Model za prikupljanje slika lica

Juriša, Robert

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:904472

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

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

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Robert Juriša

MODEL ZA PRIKUPLJANJE SLIKE LICA

ZAVRŠNI RAD

Varaždin, 2020.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Robert Juriša

Matični broj: 45964/17-R

Studij: Informacijski sustavi

MODEL ZA PRIKUPLJANJE SLIKE LICA

ZAVRŠNI RAD

Mentorica:

Doc. dr. sc. Petra Grd

Varaždin, kolovoz 2020.

Robert Juriša

Izjava o izvornosti

Izjavljujem da je moj završni rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

U ovom radu će se govoriti o općenitim pojmovima koji su potrebni da se detaljnije shvati koncept prikupljanja fotografija. Postoje mnogi uvjeti koji moraju biti zadovoljeni od fizičkih, tako i do softverskih faktora. Samo prikupljanje fotografija je delikatan i vrlo zamršen proces, te da bi se kvalitetno i uspješno izveo, potrebno je pobliže shvatiti i uvjete koje fotografija mora zadovoljiti. Prikupljanje fotografija lica je jedan od koraka koji također uključuje i otkrivanje lica s fotografija i prepoznavanje lica. Potrebno je zadovoljiti mnoge parametre kako bi se lice prvo prepoznalo, a zatim i prikupilo s fotografije.

Ključne riječi: fotografije, modeli, senzori, kamere, leća, otkrivanje lica, prepoznavanje lica, prikupljanje slika, prikupljanje slike lica, uvjeti za prepoznavanje lica

Sadržaj

Sadržaj iii
1. Uvod 1
2. Prikupljanje fotografija 2
2.1. Fotografije i vrste fotografija 2
2.2. Ciljevi prikupljanja fotografija 2
2.3. Modeli prikupljanja fotografija 4
2.4. Tehnike prikupljanja fotografija 4
2.5. Osvjetljenje 5
2.6. Preporučeni intenzitet žarulje 8
2.7. Optički sustav 8
2.8. Leća 10
2.9. Senzor slike 16
2.10. Jačina kamere i područje interesa (ROI) 20
3. Kamere za prikupljanje fotografija 21
3.1. Analogne kamere 21
3.2. Digitalne kamere 22
3.2.1. Paralelne digitalne kamere 22
3.2.2. Camera Link 23
3.2.3. IEEE 1394 standard 23
3.3. Važne tehnologije kamera 23
3.3.1. Progresivno skeniranje 23
3.3.2. Infracrvene kamere 24
4. Fotografije lica 25
4.1. Faktori koji utječu na otkrivanje i prikupljanje lica s fotografija 25
4.1.1. Okluzija (pokrivenost) 26
4.1.2. Niska rezolucija fotografije 26
4.1.3. Šum fotografije 27
4.1.4. Osvjetljenje lica na fotografiji 28
4.1.5. Promjena u položaju lica 29
4.1.6. Artefakti pokreta 29
5. Praktično rješenje 31
5.1. Open CV 31
5.2. Detekcija lica pomoću Haar Cascades 31

5.3. Programski kod ... 33
5.4. Dobri i loši primjeri fotografija s licem ... 35
5.4.1. Položaj osvjetljenja ... 35
5.4.2. Položaj i držanje lica ... 38
5.4.3. Pokrivenost lica (okluzija) ... 39
5.4.4. Lice u pokretu ... 40
5.4.5. Udaljenost ... 41
6. Zaključak ... 42
Popis literature ... 43
Popis slika ... 44
Programski kod ... 46

1. Uvod

Danas se sve više koristi pojam prikupljanje fotografija. Kako napreduje tehnologija, tako i sigurnost ljudi mora biti na visokoj razini. Sve više i više se koristi videonadzor kao oblik osiguranja prostora, te je bitno znati koji su faktori bitni za otkrivanje lica s fotografija kako bi se moglo prikupiti za daljnju obradu. Postoje mnogi čimbenici koji utječu na izgled fotografije, od osvjetljenja pa sve do brzine zatvarača fotoaparata. Kako bi se fotografija mogla obraditi u nekom softveru, potrebni su uvjeti koji se moraju zadovoljiti. U teorijskom dijelu ovog rada će se detaljnije objasniti o načinu prikupljanja fotografija, faktorima koji utječu na fotografije, i nakon toga koji uvjeti se trebaju zadovoljiti kako bi se fotografija lica kvalitetno prikupila.

Dok u praktičnom dijelu rada bit će objašnjena biblioteka koja se najviše koristi u prepoznavanju lica s fotografija, primjer koda koji se koristi za prepoznavanje lica, ali i najvažniji dio, a to su vanjski uvjeti koji utječu na otkrivanje i prepoznavanje lica s fotografija, a zatim i prikupljanje lica s fotografija. Koristiti će se primjeri s vlastitim fotografijama, te će se detaljno objasniti koji su to dobri, a koji loši su loši primjeri vanjskih utjecaja na fotografiju i na otkrivanje lica s fotografije.

2. Prikupljanje fotografija

2.1. Fotografije i vrste fotografija

Fotografija se može definirati kao 2D funkcija (f(x,y)) gdje su varijable (x,y) koordinate 2D polja. Svaka koordinata u tom polju je zapravo najmanja jedinica same fotografije koja se naziva element fotografije odnosno piksel. Što bi značilo, da se fotografija sastoji od piksela, a svaki piksel je predstavnik neke određene boje. Digitalne fotografije se sastoje od dviju vrsta, a to su crno-bijela fotografija i fotografija u boji.

Crno bijele fotografije su napravljene od različitih nijansi sive boje. Te nijanse se nalaze između vrijednosti 0 i 255, kod kojih 0 predstavlja crnu boju, dok 255 predstavlja bijelu boju, a brojevi između su nijanse sive boje, odnosno, kombinacije crne i bijele boje.

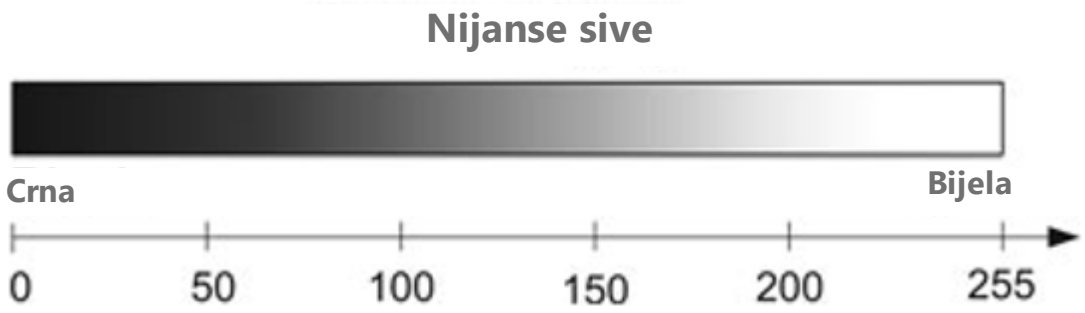

Slika 1 Različite nijanse sive (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

Kao što su se spomenule boje kod crno-bijelih fotografija koje se sastoje samo od crnih i bijelih boja, tj. njihovih kombinacija, fotografija u boji se sastoji od obojenih piksela. Spektar boja, kada sunčeva svjetlost prođe kroz prizmu, se broji u milijardama, dok ljudsko oko može prepoznati 7-10 miliona boja. Najpoznatiji priznati sustav boja je RGB, odnosno kombinacije crvene (RED), zelene (GREEN), i plave (BLUE) boje. (Mishra, Kumal, Shukla, 2017)

2.2. Ciljevi prikupljanja fotografija

Jedan od ciljeva prikupljanja fotografija je da se transformira optička slika u polje numeričkih podataka koji kasnije mogu biti manipulirane od strane računala i računalnih programa, a ujedno je to i prvi korak kod sustava obrade fotografija. Sami proces prikupljanja slika se sastoji od 3 koraka:

- Optički sustav koji se fokusira na energiju
- Energija koja se odbija od objekta
- Senzori koji mjere količinu energije

Također, kako bi se fotografija kvalitetno prikupila, mora se prikupiti pomoću prikladne kamere odnosno fotoaparata. Primjerice, ako se koristi za fotografije prikupljene x-zrakama, tada su potrebne kamere koje su osjetljive isključivo na x-zrake. Isto vrijedi i za infracrvene fotografije, odnosno, potrebna je kamera koja je osjetljiva na infracrveno zračenje. Za prikupljanje običnih fotografija se koriste obične kamere, odnosno, obični fotoaparati.
(Mishra, Kumal, Shukla, 2017)

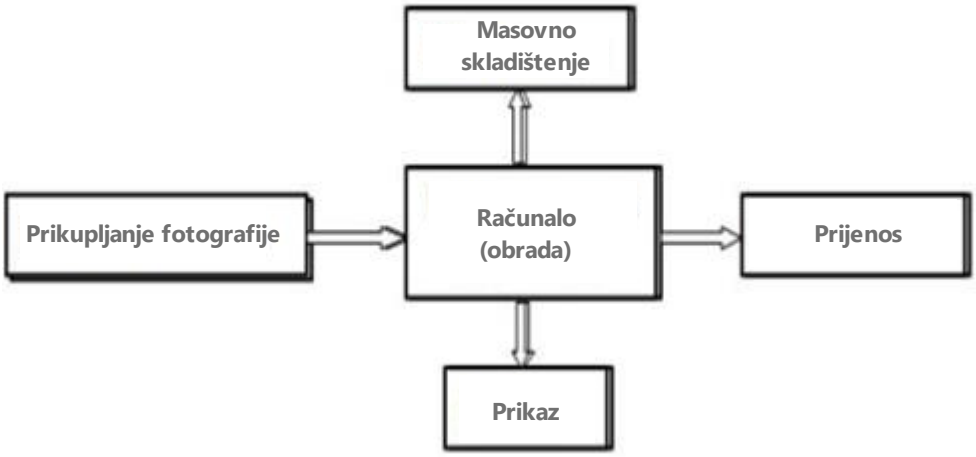

Slika 2: Obrada fotografije (Izvor: Mishra, Kumal, Shukla, 2017)

2.3. Modeli prikupljanja fotografija

Kombinacijom izvora osvjetljenja i refleksije ili upijanja te energije generira se fotografija. Na primjeru se može vidjeti shema kako se fotografija generira.

Osvjetljene koje je potrebno za fotografiju može imati nekoliko izvora, a neki izvori su radar, izvor infracrvene energije, računalno generirani izvor, ultrazvučni izvor energije, x-zrake. Pomoću senzora, energija osvjetljenja se pretvara u digitalnu fotografiju. Jedna od ideja je da dolazna energija osvjetljenja se pretvara u napon, kombinacijom ulazne električne energije i materijala čiji senzori reagiraju s određenom energijom koja se tada otkriva. Time se dobije valni oblik čiji je izlazni odgovor digitaliziran kako bi se dobila digitalna slika. (Mishra, Kumal, Shukra, 2017)

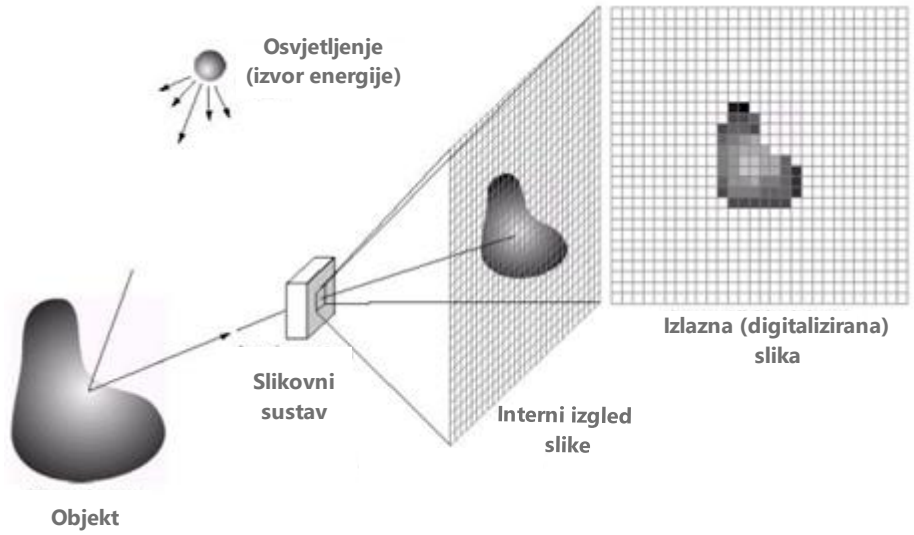

Slika 3: Shema prikupljanja fotografije (Izvor: Mishra, Kumal, Shukle, 2017)

2.4. Tehnike prikupljanja fotografija

Prikupljanje fotografija jako ovisi o hardverskom sustavu čiji senzor također može biti hardverski uređaj. U fotoaparatu, senzor mjeri odbijenu energiju od objekta koji se fotografira. Fotografski senzor koji se koristi u većini fotoaparata je sklop s prijenosom naboja (eng. CCD), dok neke vrste fotoaparata koriste komplementarno metalno oksidne poluvodiče (eng. CMOS). Obje vrste senzora pretvaraju svjetlost u elektrone.

Ako bi se to objasnilo jednostavnijim putem, senzori su zapravo 2D polja koja se sastoje od tisuća pa čak i miliona solarnih ćelija. Jednom kada senzor pretvori svjetlost u elektrone, tada

pročita vrijednost svake ćelije fotografije. Sklop s prijenosom naboja prenosi naboj preko čitavog čipa te na jednom kraju retka čita te vrijednosti. Tada analogno-digitalni pretvarač pretvara vrijednost svakog piksela tako što mjeri količinu naboja svake ćelije i pretvara u vrijednost binarnog oblika. Za strojni vid, brzina i šum su najbitniji parametri. CMOS i CCD senzori se razlikuju u načinu pretvaranja naboja u analogni zatim u digitalni signal. CMOS podaci su pretežito u digitalnoj domeni, dok CCD sadrži veliki broj paralelnih brzih izlaznih kanala.

CMOS uređaji koriste nekoliko tranzistora koji svakom pikselu pojačavaju i prebacuju naboj koristeći žice. CCD senzori proizvode visoko kvalitetne fotografije s manje šuma, dok CMOS senzori proizvode fotografije s više šuma, ali CMOS senzori koriste manje energije, dok CCD senzori koriste i do 100 puta više energije od CMOS senzora. (Mishra, Kumal, Shukra 2017) (DALSA, 2020)

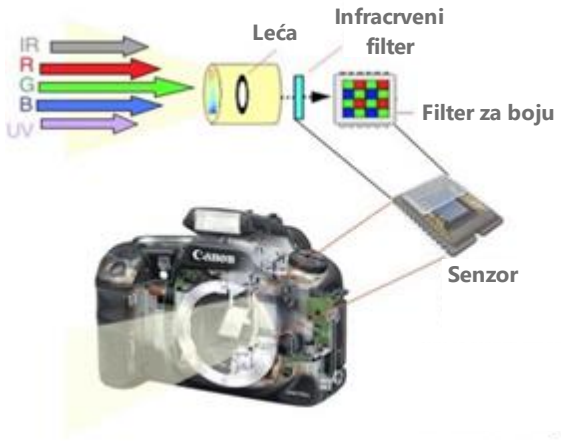

Slika 4: Unutrašnjost *digitalne* kamere (Izvor: Mishra, Kumar, Shukla, 2017)

2.5. Osvjetljenje

Osvjetljenje igra važnu ulogu u prikupljanju fotografija, prema tome je potrebno ispuniti neke od sljedećih uvjeta. Jedan od uvjeta je geometrija. Ona mora osiguravati dobru prostornu ujednačenost prostora kojega se skenira. Drugi uvjet je jačina žarulje, koja mora biti dovoljno visoka kako bi dala potrebnu jačinu signalima koji bi prošli i kroz najuže filtere sustava. No, ako bi se izlagalo na duži period, kako bi se nadoknadio mogući nizak intenzitet, to bi donijelo

dodatne probleme, poput sporijeg prikupljanja fotografije i veće količine šuma. Sljedeći uvjet je spektralno svojstvo žarulje.

Žarulja koja osvjetljuje objekt, mora imati dovoljnu jačinu u čitavom vidljivom spektru. Također, vrlo važna stabilnost i ponovljivost osvjetljenja. To je vrlo važno za pouzdane i točne rezultate mjerenja. Na fotografiji ispod se može vidjeti energija, frekvencija i valna dužinu jednog fotona. Također se vidi i gdje se nalazi vidljiva svjetlost odnosno spektar boja. (Daniel Nyström, 2006)

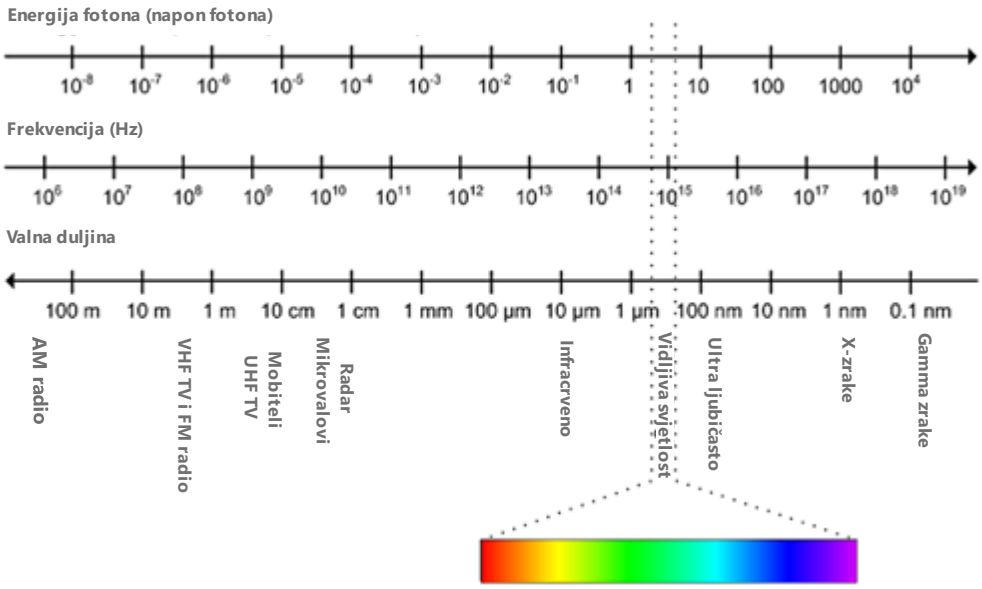

Slika 5: Prikaz energije, frekvencije i valne dužine jednog fotona (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Ako bi se fotografija, koja se nije snimila od strane fotografa, obrađivala, tada osvjetljenje ne igra značajnu ulogu jer se nije direktno moglo utjecati na njenu visinu, jačinu, kut. No, ako se može direktno utjecati osvjetljenje za snimanje fotografije, tada je jako važno kakvo će osvjetljenje biti. Primjerice, u području računalnog vida, vrijedi pravilo da je osvjetljenje dvije trećine cjelokupnog dizajna sustava, dok je za softver samo jedna trećina. Na idućoj fotografiji se može vidjeti primjer s koje visine, odnosno iz kojeg smjera se nalazi osvjetljenje.

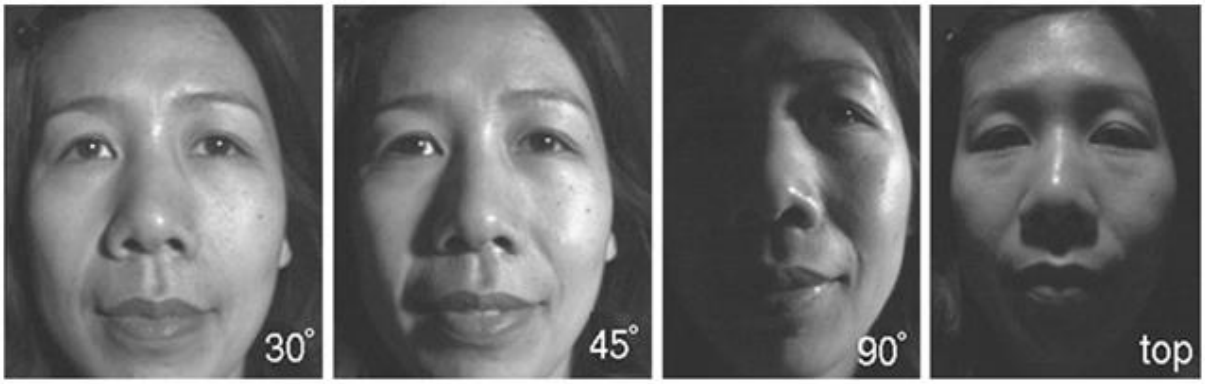

Slika 6: Primjer kutova osvjetljenja (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Iako, tu dolazi još jedan problem što se tiče smjera osvjetljenja. Naprimjer, ako se osvjetljenje nalazi direktno iza objekta snimanja, detalji objekta se neće vidjeti. Odnosno, objekt će poprimiti crnu boju i ako se gleda samo obrub onda se može vidjeti kako objekt izgleda. Najbolji primjer toga je pomrčina Sunca, odnosno kada se Mjesec nalazi između Sunca i Zemlje. U tom slučaju se može vidjeti Mjesec crne boje, okruglog oblika, dok se u pozadini nalazi žarko Sunce. Na fotografiji se može vidjeti primjer gore navedene tvrdnje, odnosno kako se vidi samo objekt u crnoj boji.

Slika 7 Primjer osvjetljenog objekta (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Isto tako, dobro je spomenuti da i infracrveno osvjetljenje može dobro poslužiti u prikupljanju fotografija ili u snimanju. Primjerice, ako se prati kretanje ljudskog dijela tijela, tada za animaciju se koristi infracrveno osvjetljenje. U praksi, se stavljaju reflektirajući markeri u obliku

malih kuglica koji će se isticati kada budu osvijetljeni. Tada, radi tih markera, lakše je prepoznati objekt u obradi fotografije. (The-Crankshaft Publishing, Image acquisition part 1)

2.6. Preporučeni intenzitet žarulje

Spektralna svojstva žarulje strogo ovise o intenzitetu na kojem rade. Za žarulje s nižim intenzitetom, intenzitet boja snažno opada te zračenje od te žarulje skoro pa ne sadrži nikakvu snagu spektra plave boje. Nadalje, odnos u snazi zračenja nije linearan s obzirom na jačinu žarulje.

Primjerice, ako se koristi žarulja koja sadrži razinu intenziteta od 50%, ona će generirati samo 15% snage zračenja u usporedbi s razinom punog intenziteta. Preporučeno je da žarulja radi na 90% svog intenziteta, kako bi se izbjegla moguća degradacija i prerano kvarenje same žarulje. Primjerice, ako je žarulja na 100% svog intenziteta, ona će trajati oko 500 radnih sati, a ako radi na 90% intenziteta, žarulja može doseći čak 900 radnih sati što je otprilike 80-90% poboljšanja u trajnosti. (Daniel Nyström, 2006)

2.7. Optički sustav

Nakon što se osvijetli objekt, tada se svjetlost reflektira od objekta i ta svjetlost mora biti uhvaćena fotoaparatom. Ako se materijal koji je osjetljiv na reflektiranu svjetlost postavi u blizinu objekta, tada se snima slika tog objekta. No, kao što je prikazano na slici, svjetlost iz različitih točaka objekta će se pomiješati te onda kao rezultat toga se dobije sasvim beskorisna sliku. Da bi stvar bila gora, svjetlost okoline će se također pomiješati te će onda rezultat biti dodatno pogoršan.

Slika 8: Primjer odbijanja svjetlosti od objekta (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Taj problem bi se najlakše mogao riješiti tako što bi postavili neku barijeru između objekta snimanja i samog senzora. Jedina stvar koja bi se promijenila je da bi krajnja fotografija bila okrenuta naopako, ali to ne predstavlja problem jer se fotografija pomoću softvera ispravi.

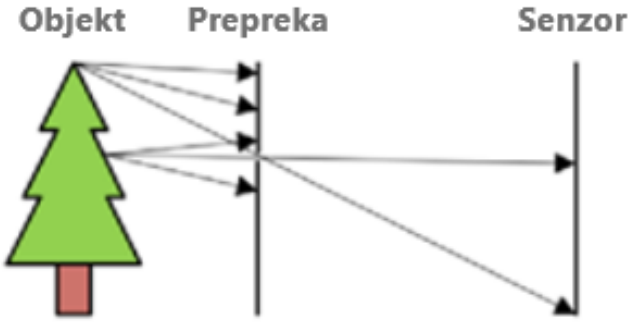

Slika 9 Primjer odbijanja svjetlost od objekta s preprekom (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Iako ni to nije baš optimalno rješenje, problem je što premalo svjetla dolazi do senzora. Kako bi se riješio i taj problem, potrebno je uvesti optički sustav u rupu kroz koju prolazi svjetlost. Kako bi se to moglo bolje predočiti, može se uzeti u primjer Hubble teleskop kojeg je NASA poslala u svemir kako bi neometano istraživao druge galaksije, zvijezde, komete i ostalo. Hubbleov teleskop radi poput kamere, odnosno, optički sustav teleskopa preusmjerava primljenu svjetlost na senzor. Mora se napomenuti da je to kompleksna znanost i da je to takozvana umjetnost ljudskog djela. (The-Crankshaft Publishing, Image acquisition part 1)
Nakraju, na sljedećoj fotografiji se može vidjeti kako bi izgledao konačni model koji bi riješio sve navedene probleme koje smo imali.

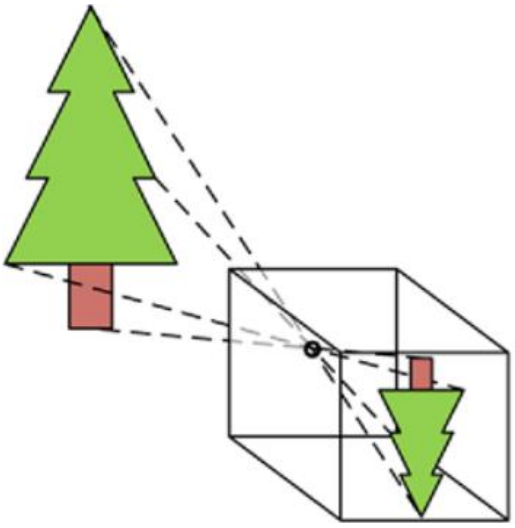

Slika 10: Odbijanje zrake od objekta u jednu točku (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

2.8. Leća

Jedna od osnovnih stavki svakog optičkog sustava je leća. Leća je zapravo komad stakla koja fokusira, tj. prijenosi primljenu svjetlost na senzor. Veliki broj svjetlosnih zraka s različitim kutevima se sudaraju sa svakom točkom na površini objekta te se neke od tih zraka reflektiraju prema optičkom sustavu gdje se nalaze leće. Na slici se može vidjeti tri svjetlosne zrake koje se kreću iz dvije različite točke objekta. Sve tri zrake za određenu točku se presijecaju u točki s desne strane leće. Upravo takvo fokusiranje tih zraka je i sama svrha leće. To bi značilo da se slika objekta formira s desne strane i to je zapravo slika koju kamera snima. Također, na fotografiji se može vidjeti kako paralelne zrake prolaze kroz točku F, takozvano žarište, dok bi udaljenost od leće, optičkog centra O, pa sve do točke gdje se sijeku sve paralelne točke, zvala žarišna udaljenost. Linija na kojoj su O i F se naziva optička os.

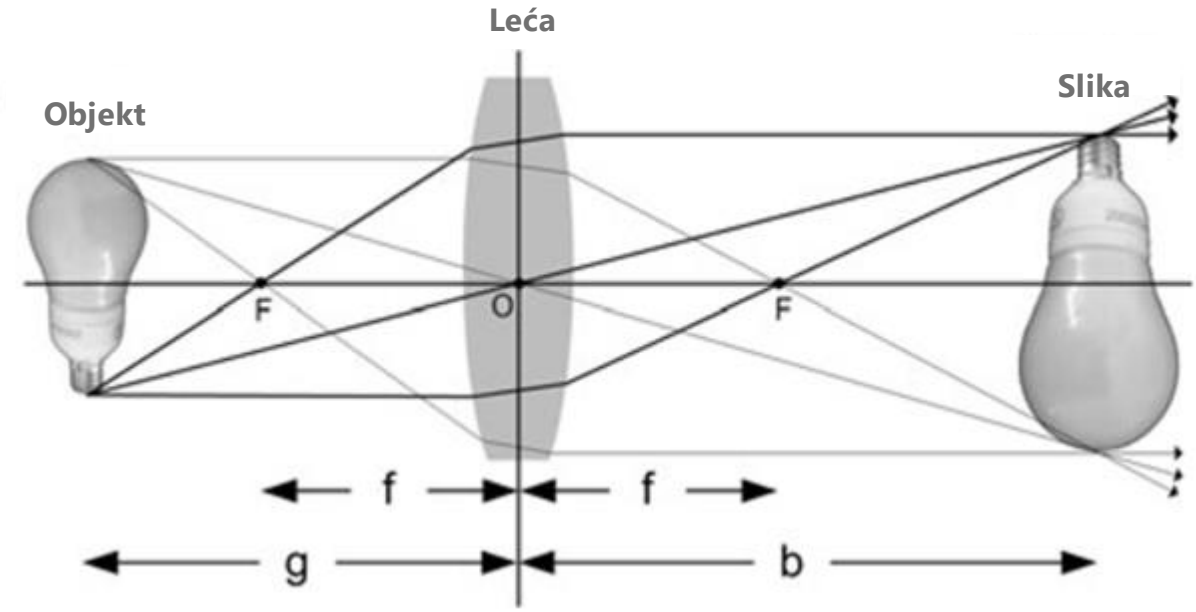

Slika 11 Izgled leće (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Nadalje, može se i definirati udaljenost objekta i leće. Tu udaljenost se može označiti oznakom g, dok mjest udaljenost od leće do mjesta presijecanja zraka označujemo s oznakom b (primjer možemo vidjeti na slici iznad). Također, to se definira pomoću sljedeće formule:

$$\frac{1}{g} + \frac{1}{b} = \frac{1}{f}$$

Oznake f i b su uglavnom u rasponu od 1 do 100 milimetara. To bi značilo da ako se objekt udalji par metara od kamere odnosno leće, oznaka g nema nikakvu vrijednost u jednadžbi pošto je tada b = f. Sve ovo govori da se slika formira vrlo blizu samog žarišta. Gore navedena jednadžba se zove jednadžba leće.

Još jedna stvar koju je dobro napomenuti kod leća je ta da veličina objekta u fotografiji se povećava ako se povećava i udaljenost između leće i žarišta. To je poznato po drugim nazivom kao što je optičko povećanje (zoom). Ta udaljenost se mijenja ako se mijenja raspored leća, odnosno, udaljenost pojedinih leća u optičkom sustavu. Na sljedećoj fotografiji je grafički prikazana kako se može dobiti optički zoom (uvećanje) pomicanjem udaljenosti žarišta.

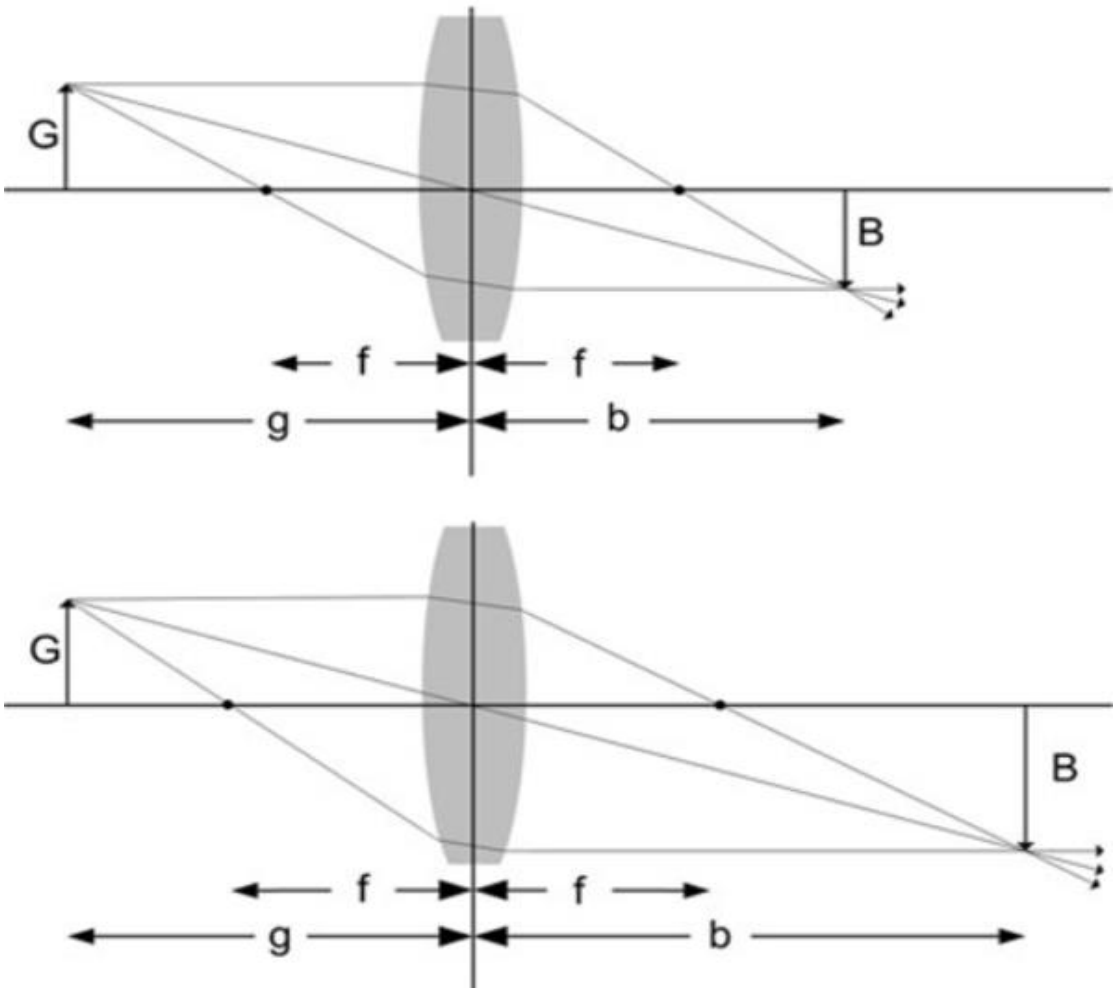

Slika 12: Izgled uvećanja: (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Ovdje je oznaka G prava visina objekta, dok je oznaka B veličina objekta u fotografiji. Ovaj primjer se često koristi kako bi se saznalo koliko fizičkog objekta će stati na čipu senzora slike kada se kamera postavi na određenoj udaljenosti od objekta. Također tu se može iskoristiti i sljedeća formula koja glasi:

$$\frac{b}{B} = \frac{g}{G}$$

Sada se može pretpostaviti da se ovdje nalazi leća koja ne može povećavati, tj. da je udaljenost između optičkog sustava i žarišta konstantne veličine.

Kada se mijenja udaljenost između objekta i kamere, prema prvoj jednadžbi, može se vidjeti da bi se onda i udaljenost od leće do mjesta presijecanja zraka trebala povećavati, što bi značilo da se senzor treba pomaknuti malo dalje od leće kako bi se slika stvorila.

Na idućoj fotografiji se vidi što bi se dogodilo ako se udaljenost između optičkog sustava i žarišta ne mijenja. Za takvu fotografiju se kaže da je izvan fokusa. Ako bi se htio namjestiti fokus kako bi fotografija bila čišćeg i kvalitetnijeg izgleda, zapravo bi se prilagođavala, odnosno mijenjala udaljenost sve dok se senzor ne nalazi na mjestu gdje bi se formirala slika.

.

Slika 13: Zamućenje fotografije (Izvor: https://zhivagoksenia.wordpress.com/tag/dots/)

Jedan od razloga što je fotografija ne fokusirana je taj da se senzor sastoji od piksela te svaki piksel ima određenu veličinu. Sve dok se zrake iz jedne točke ostanu u jednom određenom

pikselu, taj će piksel biti fokusiran, no ako zrake iz drugih točaka presijecaju baš taj piksel, tada će taj piksel dobiti svjetlost iz više različitih točaka, pa onda i vrijednost piksela bude mješavina svjetlosti iz različitih točaka, te na temelju toga se dobije ne fokusirana slika.

Povećanjem žarišne duljine se dobije manja dubina polja. Dubinu polja se može definirati tako da je to udaljenost po kojoj se objekt može pomicati, a da ne se izgubi fokus objekta, odnosno da se ne dobije ne fokusiranu fotografiju.

Na fotografiji se može vidjeti kako pune crte ilustriraju zrake osvjetljenja od točke na objektu na optičkoj osi i njihovih staza koje se kreću kroz leću sve do senzora gdje se presijecaju u istom pikselu koji je prikazan kao crno obojani pravokutnik. Isprekidane i istočkane crte ilustriraju svjetlosne zrake iz drugih (dviju) točaka objekta na optičkoj osi. Ovi objekti su karakterizirani kao najekstremnija mjesta na kojima svjetlosne točke još uvijek ulaze u isti piksel, tj. mjesta gdje je slika još uvijek fokusirana.

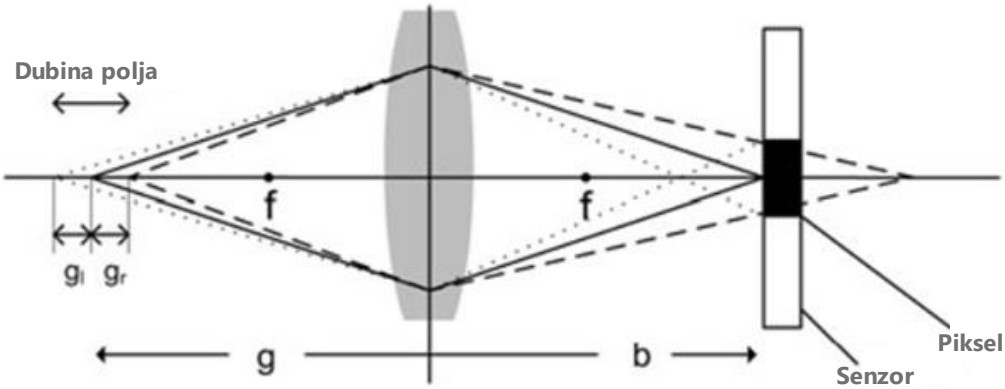

Slika 14: Dubina polja (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

Kao što se već reklo, da povećanjem žarišne duljine dobijemo manju dubinu polja, a posljedica toga je smanjena površine okoline koja se promatra kamerom. Promatrana okolina se naziva vidno polje kamere. Vidno polje kamere, osim što ovisi žarišnom duljinom, također ovisi i o fizičkoj veličini senzora slike. Uobičajeno je senzor pravokutnog oblika, a ne kvadratnog, iz čega nam slijedi da kamera ima vidno polje u okomitom i vodoravnom smjeru. Također i tu možemo primijeniti formulu koja glasi sljedeće:

$$FOV_x = 2 \cdot \tan(\frac{širina\ senzora/2}{f})^{-1}$$

$$FOV_y = 2 \cdot \tan(\frac{visina\ senzora/2}{f})^{-1}$$

gdje nam je oznaka f, žarišna duljina, a visina i širina se mjere u milimetrima.

Na fotografiji ispod se može vidjeti dva različita vidna polja kamere. Kut vidnog polja, koji je definiran oznakom V, predstavlja dio okoline koji je promatran kamerom. Povećavanjem žarišne udaljenosti povećava se i udaljenost između leće i senzora te za rezultat daje manje vidno polje. Postoje i horizontalno i vertikalno vidno polje. Samo u slučaju da su visina i širina senzora isti tada su i horizontalno i vertikalno polje isto. Postoji i još jedna jednadžba koja nam određuje žarišnu duljinu. Ona se temelji na umnošku veličine senzora i udaljenosti objekta te se dijeli s dubinom polja. Ukratko, njena jednadžba je sljedeća:

žarišna duljina = (veličina senzora X udaljenost objekta) / dubina polja

Leće se proizvode s ograničenim brojem standardnih žarišnih duljina. Žarišne duljine uobičajenih leća su: 6 mm, 8 mm, 12.5 mm, 25 mm i 50 mm. Jednom kada se odabere žarišna udaljenost koja je najbliža žarišnoj udaljenosti koju zahtjeva sustav za prikupljanje, tada je potrebno prilagoditi i udaljenost objekta kako bi se objekt mogao fokusirati. Leće s kratkim žarišnim duljinama (manjim od 12 mm) proizvode slike s većom distorzijom. Ako je aplikacija koja se koristi u prikupljanju fotografija osjetljiva na distorziju odnosno izobličenje fotografije, tada je potrebno povećati udaljenost od objekta i potrebno je koristiti leću s većom žarišnom duljinom. (The-Crankshaft Publishing, Image acquisition part 1) (Engineer Ambiiously, Image acquisition System Setup, 2020)

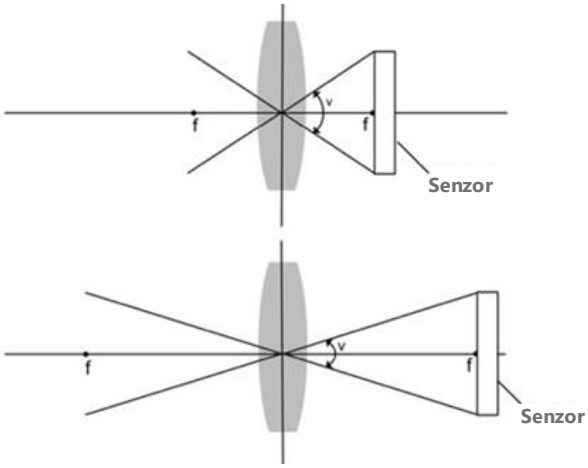

Slika 15: Vidno polje (Izvor: The-Crankshaft Publishing, Image acquisition part 1)

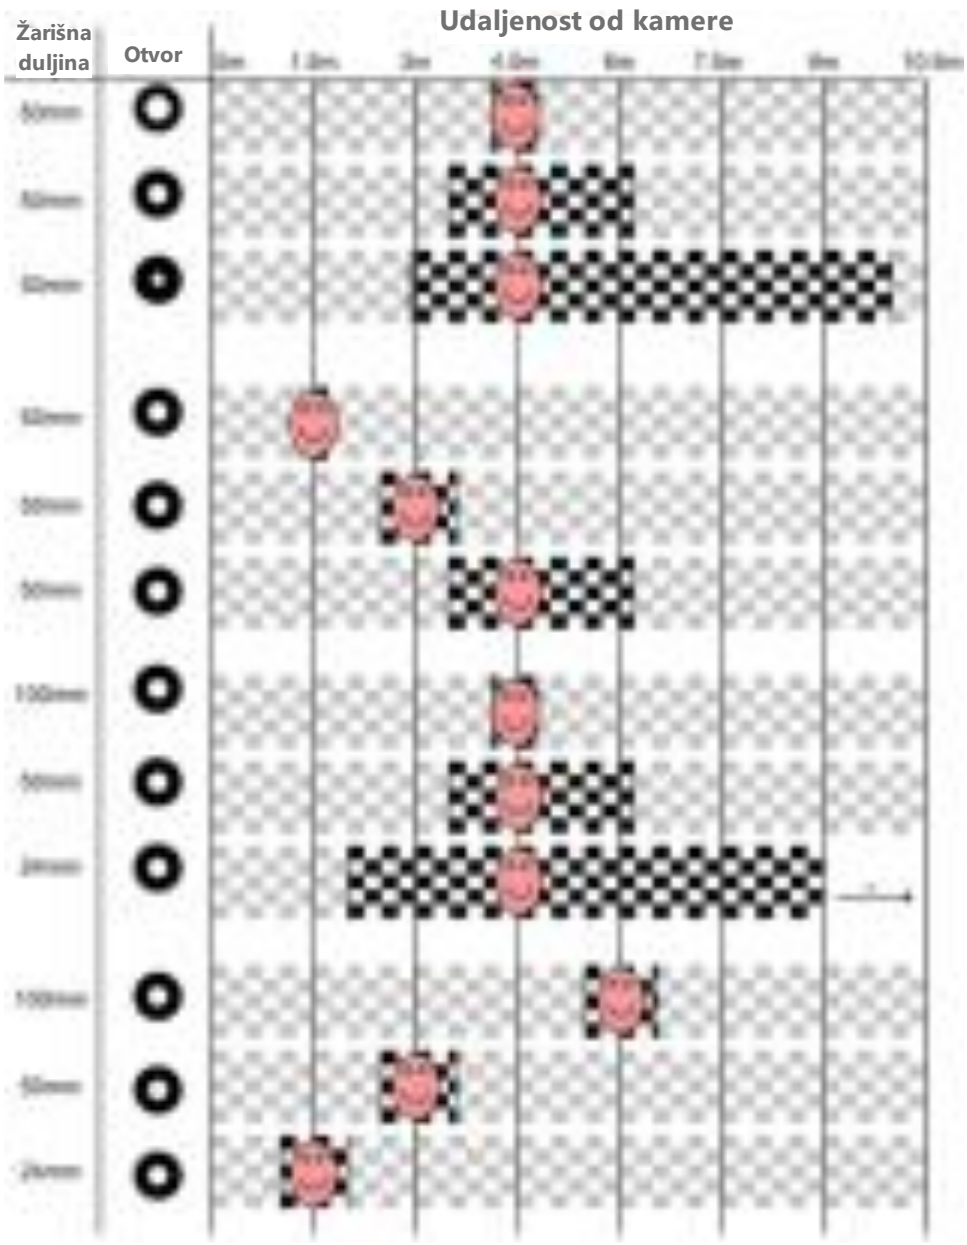

Slika 16: Izgled postavki kamera (izvor: The-Crankshaft Publishing, Image acquisition part 2)

Na primjeru slike 16, vidi se kako razne postavke žarišne duljine, otvora za svjetlost i udaljenosti objekta daju različitu dubinu polja. Također se vidi kako određenom kombinacijom tih triju postavki se dobije fokusirana fotografija. Fokusirana lica predstavljaju dubinu polja za određene postavke, odnosno raspon u kojemu će objekt biti fokusiran. Ovakve postavke najviše koriste profesionalni fotografi kako bi dobili što kvalitetniju, izoštreniju fotografiju. (The-Crankshaft Publishing, Image acquisition part 2)

2.9. Senzor slike

Nakon što se svjetlost reflektira od objekta, ona se fokusira pomoću optičkog sustava pa se snimi kamerom. Kako bi se ta radnja u potpunosti odvila, potreban je senzor slike. Kao što e već reklo, senzor se sastoji od 2D polja te je svako polje zapravo jedan piksel i svako polje mjeri količinu primljene svjetlosti i pretvara ju u napon koji se kasnije pretvara u digitalni broj. Što je veća količina upadne svjetlosti, to je veći napon, a samim time i digitalni broj. Prije nego kamera snimi fotografiju, svaka ćelija u polju mora biti ispražnjena, odnosno ne smije sadržavati nikakav napon. Nakon što kamera snimi fotografiju, tada se dozvoljava svjetlosti da uđe te da napuni svaku ćeliju naponom.

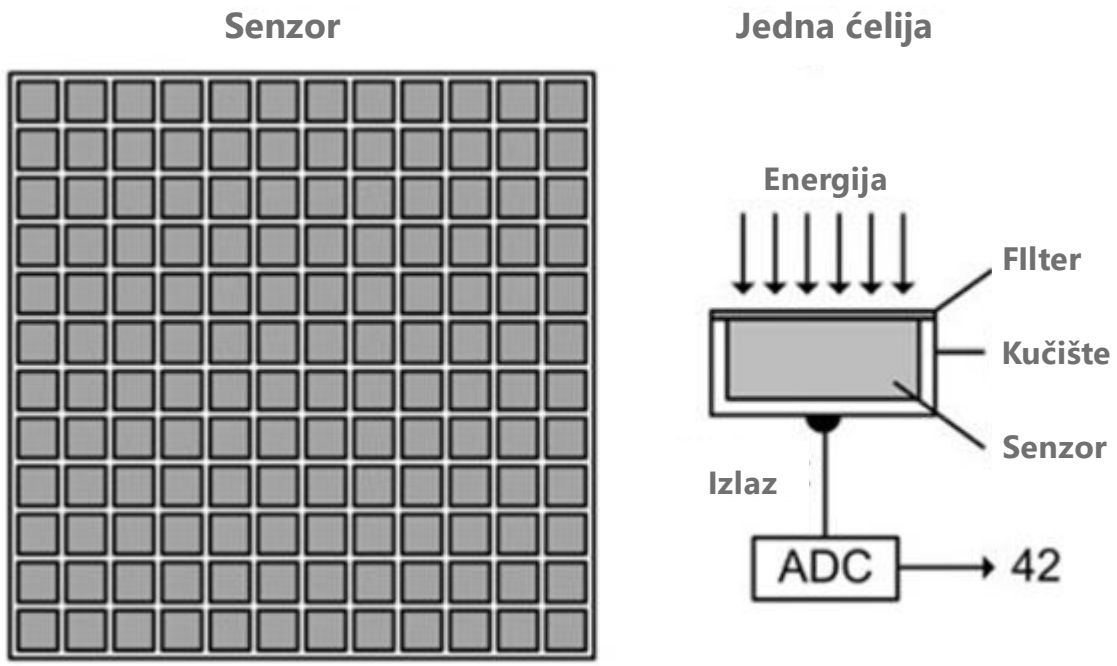

Slika 17: Izgled senzora kamere (izvor: The-Crankshaft Publishing, Image acquisition part 2)

Kako bi se još bolje objasnilo kako to izgleda, odnosno, funkcionira senzor, na slici se može grafički prikazati shema senzora i ćelije. Već se spomenulo da je senzor skup povezanih ćelija. Svaka ćelija se sastoji od kućišta koje se sastoji od filtera, senzora te izlaza. Filter kontrolira kojem tipu energije je dopušten ulaz u kućište. Senzor mjeri količinu energije, odnosno, napona koji se kasnije pretvara pomoću analogno-digitalnog pretvarača.

Nakon određenog vremena, poznato kao vrijeme ekspozicije, koje se kontrolira pomoću zatvarača, ulazna svjetlost se ponovo gasi. Ako je vrijeme ekspozicije predugačko ili prekratko, tada kao rezultat dobijemo koja je ili previše svijetla ili previše tamna. Primjer se može vidjeti na fotografiji.

Slika 16: Izgled ekspozicije (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

Na prvoj fotografiji se može vidjeti kako je korektno uslikana, odnosno, vrijeme ekspozicije nije predugačko, a ni prekratko. Dok na sljedeće dvije slike se može vidjeti kako se nalazi previše odnosno premalo ekspozicije što rezultira fotografijama koje su previše svijetle, odnosno previše tamne. Dok na zadnjoj fotografiji se može vidjeti kako je ili objekt ili kamera u pokretu pa je onda slika zamućena. Nadalje, prikupljena energija na ćelijama se pretvara u digitalni oblik pomoću analogno-digitalnog pretvarača. Takav postupak pretvara vanjsku okolinu u digitalni prikaz koji će biti spremljen za daljnji proces, tj. ovdje slika prelazi u digitalni oblik. Na idućoj fotografiji se može vidjeti kako dolazna svjetlost udara različite ćelije, isto tako se vidi da su neke ćelije tamnije a neke svjetlije. Razlog tome je što svjetlost više puta udari u istu ćeliju te što više puta svjetlost udari u ćeliju time je ćelija svjetlija.

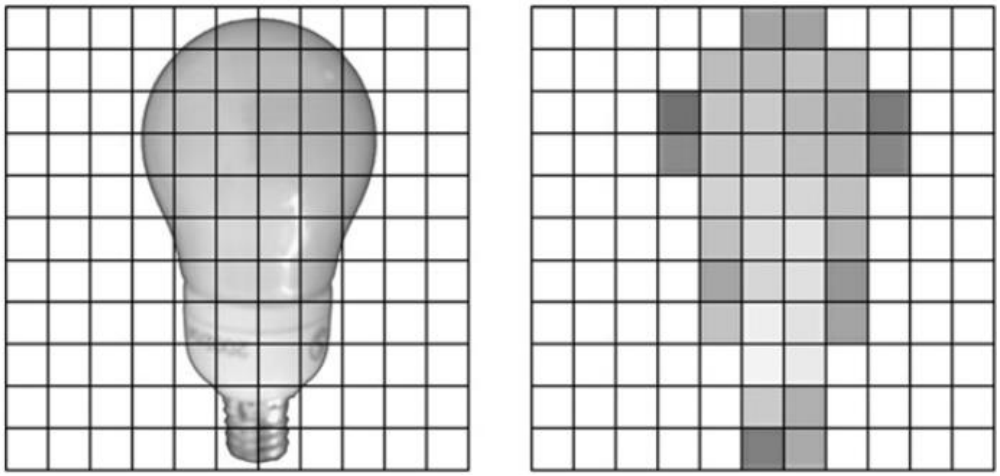

Slika 17: Primjer fotografije na ćelijama (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

Ćelije su osjetljive na dolaznu svjetlost, ali nisu osjetljive na točno mjesto udarca dolazne svjetlosti. Da bi oblik bio sačuvan, veličina ćelije mora biti beskonačno mala, a to znači da bi fotografija bila beskonačno velika u horizontalnom i vertikalnom smjeru. Takvu fotografiju nije moguće snimiti, samim time i ćelija mora imati konačnu veličinu. Konačna veličina ćelije dovodi do gubitka preciznosti odnosno gubitka podataka, te se taj proces zove prostorna kvantizacija. Broj piksela koji predstavljaju sliku se naziva prostorna rezolucija slike. Što je veća rezolucija, to se koristi veći broj piksela te to rezultira kvalitetnom slikom, dok se pod nižom rezolucijom misli na relativno niski broj piksela koji se koriste. Primjer različitih rezolucija se može vidjeti na sljedećim fotografijama, na prvoj fotografiji se radi o 256 puta 256 piksela, na drugoj 64 puta 64 piksela te na trećoj 16 puta 16 piksela u polju. (The-Crankshaft Publishing, Image acquisition part 2)

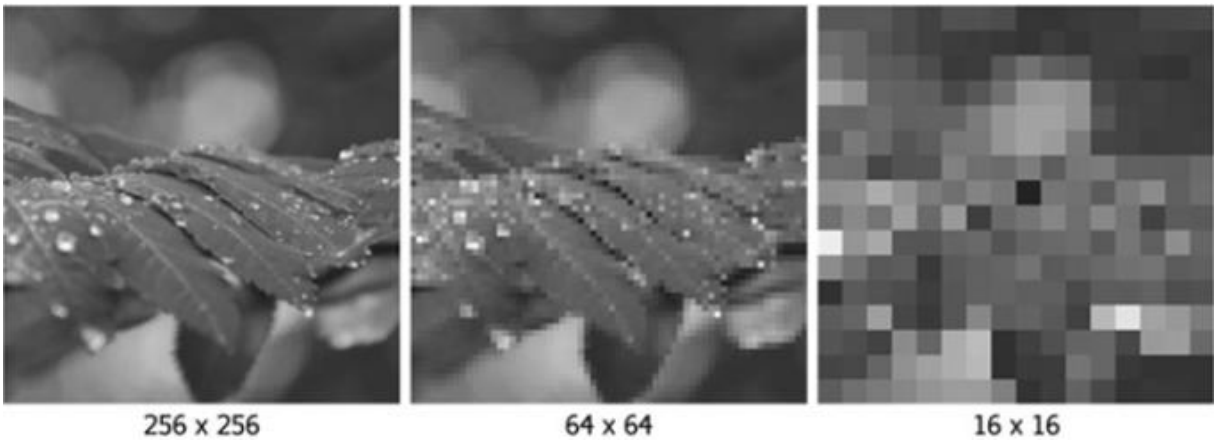

Slika 18: Različite rezolucije fotografija (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

Zaključno tome, postoji kompromis između memorije i očuvanja detalja slike objekta. Moguće je mijenjati rezoluciju ponekih visoko kvalitetnih fotografija u fotografije niže kvalitete odnosno rezolucije, ali nije moguće da se od fotografije koja je originalno niže rezolucije, napravi fotografija visoke rezolucije.

Također, važno je spomenuti i količinu dolazne svjetlosti u pojedinu ćeliju. Tu se govori o broju fotona koji udaraju u ćeliju, te oni mogu biti izrazito velikog broja pri čemu je potreban i digitalni broj koji će predstavljati tu informaciju. Međutim, ljudsko oko ne može raspoznati točan broj fotona, zato se mora kvantificirati broj fotona koji udaraju u ćeliju. Često ta kvantifikacija rezultira reprezentacijom jednog bajta (8 bitova), a razlog tomu je što memorija računala je organizirana tako da odgovara toj jedinici. U slučaju osmo-bitne kvantizacije stanje bez napona kvantizira se s brojem 0, dok visoki napon s brojem 255. Efekt mijenjanja kvantizacije razine sive boje može se vidjeti na sljedećoj fotografiji, gdje je razina 16, što se tiče kvalitete fotografije, još uvijek prihvatljiva, ali sve ispod toga je već loše kvalitete.

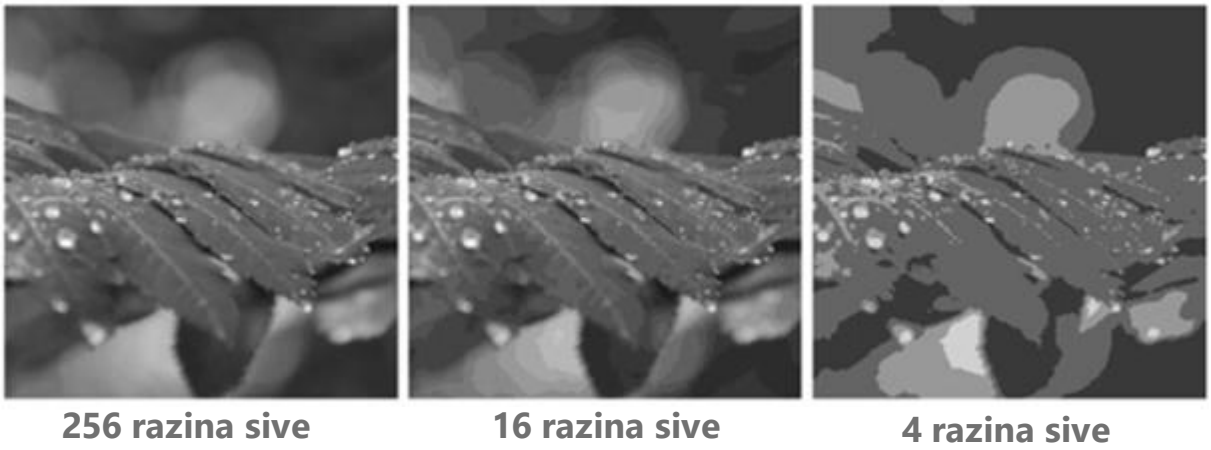

Slika 19: Razina sive boje na fotografiji (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

U slučaju fotografije kojoj je ekspozicije prenaglašena, broj ćelija sadrži napon koji je veći od maksimalno mjerljivog napona. Takve ćelije su maksimalno kvantizirane (255) i nikako se ne može pretpostaviti koliko je dolazne svjetlosti ušlo u takvu ćeliju pa time se zaključuje da je takva fotografija zasićena. Da ne bi došlo do takvog događaja, koristi se zatvarač, a takve fotografije će biti potrebno dodatno razraditi. Također, ako je ćelija zasićena, postoji mogućnost da će to utjecati i na susjedne ćelije te će onda povećati i njihovu vrijednost napona. Veličina piksela se mjeri u mikrometrima i ono uključuje cijelo područje i fotodiode i okolne elektronike. Uobičajeno je da veća količina piksela bolja za povećanu osjetljivost na svjetlost. Razlog tomu je taj što sadrži veće područje fotodiode za primanje svjetlosti.

No, ako format senzora ostane isti, ali razlučivost se poveća, veličina piksela se mora smanjiti. Iako bi ovo moglo smanjiti osjetljivost senzora, poboljšanje u strukturi piksela, tehnologija smanjenja šuma i obrada slike mogu bi to mogle ublažiti. (The-Crankshaft Publishing, Image acquisition part 2) (Lucid, 2020)

2.10. Jačina kamere i područje interesa (ROI)

Današnja tehnologija se jako brzo razvija, time se i razvijaju kamere sa sve većim i većim brojem piksela na senzoru. Veličina slike se računa tako da se pomnože vertikalni broj s horizontalnim brojem piksela. Što je veći broj piksela u fotografiji, time je fotografija kvalitetnija, no tu dolazi novi problem. Jedan od glavnih problema je obrada tako kvalitetne fotografije. Osim ako su i najsitniji detalji potrebni, bolje je da se koristi fotografija manjeg formata, a zbog tako velikog broja piksela, bit će i veliki broj matematičkih operacija, odnosno, potrebna je jaka računalna snaga koja će to izračunati.

Primjerice, ako imamo fotografiju s 500x500 piksela. To znači da fotografija se sastoji od 250.000 piksela. Sada uzmemo u obzir da obrađujemo 30 fotografija po sekundi, te kada pomnožimo 30 * 250.000 dobijemo 7.500.000 piksela po sekundi. Nadalje, ako nam treba barem 10 matematičkih operacija po pikselu, te kada to pomnožimo s brojem piksela, dobijemo 10 * 7.500.000 odnosno 75.000.000 matematičkih operacija po sekundi. To je čak puno i za današnja računala.

Osim što se treba birati jačina kamere, važno je i područje interesa koje uglavnom bude softverski napravljeno u kameri. Područje interesa (ROI) je kvadratnog oblika koje je definirano pikselima interesa. Dok pikseli koji nisu u pikselima interesa, oni budu ignorirani te za njih je potrebna manja obrada. Prema tome, ROI je zapravo područje na koje je kamera fokusirana. Primjerice, ako se postavi kamera na ulaz neke trgovine, i softverskim putem se može reći kameri da ona bilježi samo lica osobe koja je ušla u trgovinu. Isto tako, ROI se najviše koristi u prikupljanju slika lica. Na sljedećoj fotografiji se vidi primjer područja interesa, u ovom slučaju je to lice dječaka. Područje interesa može biti manualno određeno ili pomoću softvera (polu-automatsko ili automatsko). Softver za polu-automatsko određivanje područja interesa pomaže korisniku da utvrdi koje područje je upitno područje. Korisnik navodi samo dio razgraničenja koji zatim nastavlja i dovršava program za procjenu. Ovom vrstom detekcije korisnik može utvrditi područje unutar kojeg bi softver za procjenu trebao raditi. U slučaju potpuno automatskog određivanja područja interesa, softver za ocjenjivanje preuzima obradu bez ikakve intervencije korisnika. (The-Crankshaft Publishing, Image acquisition part 2) (SmartRay 2019)

Slika 20: Područje interesa (Izvor: The-Crankshaft Publishing, Image acquisition part 2)

3. Kamere za prikupljanje fotografija

3.1. Analogne kamere

Postoje dvije vrste kamera koje se mogu koristiti za prikupljanje fotografija. Te kamere se dijele na analogne i digitalne kamere. Digitalne kamere se kasnije mogu klasificirati kao paralelne digitalne kamere, Camera Link i IEEE 1394 standard kamere.

Analogne kamere su kamere koje generiraju video signal u analogni format. One koriste potrošni film kod kojeg, kada svjetlost prođe kroz leće kamere, udari u film te potakne na kemijsku reakciju. Tako su se u prošlosti pravile fotografije pomoću analognog fotoaparata. Danas, analogni signal je digitaliziran pomoću uređaja za prikupljanje fotografija. Video signal se temelji prema televizijskom standardu, a to je i najčešći standard koji predstavlja video signal. U ovom radu se već spomenuo CCD uređaj, odnosno sklop s prijenosom naboja, koji sadrži polje od stotina pa do tisuća međusobno povezanih poluvodiča. Svaki piksel je fotosenzitivan element koji sprema i generira električni naboj kada bude osvijetljen. Također, sastavni je dio CCD sklopa, koji se sastoji od pravokutnog polja piksela na kojem se nalazi fokusirana fotografija objekta. U većini konfiguracija, senzor uključuje strujni krug koji

pohranjuje i prenosi svoj naboj u registar pomaka koji potom pretvara prostorni niz naboja, u CCD uređaju, u vremensko promjenjiv video signal. Kombinacijom informacija o vremenu za okomiti i vodoravni položaj i vrijednost senzora se formira video signal. Nadalje, za standardne analogne kamere, linije CCD-a su isprepletene radi povećanja uočene brzine ažuriranja slike, poznato kao FPS (eng. „frame per second“), tj. kadar po sekundi. To bi značilo da se prvo skeniraju neparni redci, a nakon toga parni, te ta dva polja čine jedan kadar.
Analogne kamere su vrlo jeftine i vrlo lako se povezuju s analognim uređajem za prikupljanje fotografija. Analogne nadzorne kamere se i isto odnose na CCD i CMOS uređaje koji pretvaraju svjetlost u električne signale. Ali, ti električni signali moraju prolaziti kroz fizički kabel do digitalno video snimača koji kasnije pretvara te signale u digitalni oblik.
(Engineer Ambiiously, Image acquisition 2019) (Q-SEE, 2020)

3.2. Digitalne kamere

Digitalne kamere imaju nekoliko prednosti nad analognim kamerama. Tijekom prijenosa, analogni video je osjetljiviji nego digitalni video. Digitalizacijom na razini kamere, a ne na uređaju za prikupljanje fotografija, omjer signala i šuma je obično veći što nam rezultira boljom preciznošću. Zato digitalne kamere nisu potrebne da zadovoljavaju televizijski standard, već mogu ponuditi veće veličine fotografija i veću količinu kadrova po sekundi, pa tako i veću rezoluciju piksela.
Digitalne kamere dolaze s razlučivosti od 10 do 16 bita sive boje kao standard za aplikacije astronomije, mikroskopije, termalnog snimanja i strojnog vida. Kao i analogne kamere, i digitalne kamere koriste iste CCD uređaje za snimanje fotografija, ali oni digitaliziraju videozapis prije nego što ga pošalju u hvatač kadrova. (Engineer Ambiiously, Image acquisition 2019)

3.2.1. Paralelne digitalne kamere

Donedavno, paralelne kamere su bile jedini tip digitalnih kamera koje su bile dostupne. Osim gore već navedenih osobina, paralelne digitalne kamere nemaju jasne fizičke ili protokolarne standarde, a povezivanje s digitalnim uređajima za prikupljanje fotografija može biti teško. Paralelne digitalne kamere često zahtijevaju posebne kablove za povezivanje s uređajima za prikupljanje fotografija, također, kamera mora biti kompatibilna s uređajem za prikupljanje fotografija. Srećom, danas tržište sadrži veliku bazu paralelni kamera skoro pa za sve programe za obradu fotografija. (Engineer Ambiiously, Image acquisition 2019)

3.2.2. Camera Link

Camera link je specificirano sučelje za kablove koji povezuju digitalnu kameru s uređajem za prikupljanje fotografija. Ono čuva sve pogodnosti digitalne kamere, poput fleksibilnosti za mnoge vrste senzora. No, ima samo mali konektor i jedan ili dva identična kabela koji rade sa svim Camera Link uređajima za prikupljanje. Camera Link uvelike pojednostavljuje kabliranje, što može biti poprilično složen zadatak pri radu sa standardnim digitalnim kamerama. (Engineer Ambiiously, Image acquisition 2019)

3.2.3. IEEE 1394 standard

IEEE 1394 je standard serijskih sabirnica koje se koriste u većini računalnih periferija, ali također se koristi i u digitalnim fotoaparatima. IEEE 1394 fotoaparati koriste jednostavne, fleksibilne, električne kablove s 4 ili 6 žica, dok u nekim slučajima, sama sabirnica može napajati fotoaparat. Međutim, pošto je IEEE 1394 dijeljena sabirnica, postoji i ograničenje propusnosti od 40 MB/s kada nije nijedan drugi uređaj priključen. Također, zahtijevaju i kontrolu procesora za premještanje podataka o slici, što ujedno ograničava raspoloživu propusnost za obradu fotografije. Nadalje, sadrži i funkciju za nabrajanje i postavljanje mogućnosti kamere. (Engineer Ambiiously, Image acquisition 2019)

3.3. Važne tehnologije kamera

3.3.1. Progresivno skeniranje

U standardnim analognim fotoaparatima, nakon što je CCD senzor izložen onda se čitaju neparna pa potom parna polja. Kada se slika objekt u pokretu, isprepletanje neparnih i parnih polja CCD senzora uzrokuje dvostruku ekspoziciju fotografije kao što se vidi na primjeru ispod.

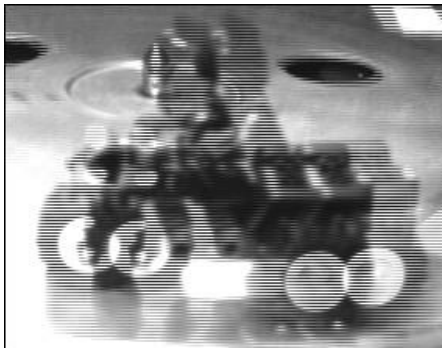

Slika 21: Objekt u kretnji (Izvor: Engineer Ambigiously, Image acquisition 2019)

U kamerama za progresivno skeniranje, parna i neparna polja u CCD senzoru su izložena u isto vrijeme, umjesto da je prvo neparno pa parno polje. Takvo ponašanje kamere za progresivno skeniranje se pokazuje izrazito korisno u primjeni gdje je objekt u pokretu. Ali, mora se postaviti odgovarajuće vrijeme ekspozicije kako bi se dobile fotografije bez zamućenja koji su uzrokovani pokretom. Primjer se može vidjeti na fotografiji gdje se objekt slikanja „a“ slika s vremenom ekspozicije od 33 milisekunde, objekt „b“ s vremenom ekspozicije od 10 sekundi i objekt „c“ s vremenom ekspozicije od 1 milisekunde. Može se zaključiti da je objekt „c“ uslikan bez ikakvih zamućenja. (Engineer Ambigiously, Image acquisition 2019)

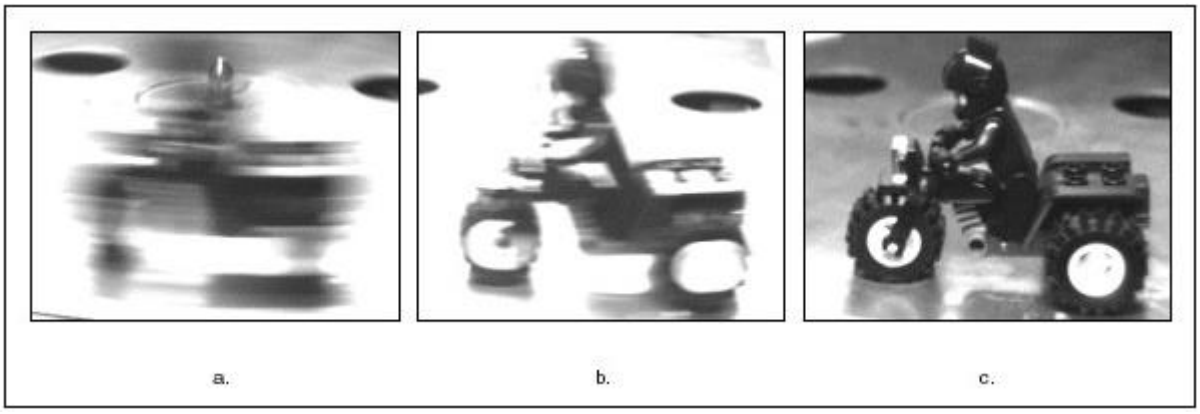

Slika 22: Različita vremena ekspozicije (Izvor: Engineer Ambigiously, Image acquisition 2019)

3.3.2. Infracrvene kamere

Infracrvene kamere mjere infracrvenu ili toplinsku energiju koja isijava s objekta snimanja. To su kamere koje pomažu u rješavanju znanstvenih i industrijskih primjena koje senzori, koji koriste vidljiv spektar svjetlosti, ne mogu riješiti. Također, greške se puno lakše uočavaju pod infracrvenim spektrom. Lakše se uočava i mjeri sadržaj spremnika ako je sadržaj različit od temperature spremnika. Na primjer, pomoću infracrvene kamere, može se vidjeti razina ulja u kompresoru gdje je ulje različite temperature od kućišta. Na sljedećem primjeru prikazana je osoba gdje se vidi kako je viša temperatura prikazana žarkim bojama, dok niže temperature su prikazane hladnim bojama. Također se može uočiti kako je područje nosa hladne boje, odnosno to je hladniji dio ljudskog lica. (Engineer Ambiiously, Image acquisition 2019)

Slika 23: Infracrvena fotografija osobe (Izvor: http://www.palmiaobservatory.com/2018/07/gamma-ray-spectrum-and-crab-nebula.html)

4. Fotografije lica

4.1. Faktori koji utječu na otkrivanje i prikupljanje lica s fotografija

Prikupljanje i otkrivanje lica s fotografija i videozapisa je vrlo zahtjevan i težak posao. Jako puno istraživanja (R. Jenkins, A. M. Burton, 2008) je već učinjeno da bi se postigla stopostotna preciznost, ali još uvijek se ne postižu zadovoljavajući rezultati. Neki čimbenici koji uvelike utječu u prikupljanju, otkrivanju i prepoznavanju lica su okluzija (blokada), niska rezolucija fotografije, osvjetljenje, pozicija lica, izraz lica, starost te plastična kirurgija. Navedeni čimbenici se mogu podijeliti u dvije različite skupine: unutarnje i vanjske. Unutarnji čimbenici uključuju fizičko stanje ljudskog lica i one više služe za raspoznavanje lica, a to su: izraz lica, starost osobe, plastična kirurgija, dok za otkrivanje lica su važni vanjski čimbenici: okluzija, niska rezolucija fotografije, osvjetljenje objekta, šum fotografije i pozicija lica.

4.1.1. Okluzija (pokrivenost)

Djelomična okluzija ili pokrivenost lica je jedan od većih izazova prikupljanja i otkrivanja lica. Bilo bi vrlo teško prepoznati lice odnosno otkriti lice s fotografije ako nedostaje dio lica, ako je prekrivano, primjerice sunčanim naočalama ili maramom, ili čak ako osoba ima gustu bradu i brkove. Takvi čimbenici pogoršavaju učinkovitost sustava za detekciju. Na fotografiji se može vidjeti primjer djelomične blokade lica na fotografiji. (Anwarul, Dahiya 2020)

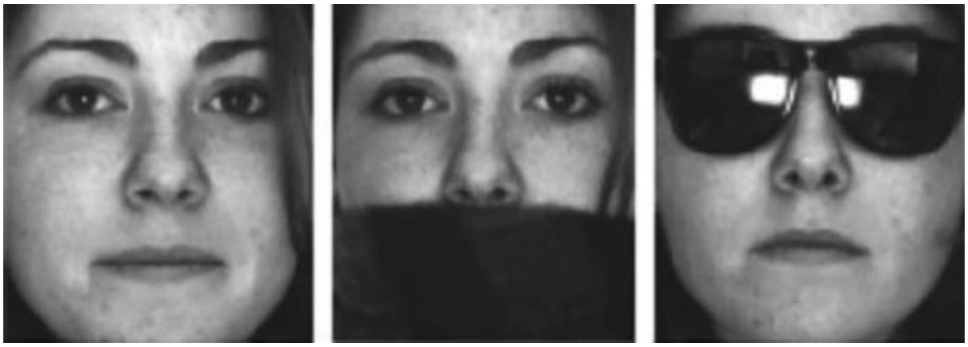

Slika 24: Okluzija lica (Izvor: Anwarul, Dahiya 2020)

4.1.2. Niska rezolucija fotografije

Još jedan od čimbenika koji utječe na otkrivanje i prepoznavanje lica s fotografije je rezolucija same fotografije. Sljedeći primjer prikazuje isječak iz videonadzora gdje se može vidjeti lice osobe koje je umanjeno radi udaljenosti osobe od kamere. Takvo umanjeno lice nam donosi sljedeći problem. Ako mi povećamo lice osobe na fotografiji, lice će biti neprepoznatljivo zato što je vrlo niska rezolucija te fotografije. Takva slika niske rezolucije sadrži izuzetno ograničene podatke, dok je veći dio područja interesa izgubljen.

Ujedno taj problem drastično pogoršava stopu prepoznavanja. Jedino optimalno rješenje takvog problema je taj da se koriste visoko rezolutne nadzorne video kamere, no takvo rješenje je skupo. Na sljedećoj fotografiji se vidi primjer fotografije niske rezolucije i slike lica koja je neprepoznatljiva. (Anwarul, Dahiya 2020)

Slika 25: Uvećanje i niska rezolucija lica na fotografiji (Izvor: Anwarul, Dahiya 2020)

4.1.3. Šum fotografije

Digitalne fotografije su podložne raznim vrstama šumova. Šum na fotografiji je vizualno izobličenje koje je slično zrnu koje mogu biti pronađene na filmskim fotografijama, ali također ože biti i promjene boja u obliku mrlje kada je jakog intenziteta, a time se u većini slučaja uništi fotografija. Šum uobičajeno dolazi pod fotografiranjem pri slabom osvjetljenju. Većina šuma dovodi do nemogućnosti otkrivanja lica na fotografiji, a time i prepoznavanja lica s fotografije. Na sljedećoj fotografiji je prikazan primjer šuma gdje je na lijevoj strani prisutan, dok na desnoj strani nije prisutan šum odnosno pomoću softvera je uklonjen. (Anwarul, Dahiya, 2020)

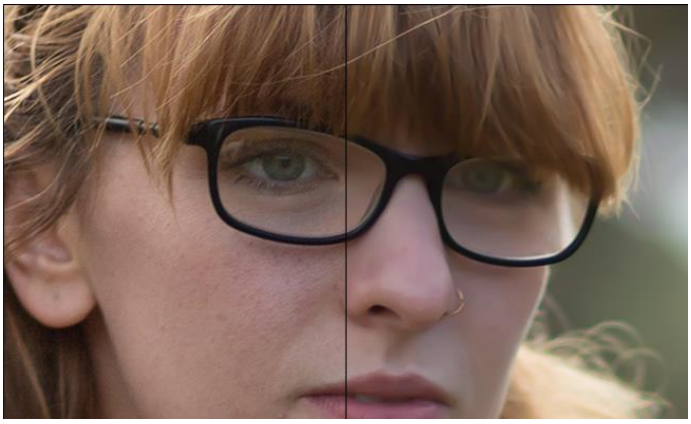

Slika 26: Šum na fotografiji lica (Izvor: https://www.howtogeek.com/368550/what-is-noise-reduction-in-digital-images/)

4.1.4. Osvjetljenje lica na fotografiji

U ovom radu se već spominjalo osvjetljenje kao bitan faktor u prikupljanju, otkrivanju i prepoznavanju lica s fotografije. Kao i ostali faktori, osvjetljenje može drastično umanjiti učinak prepoznavanja lica s fotografije. Osvjetljenje ne smije biti ni preblizu, niti predaleko. Također i visina izvora osvjetljenja mora biti na idealnoj poziciji kako bi se cijelo lice vidjelo. Što je osvjetljenje bliže licu, to mora biti blaže inače će lice biti presvijetlo i proces otkrivanja lica je otežan. Na sljedećim primjerima se vidi kako je kut i jačina osvjetljenja od izuzetne važnosti kod otkrivanja lica s fotografije. Ujedno, na jednom od primjera se vidi kako je osvjetljenje samo s lijeve ili samo s desne strane, time dobijemo da je jedan dio lica osvjetljen, dok drugi nije. Tu se povlači još jedan problem, odnosno faktor koji se ranije spomenuo, a to je okluzija tj. blokada dijela lica. (Anwarul, Dahiya, 2020)

Slika 27: Loše osvjetljenje lica (Izvor: Anwarul, Dahiya, 2020)

4.1.5. Promjena u položaju lica

Različite promjene u položaju lica također utječu na rad sustava za prepoznavanja lica. Potrebna je totalna rekonstrukcija frontalnog dijela lica kako bi se moglo uspoređivati s drugim slikama lica. Rekonstrukcija je potrebna zato što većina fotografija u određenoj bazi podatak se sastoji od frontalnog dijela lica, dok ostali dijelovi lica profila mogu generirati pogrešne rezultate. Dok raspoznaju lica s fotografije, osoba ne mora gledati direktno odnosno frontalni dio nije toliko ključan, za što uspješnije prepoznavanje i usporedbu tog lica, osoba mora biti direktno usmjerena prema kameri ili fotoaparatu. Na sljedećim primjerima se vidi različito držanje lica. (Anwarul, Dahiya, 2020)

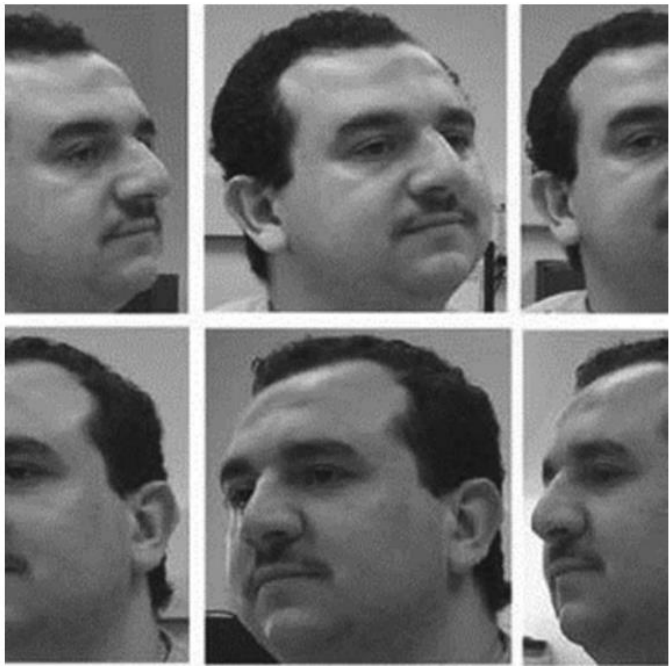

Slika 28: Različiti položaji lica (Izvor: Anwarul, Dahiya 2020)

4.1.6. Artefakti pokreta

Još jedan faktor koji utječe na prikupljanje, otkrivanje i prepoznavanje lica s fotografije su artefakti pokreta koji uključuju zamućenje. Također, to je isto jedan od velikih problema s kojim se suočava sustav za prikupljanje fotografija. U ovom radu se već govorilo o zamućenju, koje se može dogoditi zbog raznih faktora, primjerice kretanja kamere, raznih vibracija pa tako i kretanja samog subjekta. Kod subjekata koji se kreću, vrlo lako se može primijetiti vertikalna zamućenost. Ovakvi se problemi dodatno pogoršavaju ako se koriste zatvarači sporije brzine ili ako je subjekt snimanja neka pokretna platforma, primjerice brod na moru. Na sljedećem primjeru se može vidjeti subjekt u pokretu kojemu se jasno vidi zamućenje lica. (Boult, Scheirer 2009)

Slika 29: Osoba u pokretu (Izvor: Boult, Scheirer 2009)

Još jedan, ne tako poznati problem su, klizni zatvarači. Postoje dva razloga zbog kojeg se koriste klizni zatvarači na fotoaparatu. Prvi razlog je da se štedi jedan tranzistor po ćeliji u usporedbi s normalnim zatvaračem, dok drugi razlog je da omogućuje vremensku integraciju, koja je gotovo jednaka s brzinom kadrova kod normalnog zatvarača te ne sadrži značajno kašnjenje. Sam koncept kliznih zatvarača je vrlo jednostavan. Postoje dva pokazivača na senzor od kojih je jedan za čitanje podataka, dok je drugi za brisanje i resetiranje. Vremenska razlike između brisanja retka i čitanja sljedećeg se definira kao vrijeme integracije, odnosno brzina zatvarača. Problem kliznog zatvarača je taj što se i uz kratko vrijeme integracije, zatvarači dohvaćaju podatke o gornjem i donjem dijelu fotografije u sasvim različitom vremenu. Na idućem primjeru se može vidjeti razlika gdje je kamera bila podvrgnuta vodoravnom kretanju dovoljno brzo da je zid gornjem dijelu fotografije u drugačijem položaju nego na srednjem i donjem dijelu fotografije. (Boult, Scheirer 2009)

Slika 30: Primjer upotrebe kliznog zatvarača (Izvor: Boult, Scheirer 2009)

5. Praktično rješenje

Nakon teorijskog dijela ovog rada, dolazi praktični dio rada gdje će se moći vidjeti dobri i loši primjeri fotografiranja lica, odnosno hoće li program moći prepoznati lice s fotografije ili neće. Nadalje, objasniti će se uvjeti koje fotografija lica treba zadovoljiti kako bi se moglo prepoznati s fotografije, primjerice osvjetljenje, pokriće lica, položaj lica, udaljenost lica od kamere.

5.1. Open CV

Open Source Computer Vision Library je biblioteka softvera otvorenog koda za računalni vid i za strojno učenje. Izgrađen je kako bi pružio zajedničku infrastrukturu za programe računalnog vida i ubrzao upotrebu percepciju strojeva u komercijalnim proizvodima. Budući da sadrži BSD licencu, onda ujedno i olakšava tvrtkama njegovu upotrebu i mogućnost izmjene koda.

Biblioteka sadrži više od 2500 optimiziranih algoritama, što uključuje i set klasičnih i najsuvremenijih algoritama za računalni vid i strojno učenje. Ti algoritmi se uglavnom koriste za otkrivanje i prepoznavanje lica, prepoznavanje objekata, klasificiranje ljudskih radnji u raznim videozapisima, praćenje kretnji, praćenje objekata u pokretu, spajanje više slika kako bi se dobila slika visoke rezolucije, pronalaženje sličnih slika iz baze podataka slika, omogućuje uklanjanje crvenih točaka s očiju sa slika snimljenih bljeskalicom, praćenje pokreta očiju. (OpenCV team, 2020)

U praktičnom dijelu ovog rada će se koristiti algoritmi iz Open CV biblioteke pomoću kojega će se prepoznati lice s fotografije.

5.2. Detekcija lica pomoću Haar Cascades

Otkrivanje objekata pomoću Haar-ovih kaskadnih klasifikatora na temelju značajki je učinkovita metoda otkrivanja objekata koju su 2001. godine predložili Paul Viola i Michael Jones u svom radu „Rapid Object Detection using a Boosted Cascade of Simple Features“. Govore o pristupu koji je zasnovan na strojnom učenju gdje je kaskadna funkcija uvježbana iz mnogo pozitivnih (slike na kojima se nalazi lice na fotografiji) i negativnih slika (slike na kojima se ne nalaze lica na fotografiji). Također, koristi se za otkrivanje objekata iz fotografija. U ovom radu će se pomoću Haar Cascades algoritma odrediti nalazi li se lice na fotografiji ili se ne nalazi.

Ovom metoda koristi tri vrste značajki. Svaka značajka je posebna vrijednost koja je dobivena oduzimanjem zbroj piksela ispod bijelog pravokutnika od zbroja piksela ispod crnog pravokutnika. Primjer pravokutnika se može vidjeti na sljedećoj fotografiji. (OpenCV team, 2020)

Slika 31 Izgled značajki Haarove metode (izvor: OpenCV)

Za kalkulaciju svake značajke, potrebno je pronaći sumu piksela ispod bijelih i crnih pravokutnika. Da bi se to riješilo na najbrži način, uvodi se integralna fotografija. Koliko god da je velika fotografija, ona smanjuje izračune za zadani piksel na obradu koja uključuje samo četiri piksela, što uvelike ubrzava sami proces. Pomoću AdaBoosta, koja se koristi u konjunkciji s puno drugih algoritmima učenja za poboljšanje učinka algoritma, Haar metoda pronalazi najbolju granicu koja će lica klasificirati na pozitivna i negativna, odnosno postoje li ili ne postoje. Odabrati će se značajke s minimalnom stopom pogrešaka, što znači da su to one značajke koje najtočnije klasificiraju slike na kojima se, nalaze ili ne nalaze, lica. Na idućem primjeru se vide dvije vrste značajki, od kojih se jedna značajka fokusira na područje očiju zato što su oči tamnije nego područje nosa i obraza, dok druga značajka se odnosi na to da su oči tamnije od samog mosta nosa. (OpenCV team, 2020)

Slika 32: Primjer značajki (Izvor: OpenCV)

5.3. Programski kod

Prvo se instalira OpenCV biblioteka kako bi se mogla koristiti u programskom rješenju. Nakon što se instalira Python na računalo, otvori se komandtni prozor i upiše se sljedeće:

```
pip install opencv-python
```

Nakon što se instalira OpenCV biblioteka, u Python editoru se uveze OpenCV biblioteka.

```
Import cv2
```

Kada se uvezla biblioteka, sada se mogu učitati već „istrenirani“ klasifikatori za lice, oči, osmjeh itd, koji se moraju skinuti s interneta u XML obliku. Oni se koriste za detekciju lica i koristit će se u ovom primjeru.

```
klasifikatori_lica =
cv2.CascadeClassifier('haarcascade_frontalface_default.xml')
```

Nadalje, potrebno je učitati fotografiju i pretvoriti ju iz boja BGR formata u sivu boju kako bi funkcija *detectMultiScale* lakše izvukla x i y koordinate, visinu i širinu fotografije te time bi se i ubrzao postupak. U ovom slučaju, pomoću funkcije *cvtColor* iz biblioteke OpenCV, slika se pretvara iz boja BGR formata u sivu boju gdje se za prvi argument uzela slika koja se učitala, a za drugi argument funkcija pretvorbe.

```
slika = cv2.imread('slika.jpg')
siva_fotografija = cv2.cvtColor(slika, cv2.COLOR_BGR2GRAY)
```

Nakon toga, zahvaljujući OpenCV biblioteci, sa samo jednom linijom koda se može odrediti gdje se lice nalazi na fotografiji. Pomoću funkcije *detectMultiScale* se otkrije lice s fotografije. Ta funkcija uzima 3 argumenta, a to je slika koju unosimo, a koja je pretvorena u sivu, *scaleFactor* i *minNeighbours*. Pomoću *scaleFactor* određuje se za koliko se veličina slike smanjuje sa svakim skaliranjem, dok *minNeighbours* određuje koliko susjeda svaki pravokutnik kandidat treba imati da bi ga zadržao. Ovaj argument će utjecati na kvalitetu otkrivenih lica, odnosno, što je veća vrijednost argumenta, to će rezultirat manjem broju otkrića ali kvalitetnijim.

```
lica = klasifikatori_lica.detectMultiScale(siva_fotografija, 1.15, 4)
```

Nakon što su se otkrila lica na fotografiji, potrebno je nacrtati pravokutnike koji će označavati gdje se nalazi lice na fotografiji. Za to se koristi *for* petlja sa sljedećim argumentima: x i y koordinata lica, visina i širina lica. Te pomoću funkcije *rectangle* iz biblioteke OpenCV, crtaju se pravokutnici oko lica, dok za argumente se uzima slika, x i y koordinata, širina i visina, te boja u BGR formatu i jačina crte koja pravi pravokutnik.

```
for (x, y, sirina, visina) in lica:
cv2.rectangle(slika, (x, y), (x + sirina, y + visina), (255, 0, 0), 2)
```

I na samom kraju, pomoću funkcije *imshow* prikazuje se slika kao rezultat koda. Radi OpenCV biblioteke, sami program za oktrivanje lica je vrlo kratak, ali osim softverskih uvjeta za otkrivanje lica potrebni su i fizički uvjeti kako bi se lice uspješno otkrilo.

5.4. Dobri i loši primjeri fotografija s licem

U ovom radu se već pisalo u uvjetima koje lice treba zadovoljiti kako bi se kvalitetno prikupilo, otkrilo i prepoznalo. Na sljedećim primjerima se može vidjeti kako osvjetljenje, položaj lica, pokriće lica, udaljenost i kvaliteta utječe na Haar-ovu metodu za otkrivanje lica s fotografija, te koji se uvjeti moraju poštovati kako bi se lice uspješno otkrilo na fotografiji.

5.4.1. Položaj osvjetljenja

Već se nekoliko puta spomenuo pojam „osvjetljenje“ u ovom radu. Osvjetljenje je vrlo bitno za otkrivanje lica s fotografija. Ne smije biti prejako, niti preslabo, previsoko, a ni prenisko. Na sljedećem primjeru se može vidjeti dnevno svjetlo kao dobar primjer osvjetljenja i vidi se da je lice otkriveno na fotografiji.

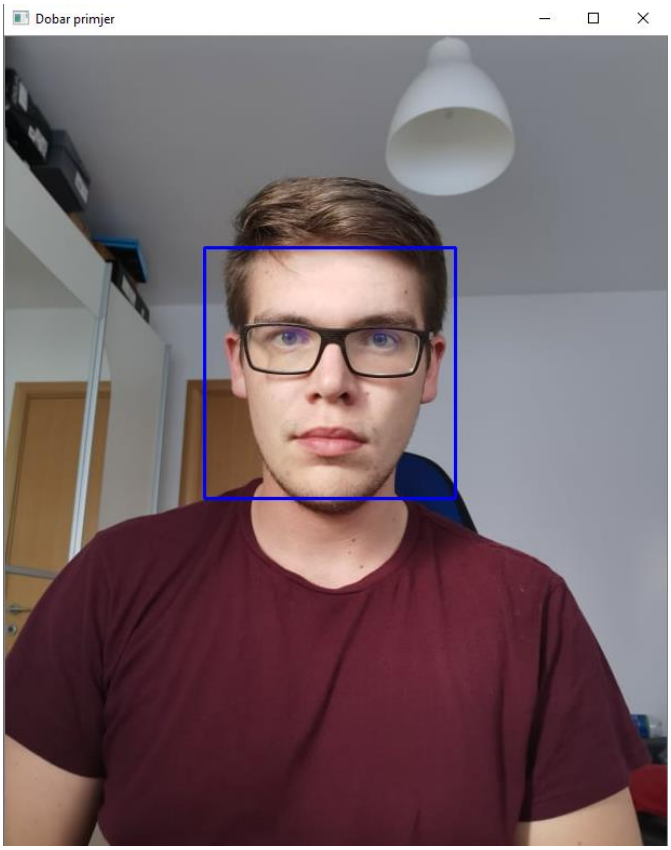

Slika 33: Dobar primjer osvjetljenja, držanja lica, ne pokrivenosti lica

Može se uočiti kako je program uočio, a time i uspješno označio pravokutnikom lice na fotografiji. Na sljedećoj fotografiji se može uočiti kako se osvjetljenje nalazi s desne strane osobe koja se fotografira i kako smeta algoritmu za otkrivanje, a time je i neuspješno otkriveno lice, odnosno fotografija ne sadrži plavi pravokutnik koji će pokazivati na područje gdje se lice nalazi.

Još jedan loš primjer se može vidjeti kada svjetlo stoji iza osobe koja se fotografira, time smeta algoritmu da prepozna boje i rubove lica, a time i nije u mogućnosti da otkrije licu.

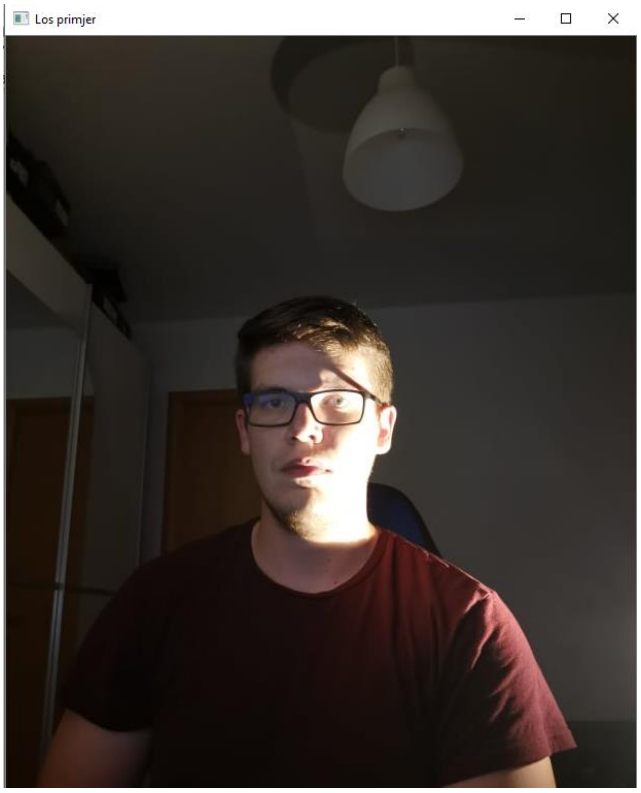

Slika 35: Loš primjer osvjetljenja (svjetlo s desne strane)

Slika 34: Loš primjer osvjetljenja (svjetlo iza osobe)

Za otkrivanje lica, najbolje je koristiti prirodno svjetlo koje će smanjiti mogućnost kontrasta između boja lica i okoline, neće biti jako a ni slabo, koje će u potpunosti osvijetliti lice te neće potamniti osobu koja se fotografira, a time i povećati mogućnost ne otkrivanja lica s fotografije. Ako se ne može koristiti prirodno svjetlo, može se koristiti i umjetno ali mora ispuniti gore navedene uvjete.

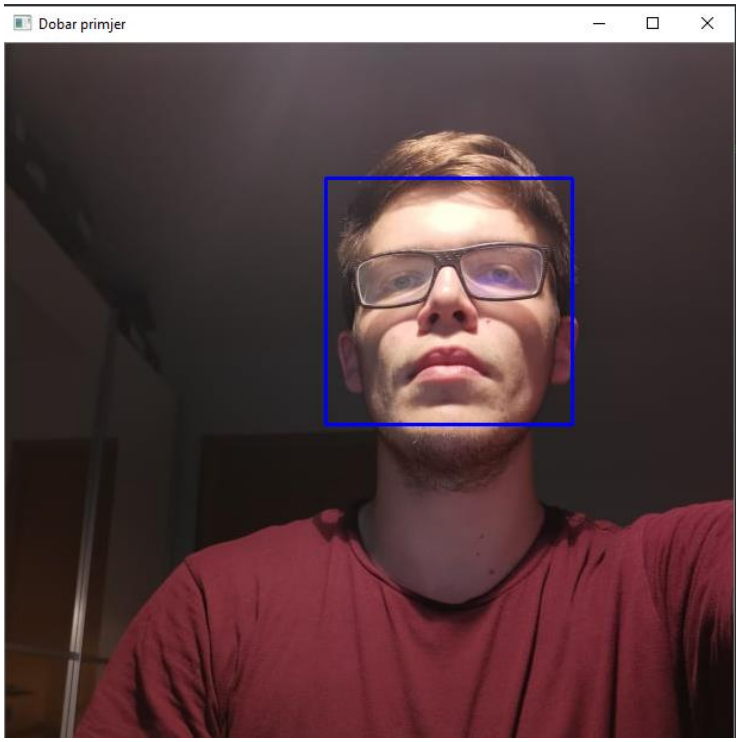

Slika 36 Dobar primjer – umjetno osvjetljenje

5.4.2. Položaj i držanje lica

Kao što se vidi na primjeru Slike 36, lice osobe je u prirodnom položaju, gleda direktno u kameru i algoritmu je omogućeno pronaći sve koordinate lica na fotografiji. Ako se gleda u stranu, prema gore ili prema dolje, algoritmu će biti teško pronaći početne i završne koordinate lica, a time neće biti u mogućnosti otkriti lice s fotografije.

Jedan od uvjeta da se pravilno prikupi slika lica je taj da lice mora biti u prirodnom položaju kako bi se mogle prikupiti sve karakteristike lica. Na primjeru se vidi osoba kako joj je položaj glave usmjeren u jednu stranu, a time algoritam nije u mogućnosti prepoznati lice s fotografije.

Slika 37: Loš primjer držanja lica (pogled u stranu)

5.4.3. Pokrivenost lica (okluzija)

Lice mora biti skroz otkriveno kako bi algoritam uspio prepoznati gdje se točno nalazi na fotografiji. Čak i ako osoba sadrži gustu bradu, to može dovesti do neuspjeha otkrića lica. Na sljedećem primjeru se može vidjeti kako osoba koja se fotografira sadrži crnu masku preko usta i nosa, te kapu preko čela i time blokira algoritmu da raspozna lice odnosno uoči gdje se nalaze oči, nos, usta i ostale karakteristike lica.

Kako bi se lice moglo otkriti s fotografije, potrebno je imati ne pokriveno lice, odnosno karakteristike lica moraju biti jasna.

Slika 38: Loš primjer - pokrivenost lica

5.4.4. Lice u pokretu

Iako je teško prepoznati gdje se točno lice nalazi ako osoba ne miruje, ovaj algoritam s uspjehom pronalazi lice koje je u pokretu. Tome pomažu boje lica, koje su kod većine ljudi u istom rasponu i vrlo lako se raspoznaju s fotografije, ali i jasnije karakteristike lica nego kod gore već navedenih loših primjera. Na primjeru se može vidjeti kako je glava osobe u pokretu, time je i lice zamućeno, no algoritam ipak uspijeva otkriti lice s fotografije.

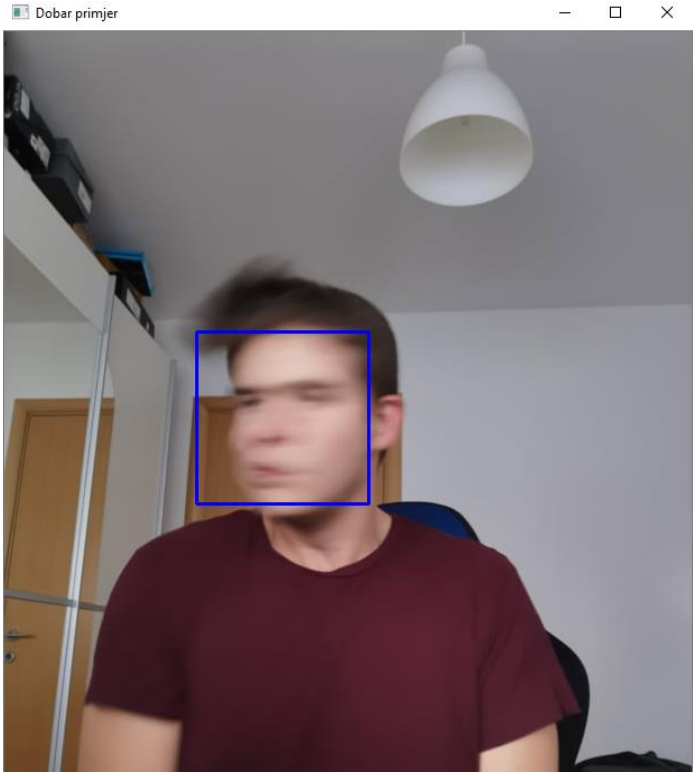

Slika 39: Dobar primjer - lice u pokretu

No, to ne mora značiti da ako je lice i otkriveno s fotografije da će daljnja obrada biti uspješna. Primjerice, ako se lice bude uspoređivalo s drugim licima, teško da će se naći savršeno poklapanje jer na primjeru karakteristike lica i dalje nisu savršeno prikazane. Zato, da bi se lice moglo i prepoznati, potrebno je da osoba bude u mirnijem položaju i da se karakteristike lica jasnije vide.

5.4.5. Udaljenost

U sljedećim primjerima se može vidjeti kako algoritam i dalje raspoznaje gdje se lice nalazi bez obzira na udaljenost od mjesta fotografiranja. Tu pomaže i kvaliteta fotoaparata ili kamere s kojom se osoba fotografira, jer tada fotografija sadrži veći broj piksela, odnosno fotografija je detaljnija i algoritam je tada uspješan u otkrivanju. Na sljedećim fotografijama se može vidjeti osoba u srednjoj i daljoj udaljenosti od mjesta fotografiranja i kako algoritam i dalje pronalazi gdje se lice nalazi na fotografiji bez obzira na udaljenost.

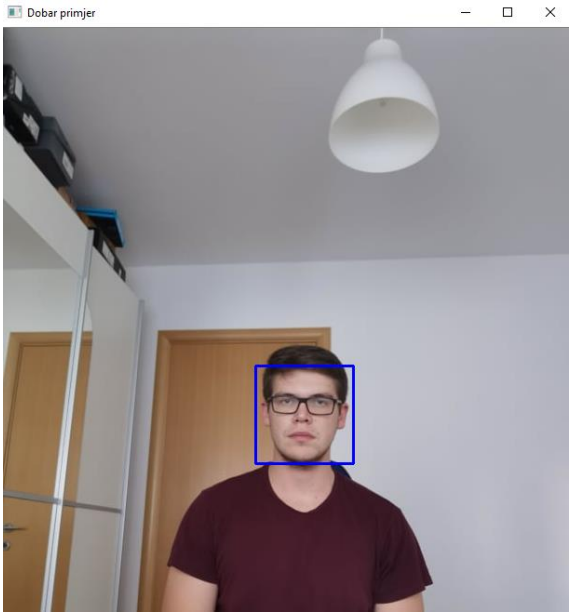

Slika 41: Dobar primjer - srednja udaljenost

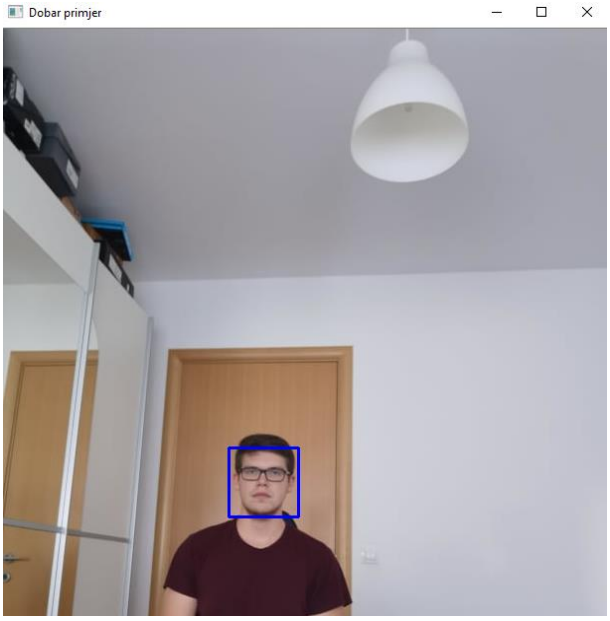

Slika 40: Dobar primjer - dalja udaljenost

6. Zaključak

Prije svake obrade videozapisa ili fotografije, sama slika mora biti prikupljena pomoću kamere ili fotoaparata te biti pretvorena s kojim se nadalje može raditi. Ujedno, taj proces se naziva prikupljanje fotografija. Prikupljanje fotografija je među početnim koracima pri obradi fotografije. Sam proces otkrivanja i prepoznavanja lica s fotografije uključuje prikupljanje fotografija, gdje fotografija mora zadovoljiti određene uvjete. Prepoznavanje lica s fotografija je jedan od ključnih faktora biometrije. U ovom radu su objašnjeni osnovni pojmovi vezani za prikupljanje fotografija, uvjeti za prikupljanje fotografija, kakvo osvjetljenje mora biti, što je to zamućenje, kakve kamere postoje za prikupljanje fotografija te detaljnije objašnjeni faktori za detekciju lica s fotografije.

Danas postoje razna programska rješenja pomoću kojih se lako raspoznaju lica s fotografije, no uvijek postoje fizički uvjeti koje lice mora zadovoljiti. Prikazani su vlastiti, dobri i loši, primjeri gdje algoritam i može, a i ne može otkriti lice s fotografije. Vrlo je važno zadovoljiti sve uvjete za otkrivanje lica, jer bez toga se ne mogu ni prikupiti lica s fotografija, a time ni prepoznati, usporediti i obrađivati.

Popis literature

Daniel Nyström (2006), *Colometric and Multispectral image acquisition*

V.K. Mishra, S. Kumar, N. Shukla (2017), *Image Acquisition and Techniques to Perform Image Acquisition*

The-Crankshaft Publishing, *Image Acquisition part 1*, preuzeto 14.8.2020 s http://what-when-how.com/introduction-to-video-and-image-processing/image-acquisition-introduction-to-video-and-image-processing-part-1/

The-Crankshaft Publishing, *Image Acquisition part 2*, preuzeto 14.8.2020 s http://what-when-how.com/introduction-to-video-and-image-processing/image-acquisition-introduction-to-video-and-image-processing-part-2/

T. E. Boult, W. Scheirer (2009.), *Long-Range Facial Image Acquisition and Quality*

S. Anwarul, S. Dahiya (2020), *A Comprehensive Review on Face Recognition Methods and Factors Affecting Facial Recognition Accuray*

Engineer Ambitiously (2019), *Image Acquisition*, preuzeto 26.8.2020 s https://www.ni.com/en-rs/innovations/white-papers/06/image-acquisition.html

OpenCV team (2020), *OpenCV,* preuzeto 5.9.2020 s https://opencv.org/about/

R. Jenkins, A. M. Burton, 2008, *100% Accuracy in Automatic Face Recognition*

Teledyne Dalsa (2020), *CCD vs CMOS,* preuzeto 6.9.2020 s https://www.teledynedalsa.com/en/learn/knowledge-center/ccd-vs-cmos/

Engineer Ambitiously (2019), *Image Acquisition System Setup,* preuzeto s https://www.ni.com/en-rs/support/documentation/supplemental/06/image-acquisition-system-setup.html

Lucid Vision Labs, *Understandig The Digital Sensor,* preuzeto 6.9.2020 s https://thinklucid.com/tech-briefs/understanding-digital-image-sensors/

SmartRay (2019), *Region of interest,* preuzeto 8.9.2020 s https://www.smartray.com/glossary/region-of-interest-roi/

Q-See (2020), *What is the difference between analog and digital*, preuzeto 8.9.2020 s https://q-see.com/blogs/q-see/what-is-the-difference-between-analog-and-digital

Popis slika

Slika 1 Različite nijanse sive (Izvor: The-Crankshaft Publishing, Image acquisition part 2).... 2
Slika 2: Obrada fotografije (Izvor: Mishra, Kumal, Shukla, 2017) 3
Slika 3: Shema prikupljanja fotografije (Izvor: Mishra, Kumal, Shukle, 2017)..... 4
Slika 4: Unutrašnjost *digitalne* kamere (Izvor: Mishra, Kumar, Shukla, 2017) 5
Slika 5: Prikaz energije, frekvencije i valne dužine jednog fotona (Izvor: The-Crankshaft Publishing, Image acquisition part 1)..... 6
Slika 6: Primjer kutova osvjetljenja (Izvor: The-Crankshaft Publishing, Image acquisition part 1) 7
Slika 7 Primjer osvjetljenog objekta (Izvor: The-Crankshaft Publishing, Image acquisition part 1) 7
Slika 8: Primjer odbijanja svjetlosti od objekta (Izvor: The-Crankshaft Publishing, Image acquisition part 1)..... 8
Slika 9 Primjer odbijanja svjetlost od objekta s preprekom (Izvor: The-Crankshaft Publishing, Image acquisition part 1)..... 9
Slika 10: Odbijanje zrake od objekta u jednu točku (Izvor: The-Crankshaft Publishing, Image acquisition part 1)..... 9
Slika 11 Izgled leće (Izvor: The-Crankshaft Publishing, Image acquisition part 1) 10
Slika 12: Izgled uvećanja: (Izvor: The-Crankshaft Publishing, Image acquisition part 1) 11
Slika 13: Zamućenje fotografije (Izvor: https://zhivagoksenia.wordpress.com/tag/dots/)..... 12
Slika 14: Dubina polja (Izvor: The-Crankshaft Publishing, Image acquisition part 1)..... 13
Slika 15: Vidno polje (Izvor: The-Crankshaft Publishing, Image acquisition part 1) 14
Slika 16: Izgled postavki kamera (izvor: The-Crankshaft Publishing, Image acquisition part 2) 15
Slika 17: Izgled senzora kamere (izvor: The-Crankshaft Publishing, Image acquisition part 2) 16
16
Slika 18: Izgled ekspozicije (Izvor: The-Crankshaft Publishing, Image acquisition part 2) ... 17
Slika 20: Primjer fotografije na ćelijama (Izvor: The-Crankshaft Publishing, Image acquisition part 2) 18
Slika 21: Različite rezolucije fotografija (Izvor: The-Crankshaft Publishing, Image acquisition part 2) 18
Slika 22: Razina sive boje na fotografiji (Izvor: The-Crankshaft Publishing, Image acquisition part 2) 19
Slika 23: Područje interesa (Izvor: The-Crankshaft Publishing, Image acquisition part 2)..... 21
Slika 24: Objekt u kretnji (Izvor: Engineer Ambigiously, Image acquisition 2019) 23

Slika 25: Različita vremena ekspozicije (Izvor: Engineer Ambigiously, Image acquisition 2019) ... 24
Slika 26: Infracrvena fotografija osobe (Izvor: http://www.palmiaobservatory.com/2018/07/gamma-ray-spectrum-and-crab-nebula.html) ... 25
Slika 27: Okluzija lica (Izvor: Anwarul, Dahiya 2020) ... 26
Slika 28: Uvećanje i niska rezolucija lica na fotografiji (Izvor: Anwarul, Dahiya 2020) ... 27
Slika 29: Šum na fotografiji lica (Izvor: https://www.howtogeek.com/368550/what-is-noise-reduction-in-digital-images/) ... 27
Slika 30: Loše osvjetljenje lica (Izvor: Anwarul, Dahiya, 2020) ... 28
Slika 31: Različiti položaji lica (Izvor: Anwarul, Dahiya 2020) ... 29
Slika 32: Osoba u pokretu (Izvor: Boult, Scheirer 2009) ... 30
Slika 33: Primjer upotrebe kliznog zatvarača (Izvor: Boult, Scheirer 2009) ... 30
Slika 34 Izgled značajki Haarove metode (izvor: OpenCV) ... 32
Slika 35: Primjer značajki (Izvor: OpenCV) ... 32
Slika 36: Dobar primjer osvjetljenja, držanja lica, ne pokrivenosti lica ... 35
Slika 37: Loš primjer osvjetljenja (svjetlo iza osobe) ... 36
Slika 38: Loš primjer osvjetljenja (svjetlo s desne strane) ... 36
Slika 39 Dobar primjer – umjetno osvjetljenje ... 37
Slika 40: Loš primjer držanja lica (pogled u stranu) ... 38
Slika 41: Loš primjer - pokrivenost lica ... 39
Slika 42: Dobar primjer - lice u pokretu ... 40
Slika 43: Dobar primjer - dalja udaljenost ... 41
Slika 44: Dobar primjer - srednja udaljenost ... 41

Programski kod

```
import cv2
klasifikacija_lica =
cv2.CascadeClassifier('haarcascade_frontalface_default.xml')
slika = cv2.imread('slika1.jpg')
siva_fotografija = cv2.cvtColor(slika,cv2.COLOR_BGR2GRAY)
lica = klasifikatori_lica.detectMultiScale(siva_fotografija, 1.15, 4)
for (x, y, sirina, visina) in lica:
      cv2.rectangle(slika, (x, y), (x+sirina, y+visina), (255, 0, 0), 2)
cv2.imshow('ime_nove_slike',slika)
cv2.waitKey()
```