Evaluacija značajki kamere prilikom snimanja video isječaka na mobilnim uređajima

Ravas, Josip

Undergraduate thesis / Završni rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:291379

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-19**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

STRUČNI STUDIJ INFORMATIKE

EVALUACIJA ZNAČAJKI KAMERE PRILIKOM SNIMANJA VIDEO ISJEČAKA NA MOBILNIM UREĐAJIMA

Završni rad

Josip Ravas

Osijek, 2016.

SADRŽAJ

1. UVOD 1

2. SNIMANJE VIDEO ISJEČAKA 2

2.1 Specifikacije mobilnih uređaja 2

2.2 Upravljačka jedinica RCX 2.0 i programiranje putanje 7

2.3 Postupak snimanja video isječka 12

3. ANALIZA SNIMLJENIH VIDEO ISJEČAKA 13

3.1 Izbor metoda za analizu snimljenih video isječaka 13

3.2 Priprema razvojnog okruženja za analizu video isječaka 14

3.3 Implementacija odabranih metoda za analizu video isječaka 15

4. EVALUACIJA SNIMLJENIH VIDEO ISJEČAKA 17

5. ZAKLJUČAK 20

LITERATURA 21

SAŽETAK 22

ABSTRACT 22

ŽIVOTOPIS 23

1. UVOD

Porastom primjene i konstantnim razvojem mobilnih telefona, većina uređaja dolazi s ugrađenom video kamerom koja ima mogućnost snimanja video isječaka u visokoj rezoluciji. Razmotrit ćemo prednosti snimanja video isječaka na novijim uređajima u odnosu na starije. Naglasak će biti na analizi kvalitete po pitanju stabilizacije i izoštravanja slike koji su bitni za video isječke snimane za sustave u kojima se primjenjuje računalna obrada slike.

U ovom završnom radu provjeravamo kvalitetu video isječaka snimljenih u pokretu na više različitih mobilnih uređaja. Za snimanje video isječaka koristiti ćemo uređaje: HTC One A9, Samsung Galaxy S4 i HTC Desire S. Zbog dosljednosti snimljenih video isječaka, mobilni uređaji postavljani su na robot s programiranom putanjom kretanja po kojoj su isječci snimani.

Upravljačka jedinica koju koristi robot je RCX 2.0 s Hitachi H8 mikrokontrolerom. Na upravljačku jedinicu preko infracrvenog sučelja prenosimo program u kojem su određeni pokreti koje će robot napraviti. Funkcije za pokrete robota napisane su u Not Quite C programskom jeziku. Pokreti koje će robot izvoditi pokušati će imitirati kretanje pri snimanju u stvarnim situacijama.

Za analizu snimljenih video isječaka napraviti ćemo aplikaciju u koju implementiramo odabrane metode kojima ćemo mjeriti stabilizacijske performanse. Aplikaciju izrađujemo u programskom jeziku C# pomoću višeplatformske programske biblioteke OpenCV.

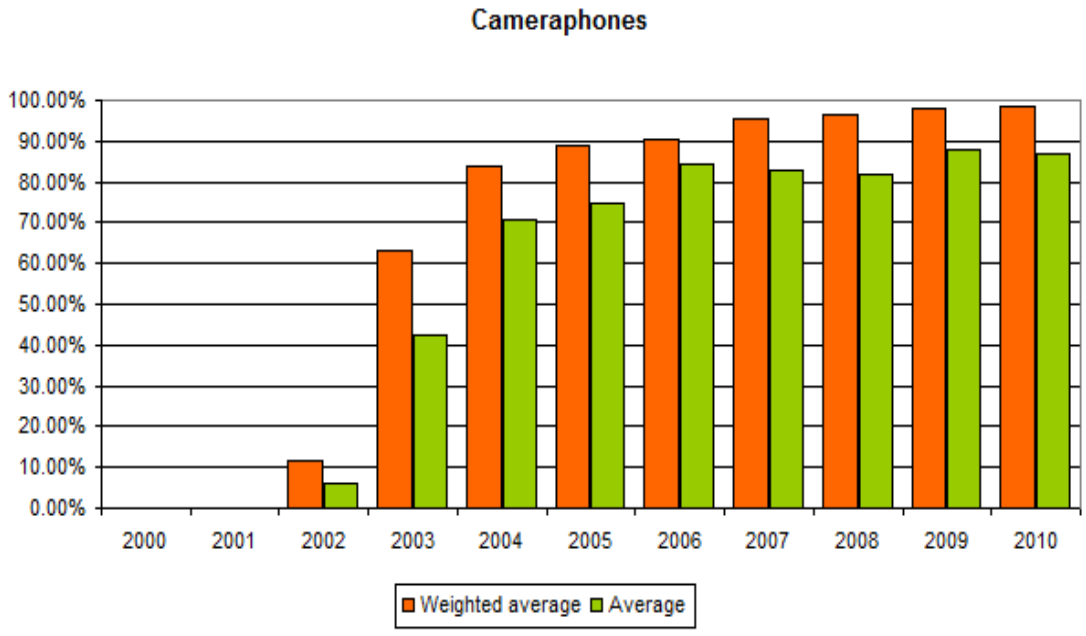
Očekuje se da će uređaji HTC One A9 i Samsung Galaxy S4 imati podjednake rezultate jer su sličnih specifikacija te da će imati puno bolje rezultate u odnosu na HTC Desire S. Analizom ćemo pokušati utvrditi razliku u kvaliteti za koju nisu zaslužne same specifikacije kamera koje proizvođači najčešće ističu nego, ugrađeni sustavi za stabilizaciju i izoštravanje slike.

2. SNIMANJE VIDEO ISJEČAKA

U ovom poglavlju dajemo uvid u kratku povijest razvoja kamera na mobilnim uređajima i specifikacije uređaja odabranih za snimanje video isječaka koje ćemo analizirati. Opisujemo pripremu upravljačke jedinice RCX 2.0 i postupak snimanja video isječaka. Pomoću upravljačke jedinice programirali smo dvije putanje kretanja robota. Jedna putanja kretanja programirana je tako da se robot kreće s više naglih pokreta, a druga s manje. Nakon što smo pripremili upravljačku jedinicu za robot, redom smo postavljali uređaje i snimali isječke po jednakim putanjama kako bi snimljeni video isječci bili što prikladniji za usporedbu.

2.1 Specifikacije mobilnih uređaja

Mobilni uređaji s ugrađenom kamerom pojavili su se na tržištu 2000. godine [1]. Zbog potrebe za zadržavanjem mobilnosti uređaja, objektiv kamere rađen je s fiksnim fokusom. Ugrađeni foto senzor manji je od senzora na digitalnoj kameri ili fotoaparatu, čime su dodatno pogoršane karakteristike u uvjetima sa slabim osvjetljenjem te kod snimanja video isječaka u pokretu. Na slici 2.1 prikazan je dijagram udjela mobilnih uređaja s ugrađenom kamerom na tržištu od 2000. do 2010. godine.



Sl.2.1 – *Udio mobilnih uređaja s ugrađenom kamerom u razdoblju od 2000. Do 2010. Godine (Izvor: GSM Arena)*

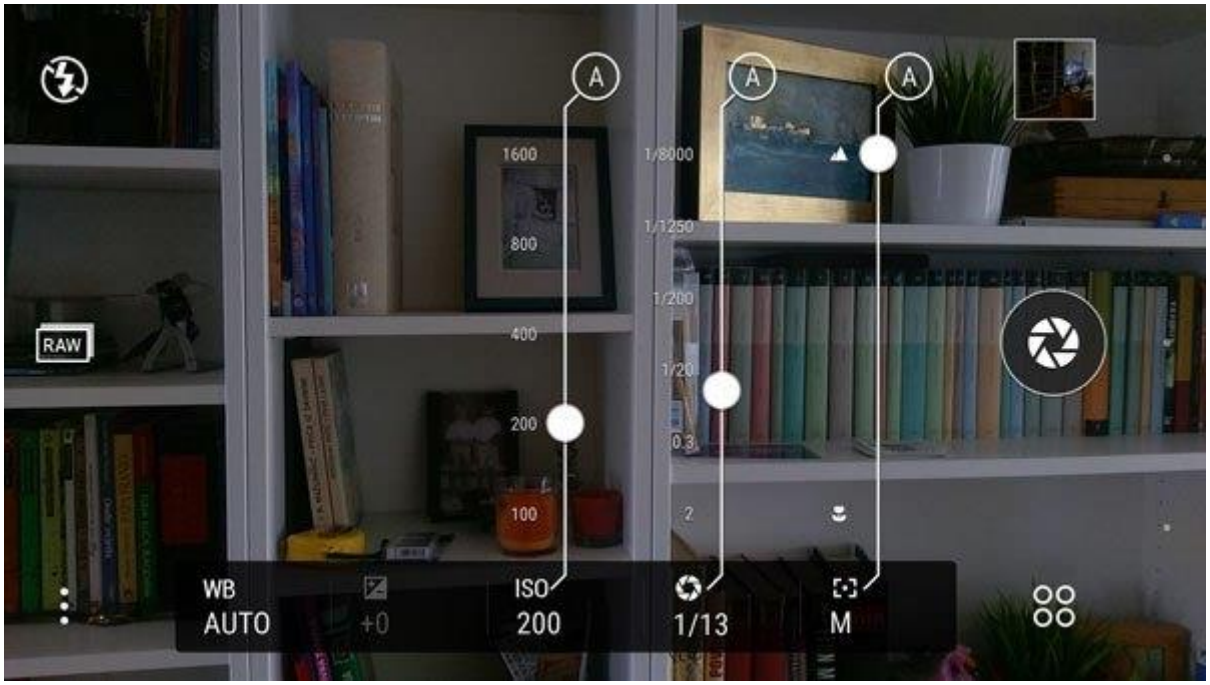
Kamere visokih rezolucija, većih senzora, kvalitetnijih leća i sustavom za fokusiranje, počele su se ugrađivati na mobilne uređaje oko 2010. godine te postaju cjenovno pristupačne i dostupne velikom broju korisnika. Iste godine broj korisnika uređaja s ugrađenom kamerom veći je od 4 milijuna [2].

Odabrani mobilni uređaji kojima su snimani video isječci iz različitih su vremenskih razdoblja. Uređaji HTC One A9 i Samsung Galaxy S4 imaju slične specifikacije ugrađenih kamera, no bitno je istaknuti da HTC One A9 ima ugrađen optički sustav za stabilizaciju slike. Ključan element kod svih optičkih sustava za stabilizaciju slike je da stabiliziraju sliku koja se projicira na senzoru, prije nego ju senzor pretvori u digitalnu informaciju [3]. Slika 2.2 prikazuje uređaje koji su odabrani za snimanje isječaka koje ćemo analizirati.



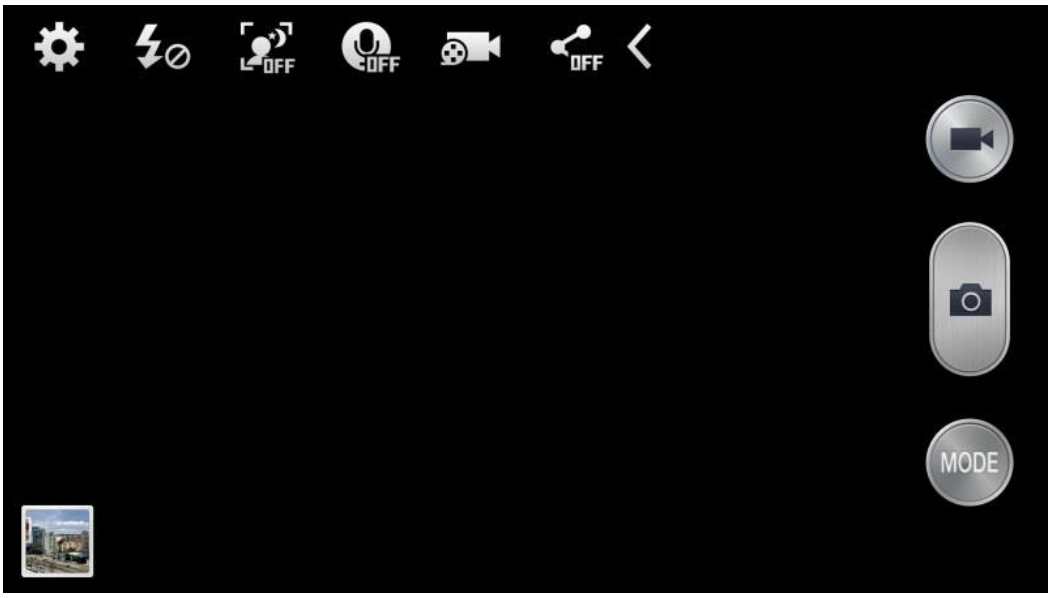
Sl.2.2 – *Uređaji odabrani za snimanje video isječaka: HTC One A9, Samsung Galaxy S4, HTC Desire S (Izvor: GSM Arena)*

HTC One A9 dolazi s ugrađenim 13MP Sony IMX214 CMOS (*engl. Complementary Metal Oxide Semiconductor*) BSI (*engl. Back-illuminated sensor*) senzorom za dohvaćanje slike, veličina otvora kamere je f/2.0, ima mogućnost snimanja video isječaka s 30 okvira u sekundi na rezoluciji od 1080p te ima ugrađen optički sustav za stabilizaciju slike. U uređaj je ugrađen Octa-core ARM 64-bit procesor koji radi na frekvenciji 1.5 GHz, grafički procesor Adreno 405 koji koristi OpenGL ES 3.1 grafički 3D standard i 3GB radne memorije. Ugrađena aplikacija kamere omogućuje detekciju lica, HDR (*engl. High-dynamic-range imaging*), panoramski način fotografiranja, spremanje geolokacije fotografija i Pro način rada u kojem se fotografije mogu snimati u RAW formatu. Slika 2.3 prikazuje sučelje fotoaparata uređaja HTC One A9.



Sl.2.3 – Sučelje fotoaparata uređaja *HTC One A9 u Pro načinu rada(Izvor: smartphonehrvatska)*

Samsung Galaxy S4 također dolazi s 13MP CMOS BSI senzorom, ima mogućnost snimanja video isječaka s 30 okvira u sekundi na rezoluciji od 1080p, ali otvor kamere je f/2.2 što je manje nego kod uređaja HTC One A9. U uređaj je ugrađen Quad-core Krait 300 procesor koji radi na frekvenciji 1.9 GHz, grafički procesor Adreno 320 i 2GB radne memorije. Ugrađena aplikacija kamere omogućuje detekciju lica, HDR, panoramski način fotografiranja, spremanje geolokacije fotografija, tipku za brzu promjenu načina fotografiranja i dodavanje efekta boje. Uređaju nedostaju postavke za preciznija ručna podešavanja. Slika 2.4 prikazuje sučelje fotoaparata uređaja Samsung galaxy S4.



Sl.2.4 – Sučelje fotoaparata uređaja *Samsung Galaxy S4(Izvor: GSM Arena)*

HTC Desire S ima ugrađen senzor za dohvaćanje slike od 5MP i mogučnost snimanja video isječaka s 30 okvira u sekundi na rezoluciji od 720p. U uređaj je ugrađen Qualcomm MSM8255 procesor koji radi na frekvenciji 1GHz, grafički procesor Adreno 205 i 768MB radne memorije. Ugrađena aplikacija kamere omogućuje detekciju lica, spremanje geolokacije fotografija i promejne efekta boje ali nema dodatnih naprednih opcija. Slika 2.4 prikazuje sučelje fotoaparata uređaja.



Sl.2.5 – Sučelje fotoaparata uređaja HTC Desire S *(Izvor: GSM Arena)*

Sva tri uređaja imaju mogućnost snimanja video isječaka u HDReady rezoluciji (1280x720px). U tablici 2.1 navedene su neke od specifikacija kamera mobilnih uređaja te godina izlaska na tržište. Detaljnije specifikacija kamera na mobilnim uređajima ponekad je gotovo nemoguće saznati jer ih proizvođači izostave kada nemaju potrebu za isticanjem istih [4].

Tab.2.1 – *Usporedba specifikacija video kamera* [5].

Naziv uređaja	HTC ONE A9	Samsung Galaxy S4	HTC Desire S
Godina proizvodnje	2015	2013	2011
Senzor stražnje kamere	13MP BSI	13MP BSI	5MP
Maksimalna rezolucija snimanja videa	1080p	1080p	720p
Broj okvira u sekundi na maksimalnoj rezoluciji	30fps	30fps	30fps
Veličina senzora	1/3.06”	1/3.06”	1/4”
Veličina pixela na senzoru	2 µm	1.14 µm	-
Leća	27.9mm	31mm	28mm
Veličina otvora kamere	f/2.0	f/2.2	-
HDR	Da	Da	-

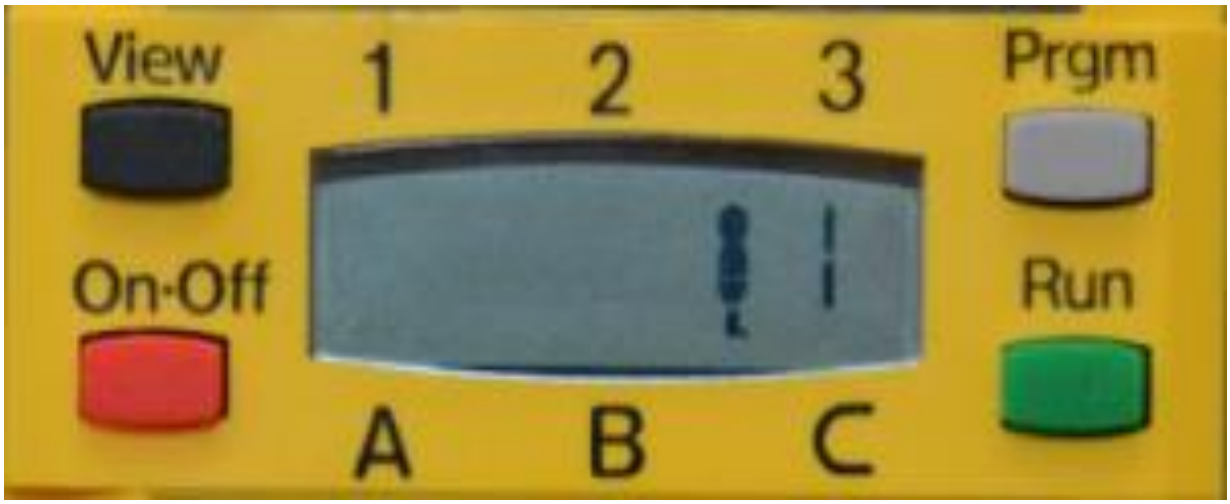
2.2 Upravljačka jedinica RCX 2.0 i programiranje putanje

S obzirom da će se snimanje testnih video isječaka vršiti pomoću robota koji se kreće po određenoj putanji. U ovom poglavlju opisana je upravljačka jedinica robota i način na koji se programira putanja kojom će se robot kretati. Upravljačka jedinica RCX 2.0 sadrži 8 bit-ni mikrokontroler iz H8 obitelji mikrokontrolera te 32K RAM na koje se preko infracrvenog sučelja pohranjuju *firmware* i korisnički programi [6]. Na slici 2.6 prikazana je upravljačka jedinica RCX 2.0.



Sl.2.6 – *Upravljačka jedinica RCX 2.0 (Izvor pbrick.info)*

Prije početka rada s upravljačkom jedinicom, potrebno je prebaciti odgovarajuću *firmware* verziju. Posljednja *firmware* verzija 3.32 može se besplatno preuzeti na internet stranici [7].



Sl.2.7 – *Prikaz zaslona upravljačke jedinice bez firmwarea (Izvor pbrick.info)*

Odgovarajuću *firmware* verziju možemo instalirati preko infracrvenog sučelja pomoću Bricx Command Center integriranog razvojnog okruženja. Nakon što je *firmware* uspješno instaliran, uređaj je spreman za unošenje korisničkih programa (Sl.2.8).



Sl.2.8 – *Prikaz zaslona upravljačke jedinice nakon prebacivanja firmwarea (Izvor pbrick.info)*

Razvojno okruženje koje je korišteno za kreiranje funkcija za putanje po kojima će se robot kretati je Bricx Command Center. Funkcije za pokrete koje će robot izvršavati napisane su pomoću programskog jezika Not Quite C. To je jednostavni programski jezik koji po svojoj sintaksi nalikuje programskom jeziku C [8]. Program napisan u NQC programskom jeziku treba imati barem jedan glavni zadatak (*engl. main task*) u kojem su napisane naredbe koje se izvršavaju nakon pokretanja. Na slici 2.9 prikazan je glavni zadatak programa u kojem robot imitira kretanje uz puno naglih pokreta.

```
task main(){
     stop(200);
     naprijed(700);
     lijevo(125);
     naprijed(700);
}
```

Sl.2.9 – *Glavni zadatak programa za snimanje video isječka u kojem robot imitira kretanje s puno naglih pokreta*

U glavnom zadatku programa pozvane su funkcije kojima je predano vrijeme trajanja izvršavanja u stotinkama. Na slici 2.10 prikazana je definicija funkcije stop. Funkcija void stop(int t) prima vrijeme trajanja u stotinkama te nema povratnu vrijednost. Vrijednost predana funkciji stop određuje vrijeme za koje će zadatak biti zadržan.

```
void stop(int t){
     Wait(t);
}
```

Sl.2.10 – *Definicija funkcije stop*

Funkcija void naprijed(int t) koja je prikazana na slici 2.11 nema povratne vrijednosti, a prima int vrijednost u stotinkama koja određuje trajanje funkcije. OnFwd(OUT_A + OUT_C) pokreće motore na izlazima A i C koji se rotiraju u smjeru za kretanje u naprijed.

```
void naprijed(int t){
     OnFwd(OUT_A + OUT_C);
     Wait(t);
     Off(OUT_AC);
}
```

Sl.2.11 – *Definicija funkcije za kretanje naprijed*

Vrijednost predana funkciji Wait(t) određuje koliko dugo će se robot kretati. Nakon isteka vremena koje je predano funkciji Wait() pokreće se funkcija Off(OUT_AC) koja gasi motore na izlazima A i C.

Funkcija void lijevo(int t) slična je funkciji naprijed jedino što funkcija lijevo uključuje samo jedan motor u smjeru za kretanje u naprijed što uzrokuje koračno skretanje robota u lijevo. Na slici 2.12 prikazana je definicija funkcije lijevo.

```
void lijevo(int t){
     OnFwd(OUT_C);
     Wait(trajanje);
     Off(OUT_AC);
}
```

Sl.2.12 – *Definicija funkcije za skretanje u lijevo*

Na slici 2.13 prikazan je program pomoću kojeg smo postigli skretanje robota uz manje naglih pokreta za razliku od prošlog programa.

```
task main(){
      stop(200);
      naprijed(700);
      r_lijevo(125);
      naprijed(700);
}
```

Sl.2.13 *– Glavni zadatak programa za snimanje video isječka u kojem robot imitira kretanje s manje naglih pokreta*

Razlika između glavnog zadatka na slici 2.13 i glavnog zadatka na slici 2.9 je funkciji r_lijevo. Funkcija r_lijevo (Sl.2.14) razlikuje se od funkcije lijevo (Sl.2.12) zato što uključuje motor na izlazu C koji se rotira u smjeru kretanja naprijed funkcijom OnFwd() te uključuje motor na izlazu A koji se rotira u smjeru kretanja za nazad funkcijom OnRev().

```
void r_lijevo(int vrijeme){
      OnFwd(OUT_C);
      OnRev(OUT_A);
      Wait(vrijeme);
      Off(OUT_AC);
}
```

Sl.2.14 *– Definicija funkcije za rotiranje u lijevo*

2.3 Postupak snimanja video isječka

U prethodnom poglavlju opisano je programiranje dvije različite putanje kretanja kako bismo što bolje imitirali stvarne situacije korištenja kamere u pokretu. Prva putanja kretanja programirana je tako da pokušava imitirati kretanje s puno naglih pokreta, a druga putanja kretanja programirana je na način da imitira kretanje bez naglih pokreta. Zbog potrebe da analizom snimljenih video isječaka ispitamo stabilizacijske karakteristike i kvalitetu fokusiranja, snimana scena na putanji kretanja nije se znatno mijenja.

Kako bismo dobili video isječke što prikladnije za usporedbu prije početka snimanja sa svakim uređajem, robot je postavljen na jednaku polazišnu točku. Osim što je robot postavljen na jednaku polazišnu točku, fokus video kamere na svim je uređajima usmjeren na istu točku. Mobilni uređaji korišteni za snimanje video isječaka pričvršćeni su na robot pomoću pomične stezaljke s kojom je postignuto da kamere uređaja budu u što sličnijim položajima. Na slici 2.15 prikazan je uređaj koji je postavljen na robot i pripremljen za snimanje video isječaka.



Sl.2.15 – *Snimanje video isječka*

3. ANALIZA SNIMLJENIH VIDEO ISJEČAKA

U ovom poglavlju opisan je način analize snimljenih video isječaka, a obuhvaća tri glavne radnje: izbor metoda za analizu, pripremu razvojnog okruženja i implementaciju odabranih metoda. Implementacijom odabranih metoda dobiti ćemo brojčane vrijednosti koje su nam potrebne kako bi mogli napraviti evaluaciju snimljenih video isječaka.

3.1 Izbor metoda za analizu snimljenih video isječaka

Pod pretpostavkom da ako je razlika između dva susjedna okvira video isječaka manja, uređaj ima bolje stabilizacijske karakteristike jer se na putanji snimanja scena nije znatno mijenjala. Na temelju te pretpostavke objektivnu kvalitetu video isječaka snimljenih u pokretu na različitim mobilnim telefonima odredit ćemo korištenjem prilagođene formule za izračunavanje srednje kvadratne pogreške.

Utvrđivanjem razlike između susjednih okvira dobivamo vrijednost koju u ovom slučaju računamo preko formule koja se inače koristi za računanje srednje kvadratne pogreške kako je navedeno u izrazu [9]:

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(tp - pp)^2 \tag{3-1}$$

gdje je:

-MSE – Srednja kvadratna pogreška

-tp – intezitet trenutnog piksela

-pp – intezitet prijašnjeg piksela

-n – ukupan broj piksela

Uvrštavanjem vrijednosti elemenata slike trenutnog okvira video isječka koji je snimljen i prijašnjeg okvira u izraz (3 – 1) dobivamo srednju kvadratnu pogrešku uvrštenih okvira. Srednju kvadratnu pogrešku dobivenu izrazom koristit ćemo za računanje omjera snage signala i šuma.

Omjer snage singala i šuma PSNR dobit ćemo uvrštavanjem MSE-a u sljedeći izraz [10]:

$$PSNR = 20 * log_{10}(MAX) - 10 * log_{10}(MSE) \quad (3\text{-}2)$$

gdje je:

-PSNR – omjer snage signala i šuma

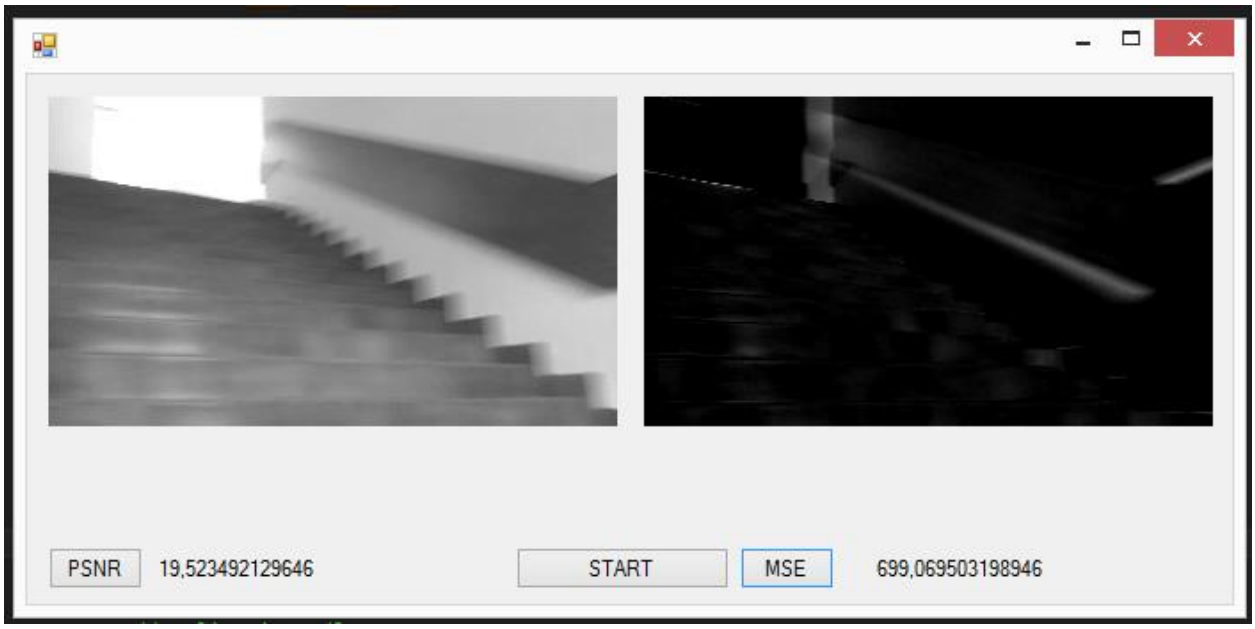
-MAX – maksimalna vrijednost elementa slike

3.2 Priprema razvojnog okruženja za analizu video isječaka

Za analizu snimljenih video isječaka koristiti ćemo OpenCV programsku knjižnicu namijenjenu za računalni vid u stvarnom vremenu. Računalni vid je tvorba eksplicitnih, značajnih opisa fizičkih objekata iz slika. Opisivanje slika je različito od obrade slike jer se obrada bavi proučavanjem transformacije slike, a ne opisivanjem. Opisivanje je preduvjet za prepoznavanje i razmišljanje o objektima [11].

OpenCV funkcije pozivat će se pomoću programskog jezika C# u Microsoft Visual Studio integriranom razvojnom okruženju. Microsoft Visual Studio integrirano razvojno okruženje koristimo jer nam znatno ubrzava i olakšava proces izrade aplikacije. Korištenje OpenCV funkcija s programskim jezikom C# omogućuje nam EmguCV višeplatformski .Net omotač. EmguCV možemo besplatno preuzeti na internet stranici [12]. Nakon preuzimanja potrebno je staviti reference na programske knjižnice u MS Visual Studio C# projektu.

U grafičkom sučelju programa s lijeve strane prikazan je okvir koji se trenutno analizira, a na desnoj strani prikazana je razlika elemenata polja između trenutno analiziranog okvira i prošlog (Sl.3.1). Klikom pokazivača na tipku start, program započinje s analizom učitanog video isječka. Vrijednosti PSNR i MSE izračunavaju klikom na istoimene tipke, navedene vrijednosti računaju se u stvarnom vremenu za protekli dio video sekvence tako da je potrebno pričekati završetak video sekvence da bi se rezultati koji su prikazani odnosili za cijelu video sekvencu.



Sl.3.1 – *Prikaz grafičkog sučelja pokrenutog programa s implementiranim metodama za analizu*

3.3 Implementacija odabranih metoda za analizu video isječaka

Programska biblioteka openCV omogućava nam učitavanje slike u obliku dvodimenzionalne matrice kroz koju prolazimo pomoću dvije for petlje unutar kojih računamo sumu razlike intenziteta trenutnog i prijašnjeg okvira analizirane video sekvence (Sl. 3.2).

```
for (i = 0; i < image.Height; i++){

     for(j=0; j<image.Width;j++){

          sum = sum + Math.Pow((image[i, j].Intensity -
          prevImage[i,j].Intensity),2);

       }

 }

MSE = MSE + sum / (image.Height * image.Width);
```

Sl.3.2 – *Implementacija izmjenjene formule za računanje srednje kvadratne pogreške*

Izraz za srednju kvadratnu pogrešku (3 – 1) u program je implemetiran dohvaćanjem svakog okvira video isječka pomoću funkcije `_capture.RetrieveGrayFrame()`. Nakon što je okvir uhvaćen, svakom elementu okvira kroz petlju očitava se intezitet pomoću funkcije `Intensity` te se oduzima od intezitea elementa prošlog okvira koji se nalazio na tom mjestu. Razliku intenziteta za pojedinih elemenata kvadriramo pomoću funkcije `Math.Pow` te ih dijelimo s ukupnim brojem elemenata slike.

Dobivenu vrijednost srednje kvadratne pogreške koristimo za računanje omjera snage signala i šuma koja se izračunava klikom na tipku u grafičkom sučelju prikazanom na slici 3.1, a dio koda na slici 3.3 prikazuje implementaciju matematičke funkcije koja je zadužena za izračun.

```
lbl2Message.Text = ((20 * Math.Log10(255)) - (10 * Math.Log10(MSE / count))).ToString();
```

Sl.3.3 – *Implementacija formule za računanje omjera snage signala i šuma*

Izraz za omjer snage signala i šuma (3 – 2) dobiven je logaritmiranjem maksimalne vrijednosti intenziteta koja je za crno-bijelu sliku 255 funkcijom `Math.Log10()` koja se množi s 20 prema izrazu te oduzimanjem logaritma srednje kvadratne pogreške množene s 10 od logaritma intenziteta.

4. EVALUACIJA SNIMLJENIH VIDEO ISJEČAKA

Snimljena su po dva isječka sa svakim od mobilnih uređaja. Prvi isječak sniman je po putanji u kojoj robot skreće rotiranjem što je uzrokovalo mala podrhtavanja. Drugi je isječak sniman po putanji u kojoj robot skreće u koracima što je zbog težine uređaja uzrokovalo veće podrhtavanje nego na prvom isječku.

Video isječci snimljeni na svim uređajima učitani su u program opisan u prošlom poglavlju, a rezultati analize video isječaka snimljenih po putanji na kojoj robot skreće koračno prikazani su u tablici 4.1.

Tab.4.1 – *Video isječci snimljeni po putanji na kojoj robot skreće koračno*

Naziv uređaja	HTC ONE A9	Samsung Galaxy S4	HTC Desire S
MSE	259,239768990619	310,452180581244	350,479522109914
PSNR	23,9937873508782	23,2108564623954	22,6841771287186

Rezultati analize video isječaka snimljenih po putanji na kojoj se robot rotira za vrijeme skretanja prikazani su u tablici 4.2.

Tab.4.2 – *Video isječci snimljeni po putanji na kojoj se robot rotira za vrijeme skretanja*

Naziv uređaja	HTC ONE A9	Samsung Galaxy S4	HTC Desire S
MSE	151,463412625636	207,114876430076	308,395244227134
PSNR	26,3277262317011	24,9686906680566	23,2397268870637

Iz rezultata prikazanih u tablici 4.1 vidljivo je da uređaj HTC ONE A9 ima najveći PSNR i najmanji MSE što znači da ima najbolje karakteristike za snimanje video isječaka u pokretu od triju uređaja koji su uspoređivani. Uređaj Samsung Galaxy S4 koji je srednjih karakteristika kod snimanja video isječka u pokretu prema tablici 4.1 bliže je rezultatima uređaja HTC ONE A9 nego rezultatima uređaja HTC Desire S. Očekivano je da će HTC Desire S imati najlošije rezultate zbog toga što je rezolucija u kojoj su video isječci snimani maksimalna za taj uređaj za razliku od ostala dva koji imaju veću maksimalnu rezoluciju. Osim rezolucije, Samsung Galaxy S4 i HTC ONE A9 imaju veći senzor za dohvaćanje slike, kako je prikazano u tablici 2.1.

U tablici 4.2 najbolji rezultat pokazuje uređaj HTC ONE A9, a najlošiji HTC Desire S. Rezultati tablice 4.2 imaju bolje rezultate od tablice 4.1. što je očekivano jer su video isječci koji su snimani po putanji na kojoj se robot rotira imali puno manje podrhtavanja. Usporedbom rezultata tablice 4.1 i tablice 4.2 vidljivo je da su video isječci snimljeni na mobilnim uređajima Samsung Galaxy S4 i HTC ONE A9 znatno bolji u tablici 4.2 od rezultata iz tablice 4.1, za razliku od HTC Desire S koji puno manju razliku rezultata između uspoređivanih tablica.

Gledanjem video isječaka pokušali smo vizualno odrediti subjektivnu kvalitetu pojedinog isječka te usporediti zapažanja s rezultatima dobivenim na računalu (Tab.4.1 i Tab4.2). Podrhtavanje uređaja vidljivo je na svim video isječcima. Kod uređaja Samsung Galaxy S4 i HTC Desire S na video isječcima snimljenim po putanji na kojoj robot skreće koračno gotovo svaki okvir ima *motion blur*. *Motion blur* (Sl.4.1) je zamućenje koje nastaje pri snimanju objekata u pokretu [13].



Sl.4.1 – *Prikaz okvira s problemom motion blura*

Na video isječku snimanom po putanji na kojoj robot skreće koračno s uređajem HTC One A9 vidljivi su rezultati ugrađene optičke stabilizacije u usporedbi s isječcima snimljenim na uređajima Samsung Galaxy S4 i HTC Desire S. Unatoč optičkoj stabilizaciji i kod uređaja HTC One A9 velik dio okvira ima prisutan *motion blur*.

Kod video isječaka snimljenih po putanji na kojoj se robot rotira za vrijeme skretanja jedino uređaj HTC Desire S ima vidljiv *motion blur* kod svakog okvira za vrijeme kretanja. Video isječci snimljeni s uređajima HTC One A9 i Samsung Galaxy S4 imaju podjednako prisustvo *motion blura*, ali je vidljivo da uređaj Samsung Galaxy S4 treba više vremena za ponovno fokusiranje. Slika 4.2 prikazuje okvire video isječaka snimljene nakon rotiranja robota na uređajima HTC One A9 s lijeve strane i Samsug Galaxy S4 s desne strane.



Sl.4.2 – *Prikaz okvira nakon rotiranja robota na uređajima: HTC One A9 i Samsung Galaxy S4*

Možemo zaključiti da su stabilizacijske performanse kod snimanja video isječaka u pokretu pri uvjetima u kojim se uređaj pretjerano trese podjednake za sva tri uspoređivana uređaja, a da su iste performanse u malo boljim uvjetima na uređajima većih performansi puno bolji nego na uređajima s manjim performansama.

5. ZAKLJUČAK

Evaluacijom značajki kamera na trima mobilnim uređajima koji imaju mogućnost snimanja video isječaka u HDReady rezoluciji, utvrđujemo performanse snimanja video isječaka snimljenih u pokretu. Zbog dosljednosti snimanih video isječaka snimamo ih postavljene na robot koji se kreće po jednakoj putanji. Na robot su prebačena dva programa za kretanje. Na prvom programu robot ima naglije pokrete nego na idućem kako bi što bolje imitirao stvarne situacije korištenja uređaja za snimanje u pokretu.

Kao što je očekivano video isječci snimljeni uređajima kojima rezolucija snimanja nije bila maksimalna pokazali su bolje performanse snimanja u pokretu od uređaja koji je snimao na maksimalnoj rezoluciji. Iako HTC ONE A9 i Samsung Galaxy S4 imaju jednake veličine senzora, maksimalne rezolucije snimanja i broj okvira u sekundi, HTC koji za razliku od uređaja Samsung Galaxy S4 ima ugrađenu optičku stabilizaciju, daje bolje rezultate prema tablicama u prošlom poglavlju.

Računalnom usporedbom susjednih okvira video isječaka snimljenih na tri različita uređaja dobili smo brojčane vrijednosti. Dobivene vrijednosti koristili smo za određivanje kvalitete snimljenih video isječaka te su se poklapale sa subjektivnom ocjenom kvalitete. Subjektivnom analizom bilo je teže odrediti koji uređaj od uređaja sličnih karakteristika ima bolje performanse kod snimanja video isječaka u pokretu, ali analizom na računalu uspjeli smo razlučiti koji uređaj će nam dati video isječak bolje kvalitete.

Možemo zaključiti da noviji uređaji imaju ugrađene bolje sustave za stabilizaciju i izoštravanje slike što uvelike povećava mogućnosti korištenja kamere u pokretu kod snimanja video isječaka za sustave u kojima se primjenjuje računalna obrada slike.

LITERATURA

[1] Godina pojavljivanja mobilnih uređaja s ugrađenom kamerom na tržištu, stranica http://www.hoista.net/post/18437919296/evolution-of-the-cameraphone-from-sharp-j-sh04-to (pristup stranici 6.7.2017.)

[2] Broj korisnika mobilnih uređaja s ugrađenom kamerom, stranica http://www.economist.com/node/15865270 (pristup stranici 6.7.2017.)

[3] Optička stabilizacija slike, stranica https://en.wikipedia.org/wiki/Image_stabilization#Optical_image_stabilization (pristup stranici 7.7.2017.)

[4] Specifikacije kamera na uređajima općenito, stranica https://www.cnet.com/news/camera-megapixels-why-more-isnt-always-better-smartphones-unlocked/ (pristup stranici 7.7.2017.)

[5] Specifikacije mobilnih uređaja, stranica http://www.gsmarena.com/ (pristup stranici 1.6.2016.)

[6] Specifikacije upravljačke jedinice RCX 2.0, stranica https://en.wikipedia.org/wiki/Lego_Mindstorms (pristup stranici 1.6.2016.)

[7] Instalacija firmware-a, stranica http://pbrick.info/rcx-firmware/ (pristup stranici 1.6.2016.)

[8] Not Quite C programski jezik, stranica http://bricxcc.sourceforge.net/nqc/ (pristup stranici 1.6.2016.)

[9] E. L. Lehmann; G Cassela, Theory of Point Estimation, Springer-Verlag, New York, 1998

[10] Huynh-Thu, Q.; Ghanbari, M. (2008). "Scope of validity of PSNR in image/video quality assessment". Electronics Letters. 44 (13): 800

[11] D. H. Ballard; C. M. Brown, Computer vision, Prentice Hall, New Jersey, 1982

[12] Instalacija EmguCV-a, stranica http://www.emgu.com/wiki/index.php/Download_And_Installation (pristup stranici 1.6.2016.)

[13] P. Favaro; S. Soatto, 3-D Shape Estimation and Image Restoration: Exploiting Defocus and Motion-Blur, Springer-Verlag, London, 2007

SAŽETAK

Evaluacija značajki kamera mobilnih uređaja pomoću OpenCV-a koji se za vrijeme snimanja video isječka kreću po jednakim putanjama. Korišteni mobilni uređaji su: Samsung Galaxy S4, HTC ONE A9 i HTC Desire S. Najlošije performanse video isječka ima HTC Desire S, a najbolje HTC ONE A9 iako ima jednaku maksimalnu rezoluciju snimanja, veličinu senzora kao i Samsung Galaxy S4.

Ključne riječi:

značajke kamere, snimanje u pokretu, evaluacija, OpenCV

ABSTRACT

Evaluation of camera recording features in movement on mobile devices using OpenCV. Used mobile devices are Samsung Galaxy S4, HTC ONE A9 and HTC Desire S. The worst performance of video clip recording has HTC Desire S and HTC ONE A9 has the best although although having the same maximum recording resolution, sensor size as the Samsung Galaxy S4.

Keywords:

camera features, capturing in motion, evaluation, OpenCV

ŽIVOTOPIS

Josip Ravas rođen 17.8.1993. u Našicama u Hrvatskoj. 2008. Godine upisuje Elektrotehničku i prometnu školu Osijek u Osijeku. Srednju školu završava 2012. godine i stječe zvanje Elektrotehničar iste godine upisuje Elektrotehnički faklultet Osijek smjer Informatika. Za vrijeme studija radi kao Web Developer i bavi se istraživanjem u područjima: razvoja Internet stranica i aplikacija, razvoja desktop aplikacija i razvoja IoT.