezolucijama zbog udaljenosti od kamere kao što je slučaj kod prepoznavanja pješaka u radu [75].

Za testiranje različitih ulaznih rezolucija slike uz inicijalno odabranu rezoluciju 640×360 odabrane su još četiri rezolucije: 1920×1080 , 1280×720 , 320×180 , 180×90 . Kako bi se predloženi algoritam za detekciju stepenica mogao testirati na različitim rezolucijama ulaznih slika, potrebno je utvrditi koje parametre u koracima algoritma treba prilagoditi kako bi rezultatna binarna slika za morfološku analizu bila strukturno slična pri svakoj rezoluciji. Najveće razlike uzrokovane različitim ulaznim rezolucijama vidljive su u koracima predobrade. Binarna slika nakon primjene Canny detektora rubova i morfološke operacije zatvaranja u velikoj mjeri ovisi o rezoluciji, stoga je nužno prilagoditi parametre korištene prilikom izvođenja spomenutih koraka predobrade.

Canny detektor rubova koristi dva osnovna parametra od kojih se prvi odnosi na prag za pronalaženje rubova, a drugi na prag za povezivanje rubova. Prvi parametar nije ovisan o rezoluciji i odnosi se samo na razlike u intenzitetima piksela, dok drugi parametar treba biti prilagođen. Na višim rezolucijama potrebno je povezati više rubova pa će se prag za povezivanje rubova smanjiti, dok ga u suprotnom, kod manjih rezolucija, treba povećati. Sljedeća radnja primjena je morfološke operacije zatvaranja gdje je potrebno prilagoditi dva parametra. Prvi je parametar veličina strukturnog elementa koji je obično kvadratnog oblika (npr. 3×3 piksela). Kako bi se vidio učinak operacije zatvaranja, s povećanjem ulazne rezolucije potrebno je povećavati i strukturni element. Operacija zatvaranja često se provodi u nekoliko iteracija kako bi se poboljšao njezin učinak. S obzirom na to da se u predloženoj metodi operacija zatvaranja koristi za uklanjanje nepotrebnih detalja na binarnoj slici, na višim rezolucijama bit će potreban poboljšan učinak zatvaranja. Stoga je sljedeći parametar koji se mora prilagoditi broj iteracija koji se povećava s povećanjem rezolucije. Svi prilagođeni parametri za predobradu na slikama različitih rezolucija dani su u tablici 4.1.

U daljnjim koracima metode, gdje se radi vertikalna i horizontalna analiza binarne slike dobivene predobradom, ne postoje parametri koje treba prilagođavati s obzirom na rezoluciju slike. Postupak vertikalne analize zasnovan je na relativnoj usporedbi susjednih nizova na slici, dok se kod horizontalne analize računa prosječna vrijednost neovisna o rezoluciji slike.

Konačan rezultat prilagodbe parametara u predobrađi vidljiv je na slici 4.9. gdje su prikazane ulazne slike u pet rezolucija i pripadajuće binarne slike nakon preobrade. Vidljivo je da se


Tablica 4.1. Prilagođeni parametri za predobradu

Rezolucija [px]	Canny detector rubova	Operacija zatvaranja	
	Prag za povezivanje rubova	Veličina strukturnog elementa	Broj iteracija
<i>160×90</i>	120	3×3	2
<i>320×180</i>	100	3×3	2
<i>640×360</i>	80	5×5	3
<i>1280×720</i>	60	7×7	4
<i>1920×1080</i>	40	7×7	5

prilagodбом parametara zadržala slična binarna struktura slika kod četiri više rezolucije (od 320×180 do 1920×1080), dok je jedino kod najniže rezolucije (160×90) uočeno značajnije odstupanje od ostalih binarnih slika.

Analiza odabira rezolucije izvršena je tako da je prikupljen reprezentativni uzorak od 68 slika izdvojenih iz video isječaka od kojih je 42 sadržavalo stepenice, a ostalih 26 nije. Odabrani su trenuci kada je osoba bila udaljena od stepenica 1 do 3 metra gdje stepenice zauzimaju barem 25 % prostora slike. Slike su inicijalno snimljene u rezoluciji 1920×1080 piksela, a onda su naknadno za potrebe istraživanja smanjene na ostale ispitivane rezolucije, kako bi istu sliku mogli testirati u 5 različitih rezolucija. Za potrebe smanjivanja rezolucije korištena je Lanczos metoda [76]. Potom su sve slike podvrgnute predobradi s prilagođenim parametrima kako je navedeno ranije, te vertikalnoj i horizontalnoj morfološkoj analizi. Kod testiranja uspješnosti detekcije stepenica pri različitim ulaznim rezolucijama pokazalo se da je najveća uspješnost od 95.2 % postignuta kod ulazne rezolucije 640×360 piksela. Niže rezolucije očekivano daju nešto slabiji postotak uspješnih detekcija, dok je zanimljivo da na višim rezolucijama poput 1280×720 i 1920×1080 postotak detekcije također opada. Više rezolucije zadržavaju puno više detalja koji su u ovom slučaju čak nepoželjni i otežavaju detekciju. Kod slika koje ne sadrže stepenice uspješnost metode relativno je ujednačena za sve testirane rezolucije. Nije uočen značajniji utjecaj rezolucije na točnost detekcije, osim blagog povećanja broja slučajnih krivih detekcija na visokim rezolucijama zbog količine detalja koje takve slike sadrže. Ukupni rezultati uspješnosti na svim rezolucijama dani su u tablici 4.2. i vizualno prikazani na grafu na slici 4.10.

Kao što graf na slici 4.11. prikazuje, vrijeme izvođenja uvelike ovisi o ulaznoj rezoluciji slike. Obrada slika u višim rezolucijama (1280×720 i 1920×1080) značajno je duža i čini ih




Slika 4.9. Ulazne slike (a) i binarne slike nakon predobrade (b) u različitim rezolucijama

Tablica 4.2. Uspješnost detekcije i brzina izvođenja na slikama različitih rezolucija


Ulazna rezolucija slike	Uspješnost detekcije		Prosječno vrijeme izvođenja (po slici)
	Sa stepenicama	Bez stepenica	
<i>160×90</i>	40,5 %	96,2 %	12 ms
<i>320×180</i>	71,4 %	92,3 %	38 ms
<i>640×360</i>	95,2 %	96,2 %	140 ms
<i>1280×720</i>	83,3 %	88,5 %	585 ms
<i>1920×1080</i>	71,4 %	84,6 %	1435 ms

neprihvatljivim za korištenje u stvarnom vremenu. Kod nižih rezolucija (320×180 i 160×90) moguće je obrađivati gotovo sve slike iz video isječaka snimljenih frekvencijom od 30 slika u sekundi. S obzirom na to da obrada svih slika iz video isječaka nije nužna za rad u stvarnom vremenu, vrijeme izvođenja pri rezoluciji 640×360 od 140 ms po slici i dalje je prihvatljivo.

Ova analiza pokazala je da više rezolucije nužno ne donose bolje razine uspješnosti detekcije. Ove činjenice upućuju da je ovakve rezolucije prikladno koristiti kada je udaljenost s koje je potrebno prepoznati stepenice znatno veća. S druge strane, ekstremno mala rezolucija 160×90 nije prihvatljiva za korištenje s metodama koje ovise o morfološkim operacijama i



Slika 4.10. Graf uspješnosti na slikama različitih rezolucija za slučajeve sa stepenicama i bez stepenica



Slika 4.11. Graf vremena izvođenja na slikama različitih rezolucija

strukturnim karakteristikama binarne slike. Pri tako malim rezolucijama u binarnim slikama obično se ne sačuva dovoljno informacija za detekciju objekata poput stepenica. Ipak, eksperiment je pokazao da rezolucija 320×180 u određenim situacijama može polučiti dobre rezultate i ima potencijal za primjenu i daljnje unapređenje metode kako bi bila prikladna za ovu rezoluciju. U ovoj fazi, inicijalno odabrana rezolucija 640×360 predstavlja najbolji kompromis između uspješnosti detekcije i brzine izvođenja, pa će daljnje opsežnije testiranje biti provedeno na video isječcima i slikama u toj rezoluciji.

4.4.2. Uspješnost detekcije

Nakon što je prethodno izvršena analiza odabira odgovarajuće rezolucije, slijedi testiranje uspješnosti predložene metode korištenjem ulaznih podataka u odabranoj rezoluciji 640×360. Za evaluaciju uspješnosti predložene metode prikupljeni su ulazni podaci, odnosno video isječci koji sadrže scene sa stepenicama, ali isto tako i one koji ne sadrže stepenice. U ovakvim i sličnim istraživanjima, osim pravilne detekcije stepenica, važno je imati i što manji broj pogrešnih pozitivnih detekcija (engl. *false positives*) u slučajevima gdje stepenice nisu prisutne na video isječku. Za potrebe testiranja, iz prikupljenih video isječaka koji sadrže stepenice (pozitivni) izdvojeno je 120 slika u trenutku kada se korisnik nalazio ispred stepenica. Isti postupak proveden je i na video isječcima koji ne sadrže stepenice (negativni) gdje je izdvojeno 120 slika odabranih u proizvoljnom trenutku. Iako se u pojedinim sličnim istraživanjima koriste pojedinačne statične fotografije za testiranje, u ovom radu korištene su isključivo slike izdvojene iz video isječaka (engl.

frames) kako bi uvjeti bili što sličniji stvarnim. Stvarni uvjeti podrazumijevaju da će kamera snimati isječke u kretanju te će zbog trešnje često dati djelomično zamućene (engl. *blurred*) ili nedovoljno fokusirane slike s obzirom na to da kamera snima 30 slika u sekundi.


Za prikupljanje video isječaka korištene su dvije kamere: kamera s mobilnog uređaja HTC One A9s [77] i akcijska kamera SJCAM 4000 [78]. Obje kamere imaju mogućnost snimanja do rezolucije 1920×1080 piksela frekvencijom 30 slika u sekundi. Detaljne značajke korištenih kamera dane su u prilogima P.1. i P.2. Glavna razlika između korištenih kamera je što kamera SJCAM 4000 ima širokokutnu leću, dok kamera s mobilnog uređaja nema. Širokokutna leća u korištenoj kameri pokriva horizontalni kut od 170° što omogućava širi pogled na okolinu korisnika. S druge strane, kamere sa standardnom lećom kakve se ugrađuju u današnje mobilne telefone u pravilu pokrivaju kut od oko 70°. Iz spomenutog razloga širokokutne kamere sve se češće koriste u istraživanjima što je posebno izraženo u pomoćnim sustavima za automobilsku industriju [79]. U testiranju koje je provedeno u ovom radu korištene su dvije vrste kamere kako bi se pokazala robusnost metode s obzirom na vrstu ulaznih podataka. Poznato je da će širokokutna kamera dati specifična izobličenja (engl. *barrel effect*), posebno na rubovima slike. Istraživanje je pokazalo da će metoda temeljena na vertikalnoj i horizontalnoj analizi biti uspješna i u slučajevima gdje rubovi stepenica nisu potpuno ravni, nego su zbog spomenutog izobličenja zaobljeni. Stoga se može reći da je razvijena metoda kompatibilna sa širokokutnom slikom na ulazu za razliku od drugih sličnih metoda koje su testirane samo na ulaznoj slici snimljenoj kamerom sa standardnom lećom ili su korištene dodatne metode za optimizaciju izobličenja širokokutne slike kao što je primjerice predloženo u radu [80]. Slike 4.12. (a) i (b) prikazuju razliku između vidnog polja kod korištenja standardne i širokokutne kamere. Ovdje je važno napomenuti da su obje slike snimljene s jednake udaljenosti od stepenica, a vidljivo je da širokokutna kamera pokriva znatno veći prostor ispred korisnika. Na slici 4.12. (b) vide se zaobljeni rubovi i izobličenja koja nastaju uslijed korištenja širokokutne leće.

Prilikom odabira testnih uzoraka slika važno je odabrati reprezentativne primjere i okruženja u kojima se osobe obično kreću. Za testiranje su odabrane sljedeće lokacije: hodnici i predvorja zgrada, pješačke staze, kuće i dvorišta. Također, kako bi uzorak bio što reprezentativniji, ulazni skup podataka sadrži isječke sa slabijim kontrastom, nedovoljno fokusirane i one snimljene u različitim svjetlosnim uvjetima. Na kraju, važno je testirati metodu na stepenicama i površinama koje imaju različite teksture kako bi se utvrdilo koliko je metoda univerzalna i primjenjiva na vizualno različitim stepenicama.

Rezultati dobiveni na skupu uzoraka od 240 slika izdvojenih iz video isječaka prikazani su u tablici 4.3. Postignuta je uspješnost detekcije stepenica od 95.8 %, dok je s druge strane bilo samo 2.5 % krivih detekcija u slučajevima gdje stepenice nisu bile prisutne na slici. Iako algoritam radi dobro s ulaznim isječcima snimljenim u različitim svjetlosnim uvjetima, pokazuje nešto bolje rezultate na onim isječcima snimljenim na otvorenim prostorima. Većina pogrešaka u detekciji



(a)



(b)

Slika 4.12. Vidno polje kod stepenica korištenjem: (a) standardne kamere; (b) širokokutne kamere

Tablica 4.3. Uspješnost predložene metode za detekciju stepenica i sličnih metoda

	Predložena metoda		Shahrabadi et al. [27] (2D kamera)		Wang et al. [48] (3D kamera)	
	Da	Ne	Da	Ne	Da	Ne
<i>Stepenice</i>	Da	Ne	Da	Ne	Da	Ne
<i>Br. ulaznih podataka</i>	120	120	92	135	106	70
<i>Detektirano</i>	115	3	76	25	103	0
<i>Uspješnost</i>	95.83 %	97.50 %	82.61 %	81.48 %	97.17 %	100.00%

nastaje zbog lošeg osvjetljenja u unutarnjim prostorima, zbog nepredvidivih prepreka na samim stepenicama ili zbog specifičnih tekstura sličnih stepenicama na ostalim površinama, najčešće podovima.


U tablici 4.3. vidljivi su i rezultati sličnih metoda iz literature, ali je ipak teško uspoređivati postotke uspješnosti jer svaka je metoda testirana na različitim ulaznim podacima. Prema tome, svaka ocjena metoda donekle je subjektivna jer su metode često prilagođene upravo za određenu vrstu stepenica u određenom okruženju kakve se i nalaze u ulaznom skupu podataka.

Primjeri na slici 4.13. prikazuju neke karakteristične situacije sa stepenicama i bez stepenica. Slika 4.13. (a) prikazuje uspješnu detekciju stepenica na širokokutnoj ulaznoj slici gdje su stepenice pozicionirane točno ispred kamere u unutarnjem prostoru. Potom je na slici 4.13. (b) primjer gdje su stepenice detektirane iako je kamera usmjerena prema njima pod određenim kutom. Slika 4.13. (c) prikazuje detekciju stepenica u unutarnjem prostoru i otežanim uvjetima gdje se na stepenicama nalaze dodatni objekti različite boje i oblika u odnosu na same stepenice. Na slici 4.13. (d) stepenice su u vanjskom prostoru detektirane bez obzira na ponavljajuće geometrijske uzorke u njihovoj okolini. Slike 4.13. (e) i (f) prikazuju situacije kada su uspješno detektirane stepenice prema dolje. Problematika detekcije stepenica čiji je smjer prema dolje uvelike ovisi o pozicioniranju i usmjeravanju kamere postavljene na korisnika. Za razvijenu metodu može se reći da uspješno detektira stepenice prema dolje, ali samo kada je korisnik već došao na malu udaljenost od ruba prve stepenice i kada je kamera blago zakrenuta prema dolje. Zbog navedenih ograničavajućih okolnosti važno je staviti dodatni naglasak na što bržu detekciju kako bi stepenice bile detektirane na vrijeme. U ovakvim slučajevima, kada treba detektirati stepenice koje idu prema dolje, u prednosti je ranije spomenuta širokokutna kamera jer će dati i nešto veći vertikalni kut vidnog polja. Na kraju, primjeri na slikama 4.13. (g) i (h) prikazuju situacije u unutrašnjim i vanjskim prostorima gdje stepenice nisu prisutne i prema razvijenoj


metodi nema pogrešne detekcije iako slika sadrži oblike koji potencijalno mogu biti nalik stepenicama i otežati donošenje odluke.



(a)



(b)




(c)



(d)



(e)



(f)



(g)



(h)

Slika 4.13. Primjeri testiranja algoritma za detekciju stepenica: (a) – (c) Scene stepenica u zatvorenim prostorima; (d) Scena stepenica u vanjskom prostoru; (e) – (f) Scene stepenica prema dolje; (g) – (h) Scene bez stepenica

Na slikama 4.14. (a) i (b) prikazani su neki od slučajeva kada stepenice nisu bile prepoznate razvijenom metodom. Slike prikazuju i detektirane rubne točke kojih nema dovoljno kako bi se donijela odluka o detekciji stepenica. Primjer na slici 4.14. (a) ukazuje na to da je glavni uzrok eventualnih neuspješnih detekcija slabija osvjetljenost u unutarnjim prostorima koja otežava prepoznatljivost rubova stepenica. To je posebno uočljivo kod tamnih stepenica u smjeru prema



(a)



(b)

Slika 4.14. Primjeri neuspješnih detekcija na slikama sa stepenicama

dolje gdje postoji mogućnost da će se sve stepenice stopiti u jednoliku cjelinu na slici. Drugi primjer na slici 4.14. (b) prikazuje slučaj kada se mali dio stepenica nalazi s bočne strane okomito na smjer kretanja što rezultira nemogućnošću detekcije dovoljno rubnih točaka u području stepenica.

4.4.3. Brzina izvođenja

S obzirom na to da bi se u stvarnosti ovakvi algoritmi koristili u hodu za vrijeme kretanja slijepo osobe, brzina izvođenja vrlo je važna i može se reći da algoritam treba raditi u stvarnom vremenu (engl. *real-time*). Važno je napomenuti da u ovom kontekstu izvođenje u stvarnom vremenu ne znači nužno obradu svih 30 slika u sekundi, već obradu dovoljno slika da sustav ne zakaže [81]. Smatrat će se da je sustav zakazao ako korisnik ne dobije informaciju o detektiranim stepenicama prije nego stane na iste. Ako se pretpostavi da se korisnik kreće prosječnom brzinom hodanja, koja prema [82] iznosi 1.4 m/s, a metoda je sposobna detektirati stepenice s najmanje 1 metra udaljenosti, onda je dovoljno obraditi 2 slike u sekundi, jer će u tom slučaju korisnik prijeći samo 0.7 metara za vrijeme obrade jedne slike. Ipak, u ovakvim sustavima dobro je uvesti dodatni stupanj sigurnosti jer postoji mogućnost pogreške prilikom donošenja odluke o detekciji. Stoga se može definirati da je za sustav detekcije stepenica koji radi u stvarnom vremenu potrebna obrada barem 3 slike u sekundi.


Kao što je ranije testirano prilikom analize odabira rezolucije, vrijeme izvođenja algoritma u prosjeku je 140 ms po slici za rezoluciju 640×360 piksela. Brzina izvođenja algoritma varira od 6 do 9 slika u sekundi. To znači da neće svaka slika iz videa biti obrađena, ako je video frekvencije 30 slika u sekundi. Ipak, vidljivo je da će korisnik informaciju o stepenicama moći dobiti svakih 0.14 sekundi, odnosno na svakih prijeđenih 0.2 metra. S obzirom na raniju analizu zahtjeva za izvođenje u stvarnom vremenu, smatra se da je to dovoljno za informiranje slijepo osobe o prepreci na vrijeme, uzimajući u obzir brzinu hodanja i mogućnost detekcije s najmanje 1 metra. Ovi podaci o brzini odnose se na izvođenje na laptopu prosječnih hardverskih specifikacija. Uz testiranje na laptopu, provedeno je i testiranje na računalu iznimno malih dimenzija (*mini-PC*) koje je prikladnije za korištenje u pokretu, ali ima istovremeno slabije hardverske specifikacije. Glavne specifikacije oba uređaja za testiranje dane su u tablici 4.4. zajedno s usporednim vremenima izvođenja po slici. Detaljne značajke korištenih uređaja za testiranje dane su u prilogima P.3. i P.4. Vidljivo je da brzina izvođenja kod *mini-PC*-ja iznosi oko 491 ms što je dovoljno za obradu 2 slike u sekundi. Prema ranijem izračunu s obzirom na prosječnu brzinu hoda može se zaključiti da je to granično za izvođenje u stvarnom vremenu. Ipak, ovi rezultati ukazuju na to da će s povećanjem

Tablica 4.4. Prosječna brzina izvođenja algoritma za detekciju stepenica dobivena na prijenosnim uređajima

	Tip	Laptop	Mini-PC
Specifikacije uređaja	Model	Lenovo V310 notebook	Lenovo Ideacentre Stick 300
	Procesor	Intel i5-6200U @ 2.3 Ghz (2 jezgre)	Intel Atom Z3735F @ 1.33 GHz (4 jezgre)
	Memorija	8 GB RAM	2 GB RAM
	Dimenzije (Š×D×V)	380mm × 262mm × 22.9mm	100mm × 38mm × 15mm
	Masa	1.85 kg	0.065 kg + 0.235 kg (baterija)
	Prosječno vrijeme obrade (po slici)	140 ms	491.3 ms
Br. slika u sekundi	7.1	2	

računalne moći uređaja malih dimenzija izvođenje ovakvog algoritma u stvarnom vremenu biti moguće.

Za izvođenje na laptopu dodatno su analizirana vremena izvođenja pojedinih koraka u algoritmu, a izmjereni podaci prikazani su grafom na slici 4.15. Algoritam je podijeljen na tri glavna koraka: predobrada, vertikalna analiza i horizontalna analiza, a za svaki od tih koraka mjereno je prosječno vrijeme izvođenja na ulaznom skupu od 240 slika. Uz prosječna vremena pojedinih koraka, na slici 4.15. dani su i vremenski udjeli pojedinih koraka u cjelokupnom algoritmu. Tako je dobiveno da vertikalna analiza kao najzahtjevniji korak traje 89 % ukupnog vremena potrebnog za obradu jedne slike dok je predobrada vremenski najmanje zahtjevna uzimajući samo 3 % ukupnog vremena. Ovime je pokazano da najviše prostora za ubrzanje algoritma ima prilikom vertikalne analize, odnosno kod detekcije karakterističnih rubnih točaka. Upravo iz tog razloga u sljedećem poglavlju bit će govora o smanjivanju količine piksela koje treba obraditi kako bi se pronašle samo one rubne točke koje su važne za detekciju.



Slika 4.15. Graf prosječnih vremena izvođenja pojedinih koraka algoritma za detekciju stepenica i postotak udjela u ukupnom vremenu izvođenja

5. MULTIREZOLUCIJSKA METODA ZA DETEKCIJU PJEŠAČKIH PRIJELAZA ZASNOVANA NA MORFOLOŠKOJ ANALIZI I ENERGIJI LINIJA

Nakon što je u prethodnom poglavlju opisana razvijena metoda za detekciju stepenica, u ovom poglavlju riječ je o problemu detekcije pješačkih prijelaza koji su također kritična mjesta od posebne važnosti za slijepe osobe. Problematika detekcije pješačkih prijelaza na slici u određenoj mjeri slična je detekciji stepenica jer su oba objekta okarakterizirana horizontalnim pravokutnim oblicima. Ipak, ako govorimo isključivo o pješačkim prijelazima „zebra“ oblika, njihov izgled i boja predvidljiviji su nego kada je riječ o stepenicama. Iz tog razloga, kod detekcije pješačkih prijelaza otvara se prostor za implementaciju dodatnih mehanizama koji će taj proces ubrzati. U ovom poglavlju opisana je predložena metoda za detekciju pješačkih prijelaza multirezolucijskim pristupom. Poglavlje se sastoji od sljedećih cjelina: multirezolucijski pristup, predobrada, morfološka analiza, energija linija i eksperimentalni rezultati.

5.1. Multirezolucijski pristup

Ranija analiza odabira odgovarajuće rezolucije već je ukazala na mogućnost korištenja slike u smanjenoj rezoluciji u nekim slučajevima. Kako bi se postiglo što kraće vrijeme izvođenja algoritma za detekciju pješačkih prijelaza, predložena je obrada slike u smanjenoj rezoluciji u pojedinim koracima algoritma [83]. Predloženi algoritam za detekciju pješačkih prijelaza može se ugrubo podijeliti na dva glavna dijela: predobrada i detekcija. Svaki od spomenutih sastoji se od nekoliko koraka opisanih na slici 5.1.

Ulazne slike s kamere uzimaju se jedna za drugom i cilj je obraditi što je više moguće slika u jedinici vremena kako bi imali što ažurniju izlaznu informaciju o postojanju pješačkog prijelaza. Metoda je prilagođena za rad s ulaznim slikama veličine 640×360 piksela koja se pokazala prikladnom za prepoznavanje objekata sličnih pješačkim prijelazima s udaljenosti od 1 do 3 metra [84]. Međutim, moguće je određene korake izvoditi na slikama nižih rezolucija što značajno ubrzava obradu jer se količina piksela koje treba obraditi višestruko smanjuje. Ovisno o zahtjevnosti pojedine radnje određeni su koraci u kojima je moguće doći do željenog rezultata korištenjem slike smanjene rezolucije, a ti koraci naglašeni su u nastavku.


Sama činjenica da se pješački prijelaz sastoji od bijelih linija na sivoj pozadini (cesti) govori da se potencijalna pozicija pješačkog prijelaza može odrediti samo na temelju detekcije bijele boje.



Slika 5.1. Koraci predloženog algoritma za detekciju pješачkih prijelaza

Sva područja koja sadrže veće količine bijele boje mogu se smatrati potencijalnim područjima interesa koja mogu, ali i ne moraju sadržavati pješачki prijelaz. Takvih područja moguće je imati više, a moguće je i da na pojedinoj slici ne bude niti jedno takvo područje. S obzirom na to da za detekciju područja bijele boje nije nužna visoka rezolucija slike, ovo je prvi dio metode koji se izvodi na slici snižene rezolucije. Za predobradu kojoj je cilj pronaći područja interesa na temelju bijele boje, koristi se slika u rezoluciji 80×45 piksela. Daljnja morfološka obrada i analiza izdvojenih područja interesa vrši se na slikama u inicijalnoj rezoluciji, ali se pritom izbjegava procesiranje nepotrebnih piksela koji se nalaze izvan područja interesa. Drugi dio koji se izvodi na smanjenoj slici izračun je energije linija temeljene na detektiranim rubnim točkama pješачkog prijelaza. Potencijalni daljnji koraci lokalizacije točnog područja pješачkog prijelaza i traženja najsigurnijeg puta za korisnika mogu se odvijati na slici u originalnoj rezoluciji.

Ovakav promjenjivi ciklus obrade slike prikazan je na slici 5.2. Promatrajući rezoluciju kroz vrijeme obrade prema izgledu smanjujućih i rastućih sekvenci ovakav pristup zvat će se W-




Slika 5.2. W-ciklus promjena rezolucije slike

ciklusni multirezolucijski algoritam, slično kao W-ciklusni *multigrid* algoritmi za rješavanje diferencijalnih jednadžbi [85].

5.2. Predobrada

U predobradi ulazna slika priprema se za pronalaženje područja interesa. S obzirom na to da su linije pješackog prijelaza uglavnom bijele boje, tražit će se područja interesa kao bilo koja područja slike u kojima dominira bijela boja. Takva područja pretežno bijele boje trebala bi biti vidljiva i na manjim slikama pa se iz tog razloga ovaj dio metode može izvoditi na slici smanjene rezolucije. Kako bi se smanjilo vrijeme izvođenja, svi koraci predobrade izvode se na slici smanjenoj na rezoluciju 80×45 koja je 8 puta manja u širini i visini od inicijalne rezolucije. Primjer ulazne slike u rezoluciji 640×360 prikazan je na slici 5.4. (a), dok je smanjena slika prikazana na slici 5.4. (b).

Prvi korak predobrade naglašavanje je bijele boje u slici jer se digitalna reprezentacija bijele boje često razlikuje od ljudske percepcije [86] zbog različitog osvjetljenja prilikom snimanja. Tako će bijela boja na digitalnoj slici poprimiti hladniji (plavkasti) ton ako je snimljena za vrijeme oblačnog vremena, dok će poprimiti topliji (crvenkasti) ton ako je snimljena u unutrašnjim prostorima pod umjetnim osvjetljenjem ili pred zalazak sunca kao što je to prikazano na slikama 5.3. (a)-(c). Uklanjanjem utjecaja osvjetljenja i samog digitalnog senzora na sliku postiže se postojanost boja (engl. *color constancy*) [87]. S obzirom na to da je spomenuti problem



Slika 5.3. Bijela boja na digitalnoj slici snimljenoj u različitim uvjetima osvjetljenja: (a) oblačno; (b) zalazak sunca; (c) normalno dnevno svijetlo

najizraženiji na primjeru bijele boje, postupak dobivanja postojanosti boja često se naziva uravnoteženje bijele (engl. *white balancing*). Mnogi algoritmi za uravnoteženje bijele boje temelje se na pretpostavci „sivog svijeta“ (engl. *gray-world assumption*) [88]. Prema ovoj pretpostavci prikaz slike u idealnim uvjetima bez negativnog utjecaja osvjetljenja trebao bi biti sive boje, a prosječan intenzitet svakog kanala boje jednak. Za potrebe uravnoteženja bijele boje u razvijenoj metodi mijenjaju se vrijednosti intenziteta piksela za sva tri kanala slike (crveni, zeleni i plavi) prema jednadžbi (5-1) gdje je nova izmijenjena vrijednost za kanal crvene boje $f_R^*(x,y)$. Vrijednost $f_R(x,y)$ predstavlja trenutni intenzitet za kanal crvene boje u promatranom x -tom retku i y -tom stupcu, a avg_R je prosječna vrijednost kanala crvene boje na cijeloj slici. Slično vrijedi i za kanale zelene i plave boje. Siva vrijednost promatranog piksela $g(x,y)$ računa se kao težinska suma sva tri kanala [89] kao što je prikazano u (5-2). Ovaj proces ponavlja se za kanale zelene i plave boje na svakom pikselu slike i konačan rezultat vidljiv je na slici 5.4. (c).

$$f_R^*(x, y) = f_R(x, y) - (avg_R - g(x, y))$$

$$f_G^*(x, y) = f_G(x, y) - (avg_G - g(x, y))$$

$$f_B^*(x, y) = f_B(x, y) - (avg_B - g(x, y))$$
(5-1)

$$g(x, y) = 0.299 * f_R(x, y) + 0.587 * f_G(x, y) + 0.114 * f_B(x, y)$$
(5-2)



(a)



(b)



(c)



(d)



(e)



(f)

Slika 5.4. Predobrada: (a) ulazna slika u boji; (b) slika smanjene rezolucije; (c) naglašena bijela boja; (d) binarna slika; (e) binaran slika nakon morfoloških operacija; (f) detektirana područja interesa


Nakon što je bijela boja dodatno naglašena nakon uravnoteživanja, smanjena slika pretvara se u binarnu sliku. Binarizacija se odvija tako da se svaki piksel pretvara u bijelu boju ako su mu vrijednosti sva tri kanala veće od 190. Pritom mora biti zadovoljen dodatni uvjet da međusobna razlika u intenzitetima kanala nije veća od 20. Ovaj dodatni uvjet uveden je iz razloga što je na digitalnoj slici čista bijela boja okarakterizirana približno jednakim intenzitetima sva tri kanala boje. Ovime će se eliminirati oni pikseli gdje intenziteti jesu visoki (svijetla područja slike), ali ipak značajnije naginju na jednu od tri osnovne boje. Dobivena binarna slika prikazana je na slici 5.4. (d).

Kao posljednji korak predobrade provode se dvije iteracije morfološke operacije zatvaranja (engl. *closing*) nakon kojih odmah slijede dvije iteracije morfološke operacije otvaranja (engl. *opening*). Za obje morfološke operacije odabran je strukturni element veličine 3×3 . Ove morfološke operacije pomažu da se izuzmu sitna bijela područja i istovremeno popune praznine unutar većih bijelih područja kako bi ona tvorila konzistentnu cjelinu kako je prikazano na slici 5.4. (e) [62]. Svi preostali oblici bijele boje potencijalna su područja pješackog prijelaza pa opisani pravokutnik oko takvih područja predstavlja područje interesa za daljnje postupke. Pozicije i veličine detektiranih područja prenose se na sliku u originalnoj rezoluciji te se na takvoj slici radi daljnja obrada, ali isključivo na detektiranim područjima interesa koja su na slici 5.4. (f) označena crvenim pravokutnicima.

5.3. Morfološka analiza

U prethodnom koraku moguće je dobiti više potencijalnih područja interesa. Sva detektirana područja interesa dalje se analiziraju kao potencijalna područja pješackog prijelaza. Ako nije bilo detektiranih područja interesa, daljnja analiza nije potrebna i algoritam uzima sljedeću sliku iz video isječka.

Svako područje interesa obrađuje se i analizira kako bi se razlučilo sadrži li ono pješacki prijelaz ili ne. U procesu analize prvi je korak pretvaranje promatranog dijela originalne slike u binarnu sliku što je učinjeno eksperimentalno dobivenim pragom od 190 za svaki kanal boje. Ovdje je izostavljen zahtjevniji postupak pripreme slike za binarizaciju kakav je proveden na smanjenoj slici u koraku predobrade radi uštede vremena. Pokazalo se da pri ovoj rezoluciji na izdvojenim područjima interesa obična binarizacija s fiksnom vrijednosti praga daje dovoljno dobre rezultate. Nakon postupka binarizacije binarne slike područja interesa izgledaju kao na slikama 5.5. (a)-(c). Dobivene slike sadrže dovoljno informacija o svjetlijim i tamnijim područjima kao što su linije pješackog prijelaza, a istovremeno smanjuju količinu nepotrebnih podataka u slici.




Slika 5.5. Područja interesa nakon: (a)-(c) binarizacije; (d)-(f) morfološke operacije zatvaranja

Sljedeći je dodatni korak morfološka operacija zatvaranja koja se ovdje izvodi sa strukturnim elementom veličine 5×5 . Ova operacija popunjava sitnije crne prostore na bijelim linijama pješačkog prijelaza koja su uglavnom uzrokovana ispranom bijelom bojom ili mrljama na pješačkom prijelazu. Rezultat nakon zatvaranja vidljiv je na slikama 5.5. (d)-(f).


Dobivene binarne verzije područja interesa prosljeđuju se na daljnju analizu s glavnim ciljem pronalaska specifičnih točaka koje predstavljaju rubove bijelih linija pješačkog prijelaza. Takve točke bit će nazvane rubnim točkama. Metoda za detekciju rubnih točaka temelji se na povećanju vertikalnih nizova bijelih i crnih piksela što je karakteristično za područje pješačkog prijelaza slično kao što je predloženo u [65]. Ovo se događa zbog perspektive i kuta gledišta kamere što je

vizualizirano i simulirano na slikama 5.6. (a) i (b). Svaki vertikalni prijelaz s bijelog na crno označen je kao rubna točka ako se duljina bijelog niza povećala u odnosu na prethodni za 20 do 110 %. Takav koeficijent povećanja z dan je jednadžbom (5-3). Proces je sličan i za vertikalne prijelaze s crnog na bijelo gdje su uspoređene duljine uzastopnih crnih nizova piksela, a tražen je isti koeficijent uvećanja z .

$$1.2 \leq z = \frac{x_{i-1}}{x_i} \leq 2.1 \quad (5-3)$$




(a)

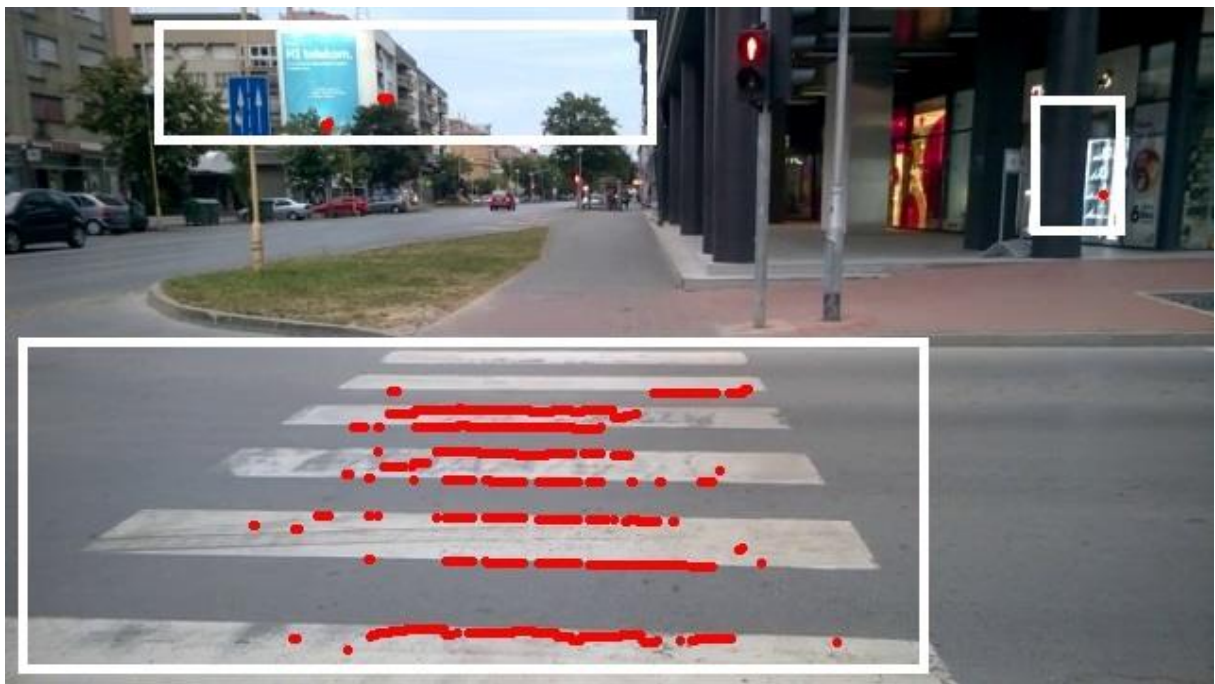


(b)

Slika 5.6. Scena s kamerom i pješačkim prijelazom: (a) Bočna perspektiva; (b) Perspektiva kamere



(a)




(b)

Slika 5.7. (a) Uvjeti detekcije rubnih točaka; (b) Detektirane rubne točke u svim područjima interesa


Ovaj postupak na binarnim slikama prikazan je na slici 5.7. (a) zajedno s algoritamskim uvjetima koji moraju biti zadovoljeni kako bi rubna točka bila detektirana. Nakon analize svakog stupca područja interesa detektirane rubne točke pješačkih prijelaza izgledaju kao na primjeru na slici 5.7. (b) gdje su crvenom bojom označene sve rubne točke u sva tri područja interesa. Najveći broj rubnih točaka očekivano se nalazi u području kojem pripada pješački prijelaz dok se u preostala dva obrađena područja nalazi tek pokoja detektirana rubna točka.

Ovaj dio algoritma zasnovan je na vertikalnoj analizi predloženoj u prethodnom poglavlju kod detekcije stepenica pa je stoga postupak analize stupaca sličan, samo su granične vrijednosti koeficijenta uvećanja prilagođene za pješačke prijelaze.

Postupak vertikalne analize stupaca kod pješačkih prijelaza prikazan je na slici 5.8. Ovdje se vertikalna analiza izvršava samo na određenim područjima interesa, a jedno takvo područje koje sadrži pješački prijelaz prikazano je na slici 5.8. (a), dok je isto područje nakon binarizacije i morfološke obrade prikazano na slici 5.8. (b). Izvršavanjem vertikalne analize u označenom stupcu (BCC) dobiva se karakterističan graf uvećanja duljina susjednih nizova iste boje prikazan na slici 5.8. (c). Ponavljanjem postupka za sve stupce može se dobiti graf potencijalnih rubova (rubnih točaka) pješačkog prijelaza po stupcu kao što je prikazano na slici 5.8. (d). Ovdje je vidljivo da u području pješačkog prijelaza broj rubnih točaka po stupcu uglavnom prelazi vrijednost 3, a najviše doseže vrijednost 7. Broj detektiranih rubnih točaka značajno je manji kada se analizira područje u kojem se ne nalazi pješački prijelaz. Postupak vertikalne analize za takav slučaj prikazan je na slikama 5.9. (a) – (d). Ovdje je na grafovima vidljivo da većina stupaca uopće ne sadrži rubne točke, a pojavljuje se najviše jedna rubna točka u nekoliko stupaca. Iz tog razloga na grafu koji



Slika 5.8. Vertikalna analiza područja s pješačkim prijelazom: (a) ulazna slika; (b) predobrađena slika; (c) graf duljina crnih i bijelih nizova u stupcu (BCC); (d) graf potencijalnih rubova po stupcu (SPC)



Slika 5.9. Vertikalna analiza područja bez pješačkog prijelaza: (a) ulazna slika; (b) predobrađena slika; (c) graf duljina crnih i bijelih nizova u stupcu (BCC); (d) graf potencijalnih rubova po stupcu (SPC)

prikazuje duljine susjednih nizova u jednom od stupaca nije moguće zabilježiti karakteristična uvećanja.

U prethodnom koraku detektirane su rubne točke koje na slici odgovaraju rubovima bijelih linija pješačkog prijelaza. Iako detektirane točke ne pokrivaju kompletne rubove, na primjeru slike s pješačkim prijelazom detektirano je dovoljno rubnih točaka da se na temelju pozicije istih može zaključiti radi li se o pješačkom prijelazu ili ne. Ovdje se može reći da algoritam pronalazi rubne točke za koje postoji najveća vjerojatnost da pripadaju pješačkom prijelazu i najčešće su one koncentrirane u sredini pješačkog prijelaza, tj. u dijelu pješačkog prijelaza koji je najjasnije vidljiv i na neki način najsigurniji za prelazak ceste.

5.4. Energija linija

Rubne točke detektirane u prethodnom koraku koriste se za donošenje konačne odluke kako bi se utvrdilo pripadaju li one pješačkom prijelazu ili ne. Na slici 5.7. (b) vidi se da rubne točke ponekad tvore približno horizontalne neprekinute nizove. Takvi horizontalni nizovi ukazuju na postojanje pješačkog prijelaza. Iz spomenutog razloga da algoritam pronalazi samo one rubne točke za koje je velika vjerojatnost da pripadaju pješačkom prijelazu, nizovi su često isprekidani. Kako bi se isprekidani horizontalni nizovi pretvorili u neprekinute nizove, dovoljno je preslikati detektirane rubne točke na sliku smanjene rezolucije. Ovime će se ostvariti dvostruka korist: u


ovom koraku obrađivat će se slika u manjoj rezoluciji i rubne točke većinom će činiti neprekinute približno horizontalne linije.

Koordinate detektiranih rubnih točaka preslikavaju se na novu praznu sliku koja ima rezoluciju smanjenu za 4 puta po širini i visini u odnosu na veličinu područja interesa. Pritom se nastoje zadržati sve rubne točke s velike inicijalne slike, ali će na smanjenoj slici one biti zbijene na manjem prostoru. Jedini slučaj kada se rubna točka gubi je taj kada dvije ili više točaka s inicijalne slike pripadnu istim koordinatama na smanjenoj slici pa u tom slučaju na dotičnom mjestu ostaje samo jedna točka. Pravilo preslikavanja rubnih točaka na sliku smanjene rezolucije dano je u (5-4):

$$b\left(\frac{x}{4}, \frac{y}{4}\right) = \begin{cases} 255, & f(x, y) \in EP \\ 0, & f(x, y) \notin EP \end{cases} \quad (5-4)$$

gdje je b nova vrijednost piksela za sliku smanjene rezolucije, x i y su koordinate piksela u području interesa inicijalne slike, f je vrijednost piksela u području interesa inicijalne slike i EP je skup piksela koji predstavljaju rubne točke.

Ovo je drugi dio algoritma koji obrađuje sliku u smanjenoj rezoluciji, a temelji se na isticanju približno horizontalnih linija koje predstavljaju rubne točke pješačkog prijelaza. Smanjena slika nakon preslikavanja rubnih točaka i prije daljnje analize prikazana je na slikama 5.10. (a)-(c). S obzirom na to da su sada rubne točke koncentrirane na manjoj površini, one tvore približno horizontalne linije koje su često kontinuirane u području pješačkog prijelaza. Kako bi se otkrilo pripadaju li preslikane točke pješačkom prijelazu, uvodi se parametar nazvan energija linija. Energija linija, kao novi parametar na temelju kojeg će se donijeti konačna odluka o detekciji, računa se traženjem grupa povezanih piksela bijele boje u slici i prolaskom kroz njihovu putanju s lijeva na desno. U ovom procesu najprije se pronalaze početni bijeli pikseli s lijeve strane svakog



Slika 5.10. (a)-(c) Binarne slike smanjene rezolucije sa svim rubnim točkama; (d)-(f) Tipovi prijelaza s lijeva na desno

niza povezanih bijelih piksela. Potom se za svaki piksel iz niza počevši od prvog s lijeve strane promatraju tri desna susjedna piksela kako bi se utvrdio smjer kretanja niza. Za svaku točku moguće su tri vrste prijelaza na desno kao što je prikazano na slikama 5.10. (d)-(f). Tipovi prijelaza su sljedeći:

- A tip: s lijeva na desno (ravno)
- B tip: s lijeva na desno-gore (dijagonalno)
- C tip: s lijeva na desno-dolje (dijagonalno)

Kada se dogodi jedan od ovakvih prijelaza, brojač se povećava za jedan i dodaje se na ukupnu sumu. Suma će biti veća ako postoji više uzastopnih bijelih piksela u istom smjeru. Ovime će se postići da približno horizontalne linije, koje kontinuirano idu u istom smjeru, u ovom koraku dobiju veću sumu. Primjerice, ako niz piksela ide potpuno horizontalno u desno, poprimit će visoke vrijednosti sume. Također, ako niz piksela kontinuirano ide dijagonalno prema gore, suma će rasti prolaskom kroz sve bijele piksele. S druge strane, kada ovakvi nizovi povezanih piksela često mijenjaju tip smjera, to će rezultirati nižom sumom jer pješački prijelaz ima potpuno ravne linije rubova i sve one bit će usmjerene otprilike u istom smjeru kada ih promatramo na slici bez obzira na kut snimanja. Kada više nema bijelih piksela u nizu s desne strane, algoritam se pomiče na sljedeću grupu bijelih piksela u slici. Pritom se oni nizovi koji su već analizirani brišu iz slike kako ne bi stvarali probleme u daljnjoj analizi.

Na kraju energija linija izračunava se kao omjer ranije spomenute sume i ukupnog broja bijelih piksela u slici. Ovaj proces opisan je pseudo-kodom danim na slici 5.11. Ako je na slici više približno horizontalnih linija istog smjera, energija linija poprima više vrijednosti. U suprotnom, ako su na slici pretežno bijele točke bez linija, energija linija težit će vrijednosti 1.

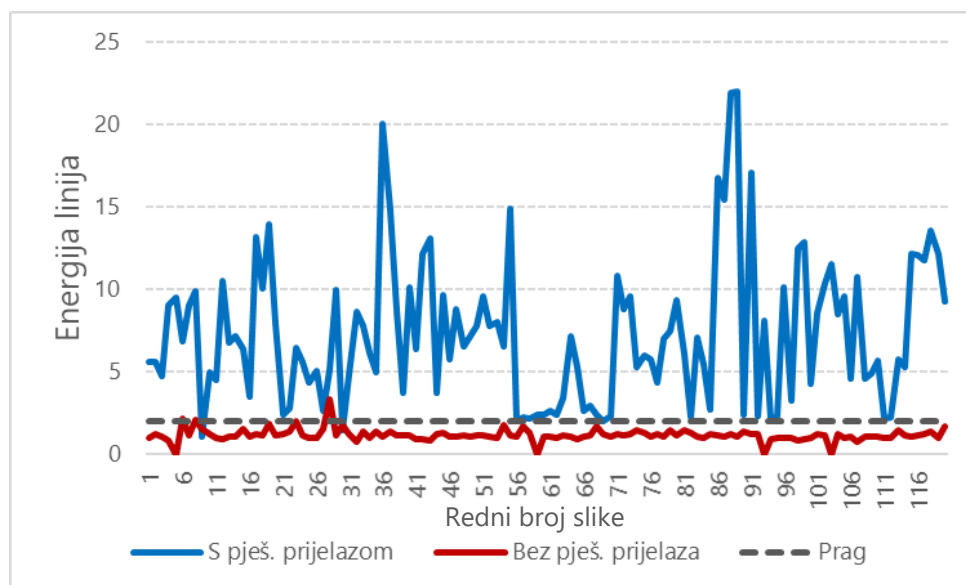
Na kraju je potrebno definirati za koje se vrijednosti energije linija može reći da je pješački prijelaz prisutan na slici, a za koje ne. Iz tog razloga proveden je izračun energije linija na 120 slika s pješačkim prijelazima i 120 slika bez pješačkog prijelaza. Slika 5.12. prikazuje kakve vrijednosti poprima energija linija u slikama s pješačkim prijelazom i bez pješačkog prijelaza na ulaznom skupu od 240 slika. Eksperimentalni podaci pokazali su da je prag najbolje postaviti na vrijednost 2 (isprekidana linija na slici) jer će tada biti najmanje nedetektiranih pješačkih prijelaza i najmanje pogrešnih slučajnih detekcija. Prema tome, konačna odluka donosi se na temelju vrijednosti parametra energija linija. Slike s energijom linija manjom od 2 ne sadrže pješački prijelaz, a kada energija linija ima vrijednost 2 ili veću, pješački prijelaz je detektiran.

```

n=0
Za svaku grupu bijelih piksela
  flag = 0
  A = B = C = 0
  n++
  Dok je (flag == 0)
    n++
    Ako je (A tip)
      A++
      Sum = Sum + A
      Pomakni se desno
    Ako je (B tip)
      B++
      Sum = Sum + B
      Pomakni se gore-desno
    Ako je (C tip)
      C++
      Sum = Sum + C
      Pomakni se dolje-desno
  U suprotnom
    flag = 1
  EnergijaLinija = Sum/n

```

Slika 5.11. Pseudo-kod za izračun energije linija



Slika 5.12. Energija linija na kompletom skupu slika s pješačkim prijelazom i bez pješačkog prijelaza

5.5. Eksperimentalni rezultati

Razvijena metoda testirana je na nekoliko načina kako bi se utvrdile njene prednosti i nedostaci po pitanju uspješnosti i performansi. Provedeni su eksperimenti koji ocjenjuju sljedeće parametre: uspješnost detekcije pješačkih prijelaza, količinu obrađenih piksela i vrijeme izvođenja po slici.

5.5.1. Uspješnost detekcije

Kod evaluacije uspješnosti detekcije pješačkih prijelaza razvijenom metodom, slično kao i kod detekcije stepenica, za potrebe testiranja snimljeni su reprezentativni video isječci. Prilikom snimanja, kamera je bila postavljena na osobu u visini prsa kako bi se dobio pogled iz prvog lica. Za snimanje su korištene dvije kamere isto kao i kod istraživanja sa stepenicama: kamera s mobilnog uređaja HTC One A9 [77] i širokokutna akcijska kamera SJCAM 4000 [78]. Ove kamere imaju mogućnost snimanja do rezolucije 1920×1080 piksela frekvencijom 30 slika u sekundi. Detaljne značajke kamera prikazane su u priložima P.1. i P.2. Slično kao i kod stepenica ovdje se nastoji postići da metoda bude uspješna neovisno o tome koristi li se standardna ili širokokutna kamera, pa će iz tog razloga testni skup podataka uključivati slike s te dvije vrste kamere što prikazuju slike 5.13. (a) i (b). Svi video isječci snimljeni su u pokretu na karakterističnim lokacijama za kretanje pješaka kao što su pješačke staze, trgovi i raskrižja. Isječci uključuju scene kada osoba prilazi pješačkom prijelazu, kada je na pješačkom prijelazu, ali i scene bez pješačkih prijelaza.

Određene slike (engl. *frames*) izdvojene su iz video isječaka i na taj način prikupljen je uzorak od 120 slika. Sve su slike različite i predstavljaju raznolikost uvjeta snimanja što uključuje: sunčano i oblačno vrijeme, male i velike pješačke prijelaze, djelomično uništene ili zaklonjene pješačke prijelaze. S druge strane, dodatnih 120 slika izdvojeno je iz scena gdje pješački prijelaz nije prisutan. Ovaj skup podataka koristit će se za izračun postotka pogrešnih pozitivnih detekcija (engl. *false positives*). S obzirom na to da je algoritam prilagođen kako bi radio uspješno s udaljenosti od 1 do 3 metra, sve slike izdvojene su u trenutku kada se osoba nalazi najviše 3 metra od pješačkog prijelaza. Primjeri detekcija prikazani su na slikama 5.14. (a)-(h). Slika 5.14. (a) prikazuje dnevnu scenu standardnog slučaja prilaska pješačkom prijelazu. Potom je na slici 5.14. (b) prikazana druga dnevna scena na kojoj je zbog istrošenosti pješačkog prijelaza detektirano manje rubnih točaka, ali metoda i dalje uspješno donosi odluku o postojanju pješačkog prijelaza. Primjer na slici 5.14. (c) pokazuje da metoda radi uspješno i kada kut snimanja nije idealan, tj. kada se linije pješačkog prijelaza pojavljuju pod određenim nagibom. Primjer sa širokokutne

kamere prikazan je na slici 5.14. (d). Nakon četiri primjera s dnevnim scenama, slijedi primjer na slici 5.14. (e) gdje je scena snimljena u ranim večernjim satima u uvjetima slabijeg osvjetljenja koje uzrokuje nizak kontrast na slici. Pokazalo se da metoda radi uspješno i u takvim uvjetima slabijeg osvjetljenja uz manju prilagodbu praga prilikom binarizacije. Kada su u pitanju uvjeti još slabijeg osvjetljenja, tj. noćni uvjeti, predlaže se korištenje dodatnog izvora infracrvene svjetlosti.




(a)



(b)

Slika 5.13. Vidno polje kod pješačkih prijelaza korištenjem: (a) standardne kamere; (b) širokokutne kamere

Ovime će se istaknuti bijela boja na pješačkom prijelazu, posebno zbog svoje reflektirajuće površine. Primjer simulirane noćne scene pod infracrvenim osvjetljenjem prikazan je na slici 5.14.



Slika 5.14. Primjeri testiranja algoritma za detekciju pješačkih prijelaza: (a) – (d) Scene pješačkih prijelaza na dnevnom svjetlu; (e) Pješački prijelaz na slici slabog kontrasta (večernja scena); (f) Pješački prijelaz u simuliranoj noćnoj sceni pod infracrvenim svjetlom; (g)-(h) Scena bez pješačkog prijelaza

(f) gdje je pješački prijelaz uspješno detektiran. Nadalje, slijede primjeri na slikama 5.14. (g) i (h) gdje na slici nema pješačkog prijelaza, što se metodom uspješno otkriva zbog premalog broja rubnih točaka i niske energije linija.

Ukupno je predložena metoda polučila dobre rezultate gdje je 118 od 120 (98.33 %) pješačkih prijelaza uspješno detektirano. Dvije negativne detekcije uzrokovane su sjenom drveća i istrošenim blijedim linijama na pješačkom prijelazu. Od 120 slika bez pješačkih prijelaza bile su tri pogrešne detekcije. Analizirajući pogreške utvrđeno je da su sve tri uzrokovane uzorcima na podu sličnim linijama pješačkih prijelaza. U usporedbi sa sličnim metodama predložena metoda dala je bolje rezultate u pogledu točnosti detekcije pješačkih prijelaza, a pritom je testirana na većem uzorku. Kod analize postotka točnih detekcija metoda koja koristi RGB-D, odnosno 3D kameru, polučila je znatno lošije rezultate nego što je to bio slučaj kod stepenica što ukazuje na to da je problem detekcije pješačkog prijelaza manje prikladan za 3D kameru. Kompetitivni rezultati postignuti su još u radu [38] gdje je naglasak stavljen na detekciju u lošim uvjetima osvjetljenja, dok su nešto lošiji rezultati kod oštećenih i istrošenih pješačkih prijelaza. Neke metode dale su bolje rezultate u pogledu pogrešnih pozitivnih detekcija, ali su testirane na znatno manjem skupu ulaznih slika. Metoda opisana u [37] ima nešto drugačiji pristup testiranja gdje se video isječak snimao isključivo na tri specifične rute gdje je detektirano 13 od 15 pješačkih prijelaza, ali su pogrešne pozitivne detekcije testirane na čitavom skupu slika iz cijelog video isječka. Ostale

Tablica 5.1. Usporedba točnosti metoda za detekciju pješačkih prijelaza

Metoda	Točne detekcije			Pogrešne pozitivne detekcije		
	Veličina uzorka	Detektirano	%	Veličina uzorka	Detektirano	%
<i>Predložena metoda</i>	120	118	98.33	120	3	2.50
<i>Segmentacija i projective invariant [38]</i>	81	77	95.06	37	0	0
<i>RGB-D [48]</i>	52	41	78.85	70	0	0
<i>Mean-shift segmentacija [12]</i>	40	33	82.50	43	2	4.65
<i>Template matching [37]</i>	15	13	86.67	19903	30	0.15

metode imaju sličan pristup testiranja kao i u ovom istraživanju, a cjelokupni usporedni rezultati sličnih metoda dani su u tablici 5.1.

Primjeri neuspješnih detekcija dani su na slikama 5.15. (a) i (b) s označenim detektiranim rubnim točkama iz kojih nije bilo moguće donijeti odluku o postojanju pješačkog prijelaza. Na slici 5.15. (a) detekciju ometa neravnomjerna svjetlina i kontrast jer je područje pješačkog prijelaza



(a)



(b)

Slika 5.15. Primjeri neuspješnih detekcija na slikama s pješačkim prijelazima

djelom u sjeni zbog drveća u okolini, a djelom izrazito osvjetljeno. Ovo se pokazalo kao najveća prepreka za pravilnu predobradu slike gdje je u ovakvom slučaju izgubljeno previše informacija potrebnih za daljnju detekciju. Slika 5.15. (b) prikazuje slučaj neuspješne detekcije gdje je pješački prijelaz oštećen i u velikoj mjeri zaprljan. U nekim dijelovima linije pješačkog prijelaza čak su poprimile boju ceste što onemogućava pravilnu detekciju rubnih točaka. Također, pritom se primjećuje veća količina rubnih točaka na drugim bijelim područjima u okolini pješačkog prijelaza.

5.5.2. Količina obrađenih piksela

Brzina izvođenja od velike je važnosti za algoritme koji trebaju osigurati informaciju za slijepu ili slabovidnu osobu. Kako bi se korisnik na vrijeme informirao o pješačkom prijelazu, predloženi algoritam optimiziran je i usmjeren da izbjegne obradu nepotrebnih piksela. Predloženi multirezolucijski pristup omogućio je obradu manjeg ukupnog broja piksela, ali pritom obrađujući sva područja koja sadrže informacije bitne za detekciju.

Kao što je u opisu pojedinih koraka metode istaknuto, na dva mjesta korištena je slika smanjene rezolucije. Prva obrada smanjene slike događa se u koraku predobrade gdje će 8 puta manja širina i visina slike smanjiti količinu piksela za obradu 64 puta. Slično će biti i u drugoj obradi smanjene slike prilikom izračuna energije linija gdje će 4 puta manja širina i visina rezultirati 16 puta manjom količinom piksela za obradu. Također, ovdje će količina piksela ovisiti i o tome koliko su velika detektirana područja interesa za pojedinu sliku. Ipak, kako bi se kvantitativno odredila ukupna ušteda obrađenih piksela u multirezolucijskom pristupu u odnosu na obradu u punoj rezoluciji, potrebno je računati obrađene piksele za cijeli postupak što će u određenim dijelovima metode značiti i obradu slike u punoj rezoluciji. S obzirom na to da će se zbog različite veličine područja interesa količine obrađenih piksela razlikovati za svaku sliku, u ovoj analizi bit će predstavljene prosječne vrijednosti na skupu od 240 ulaznih slika s pješačkim prijelazom i bez pješačkih prijelaza.

Radi lakšeg praćenja određena su dva glavna dijela metode u kojima se računa ušteda i postotak umanjenja količine piksela koju treba obraditi. Prvi dio odnosi se na predobradu i detekciju rubnih točaka, dok se drugi dio odnosi na izračun energije linija i odlučivanje. Tablica 5.2. prikazuje prosječnu količinu piksela koja se treba obraditi po slici tijekom izvođenja algoritma i koliko se ta količina piksela može smanjiti korištenjem multirezolucijskog pristupa. Vidljivo je da dvije radnje na slikama smanjene rezolucije mogu umanjiti količinu piksela za obradu za 50.38 % u prvom dijelu obrade i potom za 93.75 % u drugom dijelu obrade. Ukupno to znači

Tablica 5.2. Usporedba količine piksela koja treba biti obrađena u pojedinim koracima

Radnja	Broj piksela za obradu (prosječna vrijednost)		Postotak umanjnja
	Puna rezolucija	Više rezolucija	
<i>Predobrada i detekcija rubnih točaka</i>	230 400	114 325	-50.38 %
<i>Izračun energije linija i odlučivanje</i>	110720	6920	-93.75 %
<i>Ukupno</i>	341120	121245	-64.46 %

prosječno umanjnje od čak 64.46 % piksela. Ovaj postotak umanjnja značajno će se odraziti na vrijeme izvođenja po slici koje je analizirano u sljedećem potpoglavlju.

5.5.3. Brzina izvođenja

Osim količine piksela koju treba obraditi, brzina izvođenja algoritma ovisi o tehničkim specifikacijama uređaja na kojem se izvodi. S obzirom na to da je predviđeno da se algoritam izvodi u pokretu, testovi su provedeni na prijenosnim računalima pokretanim baterijama slično kao i kod istraživanja sa stepenicama. Prvi uređaj za testiranje brzine izvođenja bio je laptop s Intel i5-6200U procesorom i 8 GB RAM memorije. Drugi uređaj za testiranje bio je *mini PC* džepnih dimenzija s Intel Atom Z3735F procesorom i 2 GB RAM memorije. S obzirom na to da je ovaj uređaj izrazito prenosiv i praktičan za nošenje u pokretu, upravo on predstavlja najprikladniju platformu za potrebe navođenja slijepih osoba. Ovakav uređaj ima hardverske komponente slične onima u današnjim pametnim telefonima i tabletima. Iz tog razloga testiranje na ovoj platformi može pomoći za daljnje istraživanje mogućnosti izvođenja i implementacije algoritma na uređajima poput pametnih telefona ili tableta. Za sada se smatra da je prikladnije koristiti poseban uređaj kao pomoćni sustav za kretanje nego koristiti postojeći mobilni telefon koji korisniku istovremeno služi i u druge svrhe te pritom troši računalne resurse i bateriju. Detaljne značajke uređaja korištenih prilikom testiranja dane su u prilogima P.3. i P.4.


Vrijeme izvođenja mjereno je za svaku sliku iz ulaznog skupa podataka, što uključuje i slike koje ne sadrže pješački prijelaz. Kao što je prikazano u tablici 5.3., prosječno je vrijeme izvođenja po slici oko 60 milisekundi na laptopu, što znači više od 16 slika u sekundi. Ovakva brzina izvođenja trebala bi osigurati informaciju o pješačkom prijelazu na vrijeme. Brzina izvođenja na *mini-PC* džepnom uređaju je niža, ali i dalje prihvatljiva. S obradom 4 slike u sekundi i prosječnom

brzinom hodanja od 1.4 m/s ovo je i dalje dovoljno za informiranje korisnika prije nego li stane na pješački prijelaz čak i ako je prijelaz detektiran s udaljenosti od samo jednog metra. Dobivena vremena dana su u tablici 5.3. s glavnim specifikacijama korištenog uređaja za obradu. Dodatno su u tablici navedene i dimenzije te masa pojedinog uređaja kako bi se istaknula njihova prenosivost i potencijal za korištenje u pokretu.

Kako bi se utvrdila zahtjevnost pojedinog dijela algoritma, provedena je dodatna analiza vremena izvođenja za svaki korak razvijene metode. Algoritam je podijeljen u tri glavna koraka: predobrada, detekcija rubnih točaka i izračun energije linije, te je za svaki od njih mjereno prosječno vrijeme izvođenja na ulaznom skupu od 240 slika. Rezultati mjerenja vremena prikazani su grafom na slici 5.16. gdje su istaknuti i postoci udjela pojedinih koraka algoritma u cjelokupnom vremenu potrebnom za obradu jedne slike. Analizom je utvrđeno da je vremenski najzahtjevniji korak detekcije rubnih točaka koji traje 78 % ukupnog vremena. U usporedbi s korakom detekcije rubnih točaka na stepenicama ovdje je postotak nešto niži, a prosječno je vrijeme ovog koraka značajno manje (46.8 ms) nego kod algoritma za detekciju stepenica (124.5 ms). Također, može se uvidjeti da je vrijeme potrebno za izračun energije linija kod pješačkih prijelaza manje u odnosu na vrijeme izračuna horizontalne energije prilikom detekcije stepenica. Tako izračun energije linija

Tablica 5.3. Prosječna brzina izvođenja algoritma za detekciju pješačkih prijelaza dobivena na prijenosnim uređajima

	Tip	Laptop	Mini-PC
	Model	Lenovo V310 notebook	Lenovo Ideacentre Stick 300
Specifikacije uređaja	Procesor	Intel i5-6200U @ 2.3 Ghz (2 jezgre)	Intel Atom Z3735F @ 1.33 GHz (4 jezgre)
	Memorija	8 GB RAM	2 GB RAM
	Dimenzije (Š×D×V)	380 mm × 262 mm × 22.9 mm	100 mm × 38 mm × 15 mm
	Masa	1.85 kg	0.065 kg + 0.235 kg (baterija)
	Prosječno vrijeme obrade (po slici)	60.3 ms	218.1 ms
	Br. slika u sekundi	16.6	4.6



Slika 5.16. Graf prosječnih vremena izvođenja pojedinih koraka algoritma za detekciju pješačkih prijelaza i postotak udjela u ukupnom vremenu izvođenja

traje samo 4 % ukupnog vremena obrade jedne slike, dok na predobradu odlazi 18 %. Ovime je potvrđeno da multirezolucijski pristup kod detekcije pješačkih prijelaza prvenstveno smanjuje ukupno vrijeme uloženo za morfološku analizu stupaca i pronalazak rubnih točaka kao vremenski najzahtjevniji dio algoritma.

6. METODA ZVUČNOG USMJERAVANJA SLIJEPIH I SLABOVIDNIH OSOBA ODREĐIVANJEM PROSTORA ZA SIGURNO KRETANJE

Ovo poglavlje predstavlja metodu pametnog navođenja slijepih osoba u pokretu na temelju obrađene slike s kamere predloženu u radu [90]. Osim same lokalizacije objekata poput stepenica i pješačkih prijelaza važno je pronaći najsigurniji prostor za kretanje. Nadalje je predložen način informiranja slijepih osoba o prepreci i smjeru kretanja pomoću usmjerenih zvučnih signala. Na kraju poglavlja predstavljena je i pomoćna metoda za korekciju odluke na temelju promatranja nekoliko uzastopnih slika iz video isječka.

6.1. Lokalizacija na temelju rubnih točaka

Ranije predstavljene metode za detekciju stepenica i pješačkih prijelaza vertikalnom morfološkom analizom određuju potencijalne rubne točke slično kao što je prikazano na slici 6.1. i donose jednostavnu odluku nalazi li se na slici traženi objekt ili ne. Sljedeći korak bila bi lokalizacija samog objekta, točnije određivanje točnog prostora na slici u kojem se nalaze stepenice ili pješački prijelaz. Na temelju informacija o točnoj poziciji traženog objekta korisniku se može dati dodatna informacija o smjeru kretanja ako se želi kretati prema detektiranom objektu. Najjednostavniju lokalizaciju moglo bi se provesti traženjem prostora gdje se najviše gomilaju pronađene rubne točke, a kod multirezolucijskog pristupa za pješačke prijelaze već je izvršena jednostavna lokalizacija određivanjem pojedinih područja interesa. Ranije je spomenuto da su dvije razvijene metode otporne na postojanje prepreka na stepenicama ili pješačkim prijelazima i zato je metodu lokalizacije moguće dodatno unaprijediti kako to ne bi bila samo obična informacija



Slika 6.1. Karakteristične rubne točke na stepenicama dobivene vertikalnom morfološkom analizom

u kojem se smjeru nalaze stepenice ili pješački prijelaz. Cilj je iskoristiti koordinate rubnih točaka kako bi se utvrdio predloženi smjer kretanja za korisnika. Ovo će, osim same lokalizacije objekta kao što su stepenice i pješački prijelazi, značiti i lokalizaciju najsigurnijeg prostora za kretanje na istima. S obzirom na mogućnost postojanja prepreka i drugih osoba na stepenicama ili pješačkim prijelazima potrebno je pronaći najveći slobodni prostor i usmjeriti korisnika prema njemu [91]. Kako bi se od rubnih točaka kao ulaznog podatka došlo do izlaznog podatka o predloženom smjeru kretanja, razvijena je metoda koja koristi kumulativne slike generirane na temelju tih točaka.

Metoda usmjeravanja započinje koordinatama potencijalnih rubnih točaka koje su raspoređene kao na primjeru sa slike 6.3. (a) gdje su rubne točke označene crvenom bojom. Nakon što su zabilježene koordinate rubnih točaka, generira se nova slika u sivim tonovima čiji izgled ovisi o rasporedu rubnih točaka. Sve vrijednosti piksela na takvoj slici inicijalno su postavljene na 0, a potom su obrađene od vrha prema dnu tako da se nova vrijednost koju dobiva svaki piksel u stupcu postepeno povećava za jedan svaki put kada se na originalnoj slici naiđe na rubnu točku. Ovo znači da će stupac iz područja stepenica od vrha prema dnu imati vrijednosti koje se postupno povećavaju, a vrijednost na dnu slike predstavljat će broj potencijalnih stepenica po stupcu. Postupak je opisan pseudo-kodom na slici 6.2. Ovakva slika u ovom istraživanju bit će nazvana kumulativnom slikom, a na njoj će se izvršiti još nekoliko radnji kako bi se istaknuli stupci gdje se nalazi najviše detektiranih stepenica. Sljedeći je korak normalizacija takve slike gdje se vrijednosti piksela rasprostiru na raspon od 0 do 255. Dobivena slika prikazana je na slici 6.3. (b) gdje se jasno vidi da su najveći sivi stupci generirani u područjima stepenica gdje se nalazi najviše detektiranih rubnih točaka što je indikator najsigurnijeg prostora. Normalizirana slika potom se pretvara u binarnu sliku korištenjem Otsu metode [60]. Može se dogoditi da je u određenim izoliranim stupcima greškom detektiran niži broj stepenica od stvarnog, što se manifestira kroz uske prostore između visokih bijelih stupaca na binarnoj kumulativnoj slici. Slika se nadalje obrađuje s tri iteracije morfološke operacije zatvaranja korištenjem strukturnog elementa 7×7 ,


```
Za svaki stupac
  x = 0
  Za svaki redak
    Ako je (rubna točka)
      x++
      kumSlika[redak][stupac] = x
```

Slika 6.2. Pseudo-kod za stvaranje kumulativne slike


nakon čega slijedi pet iteracija dilatacije. Ove morfološke operacije popunjavaju manje praznine




(a)




(b)




(d)



(c)



(e)



(f)

Slika 6.3. (a) Ulazna slika stepenica s označenim rubnim točkama; (b) normalizirana kumulativna slika; (c) binarna kumulativna slika; (d) normalizirana obrnuta kumulativna slika; (e) binarna obrnuta kumulativna slika; (f) konačna slika i detekcija najsigurnijeg prostora za kretanje

između bijelih stupaca, a pritom čuvaju veće praznine koje potencijalno mogu biti uzrokovane preprekama na stepenicama. Konačna binarna kumulativna slika prikazana je na slici 6.3. (c).


Ovaj postupak stvaranja binarne kumulativne slike ponavlja se još jednom, ali se pritom slika obrađuje od dna prema vrhu pa rezultat za takav postupak izgleda kao na slikama 6.3. (d) i (e).

Nakon što su generirane dvije binarne kumulativne slike izvodi se logička I (engl. *AND*) operacija koja će dati bijelu boju samo na onim prostorima slike gdje je na obje kumulativne slike bila također bijela boja. Rezultantna slika prikazana je na slici 6.3. (f). Na ovoj slici bijela boja trebala bi ostati isključivo na dijelovima gdje se nalazi slobodan prostor na stepenicama. Stoga se bijeli prostor oko kojeg možemo opisati pravokutnik najveće površine uzima kao prostor najsigurnijeg kretanja i korisnik bi se trebao usmjeriti upravo u taj prostor. On može obuhvaćati cijele stepenice ili samo dio stepenica za koji je određeno da predstavlja najsigurniji prostor. U primjeru na slici 6.3. (f) taj pravokutnik označen je crvenom bojom.


S obzirom na to da je detekcija rubnih točaka prisutna i u predloženoj metodi za detekciju pješačkih prijelaza, postupak lokalizacije najsigurnijeg prostora za kretanje na pješačkom prijelazu može se odrediti na isti način kao i kod stepenica. Primjer određivanja predloženog smjera kretanja na pješačkim prijelazima prikazan je na slikama 6.4. (a)-(f). Jedina je razlika u odnosu na stepenice u tome da se kod pješačkih prijelaza generiraju kumulativne slike samo za ono područje interesa u kojem je detektiran pješački prijelaz. Na taj se način unutar takvog područja određuje uže područje koje je najsigurnije za prelazak pješačkog prijelaza. Postoji mogućnost da to područje bude veliko gotovo koliko i cijeli pješački prijelaz, ako na njemu nema drugih objekata ili bilo čega što bi otežalo njegovu vidljivost. Ako je dio pješačkog prijelaza ipak zaklonjen, ovom metodom predložit će se smjer kretanja gdje je otkriven najveći slobodni prostor. Ovdje je važno odrediti poziciju pravokutnika koji predstavlja siguran prostor na slici u punoj rezoluciji, a ne samo relativnu poziciju unutar područja interesa.

6.2. Smjer kretanja


Kod usmjeravanja slijepih osoba prvenstveno je važna horizontalna pozicija prostora za kretanje. Vertikalna pozicija nije toliko važna s obzirom na to da se korisnik kreće po tlu te nema potrebe za usmjeravanjem prema gore ili dolje, već će se usmjeravanje korisnika uglavnom svoditi na lijevo, desno ili ravno. Također, vertikalna pozicija određenog područja na slici uvelike ovisi o nagibu kamere postavljene na korisnika. S druge strane, ako je kamera približno usmjerena ravno



(a)



(b)



(d)



(c)



(e)



(f)


Slika 6.4. (a) Ulazna slika pješačkog prijelaza s označenim rubnim točkama; (b) normalizirana kumulativna slika; (c) binarna kumulativna slika; (d) normalizirana obrnuta kumulativna slika; (e) binarna obrnuta kumulativna slika; (f) konačna slika i detekcija najsigurnijeg prostora za kretanje

ispred korisnika, tada će objekti u sredini slike u stvarnosti i biti ravno ispred korisnika. Isto vrijedi i za objekte na lijevoj ili desnoj strani slike koji će u stvarnosti biti s lijeve ili desne strane korisnika. Ukratko, u ovakvom sustavu vidno polje kamere imitira vidno polje čovjeka.

Kako bi se osoba usmjerila u prethodno detektirano najsigurnije područje na stepenicama ili pješačkom prijelazu, prvo se određuje centar simetrije detektiranog pravokutnika. Taj centar simetrije pravokutnika predstavlja mjesto na koje se korisnik treba usmjeriti, dok je kao polazišno mjesto određena točka na sredini donjeg ruba slike s kamere. Prema tome, linija koja spaja te dvije točke predstavlja predloženi smjer kretanja. Kako bi se u svakom trenutku što lakše pratio podatak o smjeru kretanja, on je određen veličinom kuta α između linije smjera kretanja i okomite linije koja prolazi kroz sredinu slike s kamere koji se računa prema formuli (6-1) gdje su koordinate polazišne točke (x_1, y_1) , a koordinate centra simetrije detektiranog područja (x_2, y_2) . Vrijednost kuta u stupnjevima prilagođena je kako bi prikazivala relativni nagib u odnosu na okomitu liniju koja prolazi kroz središte slike. Pri tome će smjer kretanja prema desno poprimiti negativne vrijednosti, a smjer prema lijevo pozitivne vrijednosti kuta. Određivanje smjera kretanja prikazano je na slici 6.5. gdje je crvenim pravokutnikom označeno najsigurnije područje za kretanje, a plava linija spaja polazišnu točku i centar simetrije pravokutnika.

$$\alpha = \tan^{-1} \left(\frac{y_2 - y_1}{x_2 - x_1} \right) * \frac{180}{\pi} + 90 \quad (6-1)$$

Prethodne radnje dovele su do određivanja smjera kretanja, a sljedeća je važna radnja informiranje slijepce osobe o tome. S obzirom na to da je neprikladno neprestano informirati korisnika o točnoj veličini kuta pod kojim se treba pomicati lijevo ili desno, ova informacija o kutu se pojednostavljuje. Najčešći način pojednostavljivanja smjera kretanja za slijepce osobe svodi se na tri glavna smjera: ravno, desno i lijevo kao što je predloženo u [92]. U ovom radu, kao prikladno



Slika 6.5. Određivanje kuta smjera kretanja na slici

rješenje određeno je da se informacija o kutu pojednostavi i prikaže kao pet mogućih smjerova kretanja:

- oštro lijevo
- blago lijevo
- ravno
- blago desno
- oštro desno

Proširivanje ovog skupa s tri osnovna na pet mogućih smjerova uvedeno je uglavnom zbog širokokutnih slika koje pokrivaju šire vidno polje s lijeve i desne strane korisnika, pa se pojavila potreba za dodatnim smjerovima: „oštro desno“ i „oštro lijevo“. Ovdje je vrlo važno zadržati relativno mali broj mogućih smjerova i odluka za korisnika jer se pokazalo da velik broj mogućih odluka i njihova složenost može negativno utjecati na percepcijsko razlučivanje kod korisnika [93].

Kako bi se odredilo koji će raspon kutova predstavljati koji smjer, provedeno je istraživanje gdje su se evidentirale ljudske odluke za primjere scena. Istraživanje je provedeno na pet različitih video sekvenci posebno snimljenih za ove potrebe. Video sekvence uključuju česte promjene smjera i postojanje prepreka na stepenicama kako bi se dobio što širi spektar mogućih scena. Iz svake je video sekvence pregledano 100 nasumičnih slika koje sadrže stepenice. Ove slike koriste se isključivo za definiranje pravila za donošenje odluka na temelju izračunatog kuta. Cilj je pronaći referentne raspone kutova za svih pet smjerova tako da u što manje računalnih odluka odstupa od subjektivne odluke koju je zabilježio čovjek. Prema tome, za svaku sliku ručno je obilježeno pravokutno područje za koje se smatra da je najsigurnije za kretanje na stepenicama, a također je ručno zabilježen jedan od pet ponuđenih pojednostavljenih smjerova kretanja u kojem bi bilo najbolje uputiti slijepu osobu. Za svako ručno označeno pravokutno područje automatski se računa i veličina kuta kako bi bilo moguće dobiti prosječan raspon kutova za pojedinu odluku.

Za kutove od -90° do $+90^\circ$ u tablici 6.1. prikazane su odluke čovjeka, a tablica je prikazana u skraćenoj izvedbi gdje su istaknuta prijelazna područja između dviju odluka o smjeru. U tim prijelaznim područjima moguće je zabilježiti dvije različite subjektivne odluke za slične ili čak jednake vrijednosti kuta. Primjerice, za kut -50.3° na jednom je primjeru zabilježena subjektivna odluka „blago desno“, a drugi put za isti kut „oštro desno“. Ipak, na temelju rezultata u tablici 6.1. moguće je razlučiti granice pojedinih smjerova. Tako je vidljivo da se granična vrijednost između dvaju kutova za smjerove označene s „oštro“ i „blago“ nalazi na -50° (desno) odnosno 50° (lijevo),


dok je granična vrijednost između smjerova „ravno“ i onih označenih s „blago“ na -20° (desno) odnosno 20° (lijevo).

Prema analizi dobivenih vrijednosti kutova za pojedinu subjektivnu odluku određeni su rasponi kutova na temelju kojih će se u algoritmu donositi odluka o predloženom smjeru kretanja, a oni su prikazani na slici 6.6. Ponekad se smjer kretanja alternativno predstavlja i kao oznake vremena na satu [94].

Tablica 6.1. ujedno prikazuje i odluke računala na temelju definiranih raspona kutova. Korištenjem ovakve raspodjele odluka računat će se poklapanje odluke čovjeka i računala, o čemu će više govora biti u sljedećem potpoglavlju. Pritom je već u ovoj fazi vidljivo da u graničnim područjima između dvaju susjednih raspona kutova subjektivna odluka čovjeka može donekle varirati, pa će tako i računalna odluka ponekad biti podložna minimalnim pogreškama koje ne bi trebale biti presudne za točno usmjeravanje u cjelini.

6.3. Usmjereni zvučni signali

U kontekstu navigacije slijepih i slabovidnih osoba prijenos informacija takvim osobama u mnogim znanstvenim istraživanjima proveden je putem generiranih glasovnih poruka [95] [96]. Tako je i u ovom radu početna informacija o postojanju stepenica ili pješačkog prijelaza u blizini zamišljena kao glasovna poruka, dok će se daljnje usmjeravanje prema traženom objektu odvijati putem kratkih zvučnih signala.



Slika 6.6. Rasponi kutova za određivanje odluke o smjeru kretanja


Nakon što je na temelju određenog kuta donesena pojednostavljena odluka o smjeru kretanja, moguće je obavijestiti slijepu osobu o predloženom smjeru. Ovaj postupak najčešće se vrši

Tablica 6.1. Kutovi smjera kretanja i odluka čovjeka

Odluke čovjeka		Predložena računalna odluka
Kut kretanja	Pojednostavljeni smjer	
-59.7°	oštro desno	oštro desno
-59.4°	oštro desno	
-58.7°	oštro desno	
...	...	
-51.9°	oštro desno	
-51.6°	oštro desno	
-50.3°	oštro desno	
-50.3°	blago desno	
-50.1°	oštro desno	
-49.2°	blago desno	
-49.1°	oštro desno	blago desno
-47.2°	blago desno	
-47°	blago desno	
...	...	
-28°	blago desno	
-26.6°	blago desno	
-19.5°	blago desno	ravno
-17.1°	ravno	
-16.9°	ravno	
-14°	ravno	
...	...	
19.5°	ravno	blago lijevo
20.1°	ravno	
20.1°	ravno	
20.4°	blago lijevo	
20.4°	ravno	
22.6°	blago lijevo	
23°	blago lijevo	
23.4°	blago lijevo	
...	...	
48.2°	blago lijevo	
49.1°	blago lijevo	oštro lijevo
49.1°	blago lijevo	
49.2°	oštro lijevo	
50.2°	oštro lijevo	
56.3°	oštro lijevo	
...	...	
62.5°	oštro lijevo	
62.6°	oštro lijevo	
67.7°	oštro lijevo	

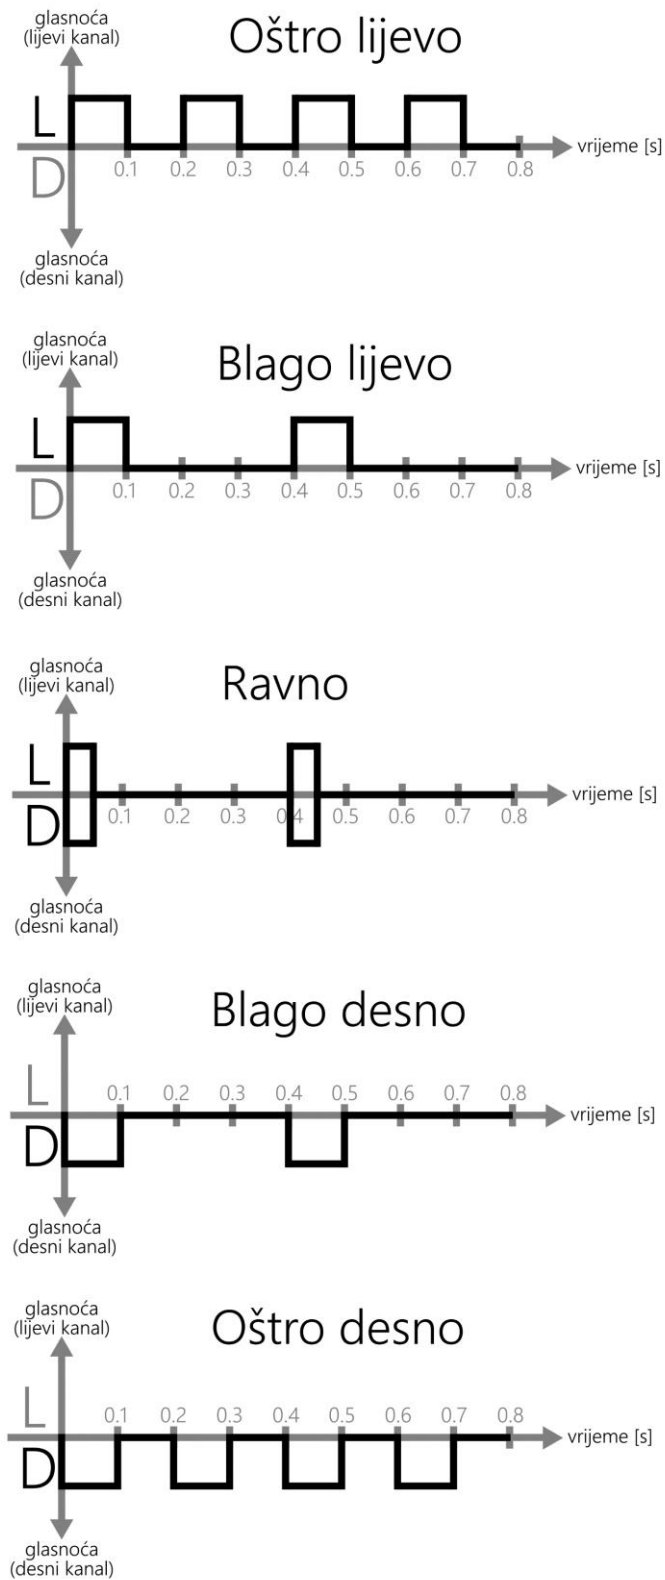
reprodukcijom prikladnih zvučnih ili taktilnih poruka i signala [22]. U ovom radu, kao prikladan oblik navođenja slijepa osobe, razvijen je model usmjerenih zvučnih signala slično kao što je predloženo u [97] za primjenu izbjegavanja detektiranih prepreka. U ovom slučaju, kod detekcije stepenica i pješačkih prijelaza, slijepa osoba navodila bi se u željenom smjeru putem stereo slušalica s mogućnošću reprodukcije zvuka na lijevom i desnom uhu. Zvuk je usmjeren na lijevu ili desnu stranu ovisno o tome u kojem smjeru se osoba treba kretati. Ovakav model usmjeravanja prikazan je primjerom na slici 6.7. gdje je smjer kretanja korisnika pomaknut u lijevo za otprilike 25° u odnosu na idealnu putanju preko pješačkog prijelaza pa će se njemu reproducirati zvučni signal na desnom uhu kako bi se usmjerio na desnu stranu prema pješačkom prijelazu. Slično ovom primjeru izvršit će se zvučno usmjeravanje i za druge smjerove.

S obzirom na to da je definirano pet smjerova koji uključuju po dvije razine odluke (oštro i blago) za lijevu i desnu stranu, zvučni signali prilagođeni su kako bi na što intuitivniji način pokazali u kojem se smjeru korisnik treba kretati. Potreba za oštrijim skretanjem bit će okarakterizirana učestalijim zvučnim signalom, dok će blago skretanje biti predstavljeno signalima koji se nešto rjeđe pojavljuju. Točnije, za oštro skretanje reproducira se signal trajanja 0.1 s, nakon kojeg slijedi jednako duga stanka. Kada korisnik treba blago skrenuti u jednu od strana, reproducirat će se zvučni signal u trajanju od 0.1 s, ali će biti praćen duljom stankom od 0.3 s. Ovakva sekvenca zvučnog signala i pauze ponavljat će se sve dok se ne promijeni predloženi smjer kretanja. Zvuk će se reproducirati i kada se korisnik kreće ravno prema željenom objektu, tj. prema detektiranom najsigurnijem prostoru. Zvučni signal za ravno bit će izrazito kratak (0.05 s) i



Slika 6.7. Primjer situacije gdje se korisnik usmjerava na desnu stranu

reproducirat će se na lijevom i desnom uhu. Kratki zvučni signal za ravno praćen je najdužom stankom u trajanju od 0.35 s i na neki način predstavlja kontrolni signal koji će korisniku dati do



Slika 6.8. Zvučni signali pojedinog smjera

znanja da se kreće u pravom smjeru. Predloženi zvučni signali za svaki pojedini smjer prikazani su na slici 6.8.

6.4. Primjeri i brzina usmjeravanja

Usmjeravanje korisnika korištenjem razvijenog algoritma testirano je na različitim primjerima scena izdvojenih iz video isječaka. Izdvojeni primjeri za stepenice prikazani su na slikama 6.9. (a)-(h). Slike uključuju scene kada korisnik prilazi stepenicama te one kada se nalazi na samim stepenicama. Na svim primjerima crvenim pravokutnikom označen je detektirani prostor za kretanje te je ispisana vrijednost određenog kuta u stupnjevima. Središte pravokutnika označeno je znakom „+“, a bijela strelica prikazuje predloženi smjer kretanja.


Primjer na slici 6.9. (a) prikazuje uobičajenu scenu prilaska stepenicama kada se one nalaze približno ravno ispred korisnika, a razvijenom metodom izračunat je kut od 14.2° što će značiti pojednostavljenu odluku „ravno“. Na slici 6.9. (b) također se stepenice nalaze približno ravno ispred korisnika (-2.5°), ali je ovaj put riječ o stepenicama prema dolje. Određivanje smjera na ovom primjeru dodatno je otežano jer na stepenicama postoje objekti (tepisi) koji se razlikuju po obliku i boji od samih stepenica, ali oni ne bi trebali negativno utjecati na određivanje smjera, tj. ne bi smjeli biti zamijenjeni za prepreke na stepenicama. Sljedeći primjer na slici 6.9. (c) uključuje stepenice s lijeve strane, a na temelju kuta od 49.6° donesena je odluka o smjeru kretanja „blago lijevo“. Detektirano pravokutno područje ne obuhvaća cijele stepenice iz razloga što se na istima nalazi druga osoba koja jednim dijelom zaklanja dio prostora na stepenicama. Primjer na slici 6.9. (d) također uključuje drugu osobu na stepenicama koja zaklanja velik dio prostora ravno ispred korisnika. Kako bi se izbjegao sudar s drugom osobom, ovdje se korisnik usmjerava u smjeru „blago desno“ na temelju određenog kuta od -26.4° . Slika 6.9. (e) prikazuje uspješno određivanje smjera „blago lijevo“ kada je slika mutna što je često problem kod snimanja u pokretu zbog naglih pokreta s kamerom. Slika 6.9. (f) još je jedan primjer gdje zbog prisutnosti drugih osoba na stepenicama algoritam traži najveći slobodan prostor siguran za kretanje koji se u ovom slučaju nalazi na desnoj strani. Odluka je „blago desno“ na temelju kuta od -25.6° . Primjer na slici 6.9. (g) odnosi se na specifičan slučaj kada su stepenice na perifernom dijelu slike i pritom je samo mali dio njih vidljiv na slici. U ovom slučaju, na slici ipak ima dovoljno informacija da bi algoritam prepoznao stepenice i odredio smjer kretanja u „oštro lijevo“ zbog velikog kuta od 65° . Posljednji primjer na slici 6.9. (h) prikazuje stepenice u smjeru „oštro desno“ pod kutom od 53.8° .



Slika 6.9. Primjeri usmjeravanja na stepenicama: (a) ravno (14.2°); (b) ravno (-2.5°); (c) blago lijevo (49.6°); (d) blago desno (-26.4°); (e) blago lijevo (45°); (f) blago desno (-25.6°); (g) oštro lijevo (65°); (h) oštro desno (-53.8°)


Na slikama 6.10. (a)-(h) nalaze se primjeri za usmjeravanje na pješačkim prijelazima. Prvi primjer na slici 6.10. (a) prikazuje standardnu scenu gdje se pješački prijelaz nalazi ravno ispred korisnika gdje je određen kut od 6.7° . Ovdje je pješački prijelaz gotovo u cijelosti jasno vidljiv na slici i eventualne pogreške može uzrokovati istrošenost bijele boje na linijama pješačkog prijelaza. Slika 6.10. (b) također sadrži pješački prijelaz ravno ispred korisnika. Iako se na pješačkom prijelazu nalaze druge osobe, one ne zauzimaju dovoljno velik prostor da bi se u trenutku snimanja smatrale preprekama, pa se određeni prostor za sigurno kretanje prostire cijelom širinom pješačkog prijelaza. Primjer na slici 6.10. (c) prikazuje scenu gdje je korisnik blago zakrenut prema desno u odnosu na putanju pješačkog prijelaza pa je određen smjer kretanja „blago lijevo“ pod kutom od 29.1° . Na slici 6.10. (d) pješački prijelaz djelomično je zaklonjen drugom osobom, pa je određeni prostor sigurnog kretanja sužen, a zbog kuta od -22.3° predložen je smjer „blago desno“. Korisnik je na slici 6.10. (e) vidno pomaknut nadesno od pješačkog prijelaza, te se zbog kuta od 37.5° upućuje na lijevu stranu. Iako je ovdje pješački prijelaz uz sami lijevi rub slike, zbog nešto veće duljine pješačkog prijelaza određeno sigurno područje za kretanje relativno je visoko na slici pa je predloženi smjer „blago lijevo“. Na slici 6.10. (f) nalazi se primjer širokokutne slike gdje pješački prijelaz zauzima vrlo malu površinu, ali je uspješno određen smjer „blago desno“ na temelju kuta od -24.1° . Na primjeru sa slike 6.10. (g) pješački prijelaz nalazi se u donjem desnom uglu slike pa je kut izrazito velik (64.2°) i određen je smjer „oštro lijevo“. Ovo je još jedan primjer koji pokazuje da zamućenost slike zbog snimanja u pokretu ne utječe negativno na određivanje smjera kretanja. Posljednji primjer na slici 6.10. (h) pokazuje da će u slučajevima kada je pješački prijelaz snimljen pod određenim kutom, predloženi prostor za kretanje zauzimati samo mali dio pješačkog prijelaza kako bi korisnik bio usmjeren tako da prati putanju pješačkog prijelaza, a ne da samo djelomično siječe njegov prostor i potencijalno ode van pješačkog prijelaza. Stoga će se u ovom posljednjem primjeru korisnik usmjeriti „oštro desno“ na temelju kuta od -55.1° .

Testirana je i vremenska zahtjevnost razvijenog algoritma za usmjeravanje kako bi se utvrdilo koliko je dodatno vrijeme potrebno da od odluke o detekciji korisnik dobije predloženi smjer kretanja. Testiranje vremena izvođenja provedeno je na istom ulaznom skupu od 120 slika kao i kod testiranja metode za detekciju stepenica u 4. poglavlju, odnosno metode za detekciju pješačkih prijelaza u 5. poglavlju.




Slika 6.10. Primjeri usmjeravanja na pješačkim prijelazima: (a) ravno (6.7°); (b) ravno (-14°); (c) blago lijevo (29.1°); (d) blago desno (-22.3°); (e) blago lijevo (37.5°); (f) blago desno (-24.1°); (g) oštro lijevo (64.2°); (h) oštro desno (-55.1°)

Pokazalo se da je nakon odluke o postojanju stepenica na slici potrebno dodatnih 8 do 12 ms za određivanje predloženog smjera kretanja kada se algoritam izvodi na istom laptopu korištenom za testiranje metode za detekciju stepenica. Ako se prosječno vrijeme od dodatnih 10 ms doda na prosječno vrijeme detekcije stepenica (140 ms), dobiva se ukupno prosječno vrijeme od 150 ms



(a)



(b)

Slika 6.11. Graf usporedbe prosječnog vremena izvođenja koraka određivanja smjera i ostalih koraka algoritma te udio u ukupnom vremenu izvođenja za: (a) stepenice; (b) pješačke prijelaze

po slici. Prema tome, cjelokupna detekcija i određivanje smjera kretanja može se izvršiti 6.7 puta u sekundi. Udio u ukupnom vremenu izvođenja algoritma koji je potreban za izvođenje koraka određivanja smjera kretanja prikazan je grafom na slici 6.11. (a). Ovaj graf prikazuje prosječna vremena pojedinih koraka algoritma te postotke koji pokazuju koliko pojedini korak traje u odnosu na ukupno vrijeme obrade. Vidljivo je da korak određivanja smjera kretanja na stepenicama uzima 7 % vremena potrebnog za ukupnu obradu jedne slike. Kada se radi o testiranju na *mini-PC*-ju, određivanje smjera zahtjeva dodatnih 33 do 36 ms (prosječno 34 ms) što produljuje ukupno vrijeme izvođenja po slici na nešto iznad pola sekunde (525.3 ms) i omogućava obradu 1.9 slika u sekundi.

Vremenska zahtjevnost algoritma za usmjeravanje na pješačkim prijelazima bit će u prosjeku nešto manja jer se algoritam određivanja smjera kretanja ovdje izvršava samo na manjem pravokutnom području slike gdje je pješački prijelaz detektiran. S obzirom na to da područja pješačkog prijelaza mogu biti različitih veličina, ovdje su moguće i veće varijacije u vremenima za određivanje smjera. Vrijeme određivanja smjera ovdje varira između 2 i 7 ms, a prosječno je vrijeme oko 4.2 ms na laptopu. Ranije dobiveno prosječno vrijeme za detekciju pješačkog prijelaza je 60.3 ms, pa ukupno vrijeme za detekciju i određivanje smjera iznosi 64.5 ms što znači dobivanje informacije o smjeru 15.5 puta u sekundi kad se algoritam izvodi na laptopu. Na grafu na slici 6.11. (b) izdvojeno je prosječno vrijeme potrebno za određivanje smjera kretanja na pješačkim prijelazima te uspoređeno s ostalim koracima algoritma. Pokazalo se da korak određivanja smjera kretanja ovdje uzima samo 6 % vremena potrebnog za obradu jedne slike. Na sporijem uređaju (*mini-PC*) određivanje smjera zahtjeva dodatnih 8 do 30 ms (prosječno 15 ms) pa će se ukupno vrijeme povećati s 218.1 ms na 233.1 ms, a takav uređaj informaciju o smjeru kretanja davat će 4.3 puta u sekundi.

Kao što je u prethodnim poglavljima rečeno, brzina izvođenja ovakvih algoritama uvelike će ovisiti o performansama uređaja na kojem se izvodi. Ipak, ovakvim ispitivanjem brzine može se uvidjeti mogućnost izvođenja na ciljanoj platformi, tj. uređaju. Također, može se zaključiti koliki postotak vremena u cjelokupnom postupku uzima određivanje smjera kretanja. Pokazalo se da kod stepenica određivanje smjera uzima samo 7 % ukupnog vremena, dok je kod pješačkih prijelaza to bilo 6 % ukupnog vremena. Dobiveni postoci stoga pokazuju da se uz minimalno produljenje vremena izvođenja po slici može dobiti konkretnija informacija za korisnika koja će uz samu informaciju o postojanju traženog objekta uključivati i predloženi sigurni smjer kretanja.

6.5. Korekcija odluke na temelju više uzastopnih slika

U dosadašnjem dijelu rada, u kontekstu usmjeravanja slijepih i slabovidnih osoba u stvarnom vremenu, odluke o smjeru donosile su se isključivo na temelju pojedinačne obrađene slike iz video isječka. Ipak, kako bi se smanjila mogućnost pogrešnog usmjeravanja i nagle promjene smjera, moguće je promatrati nekoliko uzastopnih slika i na temelju njih donijeti odluku za trenutno promatranu sliku. Na taj način mogu se dobiti korisne informacije promatranjem niza nekoliko uzastopnih odluka o postojanju traženog objekta i o smjeru kretanja. Primjerice, ako imamo izoliranu sliku u kojoj odluka odskače od onih dobivenih na slikama koje su njoj prethodile, vrlo su velike šanse da je došlo do pojedinačne pogreške na promatranoj slici. Isto tako, kada vrijednost kuta na jednoj slici značajno odstupa od prethodnih vrijednosti, postoji mogućnost da je došlo do pogreške, pa bi prije nagle promjene smjera za korisnika bilo dobro pričekati sljedeću sliku kako bi se potvrdila ili opovrgnula odluka. Ovakve dodatne mehanizme sprječavanja pogrešaka moguće je uvoditi samo kada je vrijeme obrade dovoljno malo da se stigne pričekati obrada nekoliko uzastopnih slika kako bi se donijela pravovremena odluka.

Kao prikladan mehanizam eliminacije izoliranih pogrešnih odluka na pojedinim slikama predlaže se metoda praćenja tri uzastopne slike. Za tri slike pratit će se sljedeća dva parametra: odluka je li traženi objekt pronađen i računalno određen kut smjera kretanja. Pod tri uzastopne slike smatraju se trenutno promatrana slika i dvije slike koje su joj prethodile. Kod predloženih metoda za detekciju i usmjeravanje postignuta je obrada 6.7 slika u sekundi za stepenice i 15.6 slika u sekundi za pješačke prijelaze pa će obrada tri slike koje će utjecati na odluku trajati manje od pola sekunde. To vrijeme kraće je nego što traje prosječan korak pješaka koji hoda. Stoga uzimanje u obzir informacije iz tri uzastopne slike ne bi smjelo negativno utjecati na pravovremeno informiranje korisnika.

Kao što je ranije navedeno, za tri uzastopne slike prate se dva parametra. Prvi je parametar odluka o postojanju traženog objekta koja će biti spremljena u polje od tri elementa čije će vrijednosti biti 1 ili 0 ovisno o postojanju traženog objekta na pojedinoj od tri promatrane slike. Odluka za promatranu sliku bit će medijan tih vrijednosti, odnosno vrijednost u sredini nakon što ih se sortira po veličini [98]. Na ovaj način za promatranu sliku odluka o postojanju traženog objekta moći će se donijeti samo ako je i za jednu od prethodne dvije slike donesena ista odluka. Na ovaj način izbjegava se prepoznavanje pogrešnih detekcija koje se pojavljuju samo na jednoj izoliranoj slici. Isto tako, prekid od jedne propuštene detekcije neće biti registriran ako su njemu prethodile dvije uspješne detekcije. Radi lakšeg praćenja prednosti analize tri uzastopne slike u

Tablica 6.2. Karakteristične kombinacije detekcija na tri uzastopne slike

A[n-2]	A[n-1]	A[n]		A'[n]	Opis
0	0	1	→	0	Izolirane slučajne detekcije neće biti detektirane
0	1	0	→	0	
1	0	0	→	0	
1	1	0	→	1	Izolirani slučajevi gubitka detekcije neće biti registrirani
1	0	1	→	1	
0	1	1	→	1	

tablici 6.2. prikazane su neke karakteristične situacije gdje $A[n]$ predstavlja odluku o detekciji za promatranu sliku, a $A'[n]$ predstavlja korigiranu odluku na temelju promatrane slike $A[n]$ i prethodnih slika $A[n-1]$ i $A[n-2]$.

Drugi parametar koji se prati kroz tri uzastopne slike je kut smjera kretanja. Kut određen na trenutno promatranju slici i vrijednosti kuta na prethodne dvije slike zapisuju se u polje od tri elementa te se nakon sortiranja takvog polja uzima medijan vrijednost kao rezultat. U slučajevima kada jedna od tri promatrane vrijednosti kuta odskače od druge dvije, medijan vrijednost uvijek će biti jedna od dvije slične vrijednosti dok će se ona koja odskače zanemariti. Prema tome, kod naglih promjena smjera moraju se pojaviti barem dva slična kuta kako bi se registrirala promjena. S druge strane, kada se pojavljuju kutovi sličnih veličina, medijan vrijednost neće narušiti odluku o smjeru. Ovime je izbjegnuta nepotrebna česta promjena smjera, kao i nagle velike promjene uzrokovane pogrešno određenim kutom u pojedinim izoliranim slikama. Karakteristične situacije

Tablica 6.3. Karakteristične kombinacije kutova na tri uzastopne slike

B[n-2]	B[n-1]	B[n]		B'[n]	Opis
25°	22°	-15°	→	22°	Nagla promjena kuta neće odmah utjecati na promjenu smjera, nego tek nakon 2 slična kuta
22°	-15°	-14°	→	-14°	
35°	32°	30°	→	32°	Male oscilacije u kutovima neće uzrokovati neprestane promjene smjera
32°	30°	33°	→	32°	
30°	33°	32°	→	32°	


prikazane su u tablici 6.3. gdje je $B[n]$ vrijednost kuta određenog za trenutno promatranu sliku, a $B'[n]$ je korigirana vrijednost kuta izračunata kao medijan tri vrijednosti koje uključuju kutove na trenutnoj slici ($B[n]$) i na prethodne dvije slike ($B[n-1]$ i $B[n-2]$).

7. OKVIR ZA EVALUACIJU METODA USMJERAVANJA SLIJEPIH I SLABOVIDNIH OSOBA NA STEPENICAMA I PJEŠAČKIM PRIJELAZIMA

Ovo poglavlje objedinjuje postupak testiranja razvijenih metoda za usmjeravanje slijepih i slabovidnih osoba i ocjenjivanje uspješnosti usmjeravanja usporedbom odluka čovjeka i računala. Poglavlje je podijeljeno u sljedeća potpoglavlja: testno okruženje, baza ulaznih podataka i ocjenjivanje točnosti odluka.

7.1. Testno okruženje

Kako bi se što lakše provelo testiranje razvijenih metoda, u sklopu ovog rada razvijeno je i testno okruženje (Slika 7.1.) u kojemu će se moći vršiti ispitivanja na ulaznim slikama i video isječcima. Korisniku testnog okruženja omogućeno je učitavanje slike ili video isječka te za iste može provesti računalni postupak detekcije i donošenja odluke o predloženom najsigurnijem smjeru kretanja. Računalna odluka s prikazom detektiranog područja i smjera kretanja prikazuje se na lijevom prozoru. Istovremeno, korisnik u sučelju može za promatranu sliku odrediti i spremiti odluku čovjeka o sigurnom smjeru kretanja. Odluka čovjeka sprema se tako da korisnik u desnom prozoru sa slikom označava pravokutno područje za koje smatra da je najsigurnije za kretanje. Za označeno pravokutno područje računa se kut smjera kretanja, a korisnik za istu sliku daje i svoju odluku odabirom jednog od pet pojednostavljenih smjerova kretanja. Na ovaj način bit će moguće napraviti usporedbu računalne i čovjekove odluke za svaku sliku na temelju razlike kutova i usporedbom donesenih pojednostavljenih odluka o smjeru kretanja.



Slika 7.1. Prikaz razvijenog testnog okruženja

Tablica 7.1. Funkcionalnosti razvijenog testnog okruženja

Elementi sučelja		Opis funkcionalnosti	
Odjeljak za obradu slike (Image)	Gumb <i>Start image</i>	Obrada pojedinačne slike	
	Gumb <i>Start folder</i>	Obrada više slika iz iste datoteke	
Odjeljak za obradu videa (Video)	Gumb <i>Choose video</i>	Odabir video datoteke za obradu (podržani formati: .avi i .mp4)	
	Gumb <i>Start video</i>	Obrada uzastopnih slika izravno s kamere	
		Obrada cijele video datoteke (ako je odabrana datoteka)	
	Parametar <i>Frame step</i>	Omogućava obradu svake <i>n</i> -te slike u video isječku	
	Odjeljak za analizu svake slike video isječka (<i>Frame-by-frame analysis</i>)	Gumb <i>Next</i>	Obrada sljedeće slike u video isječku
		Gumb <i>Save frame decision</i>	Spremanje računalne odluke i ručno označene čovjekove odluke
		Gumb <i>Write decisions to file</i>	Zapis svih odluka u datoteku
	Gumb <i>Save snapshot</i>	Spremanje trenutno promatrane slike iz video isječka kao nove datoteke	
Prozor <i>Human decision</i>		Prikaz slike i pregled svih računalno donesenih odluka	
Prozor <i>Computer decision</i>		Prikaz slike i mogućnost ručnog označavanja područja i odabira odluke	

Uz mogućnost obrade pojedinačnih slika sučelje omogućava i obradu video isječaka. Računalnu odluku moguće je pratiti u stvarnom vremenu kako se video reproducira, ali je moguće i analizirati svaku sliku iz video isječka pojedinačno (engl. *frame-by-frame analysis*). Odluke za sve ručno označene slike moguće je zajedno s računalnim odlukama spremi u datoteku radi lakše analize rezultata. Iako je ovo testno okruženje prilagođeno za testiranje konkretnih novorazvijenih metoda, moguće ga je koristiti i općenito za označavanje slika u svim slučajevima kada se na slici treba pronaći određeno pravokutno područje interesa. Okruženje za testiranje i vizualno korisničko sučelje razvijeni su u programskom jeziku C# uz korištenje funkcija iz OpenCV biblioteke [99] pomoću omotača (engl. *wrapper*) EmguCV [100]. Uz spomenute mogućnosti usporedbe računalne i ljudske odluke, u okruženju je moguće pratiti sve međukorake i mjeriti parametre važne za detekciju koji su prikazani na slikama ranije u ovom radu. Sve funkcionalnosti razvijenog testnog okruženja objedinjene su u tablici 7.1.

7.2. Baza slika i video isječaka

S obzirom na to da u ovom istraživačkom području nije dostupna javna baza slika ili video isječaka za testiranje uspješnosti navođenja slijepih i slabovidnih osoba u konkretnim situacijama, u sklopu ovog istraživanja snimljen je određeni broj video isječaka na kojima će se metoda testirati. Snimljeno je 20 video isječaka s kompletnim postupkom prilaska stepenicama i prelaskom preko istih. Iz svakog video isječka izdvojeno je po 25 slika što ukupno čini 500 slika za testiranje. Isti broj slika izdvojen je i za scene prilaska i prelaska preko pješačkog prijelaza. Svi ulazni video isječci snimljeni su u pokretu s kamerom postavljenom na osobu, a rezolucija video isječaka je 640×360 piksela. Prilikom izdvajanja slika odabran je reprezentativan skup koji obuhvaća što više karakterističnih situacija po pitanju zahtijevanog smjera kretanja. Uzorak uključuje situacije gdje se stepenice ili pješački prijelazi nalaze na različitim pozicijama na slici. Osim toga, iznimno su važne situacije za testiranje gdje je dio stepenica ili pješačkog prijelaza zaklonjen, što se pretežno događa zbog prisutnosti drugih osoba koje se kreću ispred korisnika. Uz prethodno navedene situacije, otežanu detekciju točnog smjera kretanja prouzrokovat će i različiti uvjeti prilikom snimanja. Iz tog razloga reprezentativni uzorak uključuje video isječke snimljene na dnevnom svjetlu, pod umjetnim osvjetljenjem, te u sunčanim i oblačnim vremenskim uvjetima. Zbog raznolikih uvjeta snimanja ulazni podaci bit će različitog kontrasta, količine šuma i svjetline. Opće karakteristike video isječaka i slika u prikupljenoj bazi podataka dane su u tablici 7.2.

Tablica 7.2. Karakteristike video isječaka i slika u bazi podataka

	Stepenice	Pješački prijelazi
<i>Broj video isječaka</i>	20	20
<i>Format video zapisa</i>	mp4	mp4
<i>Frekvencija</i>	30 fps	30 fps
<i>Rezolucija</i>	640×360	640×360
<i>Gustoća zapisa</i>	~1500 kbps	~1500 kbps
<i>Format zapisa video isječaka</i>	mp4	mp4
<i>Broj izdvojenih slika po isječku</i>	25	25
<i>Ukupno slika</i>	500	500
<i>Format zapisa slika</i>	jpg	jpg


7.3. Ocjenjivanje točnosti odluka

Kao što je ranije spomenuto, predloženi smjer kretanja na stepenicama ili pješačkim prijelazima određen je kutom između okomite linije koja prolazi sredinom slike i linije koja spaja polazišnu točku i središte detektiranog područja. Kako bi se ocijenila uspješnost određivanja smjera predloženim metodama, dobiveni kutovi smjera uspoređuju se s odlukom čovjeka koja se smatra temeljnom istinom (engl. *ground truth*). Nakon što se u testnom okruženju ručno označi pravokutno područje za koje čovjek smatra da je najsigurnije za kretanje, automatski se određuje kut kretanja na isti način kao i kod računalno detektiranog područja. S obzirom na to da će se područje sigurnog kretanja koje je označio čovjek i ono detektirano razvijenom metodom donekle razlikovati, tako će i dobivena vrijednost kuta biti različita. Kvalitativna ocjena uspješnosti dobiva se usporedbom kutova dobivenih na temelju područja koje je označio čovjek i područja dobivenog


Tablica 7.3. Prosječno odstupanje predloženog kuta kretanja od odluke čovjeka

Primjena	Broj slika	Odstupanje kuta kretanja
<i>Stepenice</i>	500	6.93°
<i>Pješački prijelazi</i>	500	5.99°

korištenjem razvijenih metoda. Tablica 7.3. prikazuje prosječno odstupanje predloženog kuta kretanja za uzorak od 500 slika sa stepenicama i 500 slika s pješačkim prijelazima iz baze podataka. Rezultati pokazuju da je prosječno odstupanje kuta kod stepenica 6.93° , dok je kod pješačkih prijelaza 5.99° . Ako se detaljnije analizira udio pojedinih odstupanja (δ) po grupama kutova (Slika 7.2.), vidljivo je da iznimno mali broj odstupanja pripada skupini gdje se kutovi razlikuju više od 20° . Takvih je značajnijih odstupanja 2.8 % kod stepenica, a samo 1.2 % kod pješačkih prijelaza na skupovima od 500 ulaznih slika. S druge strane daleko je najveća grupa



(a)



(b)

Slika 7.2. Udjeli odstupanja kutova (δ) po grupama za skup slika sa: (a) stepenicama; (b) pješačkim prijelazima

odstupanja kod kojih je razlika u kutovima manja od 5° što je gotovo zanemarivo i takva pogreška može nastati uslijed nepreciznosti čovjeka prilikom označavanja ulaznog skupa podataka.

S obzirom na to da će se slijepog ili slabovidnog korisnika informirati pojednostavljenom odlukom o predloženom smjeru kretanja, izvršena je i usporedba subjektivne čovjekove odluke s računalno donesenom odlukom. Čovjek prilikom označavanja testnih slika bira jedan od pet ponuđenih smjerova kretanja. Usporedbom tih odluka s računalno dobivenim odlukama o smjeru dobiva se postotak podudaranja odluka koji je prikazan u tablici 7.4. za stepenice i u tablici 7.5. za pješačke prijelaze. Za odluke računala koje se ne podudaraju dodatno je izrađena analiza po četiri moguće razine odstupanja. Ovdje će jedna razina odstupanja značiti da je prema razdiobi odluka sa slike 6.6. računalno donesena odluka koja je susjedna čovjekovoj odluci. Primjerice, to bi bilo u slučaju kada je subjektivna odluka čovjeka „blago desno“, a računalom dobivena odluka „oštro desno“. S druge strane, najveća pogreška od četiri razine bila bi kada je subjektivna odluka „oštro lijevo“, a računalom dobivena odluka potpuno suprotna „oštro desno“. Rezultati su pokazali da na cijelom skupu od ukupno 1000 slika stepenica i pješačkih prijelaza nije bilo pogrešaka od 2, 3 ili 4 razine. Kod slika sa stepenicama u 13 % slučajeva utvrđena je pogreška od jedne razine, dok u 87 % slučajeva nije bilo odstupanja u subjektivnoj odluci čovjeka i računalom dobivenoj odluci. Kod pješačkih prijelaza postignuti su još bolji rezultati gdje se pogreška od jedne razine dogodila u 10.2 % slučajeva, dok je uspješno bez odstupanja doneseno 89.8 % odluka.

Tablica 7.4. Zastupljenost pojedinih razina odstupanja odluke računala od odluke čovjeka prilikom određivanja smjera kretanja na stepenicama

Razina odstupanja		Udio odluka
<i>Nema odstupanja</i>		87.0 %
<i>ukupno</i>		13.0 %
1 razina	<i>odstupanje $< 15^\circ$</i>	7.8 %
	<i>odstupanje $\geq 15^\circ$</i>	5.2 %
2 razine		0 %
3 razine		0 %
4 razine		0 %

Tablica 7.5. Zastupljenost pojedinih razina odstupanja odluke računala od odluke čovjeka prilikom određivanja smjera kretanja na pješačkim prijelazima

Razina odstupanja	Udio odluka
<i>Nema odstupanja</i>	89.8 %
<i>ukupno</i>	10.2 %
<i>1 razina</i>	
<i>odstupanje < 15°</i>	9.4 %
<i>odstupanje ≥ 15°</i>	0.8 %
<i>2 razine</i>	0 %
<i>3 razine</i>	0 %
<i>4 razine</i>	0 %

Ako se detaljnije analiziraju sve pogreške od jedne razine, mogu se unutar skupa takvih pogrešaka mjeriti odstupanja od graničnih vrijednosti za ispravnu referentnu odluku čovjeka. Na taj način dobivene su dodatne informacije da je od 13 % pogrešnih odluka za stepenice većina njih (7.8 % od ukupnog broja) za manje od 15° udaljena od ispravne odluke. Slično je i kod pješačkih prijelaza gdje je od 10.2 % pogrešaka od jedne razine čak 9.4 % za manje od 15° udaljeno od ispravne odluke. Primjerice, to znači da se kod subjektivne odluke „oštro lijevo“ (raspon kutova od 50° do 90°) većina pogrešaka od jedne razine dogodila zbog računalno dobivenog kuta između 35° i 50°, a tek manji dio zbog veće pogreške kuta. Slično je i za ostale odluke, pa se može generalno zaključiti da su pogrešne odluke računala često blizu graničnih vrijednosti referentnih čovjekovih odluka.


Smatra se da pogreška od jedne razine smjera nije presudna za usmjeravanje korisnika u cjelini, posebno ako je riječ o graničnim područjima gdje ponekad i čovjek prilikom označavanja subjektivnih odluka na slici dvoji između dviju sličnih odluka. Kako bi se pravilnije ocijenile računalne odluke, u ovom radu razvijen je novi kriterij za ocjenu točnosti odluke koji će voditi računa o područjima uz granice pojedinih odluka. Prema novom kriteriju, točnost odluke neće biti isključivo binarna odluka (točno-netočno), već će u graničnim područjima točnost poprimiti vrijednosti između 0 i 1. Tako će one odluke donesene na temelju kuta koji je blizu samih graničnih referentnih vrijednosti biti znatno bolje ocijenjene od onih koje su daleko od njih. Primjerice, kada je čovjekova odluka „oštro lijevo“ (referentni raspon kutova od 50° do 90°), a računalno dobiveni kut je 49.9°, tada se može reći da je točnost izrazito visoka iako je računalna odluka „blago lijevo“.

U suprotnom, kada za istu čovjekovu odluku računalno dobiveni kut iznosi 25° , što je također odluka „blago lijevo“, točnost takve odluke bit će izrazito niska jer je dobiveni kut daleko od granica ispravne odluke.


Za određivanje točnosti (g) u graničnim područjima kriterij koristi modificiranu Gaussovu funkciju koja prima određeni kut smjera (α) kao parametar kako bi se odredila točnost ovisno o udaljenosti od granica točne odluke. Tako će za kut koji je bliži granici točne odluke točnost biti blizu vrijednosti 1, dok će udaljavanjem od točne odluke biti sve bliža vrijednosti 0. U slučajevima kada se računalno dobivena odluka poklapa s referentnom čovjekovom odlukom, točnost za takvu sliku bit će 1 bez obzira na kut. Isto tako, za sve kutove koji odstupaju od granica točne odluke za 15° ili više stupnjeva točnost će biti jednaka vrijednosti 0. S obzirom na to da svaka odluka o smjeru ima drugačiji referentni raspon kutova, definirane su formule za točnost kod svih pet slučajeva.

Prvi slučaj odnosi se na određivanje točnosti odluke računala (g_1) na temelju određenog kuta (α) za smjer „ravno“ koja je dana formulom (7-1). Graf na slici 7.3. prikazuje odnos računalno određenog kuta kretanja i točnosti donesene odluke koja može poprimiti vrijednosti od 0 do 1. Ovakav graf zvat će se kriterij za ocjenu odluke računala.

$$g_1(\alpha) = \begin{cases} e^{-(0.03 \cdot (|\alpha| - 20)^2)}, & \alpha \in \langle -35, -20 \rangle \cup \langle 20, 35 \rangle \\ 1, & \alpha \in [-20, 20] \\ 0, & \alpha \in [-90, -35] \cup [35, 90] \end{cases} \quad (7-1)$$



Slika 7.3. Kriterij za ocjenu odluke računala (smjer: *ravno*)



Slika 7.4. Kriterij za ocjenu odluke računala (smjer: *blago lijevo*)

Točnost odluke za smjer „blago lijevo“ (g_2) računa se prema formuli (7-2), a na slici 7.4. nalazi se graf koji prikazuje kriterij za ocjenu odluke računala.


$$g_2(\alpha) = \begin{cases} e^{-(0.03*(20-\alpha)^2)}, & \alpha \in \langle 5,20 \rangle \\ e^{-(0.03*(\alpha-50)^2)}, & \alpha \in \langle 50,65 \rangle \\ 1, & \alpha \in [20,50] \\ 0, & \alpha \in [-90,5] \cup [65,90] \end{cases} \quad (7-2)$$

Nadalje, točnost odluke za smjer „blago desno“ (g_3) računa se prema formuli (7-3), a graf kriterija za ovakvu odluku prikazan je na slici 7.5.

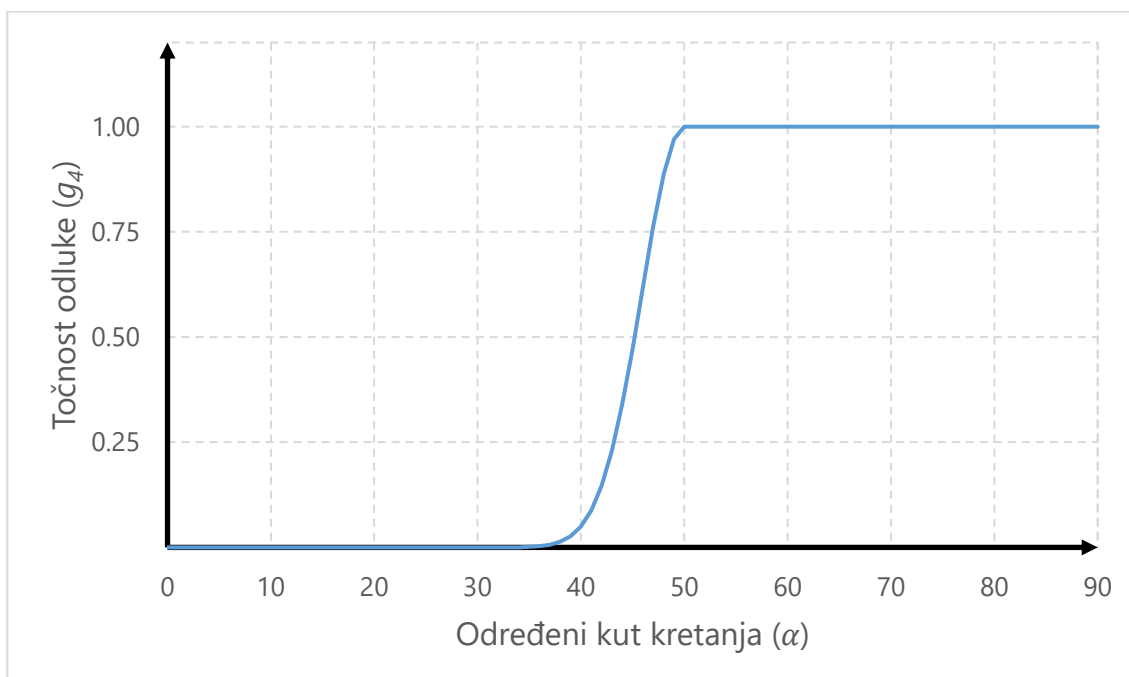
$$g_3(\alpha) = \begin{cases} e^{-(0.03*(|\alpha|-50)^2)}, & \alpha \in \langle -65, -50 \rangle \\ e^{-(0.03*(20-|\alpha|)^2)}, & \alpha \in \langle -20, -5 \rangle \\ 1, & \alpha \in [-50, -20] \\ 0, & \alpha \in [-90, -65] \cup [-5,90] \end{cases} \quad (7-3)$$

Formula (7-4) definira određivanje točnosti odluke za smjer „oštro lijevo“ (g_4), a takav kriterij prikazan je grafom na slici 7.6.

$$g_4(\alpha) = \begin{cases} e^{-(0.03*(50-\alpha)^2)}, & \alpha \in \langle 35,50 \rangle \\ 1, & \alpha \in [50,90] \\ 0, & \alpha \in [-90,35] \end{cases} \quad (7-4)$$




Slika 7.5. Kriterij za ocjenu odluke računala (smjer: *blago desno*)



Slika 7.6. Kriterij za ocjenu odluke računala (smjer: *oštro lijevo*)

Posljednji je slučaj definiranje točnosti za smjer „oštro desno“ (g_5) prema formuli (7-5), a ovaj je kriterij vizualiziran grafom na slici 7.7.



Slika 7.7. Kriterij za ocjenu odluke računala (smjer: *oštro desno*)

$$g_5(\alpha) = \begin{cases} e^{-(0.03 \cdot (50 - |\alpha|)^2)}, & \alpha \in (-50, -35) \\ 1, & \alpha \in [-90, -50] \\ 0, & \alpha \in [-35, 90] \end{cases} \quad (7-5)$$

Nakon što je definiran kriterij za ocjenu točnosti računalnih odluka, moguće je prema takvom kriteriju izračunati prosječnu uspješnost metode za određivanje smjera kretanja na stepenicama i pješačkim prijelazima. Metoda je opet testirana na skupu od 500 slika za stepenice i 500 slika za pješačke prijelaze. Rezultati ocjene uspješnosti razvijene metode prema novom kriteriju prikazani su u tablici 7.6. Pokazalo se da je prosječna uspješnost metode veća nego što je to bio slučaj kada se radila gruba ocjena samo na temelju usporedbe odluka (tablice 7.4. i 7.5.). Uspješnost razvijene metode za usmjeravanje na stepenicama iznosi 93.96 %, dok je kod usmjeravanja na pješačkim prijelazima postignuta još veća točnost od 97.17 %.

Tablica 7.6. Uspješnost metode za usmjeravanje prema novom kriteriju

Primjena	Broj slika	Prosječna točnost
<i>Stepenice</i>	500	93.96 %
<i>Pješački prijelazi</i>	500	97.17 %

Iako je predloženi kriterij prikazan i testiran na primjeru usmjeravanja na stepenicama i pješačkim prijelazima, može se zaključiti da je on univerzalno primjenjiv i na druge postupke usmjeravanja. Predloženi kriterij moguće je, bez obzira na konačno mjesto primjene, koristiti za ocjenu usmjeravanja kada je smjer kretanja određen veličinom kuta kao što je to predloženo u potpoglavlju 6.2.

8. ZAKLJUČAK

Razvoj naprednih digitalnih pomagala za slijepe i slabovidne osobe nije česta tema znanstvenih istraživanja. Ipak, pokazalo se da metode temeljene na računalnoj obradi slike doprinose razvoju ovakvih pomagala, posebno u užem području koje se odnosi na problem samostalnog kretanja slijepih i slabovidnih osoba. U ovoj disertaciji prikazano je da problemi upozoravanja i usmjeravanja slijepih i slabovidnih osoba u kritičnim situacijama kao što su hodanje po stepenicama ili pješačkim prijelazima mogu biti uspješno riješeni računalnom obradom slike u stvarnom vremenu.

Predložene su dvije nove metode za detekciju stepenica i pješačkih prijelaza, te metoda zvučnog usmjeravanja određivanjem prostora za sigurno kretanje. Sve tri metode zasnovane su na postupcima morfološke obrade i analize slike. Prilikom ovog istraživanja prikupljen je velik broj slika i video isječaka koji čine bazu ulaznih podataka za testiranje. Svi podaci prikupljeni su standardnim monokularnim kamerama malih dimenzija, a testiranje je provedeno na prijenosnim uređajima kako bi se pokazala mogućnost korištenja u pokretu. Uz bazu podataka dodatno je razvijeno testno okruženje za evaluaciju ovakvih metoda uz novi kriterij za ocjenu točnosti usmjeravanja.

Predložena metoda za detekciju stepenica korištenjem vertikalne i horizontalne analize u video isječcima pokazala se prikladnom i uspješnom u otvorenim i zatvorenim prostorima. Stavljanjem analize binarnih stupaca slike u prvi plan ispred ustaljenog traženja horizontalnih linija postignuti su brojni pozitivni učinci. Predloženim postupkom postignute su prednosti u odnosu na postojeće metode, što se prvenstveno odnosi na robusnost u slučajevima raznih nepravilnosti na stepenicama te kod prisutnosti drugih osoba na stepenicama. Metoda je kompatibilna s ulaznim podacima sa širokokutne kamere, što nije slučaj kod sličnih metoda. Rezultati testiranja uspješnosti ove metode (95.83 %) ukazali su na veću uspješnost od ostalih metoda koje koriste monokularne kamere, a tek neznatno slabiji rezultat od metoda koje koriste stereo kamere. Brzina izvođenja na prosječnom prijenosnom uređaju od 7.1 slika po sekundi zadovoljava uvjete za izvođenje u stvarnom vremenu prilikom kretanja osobe.

Predložena metoda za detekciju pješačkih prijelaza zbog multirezolucijskog pristupa odskoče od drugih metoda koje obrađuju sliku u jednoj rezoluciji. Ovakvim pristupom postignuta su značajna ubrzanja smanjivanjem količine podataka koje treba obraditi za 64.46 % što u konačnici doprinosi mogućnosti primjene metode u stvarnom vremenu s obradom 16.6 slika u sekundi na prosječnom prijenosnom uređaju. Uspješnost ove metode prilikom testiranja bila je

98.33 %, što nadilazi postojeće metode koje koriste monokularne kamere, ali i one koje koriste stereo kamere. Testiranje ove metode na reprezentativnom uzorku ulaznih slika pokazalo je robusnost u slučajevima oštećenja i istrošenosti pješačkih prijelaza te prilikom značajnijeg zamućenja slika nastalog uslijed snimanja u pokretu. Kao i prethodna metoda za detekciju stepenica i ova je metoda kompatibilna s ulaznim podacima sa širokokutne kamere što ju dodatno ističe u odnosu na slične metode.

Kako bi razvijene metode bile potencijalno primjenjive za orijentaciju i stvaranje percepcije prostora kod slijepih i slabovidnih osoba, razvijena je i dodatna metoda za usmjeravanje na detektiranim stepenicama i pješačkim prijelazima. Glavni je doprinos ove metode određivanje prostora za sigurno kretanje, što uključuje izbjegavanje potencijalnih prepreka i drugih osoba na samim stepenicama ili pješačkim prijelazima. Iako je metoda prilagođena za korištenje rubnih točaka iz prethodne dvije metode kao ulaznih podataka, moguće je dio metode koristiti kao univerzalan način usmjeravanja prema području interesa detektiranom na slici. Predloženi model zvučnog navođenja u pojednostavljenih pet mogućih smjerova pokazao se kao vrlo intuitivan način informiranja i usmjeravanja slijepih i slabovidnih osoba u pokretu.

Prilikom istraživanja u ovom znanstvenom području nije pronađena unificirana baza ulaznih podataka za probleme detekcije stepenica i pješačkih prijelaza, pa je stvaranje takve baze bio jedan od ključnih čimbenika prilikom kvalitativne ocjene razvijenih metoda za detekciju i usmjeravanje. Stvorena baza podataka sadrži video isječke i skup reprezentativnih slika izdvojenih iz istih. Isječci su snimljeni u pokretu s kamerom postavljenu na osobu, a izdvajanje slika za testiranje izravno iz takvih video isječaka doprinosi postizanju što realnijih uvjeta prilikom testiranja. Osim prikupljanja reprezentativnih ulaznih podataka, razvijeno je i testno okruženje za evaluaciju metoda usmjeravanja slijepih i slabovidnih osoba koje znatno olakšava testiranje i ocjenu ovakvih i sličnih metoda. Uz testno okruženje predložen je i novi kriterij za ocjenu točnosti usmjeravanja zasnovan na mjerenju udaljenosti određenog kuta kretanja od referentnih raspona kutova za pojedini smjer. Ovaj kriterij omogućio je pravedniju ocjenu točnosti metoda kojima je cilj odrediti točan smjer kretanja.

Razvijene metode mogu pomoći samo u specifičnim kritičnim točkama kao što su stepenice i pješački prijelazi. Ovakve metode trebale bi biti dio većeg sustava za pomoć slijepim i slabovidnim osobama u raznim kritičnim točkama. Već je ranije spomenuto da osim stepenica i pješačkih prijelaza postoje mnoge prepreke prilikom kretanja slijepih i slabovidnih koje se mogu detektirati, isto tako i točke interesa prema kojima se žele kretati. Stoga je krajnji cilj imati jedan

sustav koji će integrirati više načina i više područja u kojima pomaže slijepim i slabovidnim osobama.

U posljednje vrijeme računalna obrada slike i računalni vid izrazito su zastupljeni u znanstvenim istraživanjima, posebno u kontekstu razvoja autonomnih vozila, robota i raznih sigurnosnih mehanizama u istima. Iako je digitalizacija pomagala za kretanje slijepih i slabovidnih osoba srodna ovim problemima, u znanosti je ipak u znatno manjoj mjeri zastupljena. Stoga istraživanja poput opisanog u ovoj disertaciji imaju važnu ulogu i u podizanju svijesti o problemima slijepih i slabovidnih osoba te o osobama s posebnim potrebama općenito.

LITERATURA

- [1] World Health Organization, „Visual impairment and blindness“. [Na internetu]. Dostupno na: <http://www.who.int/mediacentre/factsheets/fs282/en/>. [Pristupljeno: 13-lis-2015].
- [2] S. Shoval, I. Ulrich, i J. Borenstein, „NavBelt and the Guide-Cane [obstacle-avoidance systems for the blind and visually impaired]“, *IEEE Robotics Automation Magazine*, sv. 10, izd. 1, str. 9–20, ožu. 2003.
- [3] L. Hakobyan, J. Lumsden, D. O’Sullivan, i H. Bartlett, „Mobile assistive technologies for the visually impaired“, *Survey of Ophthalmology*, sv. 58, izd. 6, str. 513–528, stu. 2013.
- [4] Ł. K. Andrzej Stepnowski, „Voice maps: the system for navigation of blind in urban area“, str. 201–206, 2011.
- [5] Coughlan, „Functional Assessment of a Camera Phone-Based Wayfinding System Operated by Blind and Visually Impaired Users“, *International Journal on Artificial Intelligence Tools, Special Issue on Artificial Intelligence Based Assistive Technologies: Methods and Systems for People with Disabilities*, sv. 18, str. 379–397, 2009.
- [6] M. F. Joao Jose, „The Smart Vision Local Navigation Aid for Blind and Visually Impaired Persons“, *JDCTA: International Journal of Digital Content Technology and its Applications*, sv. 5, izd. 5, str. 362–375, 2011.
- [7] E. Peng, P. Peursum, L. Li, i S. Venkatesh, „A Smartphone-Based Obstacle Sensor for the Visually Impaired“, u *Ubiquitous Intelligence and Computing*, Z. Yu, R. Liscano, G. Chen, D. Zhang, i X. Zhou, Ur. Springer Berlin Heidelberg, 2010, str. 590–604.
- [8] D. AbdulRasool i S. Sabra, „Mobile-Embedded Smart Guide for the Blind“, u *Digital Information and Communication Technology and Its Applications*, H. Cherifi, J. M. Zain, i E. El-Qawasmeh, Ur. Springer Berlin Heidelberg, 2011, str. 571–578.
- [9] S. Carbonara i C. Guaragnella, „Efficient stairs detection algorithm Assisted navigation for vision impaired people“, u *2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings*, 2014, str. 313–318.
- [10] H. Shen, K.-Y. Chan, J. Coughlan, i J. Brabyn, „A mobile phone system to find crosswalks for visually impaired pedestrians“, *Technology and disability*, sv. 20, izd. 3, str. 217, 2008.
- [11] J. M. Coughlan i H. Shen, „A fast algorithm for finding crosswalks using figure-ground segmentation“, u *Proc. 2nd Workshop on Applications of Computer Vision, in conjunction with ECCV*, 2006.
- [12] M. Radvanyi, B. Varga, i K. Karacs, „Advanced crosswalk detection for the Bionic Eyeglass“, u *12th International Workshop on Cellular Nanoscale Networks and Their Applications (CNNA)*, 2010, str. 1–5.
- [13] K. Karacs, M. Radvanyi, M. Görög, Á. Kusnyerik, i T. Roska, „A mobile visual navigation device: New algorithms for crosswalk and pictogram recognition“, u *Applied Sciences in Biomedical and Communication Technologies, 2009. ISABEL 2009. 2nd International Symposium on*, 2009, str. 1–2.
- [14] X. Liu, D. Doermann, i H. Li, „Mobile Visual Aid Tools for Users with Visual Impairments“, u *Mobile Multimedia Processing*, X. Jiang, M. Y. Ma, i C. W. Chen, Ur. Springer Berlin Heidelberg, 2010, str. 21–36.

- [15] V. Kulyukin i A. Kutiyawala, „Accessible shopping systems for blind and visually impaired individuals: Design requirements and the state of the art“, *The Open Rehabilitation Journal*, sv. 3, str. 158–168, 2010.
- [16] „OrCam MyEye 2“, *OrCam*. [Na internetu]. Dostupno na: <https://www.orcam.com/gb/myeye2/>. [Pristupljeno: 12-srp-2018].
- [17] E. J. Steel i L. P. de Witte, „Advances in European Assistive Technology Service Delivery and recommendations for further improvement“, *Technology and Disability*, sv. 23, str. 131–138, 2011.
- [18] M. Billi i ostali, „A unified methodology for the evaluation of accessibility and usability of mobile applications“, *Univ Access Inf Soc*, sv. 9, izd. 4, str. 337–356, ožu. 2010.
- [19] R. Velzquez, F. Maignraud, i E. E. Pissaloux, „Intelligent Glasses: A New Man-Machine Interface Concept Integrating Computer Vision and Human Tactile Perception“, u *Proceedings of EuroHaptics 2003*, 2003, str. 456–460.
- [20] A. Betancourt, P. Morerio, C. S. Regazzoni, i M. Rauterberg, „The Evolution of First Person Vision Methods: A Survey“, *IEEE Transactions on Circuits and Systems for Video Technology*, sv. 25, izd. 5, str. 744–760, svi. 2015.
- [21] N. Kehtarnavaz i M. N. Gamadia, *Real-time Image and Video Processing: From Research to Reality*. Morgan & Claypool Publishers, 2006.
- [22] D. Dakopoulos i N. G. Bourbakis, „Wearable Obstacle Avoidance Electronic Travel Aids for Blind: A Survey“, *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, sv. 40, izd. 1, str. 25–35, sij. 2010.
- [23] H. S. Tomohiro Amemiya, „Haptic handheld wayfinder with pseudo-attraction force for pedestrians with visual impairments“, *Proceedings of the 11th International ACM SIGACCESS Conference on Computers and Accessibility*, str. 107–114, 2009.
- [24] T. Amemiya i H. Sugiyama, „Orienting Kinesthetically: A Haptic Handheld Wayfinder for People with Visual Impairments“, *ACM Transactions on Accessible Computing*, sv. 3, izd. 2, str. 1–23, stu. 2010.
- [25] J. Krumm, *Ubiquitous Computing Fundamentals*. CRC Press, 2009.
- [26] R. O. Duda i P. E. Hart, „Use of the Hough Transformation to Detect Lines and Curves in Pictures“, *Commun. ACM*, sv. 15, izd. 1, str. 11–15, sij. 1972.
- [27] S. Shahrabadi, J. M. Rodrigues, i J. H. Du Buf, „Detection of indoor and outdoor stairs“, u *Pattern Recognition and Image Analysis*, Springer, 2013, str. 847–854.
- [28] S. Se i M. Brady, *Vision-based Detection of Stair-cases*. 2000.
- [29] W. Li, K. Mao, H. Zhang, i T. Chai, „Selection of Gabor filters for improved texture feature extraction“, u *2010 17th IEEE International Conference on Image Processing (ICIP)*, 2010, str. 361–364.
- [30] C. Zhong, Y. Zhuang, i W. Wang, „Stairway detection using Gabor Filter and FPPG“, u *2011 International Conference of Soft Computing and Pattern Recognition (SoCPaR)*, 2011, str. 578–582.
- [31] D. C. Hernández i K.-H. Jo, „Stairway segmentation using Gabor Filter and vanishing point“, u *2011 International Conference on Mechatronics and Automation (ICMA)*, 2011, str. 1027–1032.

- [32] S. Se, „Zebra-crossing detection for the partially sighted“, u *IEEE Conference on Computer Vision and Pattern Recognition, 2000. Proceedings*, 2000, sv. 2, str. 211–217.
- [33] D. C. Hernández, T. Kim, i K.-H. Jo, „Stairway Detection Based on Single Camera by Motion Stereo“, u *Modern Approaches in Applied Intelligence*, K. G. Mehrotra, C. K. Mohan, J. C. Oh, P. K. Varshney, i M. Ali, Ur. Springer Berlin Heidelberg, 2011, str. 338–347.
- [34] X. Y. Yingli Tian, „Toward a Computer Vision-based Wayfinding Aid for Blind Persons to Access Unfamiliar Indoor Environments“, *Machine vision and applications*, sv. 24, izd. 3, str. 521–535, 2013.
- [35] J. A. Hesch, G. L. Mariottini, i S. I. Roumeliotis, „Descending-stair detection, approach, and traversal with an autonomous tracked vehicle“, u *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2010, str. 5525–5531.
- [36] S. Wang i H. Wang, „2D staircase detection using real AdaBoost“, u *7th International Conference on Information, Communications and Signal Processing, 2009. ICICS 2009*, 2009, str. 1–5.
- [37] T. Asami i K. Ohnishi, „Crosswalk location, direction and pedestrian signal state extraction system for assisting the expedition of person with impaired vision“, u *Mecatronics (MECATRONICS), 2014 10th France-Japan/8th Europe-Asia Congress on*, 2014, str. 285–290.
- [38] M. S. Uddin i T. Shioyama, „Robust zebra-crossing detection using bipolarity and projective invariant.“, u *ISSPA*, 2005, str. 571–574.
- [39] M. S. Uddin i T. Shioyama, „Detection of Pedestrian Crossing Using Bipolarity Feature-an Image-based Technique“, *Trans. Intell. Transport. Sys.*, sv. 6, izd. 4, str. 439–445, pros. 2005.
- [40] V. Ivanchenko, J. Coughlan, i H. Shen, „Detecting and locating crosswalks using a camera phone“, u *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2008. CVPRW'08.*, 2008, str. 1–8.
- [41] V. N. Murali i J. M. Coughlan, „Smartphone-based crosswalk detection and localization for visually impaired pedestrians“, u *2013 IEEE International Conference on Multimedia and Expo Workshops (ICMEW)*, 2013, str. 1–7.
- [42] J. M. Coughlan i H. Shen, „Crosswatch: a System for Providing Guidance to Visually Impaired Travelers at Traffic Intersections“, *J Assist Technol*, sv. 7, izd. 2, tra. 2013.
- [43] G. Fusco, H. Shen, V. Murali, i J. Coughlan, „Determining a Blind Pedestrian’s Location and Orientation at Traffic Intersections“, 2014. .
- [44] D. Ahmetovic, R. Manduchi, J. Coughlan, i S. Mascetti, „Zebra Crossing Spotter: Automatic Population of Spatial Databases for Increased Safety of Blind Travelers“, 2015. .
- [45] D. Ahmetovic, R. Manduchi, J. Coughlan, i S. Mascetti, „Mind your crossings: Mining GIS imagery for crosswalk localization“, *ACM Transactions on Accessible Computing (TACCESS)*, sv. 9, izd. 4, 2017.
- [46] J. Choi, B. T. Ahn, i I. S. Kweon, „Crosswalk and traffic light detection via integral framework“, u *Frontiers of Computer Vision,(FCV), 2013 19th Korea-Japan Joint Workshop on*, 2013, str. 309–312.

- [47] S. Wang i Y. Tian, „Detecting stairs and pedestrian crosswalks for the blind by RGBD camera“, u *2012 IEEE International Conference on Bioinformatics and Biomedicine Workshops (BIBMW)*, 2012, str. 732–739.
- [48] S. Wang, H. Pan, C. Zhang, i Y. Tian, „RGB-D image-based detection of stairs, pedestrian crosswalks and traffic signs“, *Journal of Visual Communication and Image Representation*, sv. 25, izd. 2, str. 263–272, velj. 2014.
- [49] R. Munoz, X. Rong, i Y. Tian, „Depth-aware indoor staircase detection and recognition for the visually impaired“, predstavljeno na The 3rd IEEE International Workshop on Mobile Multimedia Computing (MMC 2016) in conjunction with ICME 2016., 2016, str. 1–6.
- [50] T. J. J. Tang, W. L. D. Lui, i W. H. Li, „Plane-based detection of staircases using inverse depth“, u *2012 Australasian Conference on Robotics and Automation (Dale Carnegie 3 December 2012 to 5 December 2012)*, 2012, str. 1–10.
- [51] Microsoft, „Developing with Kinect for Windows“. [Na internetu]. Dostupno na: <https://dev.windows.com/en-us/kinect/develop>. [Pristupljeno: 20-lis-2015].
- [52] Y. H. Lee, T.-S. Leung, i G. Medioni, „Real-time staircase detection from a wearable stereo system“, u *2012 21st International Conference on Pattern Recognition (ICPR)*, 2012, str. 3770–3773.
- [53] L. Maohai, W. Han, S. Lining, i C. Zesu, „A robust vision-based method for staircase detection and localization“, *Cogn Process*, sv. 15, izd. 2, str. 173–194, stu. 2013.
- [54] M. Poggi, L. Nanni, i S. Mattoccia, „Crosswalk Recognition Through Point-Cloud Processing and Deep-Learning Suited to a Wearable Mobility Aid for the Visually Impaired“, u *New Trends in Image Analysis and Processing -- ICIAP 2015 Workshops*, 2015, str. 282–289.
- [55] D. J. Calder, „Ecological solutions for the blind“, u *2010 4th IEEE International Conference on Digital Ecosystems and Technologies (DEST)*, 2010, str. 625–630.
- [56] J. Borenstein, „The GuideCane-applying mobile robot technologies to assist the visually impaired“, *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, sv. 31, izd. 2, str. 131–136, ožu. 2001.
- [57] M. Bousbia-Salah, A. Redjati, M. Fezari, i M. Bettayeb, „An Ultrasonic Navigation System for Blind People“, u *IEEE International Conference on Signal Processing and Communications, 2007. ICSPC 2007*, 2007, str. 1003–1006.
- [58] F. Y. Shih, *Image Processing and Mathematical Morphology: Fundamentals and Applications*. CRC Press, 2017.
- [59] R. C. Gonzalez i R. E. Woods, *Digital Image Processing*. Pearson Education, 2011.
- [60] N. Otsu, „A Threshold Selection Method from Gray-Level Histograms“, *IEEE Transactions on Systems, Man, and Cybernetics*, sv. 9, izd. 1, str. 62–66, sij. 1979.
- [61] R. Fisher, S. Perkins, A. Walker, i E. Wolfart, *Hypermedia Image Processing Reference*, Cdr edition. West Sussex, England: John Wiley & Sons, 1996.
- [62] P. Soille, *Morphological Image Analysis: Principles and Applications*. Springer Science & Business Media, 2013.
- [63] Y. V. Vizilter, Y. P. Pyt'ev, A. I. Chulichkov, i L. M. Mestetskiy, „Morphological Image Analysis for Computer Vision Applications“, u *Computer Vision in Control Systems-1*, Springer, Cham, 2015, str. 9–58.

- [64] K. Michielsen, H. D. Raedt, i T. Kawakatsu, „Morphological Image Analysis“, u *Computer Simulation Studies in Condensed-Matter Physics XIII*, Springer, Berlin, Heidelberg, 2001, str. 87–91.
- [65] K. Romić, I. Galić, i T. Galba, „Technology Assisting the Blind - Video Processing Based Staircase Detection“, predstavljeno na 57th International Symposium ELMAR-2015, 2015.
- [66] M. Nixon, *Feature Extraction and Image Processing for Computer Vision, Third Edition*, 3 edition. Oxford: Academic Press, 2012.
- [67] „Emgu CV Library Documentation - Canny Method“. [Na internetu]. Dostupno na: <http://www.emgu.com/wiki/files/1.3.0.0/html/ba736ea5-ba99-bcd4-6152-216a82e35066.htm>. [Pristupljeno: 23-lis-2015].
- [68] M. Ghasemi Naraghi, M. Koochi, i A. Shakery, „Edge Detection in Multispectral Images Based on Structural Elements“, *The International journal of Multimedia & Its Applications*, sv. 3, izd. 1, str. 90–99, velj. 2011.
- [69] Jayanta Mukhopadhyay, Partha Pratim Das, Samiran Chattopadhyay, Partha Bhowmick, i Biswa Nath Chatterji, *Digital Geometry in Image Processing*, 1 edition. Boca Raton, FL: Chapman and Hall/CRC, 2013.
- [70] M. Hazewinkel, *Encyclopaedia of Mathematics*. Springer Science & Business Media, 1993.
- [71] T. Schwarze i Z. Zhong, „Stair detection and tracking from egocentric stereo vision“, u *2015 IEEE International Conference on Image Processing (ICIP)*, 2015, str. 2690–2694.
- [72] D. Dakopoulos i N. Bourbakis, „Preserving Visual Information in Low Resolution Images During Navigation of Visually Impaired“, u *Proceedings of the 1st International Conference on Pervasive Technologies Related to Assistive Environments*, New York, NY, USA, 2008, str. 27:1–27:6.
- [73] T. Marciniak, A. Chmielewska, R. Weychan, M. Parzych, i A. Dabrowski, „Influence of low resolution of images on reliability of face detection and recognition“, *Multimedia Tools and Applications*, sv. 74, izd. 12, str. 4329–4349, srp. 2013.
- [74] N. Zarinabad, A. Chiribiri, G. L. T. F. Hautvast, M. Breeuwer, i E. Nagel, „Influence of spatial resolution on the accuracy of quantitative myocardial perfusion in first pass stress perfusion CMR“, *Magnetic Resonance in Medicine*, sv. 73, izd. 4, str. 1623–1631, tra. 2015.
- [75] J. Yan, X. Zhang, Z. Lei, S. Liao, i S. Z. Li, „Robust Multi-resolution Pedestrian Detection in Traffic Scenes“, u *2013 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2013, str. 3033–3040.
- [76] K. Turkowski, „Graphics Gems“, A. S. Glassner, Ur. San Diego, CA, USA: Academic Press Professional, Inc., 1990, str. 147–165.
- [77] „HTC One A9 Specs and Reviews | HTC United States“, *HTC*. [Na internetu]. Dostupno na: <http://www.htc.com/us/smartphones/htc-one-a9/>. [Pristupljeno: 28-lip-2018].
- [78] „SJ4000 Series Action Camera • The Official SJCAM Website“, *SJCAM Official Website*. [Na internetu]. Dostupno na: <https://sjcam.com/product/sj4000/>. [Pristupljeno: 28-lip-2018].
- [79] C. Hughes, M. Glavin, E. Jones, i P. Denny, „Wide-angle camera technology for automotive applications: a review“, *IET Intelligent Transport Systems*, sv. 3, izd. 1, str. 19–31, ožu. 2009.
- [80] F. E. Sahin i A. R. Tanguay, „Distortion optimization for wide-angle computational cameras“, *Opt Express*, sv. 26, izd. 5, str. 5478–5487, ožu. 2018.

- [81] P. A. Laplante, *Real-Time Systems Design and Analysis*. John Wiley & Sons, 2004.
- [82] R. C. Browning, E. A. Baker, J. A. Herron, i R. Kram, „Effects of obesity and sex on the energetic cost and preferred speed of walking“, *Journal of Applied Physiology*, sv. 100, izd. 2, str. 390–398, velj. 2006.
- [83] K. Romić, I. Galić, H. Leventic, i K. Nenadić, „Real-time Multiresolution Crosswalk Detection with Walk Light Recognition for the Blind“, *Adv. Electr. Comp. Eng.*, sv. 18, izd. 1, str. 11–20, velj. 2018.
- [84] K. Romić, I. Galić, i H. Leventić, „Influence of the input image resolution on the staircase detection“, u *ELMAR, 2016 International Symposium*, 2016, str. 177–180.
- [85] W. Hackbusch, *Multi-Grid Methods and Applications*. Springer Science & Business Media, 2013.
- [86] C. Fernandez-Maloigne, F. Robert-Inacio, i L. Macaire, *Digital Color: Acquisition, Perception, Coding and Rendering*. John Wiley & Sons, 2013.
- [87] M. Ebner, *Color Constancy*. John Wiley & Sons, 2007.
- [88] G. Buchsbaum, „A spatial processor model for object colour perception“, *Journal of the Franklin Institute*, sv. 310, str. 1–26, srp. 1980.
- [89] W. Burger i M. J. Burge, *Digital Image Processing: An Algorithmic Introduction Using Java*. Springer, 2016.
- [90] K. Romić, I. Galić, i T. Galba, „Technology assisting the blind - Routing on the staircases using wide-angle camera“, u *2017 International Symposium ELMAR*, 2017, str. 43–46.
- [91] J. Snoek, J. Hoey, L. Stewart, R. S. Zemel, i A. Mihailidis, „Automated detection of unusual events on stairs“, *Image and Vision Computing*, sv. 27, izd. 1–2, str. 153–166, sij. 2009.
- [92] A. Bujnowski, M. Drozd, R. Kowalik, i J. Wtorek, „A tactile system for informing the blind on direction of a walk“, u *2008 Conference on Human System Interactions*, 2008, str. 893–897.
- [93] A. Gallace, H. Z. Tan, i C. Spence, „Tactile change detection“, u *First Joint Eurohaptics Conference and Symposium on Haptic Interfaces for Virtual Environment and Teleoperator Systems. World Haptics Conference*, 2005, str. 12–16.
- [94] Q. Lin i Y. Han, „A Context-Aware-Based Audio Guidance System for Blind People Using a Multimodal Profile Model“, *Sensors (Basel)*, sv. 14, izd. 10, str. 18670–18700, lis. 2014.
- [95] L. Kaminski, R. Kowalik, Z. Lubniewski, i A. Stepnowski, „„VOICE MAPS“ - portable, dedicated GIS for supporting the street navigation and self-dependent movement of the blind“, u *2010 2nd International Conference on Information Technology, (2010 ICIT)*, 2010, str. 153–156.
- [96] J. S. Cha, D. K. Lim, i Y.-N. Shin, „Design and Implementation of a Voice Based Navigation for Visually Impaired Persons“, *International Journal of Bio-Science and Bio-Technology*, sv. 5, izd. 3, str. 61–68.
- [97] A. Rodríguez, J. J. Yebes, P. F. Alcantarilla, L. M. Bergasa, J. Almazán, i A. Cela, „Assisting the Visually Impaired: Obstacle Detection and Warning System by Acoustic Feedback“, *Sensors*, sv. 12, izd. 12, str. 17476–17496, pros. 2012.
- [98] D. Bouyssou, D. Dubois, H. Prade, i M. Pirlot, *Decision Making Process: Concepts and Methods*. John Wiley & Sons, 2013.

- [99] A. Kaehler i G. Bradski, *Learning OpenCV 3: Computer Vision in C++ with the OpenCV Library*. O'Reilly Media, Inc., 2016.
- [100] „Emgu CV: OpenCV in .NET (C#, VB, C++ and more)“. [Na internetu]. Dostupno na: http://www.emgu.com/wiki/index.php/Main_Page. [Pristupljeno: 14-srp-2018].

POPIS SLIKA

Slika 2.1.	Prilazak osobe objektu i prikaz ulazne slike s kamere za: (a)-(c) stepenice; (d)-(g) pješački prijelaz.....	6
Slika 2.2.	Koraci u automatiziranom sustavu za pomoć slijepim i slabovidnim osobama	7
Slika 2.3.	Prototip sustava za pomoć slijepim i slabovidnim osobama.....	9
Slika 2.4.	Znanstveno-istraživačka područja i časopisi.....	10
Slika 2.5.	Približno paralelne linije i točka nestajanja	11
Slika 3.1.	Postupak binarizacije: (a) Ulazna slika; (b) Binarna slika ($T = 120$); (c) Binarna slika ($T = 160$); (d) Binarna slika ($T = 200$); (e) Binarna slika ($T = 240$).....	16
Slika 3.2.	Postupak binarizacije: (a) Ulazna slika; (b) Binarna slika (Otsu metoda); (c) Binarna slika (adaptivna metoda)	17
Slika 3.3.	Morfološka operacija erozije: (a) Ulazna binarna slika; (b) 1 iteracija erozije; (c) 2 iteracije erozije; (d) 3 iteracije erozije; (e) 4 iteracije erozije	19
Slika 3.4.	Morfološka operacija dilatacije: (a) Ulazna binarna slika; (b) 1 iteracija dilatacije; (c) 2 iteracije dilatacije; (d) 3 iteracije dilatacije; (e) 4 iteracije dilatacije.....	20
Slika 3.5.	Morfološka operacija otvaranja: (a) Ulazna binarna slika; (b) Otvaranje (strukturni element 3×3); (c) Otvaranje (strukturni element 5×5); (d) Otvaranje (strukturni element 7×7); (e) Otvaranje (strukturni element 9×9);.....	21
Slika 3.6.	Morfološka operacija zatvaranja: (a) Ulazna binarna slika; (b) Zatvaranje (strukturni element 3×3); (c) Zatvaranje (strukturni element 5×5); (d) Zatvaranje (strukturni element 7×7); (e) Zatvaranje (strukturni element 9×9);	22
Slika 3.7.	Pojmovi i parametri važni za morfološku analizu stepenica (a) i pješačkih prijelaza (b).....	24
Slika 4.1.	Predobrada: (a) Ulazna slika sa stepenicama; (b) Canny detektor rubova; (c) Operacija zatvaranja.....	27
Slika 4.2.	Predobrada: (a) Ulazna slika bez stepenica; (b) Canny detektor rubova; (c) Operacija zatvaranja	28
Slika 4.3.	Promjena visina gornjih i prednjih ploha stepenica s obzirom na perspektivu snimanja	29
Slika 4.4.	Vertikalna analiza slike sa stepenicama: (a) ulazna slika; (b) predobrađena slika; (c) graf izmjenjivanja crnih i bijelih duljina nizova u stupcu (BCC); (d) graf potencijalnih stepenica po stupcu (SPC).....	30

Slika 4.5.	Vertikalna analiza slike bez stepenica: (a) ulazna slika; (b) predobrađena slika; (c) graf izmjenjivanja crnih i bijelih duljina nizova u stupcu; (d) graf potencijalnih stepenica po stupcu (SPC).....	31
Slika 4.6.	Točke na mjestima gdje su vertikalnom analizom uočene potencijalne stepenice na slici: (a) sa stepenicama; (b) bez stepenica	33
Slika 4.7.	Generirane slike područja interesa iz ulazne slike: (a) sa stepenicama (HE = 24,12); (b) bez stepenica (HE = 1,44)	34
Slika 4.8.	Horizontalna energija na skupu slika sa stepenicama i bez stepenica	35
Slika 4.9.	Ulazne slike (a) i binarne slike nakon predobrade (b) u različitim rezolucijama	38
Slika 4.10.	Graf uspješnosti na slikama različitih rezolucija za slučajeve sa stepenicama i bez stepenica.....	39
Slika 4.11.	Graf vremena izvođenja na slikama različitih rezolucija.....	40
Slika 4.12.	Vidno polje kod stepenica korištenjem: (a) standardne kamere; (b) širokokutne kamere.....	42
Slika 4.13.	Primjeri testiranja algoritma za detekciju stepenica: (a) – (c) Scene stepenica u zatvorenim prostorima; (d) Scena stepenica u vanjskom prostoru; (e) – (f) Scene stepenica prema dolje; (g) – (h) Scene bez stepenica	44
Slika 4.14.	Primjeri neuspješnih detekcija na slikama sa stepenicama.....	45
Slika 4.15.	Graf prosječnih vremena izvođenja pojedinih koraka algoritma za detekciju stepenica i postotak udjela u ukupnom vremenu izvođenja.....	48
Slika 5.1.	Koraci predloženog algoritma za detekciju pješačkih prijelaza.....	50
Slika 5.2.	W-ciklus promjena rezolucije slike.....	51
Slika 5.3.	Bijela boja na digitalnoj slici snimljenoj u različitim uvjetima osvjetljenja: (a) oblačno; (b) zalazak sunca; (c) normalno dnevno svjetlo.....	52
Slika 5.4.	Predobrada: (a) ulazna slika u boji; (b) slika smanjene rezolucije; (c) naglašena bijela boja; (d) binarna slika; (e) binarna slika nakon morfoloških operacija; (f) detektirana područja interesa	53
Slika 5.5.	Područja interesa nakon: (a)-(c) binarizacije; (d)-(f) morfološke operacije zatvaranja	55
Slika 5.6.	Scena s kamerom i pješačkim prijelazom: (a) Bočna perspektiva; (b) Perspektiva kamere.....	56
Slika 5.7.	(a) Uvjeti detekcije rubnih točaka; (b) Detektirane rubne točke u svim područjima interesa	57

Slika 5.8.	Vertikalna analiza područja s pješačkim prijelazom: (a) ulazna slika; (b) predobrađena slika; (c) graf duljina crnih i bijelih nizova u stupcu (BCC); (d) graf potencijalnih rubova po stupcu (SPC)	58
Slika 5.9.	Vertikalna analiza područja bez pješačkog prijelaza: (a) ulazna slika; (b) predobrađena slika; (c) graf duljina crnih i bijelih nizova u stupcu (BCC); (d) graf potencijalnih rubova po stupcu (SPC)	59
Slika 5.10.	(a)-(c) Binarne slike smanjene rezolucije sa svim rubnim točkama; (d)-(f) Tipovi prijelaza s lijeva na desno	60
Slika 5.11.	Pseudo-kod za izračun energije linija	62
Slika 5.12.	Energija linija na kompletnom skupu slika s pješačkim prijelazom i bez pješačkog prijelaza.....	62
Slika 5.13.	Vidno polje kod pješačkih prijelaza korištenjem: (a) standardne kamere; (b) širokokutne kamere	64
Slika 5.14.	Primjeri testiranja algoritma za detekciju pješačkih prijelaza: (a) – (d) Scene pješačkih prijelaza na dnevnom svjetlu; (e) Pješački prijelaz na slici slabog kontrasta (večernja scena); (f) Pješački prijelaz u simuliranoj noćnoj sceni pod infracrvenim svjetlom; (g)-(h) Scena bez pješačkog prijelaza	65
Slika 5.15.	Primjeri neuspješnih detekcija na slikama s pješačkim prijelazima	67
Slika 5.16.	Graf prosječnih vremena izvođenja pojedinih koraka algoritma za detekciju pješačkih prijelaza i postotak udjela u ukupnom vremenu izvođenja.....	71
Slika 6.1.	Karakteristične rubne točke na stepenicama dobivene vertikalnom morfološkom analizom.....	72
Slika 6.2.	Pseudo-kod za stvaranje kumulativne slike	73
Slika 6.3.	(a) Ulazna slika stepenica s označenim rubnim točkama; (b) normalizirana kumulativna slika; (c) binarna kumulativna slika; (d) normalizirana obrnuta kumulativna slika; (e) binarna obrnuta kumulativna slika; (f) konačna slika i detekcija najsigurnijeg prostora za kretanje.....	74
Slika 6.4.	(a) Ulazna slika pješačkog prijelaza s označenim rubnim točkama; (b) normalizirana kumulativna slika; (c) binarna kumulativna slika; (d) normalizirana obrnuta kumulativna slika; (e) binarna obrnuta kumulativna slika; (f) konačna slika i detekcija najsigurnijeg prostora za kretanje.....	76
Slika 6.5.	Određivanje kuta smjera kretanja na slici	77
Slika 6.6.	Rasponi kutova za određivanje odluke o smjeru kretanja.....	79
Slika 6.7.	Primjer situacije gdje se korisnik usmjerava na desnu stranu.....	81

Slika 6.8.	Zvučni signali pojedinog smjera	82
Slika 6.9.	Primjeri usmjeravanja na stepenicama: (a) ravno (14.2°); (b) ravno (-2.5°); (c) blago lijevo (49.6°); (d) blago desno (-26.4°); (e) blago lijevo (45°); (f) blago desno (-25.6°); (g) oštro lijevo (65°); (h) oštro desno (-53.8°).....	84
Slika 6.10.	Primjeri usmjeravanja na pješačkim prijelazima: (a) ravno (6.7°); (b) ravno(-14°); (c) blago lijevo (29.1°); (d) blago desno (-22.3°); (e) blago lijevo (37.5°); (f) blago desno (-24.1°); (g) oštro lijevo (64.2°); (h) oštro desno (-55.1°)	86
Slika 6.11.	Graf usporedbe prosječnog vremena izvođenja koraka određivanja smjera i ostalih koraka algoritma te udio u ukupnom vremenu izvođenja za: (a) stepenice; (b) pješačke prijelaze	87
Slika 7.1.	Prikaz razvijenog testnog okruženja	92
Slika 7.2.	Udjeli odstupanja kutova (δ) po grupama za skup slika sa: (a) stepenicama; (b) pješačkim prijelazima	96
Slika 7.3.	Kriterij za ocjenu odluke računala (smjer: <i>ravno</i>)	99
Slika 7.4.	Kriterij za ocjenu odluke računala (smjer: <i>blago lijevo</i>).....	100
Slika 7.5.	Kriterij za ocjenu odluke računala (smjer: <i>blago desno</i>)	101
Slika 7.6.	Kriterij za ocjenu odluke računala (smjer: <i>oštro lijevo</i>)	101
Slika 7.7.	Kriterij za ocjenu odluke računala (smjer: <i>oštro desno</i>).....	102

POPIS TABLICA

Tablica 4.1. Prilagođeni parametri za predobradu	37
Tablica 4.2. Uspješnost detekcije i brzina izvođenja na slikama različitih rezolucija.....	39
Tablica 4.3. Uspješnost predložene metode za detekciju stepenica i sličnih metoda	43
Tablica 4.4. Prosječna brzina izvođenja algoritma za detekciju stepenica dobivena na prijenosnim uređajima.....	47
Tablica 5.1. Usporedba točnosti metoda za detekciju pješačkih prijelaza.....	66
Tablica 5.2. Usporedba količine piksela koja treba biti obrađena u pojedinim koracima	69
Tablica 5.3. Prosječna brzina izvođenja algoritma za detekciju pješačkih prijelaza dobivena na prijenosnim uređajima	70
Tablica 6.1. Kutovi smjera kretanja i odluka čovjeka.....	80
Tablica 6.2. Karakteristične kombinacije detekcija na tri uzastopne slike	90
Tablica 6.3. Karakteristične kombinacije kutova na tri uzastopne slike.....	90
Tablica 7.1. Funkcionalnosti razvijenog testnog okruženja.....	93
Tablica 7.2. Karakteristike video isječaka i slika u bazi podataka	95
Tablica 7.3. Prosječno odstupanje predloženog kuta kretanja od odluke čovjeka.....	95
Tablica 7.4. Zastupljenost pojedinih razina odstupanja odluke računala od odluke čovjeka prilikom određivanja smjera kretanja na stepenicama.....	97
Tablica 7.5. Zastupljenost pojedinih razina odstupanja odluke računala od odluke čovjeka prilikom određivanja smjera kretanja na pješačkim prijelazima	98
Tablica 7.6. Uspješnost metode za usmjeravanje prema novom kriteriju	102

SAŽETAK

Većina slijepih i slabovidnih osoba još ne koristi napredne sustave za pomoć pri kretanju i orijentaciji. Iako još nije vrijeme za potpuno izbacivanje ustaljenih metoda poput bijelog štapa, napredak tehnologije sada omogućava razvijanje i postupno uvođenje digitalnih mobilnih sustava za pomoć slijepima i slabovidnima. U ovoj disertaciji opisana je problematika koju mora riješiti takav sustav s naglaskom na metode navođenja prilikom kretanja korištenjem kamere i računalnom obradom slike. Ovo istraživanje usmjereno je na specifične situacije kada se osoba nalazi ispred ili na stepenicama i pješačkim prijelazima kao potencijalnim kritičnim točkama prilikom kretanja. Osim pregleda postojećih metoda detaljno su opisane tri novorazvijene metode zajedno s njihovom evaluacijom. Razvijene metode uključuju: metodu za detekciju stepenica zasnovanu na vertikalnoj i horizontalnoj analizi, multirezolucijsku metodu za detekciju pješačkih prijelaza zasnovanu na morfološkoj analizi i energiji linija, metodu za zvučno usmjeravanje slijepih i slabovidnih određivanjem prostora za sigurno kretanje. Dodatno je razvijen okvir za evaluaciju metoda usmjeravanja slijepih i slabovidnih osoba na stepenicama i pješačkim prijelazima. Testiranjem razvijenih metoda pokazane su određene prednosti u odnosu na postojeće metode po pitanju uspješnosti detekcije, mogućnosti korištenja širokokutnih ulaznih slika i robusnosti u slučajevima zaklonjenosti traženih objekata. Testiranjem brzine izvođenja razvijenih metoda pokazana je mogućnost izvođenja u realnom vremenu što je iznimno važno za pomoćne sustave koji bi se trebali koristiti u pokretu.

Ključne riječi: *pomoćni sustavi, slijepi i slabovidni, morfološka obrada i analiza slike, detekcija stepenica, multirezolucijska metoda, detekcija pješačkih prijelaza, zvučno usmjeravanje*

Stairs and Pedestrian Crosswalks Detection Using Morphological Image Processing and Analysis in Order to Guide Visually Impaired Persons

ABSTRACT

Most of the blind and visually impaired persons are still not using advanced navigation and orientation assistance systems. Though it is not yet time to fully expel standard methods such as a white cane, advances in technology now enable the development and gradual introduction of digital mobile systems for helping the blind and visually impaired people. This dissertation describes the issues that need to be solved by such a system, focusing on navigation methods using camera and digital image processing. This research is focused on specific situations when a person is in front of or on stairs and pedestrian crosswalks as potential critical points when walking. In addition to an overview of the existing methods, three newly developed methods are described in detail along with their evaluation. Developed methods include: method for stairs detection using vertical and horizontal analysis, multiresolution method for pedestrian crosswalks detection based on morphological analysis and line energy, method for sound guidance of the blind and visually impaired by determining space for safe movement. There is also an additionally developed framework for evaluating the methods for guidance of the blind and visually impaired on stairs and pedestrian crosswalks. Testing of the developed methods has shown some advantages over existing methods regarding the accuracy, the ability to use with wide-angle input images and the robustness in cases of concealed objects. By testing the processing speed for developed methods, possibility to perform in real-time is proven, which is extremely important for the assistance systems that should be used in the movement.

Keywords: *assistance systems, blind and visually impaired, morphological image processing and analysis, stairs detection, multiresolution method, pedestrian crosswalk detection, sound guidance*

ŽIVOTOPIS

Krešimir Romić rođen je 3. travnja 1987. u Osijeku. Osnovnu i srednju školu pohađao je u Valpovu, a školovanje nastavlja na Elektrotehničkom Fakultetu u Osijeku gdje je 2006. godine ostvario izravan upis na preddiplomski studij računarstva. Nakon prve tri godine studija i stjecanja akademskog naziva sveučilišni prvostupnik računarstva, obrazovanje nastavlja 2009. godine na diplomskom studiju računarstva također na Elektrotehničkom Fakultetu u Osijeku. Diplomski studij završava 2011. godine, te stječe zvanje magistar inženjer računarstva. Nakon završenog diplomskog studija pohađa stručno osposobljavanje za rad u Zavodu za informatiku Osijek u trajanju od jedne godine. Po završetku osposobljavanja uspješno polaže državni stručni ispit iz područja informatičkih poslova. Od 2013. godine radi kao asistent na Elektrotehničkom fakultetu u Osijeku, gdje upisuje i poslijediplomski doktorski studij Elektrotehnike. U svom znanstveno-istraživačkom radu bavi se računalnom obradom slike s primjenom u sustavima za pomoć slijepim i slabovidnim osobama. Istraživačkim radom za vrijeme poslijediplomskog studija postao je autor tri rada u znanstvenim časopisima i osam radova u zbornicima međunarodnih skupova. Za vrijeme poslijediplomskog studija dio vremena boravio je u stranoj instituciji University of Technology Graz u Austriji. Od 2018. godine član je znanstveno-istraživačkog tima na projektu Hrvatske zaklade za znanost „Metode za interpretaciju medicinskih snimki za detaljnu analizu zdravlja srca“.

Krešimir Romić

PRILOZI

Prilog P.1. Značajke kamere s uređaja HTC One A9s

<i>Značajka</i>	<i>Vrijednost</i>
<i>Tip senzora</i>	BSI CMOS
<i>Veličina piksela</i>	1,12 μm
<i>Žarišna duljina</i>	28,3 mm
<i>Otvor blende</i>	f/2,2
<i>Širina kuta snimanja</i>	74,4°
<i>Maksimalna rezolucija fotografije</i>	13 MP
<i>Maksimalna rezolucija snimanja video isječka</i>	1080p (1920×1080)
<i>Brzina snimanja pri maksimalnoj rezoluciji</i>	30 fps
<i>Dimenzije</i>	146,5 × 71,5 × 8 mm
<i>Masa</i>	149,8 g

Prilog P.2. Značajke kamere SJCAM SJ4000

<i>Značajka</i>	Vrijednost
<i>Tip senzora</i>	CMOS
<i>Veličina piksela</i>	2,2 μm
<i>Žarišna duljina</i>	2,99 mm
<i>Otvor blende</i>	f/2,8
<i>Širina kuta snimanja</i>	170°
<i>Maksimalna rezolucija fotografije</i>	12 MP
<i>Maksimalna rezolucija snimanja video isječka</i>	1080p (1920×1080)
<i>Brzina snimanja pri maksimalnoj rezoluciji</i>	30 fps
<i>Dimenzije</i>	59,2 × 29,8 × 41 mm
<i>Masa</i>	58 g

Prilog P.3. Značajke računala Lenovo V310-15ISK

<i>Značajka</i>	<i>Vrijednost</i>
<i>Tip računala</i>	Laptop
<i>Model procesora</i>	Intel Core i5-6200U
<i>Broj jezgri</i>	2
<i>Procesor</i>	<i>Broj niti</i> 4
	<i>Frekvencija radnog takta</i> 2,3 GHz
	<i>Priručna memorija</i> 3 MB
	<i>Tip</i> DDR4
<i>Radna memorija</i>	<i>Količina</i> 8 GB
	<i>Brzina</i> 2133 MHz
<i>Grafički procesor</i>	Intel HD Graphics 520
<i>Napajanje</i>	AC adapter (45 W)
	Integrirana Li-Ion baterija (32 Wh)
<i>Dimenzije</i>	380 × 262 × 22,9 mm
<i>Masa</i>	1,85 kg

Prilog P.4. Značajke računala Lenovo Ideacentre Stick 300-01IBY

<i>Značajka</i>	<i>Vrijednost</i>	
<i>Tip računala</i>	Mini-PC	
<i>Procesor</i>	<i>Model procesora</i>	Intel Atom Z3735F
	<i>Broj jezgri</i>	4
	<i>Broj niti</i>	4
	<i>Frekvencija radnog takta</i>	1,33 GHz
	<i>Priručna memorija</i>	2 MB
<i>Radna memorija</i>	<i>Tip</i>	DDR3L
	<i>Količina</i>	2 GB
	<i>Brzina</i>	1333 MHz
<i>Grafički procesor</i>	Intel HD Graphics	
<i>Napajanje</i>	AC adapter	
	Vanjska Li-Ion baterija (36 Wh)	
<i>Dimenzije</i>	100 × 38 × 15 mm	
<i>Masa</i>	0,065 kg	
	+ 0,235 kg (vanjska baterija)	