

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

# Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana Tehnička dokumentacija Verzija 1.1

**Studentski tim:** Matija Folnović  
Mislav Larva  
Petra Marče  
Ivan Relić  
Dario Smolčić  
Domagoj Vukadin  
Filip Zelić

**Nastavnik:** izv. prof. dr. sc. Siniša Šegvić

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## Sadržaj

|                                                                             |    |
|-----------------------------------------------------------------------------|----|
| 1. Uvod                                                                     | 3  |
| 2. Kalibracija stereo sustava i rektifikacija slika                         | 4  |
| 2.1. Kalibracija stereo sustava                                             | 6  |
| 2.1.1. Implementacija kalibracije stereo sustava                            | 7  |
| 2.1.2. Rezultati kalibracije stereo sustava                                 | 7  |
| 2.2. Rektifikacija slika                                                    | 8  |
| 2.2.1. Implementacija rektifikacije slika                                   | 8  |
| 2.2.2. Rezultati rektifikacije slika stereo sustava                         | 9  |
| 3. Stereoskopska rekonstrukcija                                             | 10 |
| 3.1. Kriteriji korespondencije                                              | 10 |
| 3.1.1. Implementacija kriterija korespondencije                             | 11 |
| 3.2. Računanje dispariteta i udaljenosti od stereo sustava                  | 14 |
| 3.2.1. Implementacija računanja dispariteta i udaljenosti od stereo sustava | 15 |
| 4. Evaluacija i rezultati                                                   | 17 |
| 5. Zaključak                                                                | 22 |
| 6. Upute za korištenje                                                      | 23 |
| 6.1. Upute za instalaciju                                                   | 23 |
| 6.2. Kalibracija i rektifikacija                                            | 23 |
| 6.3. Stereoskopska rekonstrukcija                                           | 24 |
| Literatura                                                                  | 26 |

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

# Tehnička dokumentacija

## 1. Uvod

Ljudsko oko je najvažnije osjetilo zbog činjenice da preko njega primamo većinu informacija iz okoline. Odavno ljude zanima na koji način oko percipira prostornost koju promatra, ali to još uvijek nije poznato te se taj problem pokušava objasniti matematičkim modelima. Kako napreduje tehnologija, ljudi pokušavaju raznim tehnikama imitirati ljudski vid. Iz traganja za sve boljim algoritmima za oponašanje ljudskog vida utemeljena je znanstvena disciplina računalni vid. Računalni vid uključuje stjecanje, obradu, analizu i razumijevanje slike, odnosno bavi se izdvajanjem podataka iz slike za obradu numeričkih i simboličkih informacija. U ovom radu bavit ćemo se stereoskopskom rekonstrukcijom, što je samo jedna od mnogih poddomena računalnog vida.

Stereoskopski sustav sastoji se od barem dvije kamere koje scenu gledaju iz različitih gledišta. Zadatak stereoskopske rekonstrukcije je odrediti 3D geometriju dijelova scene koji su u vidnom polju više kamera. Da bi se taj složeni zadatak čim više olakšao, kamere se tipično učvršćuju na kruti okvir koji osigurava da međusobni prostorni odnos kamera bude stalan.

Međusobni prostorni odnos kamera stereoskopskog sustava izražavamo parametrima pomaka druge kamere u odnosu na prvu. Te i druge parametre stereoskopskog sustava tipično kalibriramo prije provođenja rekonstrukcije. Taj postupak ćemo detaljnije opisati u odjeljku 2. Kalibracija stereoskopskog sustava je postupak računanja parametara kamere kako bi kamere bile preciznije u fotografiranju slika.

Rekonstrukciju provodimo nad parom slika koje su pribavljene kalibriranim stereoskopskim sustavom. Ključan korak za ostvarivanje tog cilja jest određivanje korespondencije među tim dvjema slikama. Jednostavnim jezikom rečeno, za svaki piksel prve slike trebamo odrediti odgovarajući (ili korespondentni) piksel u desnoj slici. Postoje različite metode određivanja korespondencije, a mi ćemo obraditi lokalne metode. Lokalne metode određuju korespondenciju na temelju kriterija korespondencije u oknu. Uz lokalne metode postoje i globalne metode koje određuju korespondenciju temeljem svih piksela na slici.

Lokalne metode koriste različite kriterije korespondencije, a neke od njih su: *SSD* (eng. *sum of squared differences*), *ZSAD* (eng. *zero-mean sum of absolute differences*), i *Census*. Navedene metode i njihovo korištenje u stereoskopskoj rekonstrukciji ćemo detaljnije opisati u odjeljku 3, kao i izradu rezultatne slike stereoskopske rekonstrukcije i slike koja pokazuje dubinu u prostoru.


Na kraju, u odjeljku 4 ćemo pokazati rezultate implementiranih lokalnih metoda nad skupom slika kao i grafove ovisnosti pogreške stereoskopske rekonstrukcije o odabranom kriteriju korespondencije i veličini slikovnih okana.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## 2. Kalibracija stereo sustava i rektifikacija slika

Parametre koji karakteriziraju kameru kao matematički model možemo podijeliti na ekstrinzične i intrinzične. Matrica koja sadrži linearne intrinzične parametre naziva se matrica kamere i ona opisuje linearnu transformaciju normaliziranih koordinata projekcije u koordinate slike.

$$\mathbf{K} = \begin{bmatrix} f & 0 & c_x & 0 \\ 0 & f & c_y & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$




Slika 2.1. Ilustracija intrinzičnih parametara matrice kamere




|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Nelinearni intrinzični parametri su koeficijenti distorzije koji opisuju efekt radijalne i tangencijalne distorzije. Radijalna distorzija pojavljuje se kao posljedica toga što prijelom zrake na leći ovisi o mjestu upada zrake na leću. Tangencijalna distorzija je uzrokovana greškom u poravnanju leće i senzora kamere koji u realnoj fizičkoj izvedbi nisu međusobno savršeno paralelni.



Slika 2.2. Nejednolik lom svjetlosti koji uzrokuje radijalnu distorziju

Matrica koja sadrži ekstrinzične parametre naziva se transformacijska matrica. Transformacijska matrica sadrži parametre rotacije i translacije i služi za modeliranje gibanja točaka u odnosu na kameru koja se uvijek nalazi u ishodištu koordinatnog sustava. Točnije, promatrane točke transformiramo u položaj u kojem bi se našle da se kamera giba s koordinatnim sustavom svijeta. Ekstrinzični parametri kamere također opisuju međusoban odnos položaja dvaju kamera u prostoru što je prikazano na slici 2.2.




Slika 2.3. Prikaz ekstrinzičnih parametara kamera

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Nakon utvrđivanja intrinzičnih parametara svake pojedine kamere i ekstrinzičnih parametara međusobnog odnosa stereo kamera, možemo provesti postupak rektifikacije slike. Rektifikacija slika je transformiranje slika tako da dobijemo slike koje bi se dobile ako bi projekcijske ravnine kamere ležale u istoj ravnini paralelno jedna uz drugu na način da se horizontalne osi dviju slika preklapaju.

## 2.1. Kalibracija stereo sustava

Jedan od načina kalibriranja kamere je da se kamerom promatra neki objekt čija je geometrija poznata. Koristili smo uzorak šahovske ploče koji je pogodan jer se kutovi šahovskih polja lako detektiraju pa se time umanjuje mogućnost da neki kut ostane nepronaden. Stereo sustavom kamera<sup>1</sup> snimili smo 20 parova slika šahovskog polja na LCD ekranu<sup>2</sup>.



Slika 2.1.1. Prikaz uzorka šahovskog polja na LCD ekranu

<sup>1</sup> korištene kamere stereo sustava

<http://www.baslerweb.com/en/products/area-scan-cameras/scout>

<sup>2</sup> LCD ekran na kojem su prikazani uzorci šahovskog polja

<http://www.dell.com/hr/p/dell-u2713hm/pd>

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

### 2.1.1. Implementacija kalibracije stereo sustava

Kalibraciju stereo sustava proveli smo koristeći razred **Calibration** koji predstavlja našu vlastitu implementaciju kalibracije stereo sustava kamera pomoću parova slika šahovskog polja uz korištenje metoda *OpenCV* (*Open Computer Vision*) libraryja za različite operacije poput traženja kuteva šahovskog polja, kalibraciju kamera koristeći pronađene kuteve šahovskog polja i tako dalje. Kroz konstruktor razreda predajemo listu slika lijeve kamere, listu slika desne kamere, parametar veličine uzorka koji predstavlja broj unutarnjih kutova uzorka po širini i visini te dimenziju jednog kvadrata uzorka šahovske ploče u proizvoljnoj mjernoj jedinici, potrebno je samo paziti da će i izlazni parametri kalibracije biti u toj jedinici. Konkretno, na primjeru slike 2.2.1, ulazni parametar veličine uzorka bio bi `Size(8, 6)`, a dimenzija kvadrata uzorka je 4.68. Liste lijevih i desnih slika kamere dobili smo pomoću metoda dohvata lijevih i desnih slika razreda **Input** koji prima putanju do korijenskog direktorija lijevih i desnih slika i broj slika u direktorijima. Datoteke slika u direktorijima moraju biti nazvane slijedno od 0 do  $n - 1$ , gdje je  $n$  predan broj slika, uz pretpostavljenu ekstenziju slika .PNG.

Razred **Calibration** uz metode za dohvrat intrinzičnih i ekstrinzičnih parametara stereo sustava sadrži i sljedeće javne metode:

**double calibrate()** - Funkcija provodi kalibraciju stereo sustava. Kalibracija se provodi na sljedeći način: prvo se traže unutarnji kutovi predanih uzoraka šahovske ploče i odbacuju se oni parovi slika u kojima nisu uspješno pronađeni svi kutovi u obje slike, zatim se dobivenim kutovima provodi kalibracija svake kamere zasebno i dobivaju se intrinzični parametri za svaku kameru. Dobiveni parametri se zatim prosljeđuju metodi koja vrši stereo kalibraciju i koja ih koristi za računanje ekstrinzičnih parametara koji opisuju međusobni odnos položaja dvaju kamera.

### 2.1.2. Rezultati kalibracije stereo sustava

Rezultat kalibracije dobili smo uz prosječnu pogrešku iznosa **0.2229**. Dobivena pogreška predstavlja sumu kvadrata udaljenosti između stvarnih, onih koji se pronađu na slikama, i kuteva šahovskog polja koji se izračunaju uz dobivene parametre modela kamere.

Matrica lijeve kamere:

$$\begin{bmatrix} 856.716 & 0 & 336.613 \\ 0 & 856.246 & 239.386 \\ 0 & 0 & 1 \end{bmatrix}$$

Matrica distorzije lijeve kamere:

$$[-0.1944 \ 0.1833 \ 0.0010 \ -0.0012 \ 0.2892]$$

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Matrica desne kamere:

$$\begin{bmatrix} 856.530 & 0 & 331.556 \\ 0 & 856.179 & 222.448 \\ 0 & 0 & 1 \end{bmatrix}$$

Matrica distorzije desne kamere:

$$[-0.1297 \ -0.2731 \ -0.0012 \ 0.0028 \ 1.5545]$$

Ekstrinzični parametri rotacije između dvije kamere:

$$\begin{bmatrix} 0.9999 & 0.0022 & 0.0166 \\ -0.0024 & 0.9999 & 0.0110 \\ -0.0116 & -0.0110 & 0.9998 \end{bmatrix}$$

Ekstrinzični parametri translacije između dvije kamere:

$$[-550.46 \ -2.7998 \ 12.7265]$$

## 2.2. Rektifikacija slika

Rektifikacija slika je postupak uklanjanja distorzije i određivanja transformacije slike koja bi se dobila ako bi projekcijske ravnine kamera ležale u istoj ravnini paralelno jedna uz drugu na istim visinama. Taj postupak se pro korištenjem transformacijskih matrica koje se računaju iz ekstrinzičnih parametara dobivenih kalibracijom stereo sustava.

Nakon provođenja rektifikacije, intrinzični parametri obje kamere stereo sustava su potpuno jednaki budući da žarišna udaljenost  $f$  mora biti jednaka za obje kamere jer smo ih postavili u istu ravninu okomitu na centralnu os. Prednost ovakvog modela u odnosu na onaj nerektificirani je taj da korespondencije značajki pretražujemo samo u jednoj dimenziji i to na istoj visini (isti redak piksela) pa je računanje dispariteta bitno brže i jednostavnije. Rezultat rektifikacije najbolje se može uočiti na primjeru u nastavku teksta.

### 2.2.1. Implementacija rektifikacije slika

Rektifikaciju slika proveli smo koristeći razred **Rectification** koji predstavlja našu vlastitu implementaciju sustava za rektifikaciju parova slika koristeći metode *OpenCV* libraryja. Kroz konstruktor razreda predajemo matrice intrinzičnih i ekstrinzičnih parametara stereo sustava dobivene kalibracijom. Koristeći sljedeće javne metode navedenog razreda možemo rektificirati parove slika stereo sustava:

**void calculateRectifyMaps()** - Računa rektifikacijske transformacijske mape iz pohranjenih intrinzičnih i ekstrinzičnih parametara stereo sustava i pomoću izračunatih mapa vrši rektifikaciju parova slika.

**void rectify(Mat leftPic, Mat rightPic, Mat& leftRectifiedPic, Mat& rightRectifiedPic)** – Prima parametre *lijevaSlika* i

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

*desnaSlika* koje predstavljaju par slika stereo kamere koji je potrebno rektificirati. Izlazni parametri *lijevaRektificiranaSlika* i *desnaRektificiranaSlika* predstavljaju rektificirani par predanih slika.

### 2.2.2. Rezultati rektifikacije slika stereo sustava



Slika 2.2.2.1. Prikaz para nerektificiranih slika



Slika 2.2.2.2. Prikaz para rektificiranih slika

Slika 2.2.2.1. prikazuje par slika prije rektifikacije, a slika 2.2.2.2. nakon rektifikacije. Linije su dodane kako bi se distorzija na njima mogla lakše uočiti. Potrebno je promatrati parove korespondentnih točaka na slikama npr. krajnje gornji desni kut šahovnice. Uočavamo da jedna linija na rektificiranim slikama bolje pogađa korespondentne točke.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

### 3. Stereoskopska rekonstrukcija

Proces stereoskopske rekonstrukcije podijeljen je u nekoliko koraka koje ćemo detaljnije opisati u daljnjem tekstu. Koristili smo lokalne metode za implementaciju kriterija korespondencije. Lokalne metode određuju korespondenciju na temelju podudaranja slikovnih okana (područje oko promatranog piksela), gdje se za svaki piksel i njegovo okno odabire disparitet za koji je agregirana vrijednost kriterija korespondencije minimalna. S druge strane, globalne metode ne rade sa slikovnim oknima, nego optimiziraju funkciju odabira dispariteta kroz sve piksele minimiziranjem vrijednosti kriterija korespondencije.

#### 3.1. Kriteriji korespondencije

Za izračunavanje korespondencije implementirali smo kriterije korespondencije: *SSD* (eng. *sum of squared differences*), *ZSAD* (eng. *zero-mean sum of absolute differences*) i *Census*.

Metoda sume kvadrata razlike definirana je formulom:

$$C_{SSD}(x, d) = \sum_i [I_R(x_i + d) - I_L(x_i)]^2$$

gdje je  $d$  disparitet, a  $x$  je piksel na desnoj slici  $I_R$  te na lijevoj  $I_L$ . Optimalna vrijednost sličnosti za ovu metodu je nula. Loše podudarnosti između lijeve i desne slike rezultiraju velikim vrijednostima. Metoda *SSD* općenito se koristi zbog svoje jednostavnosti i relativno niske računalne cijene. Kriterij korespondencije može biti robusniji na prisutnosti šuma u slici, ako raste sporije od kvadratne *SSD* metode.

Uobičajen primjer takve robusne mjere je *SAD* (engl. *sum of absolute differences*). Kod metode sume razlike apsolutnih vrijednosti intenziteta funkcija linearno raste s pogreškom između prozora u slikama čime smanjuje utjecaj neusklađenih piksela. Mi smo koristili njegovu inačicu sa srednjom vrijednošću razlike intenziteta jednakom nula (*ZSAD*). Vrlo slična metoda, ali srednja vrijednost slikovnog okna se oduzima od intenziteta piksela. Zbog toga je cijena agregacije otporna na linearne razlike intenziteta između dvije slike što će nama biti korisno u izračunu kriterija korespondencije nad rektificiranim slikama. Računa se prema formuli:

$$C_{ZSAD}(x, d) = \sum_i |(I_R(x_i + d) - M_R) - (I_L(x_i) - M_L)|$$

gdje je  $d$  disparitet, a  $x$  je piksel na desnoj slici  $I_R$  te na lijevoj  $I_L$ , dok  $M_R$  i  $M_L$  predstavljaju izračun aritmetičke srednje vrijednosti okana lijeve i desne slike.

Metoda *Census* je transformacija koja slikovna okna predstavlja binarnim deskriptorima, a vrijednost kriterija korespondencije je jednaka Hammingovoj udaljenosti između binarnog deskriptora slikovnog okna lijeve slike i okna desne slike. To je lokalna metoda bez parametara



|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

koja koristi razlike intenziteta unutar područja oko piksela (okna) za određivanje binarnog deskriptora čija će veličina biti jednaka površini prozora.. Za piksel  $p$  i piksel  $q$  u okolini piksela  $p$  koristi se formula za izračun binarnog deskriptora:

$$c(p, q) = \begin{cases} 0 & I(p) \leq I(q) \\ 1 & I(p) > I(q) \end{cases}$$

Kvaliteta izračuna disparitetne mape ovisi o odabiru odgovarajućeg okna. Optimalno okno trebalo bi biti dovoljno veliko kako bi omogućilo pouzdano podudaranje. S druge strane dovoljno maleno da smanji velike oscilacije dispariteta na dubinskim diskontinuitetima. U ovom radu koristimo kvadratno okno fiksne veličine koje mijenjamo kroz evaluaciju.

### 3.1.1. Implementacija kriterija korespondencije

Svaka implementacija kriterija korespondencije nasljeđuje razred **MatchingCost**, čiji je konstruktor:

```
MatchingCost(image &left_image, image &right_image, pair<int,  
int> window, int disp_max)
```

*left\_image* i *right\_image* predstavljaju lijevu i desnu sliku, *window* veličinu prozora i *disp\_max* maksimalni disparitet za koji se računaju vrijednosti kriterija korespondencije. Ovi parametri se pohranjuju kao podatkovni članovi razreda.

Definicija podatkovne strukture **image** je `png::image<png::gray_pixel>`, što je dio biblioteke *png++*<sup>3</sup>, C++ omotač oko biblioteke *libpng*<sup>4</sup>, službene biblioteke za rad s *png* slikama.

Uz to, svaka implementacija mora implementirati metodu:

```
void calculate(matching_cost &costs) - Računa vrijednosti kriterija  
korespondencije za svaki piksel lijeve slike i svaki disparitet te popunjava matricu costs  
dimenzija visina slike × širina slike × maksimalni disparitet s rezultatima izračuna.
```

Naša implementacija sadrži tri razreda koja predstavljaju pojedine implementacije kriterija korespondencije: **Census**, **SSD** i **ZSAD**. Uz metodu **calculate** koju su naslijedili od razreda **MatchingCost** i koju moraju implementirati, svaki razred ima i konstruktor identičan konstruktoru razreda **MatchingCost**.

<sup>3</sup> <http://www.nongnu.org/pngpp/>

<sup>4</sup> <http://www.libpng.org/pub/png/libpng.html>

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Naša prva implementacija funkcije `calculate` se svodila na sljedeći pseudokod (1):

```


za svaki piksel p(x, y) lijeve slike
  za svaki disparitet d
    cijena[y][x][d] = 0
    za svaki piksel q u prozoru oko p
      cijena[y][x][d] += f(q, d)

```

gdje funkcija `f` računa vrijednost kriterija korespondencije za piksel `q` i disparitet `d`, što je za:

1. Census: izračun Hammingove udaljenosti za pojedini bit binarnog deskriptora lijevog i desnog slikovnog okna (koji se odnosi na piksel `q`)
2. SSD:  $[I_R(x+d, y) - I_L(x, y)]^2$
3. ZSAD:  $|I_R(x+d, y) - M_R - (I_L(x, y) - M_L)|$

Također vrijedi:  $0 \leq d \leq \text{maksimalni disparitet}$ . 3D Polje `cijena` predstavlja vrijednost kriterija korespondencije za svaki piksel i disparitet. Polje nam je potrebno za stereoskopsku rekonstrukciju, gdje ćemo za svaki piksel odabrati disparitet za koji je podatkovna cijena minimalna (više o tome u poglavlju 3.2.).



Slika 3.1.1.1.: Prikaz situacije lijeve i desne slike kada je  $\mathbf{p} = (6,5)$  i  $\mathbf{d}=1$

Na slici 3.1.1.1. možemo vidjeti prikaz jedne od situacije pseudokoda 1. Gornja lijevo točka slika je (0, 0), a prikazana je situacija kada je  $\mathbf{p} = (6,5)$  i  $\mathbf{d}=1$ . Točke `q` će biti sve točke na lijevoj slici koje su označene s debljom linijom. Kod kriterija korespondencije *SSD* i *ZSAD*, uspoređivat će se pikseli: (4,3) lijeve i (3,3) desne, (5,3) lijeve i (4,3) desne, ..., (7, 7) lijeve i (6, 7) desne, (8, 7) lijeve i (7, 7) desne. Kod kriterija korespondencije *Census*, prvo će se računati Census transformacije svih piksela lijeve slike između (4, 3) i (8, 7), te desne slike između (3,3) i (7, 7), čime dobivamo dva binarna deskriptora veličine 25 bitova i nakon izračuna njihove Hammingove udaljenost dobivamo vrijednost koeficijenta usporedbe.

Primijetimo što se događa kada je disparitet za koji ispitujemo veći od `x` koordinate središnjeg piksela okna lijeve slike. U toj situaciji okno desne slike je izvan slike, što znači da ne



|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

možemo odrediti korespondenciju. Tada disparitet postavljamo na maksimalan, povećavajući pogrešku rekonstrukcije.

Ovakva implementacija se pokazala lošom, jer je njezina složenost:  $O(\text{visina slike} \times \text{širina slike} \times \text{maksimalni disparitet} \times \text{veličina prozora}^2)$ , što je za naš primjer puno (u najgorem slučaju  $1282 \times 1110 \times 255 \times 63 \times 63 \approx 1.44 \times 10^{12}$ ). Dodatno, metoda *ZSAD* uključuje računanje srednje vrijednosti prozora, te metoda *Census* računanje Census transformacije svakog piksela, čime složenost dodatno raste.

Prvi korak koji smo poduzeli je paralelizacija petlji koristeći **OpenMP**<sup>5</sup>, uz pomoć čega smo postigli veliko ubrzanje. Ipak, ako pogledamo gornji pseudokod, možemo primijetiti da radimo puno uzaludnog računanja po prozorima, tj. da za neki piksel  $\mathbf{q}$  računamo rezultat funkcije  $f(\mathbf{q}, \mathbf{d})$  maksimalno  $\text{veličina prozora}^2$  puta, umjesto samo jednom. To nas dovodi do sljedeće optimizacije i pseudokoda (2):

```

za svaki piksel  $\mathbf{p}(\mathbf{x}, \mathbf{y})$  lijeve slike
  za svaki disparitet  $\mathbf{d}$ 
     $\mathbf{acc}[\mathbf{y}][\mathbf{x}][\mathbf{d}] = f(\mathbf{p}, \mathbf{d}) + \mathbf{acc}[\mathbf{y}-1][\mathbf{x}][\mathbf{d}] +$ 
       $\mathbf{acc}[\mathbf{y}][\mathbf{x}-1][\mathbf{d}] - \mathbf{acc}[\mathbf{y}-1][\mathbf{x}-1][\mathbf{d}]$ 

```

Gornja petlja popunjava matricu  $\mathbf{acc}[\mathbf{y}][\mathbf{x}][\mathbf{d}]$  čije će vrijednosti za svaki  $\mathbf{p}(\mathbf{x}, \mathbf{y})$  biti suma svih  $f(\mathbf{q}, \mathbf{d})$ ,  $\mathbf{q}(\mathbf{x}', \mathbf{y}')$  za koje vrijede:

$$\begin{aligned} 0 &\leq x' \leq x \\ 0 &\leq y' \leq y \end{aligned}$$

Nakon što popunimo matricu  $\mathbf{acc}$ , sljedećom formulom u konstantnoj složenosti možemo izračunati vrijednost kriterija korespondencije za točku  $\mathbf{p}$  i prozor veličine  $\mathbf{w}$ :

$$\begin{aligned} \mathbf{cijena}[\mathbf{y}][\mathbf{x}][\mathbf{d}] &= \mathbf{acc}[\mathbf{y} + \mathbf{w}/2][\mathbf{x} + \mathbf{w}/2] - \\ &\quad \mathbf{acc}[\mathbf{y} + \mathbf{w}/2][\mathbf{x} - \mathbf{w}/2 - 1] - \\ &\quad \mathbf{acc}[\mathbf{y} - \mathbf{w}/2 - 1][\mathbf{x} + \mathbf{w}/2] + \\ &\quad \mathbf{acc}[\mathbf{y} - \mathbf{w}/2 - 1][\mathbf{x} - \mathbf{w}/2 - 1] \end{aligned}$$

Ova formula zapravo predstavlja sumu svih  $f(\mathbf{q}, \mathbf{d})$ ,  $\mathbf{q}(\mathbf{x}', \mathbf{y}')$ , gdje vrijede relacije u nastavku (koje predstavljaju relacije koje moraju vrijediti da bi točka  $\mathbf{q}$  bila unutar prozora veličine  $\mathbf{w}$ ):

$$\begin{aligned} x - \mathbf{w} \div 2 &\leq x' \leq x + \mathbf{w} \div 2 \\ y - \mathbf{w} \div 2 &\leq y' \leq y + \mathbf{w} \div 2 \end{aligned}$$

Ovakvu optimizaciju smo primijenili na implementacijama kriterija korespondencije *SSD* i *ZSAD*, čime smo smanjili početnu složenost na:

$$O(\text{visina slike} \times \text{širina slike} \times \text{maksimalni disparitet}).$$

<sup>5</sup> <http://en.wikipedia.org/wiki/OpenMP>

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Kod kriterija korespondencije *Census*, primijenjena je jednostavnija optimizacija. Prvo se izračunaju *Census* transformacije svakog piksela lijeve i desne slike, čija je složenost:  $O(visina\ slike \times širina\ slike \times veličina\ prozora^2)$ .

Rezultat *Census* transformacije se sprema u *bitset* fiksne veličine 4096 bitova, gdje će biti iskorišteno prvih  $veličina\ prozora^2$  bitova). Nakon toga, za svaki piksel računamo Hammingovu binarnih deskriptora lijevog i desnog slikovnog okna operacijom *xor* (zbrajanje u aritmetici modula 2) i prebrojavanjem broja postavljenih bitova u *bitsetu*, čime dobivamo broj bitova deskriptora lijevog i desnog slikovnog okna koji se razlikuju.

Tehnička implementacija *bitseta* se svodi na korištenje tipa podatka veličine 64 bita (*long long*), čime se operacije nad bitovima ubrzavaju za 64 puta, u odnosu na jednostavnije rješenje gdje smo mogli imati niz od 4096 bitova (tip podatka *byte*). Zbog odabira *bitseta* postićemo značajno ubrzanje u računanju Hammingove udaljenosti, čime složenost drugog dijela algoritma možemo svesti na:  $O(visina\ slike \times širina\ slike \times maksimalni\ disparitet)$ .

### 3.2. Računanje dispariteta i udaljenosti od stereo sustava


Disparitet ili horizontalni pomak računamo na temelju vrijednosti kriterija korespondencije. Lokalne metode koriste lokalnu WTA (engl. “winner-take-all”) optimizaciju za svaki piksel, tj. za vrijednost dispariteta uzimamo onaj disparitet za koji je vrijednost kriterija korespondencije najmanja. Izračunavanjem dispariteta za sve elemente slike dobiva se mapa dispariteta. Ona nam koristi za rekonstrukciju scene i za računanje dubine odnosno udaljenosti kamera od same scene. Rekonstrukciju scene ćemo dobiti prikazivanjem intenziteta piksela u svojoj skali iz mape dispariteta kao izlaznu sliku.

Računanje udaljenosti je vrlo jednostavan postupak ako nam je poznata mapa dispariteta, žarišna daljina koja je jednaka za obje kamere i udaljenost između kamera odnosno bazna duljina (engl. *baseline*).

Usporedbom sličnih trokuta (slika 3.2.1) može se izvesti formula i izračunati udaljenost do točke objekta u prostoru. Postupak se naziva reprojekcija, a njegov izlaz je dubinska mapa.

$$\frac{Z+f}{Z} = \frac{X_L+X_R+B}{X_L+X_R} \Rightarrow Z = \frac{f*B}{d}, d = X_L + X_R$$

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |



Slika 3.2.1: Prikaz rektificirane triangulacije

Važno je primijetiti da je udaljenost obrnuto proporcionalna disparitetu. Dobru dubinsku udaljenost stereo sustavi postižu samo za objekte koji se nalaze relativno blizu kamerama.

### 3.2.1. Implementacija računanja dispariteta i udaljenosti od stereo sustava

Računanje dispariteta i mjerenje udaljenosti nalazi se u razredu **DenseStereoReconstructor** čiji je konstruktor:

```
DenseStereoReconstructor(image &left_image, image &right_image,
MatchingCostType type, int frame_width, int frame_height, int
disp_max, int dmin)
```

*left\_image* i *right\_image* predstavljaju lijevu i desnu sliku, *type* ime kriterija korespondencije (gdje je **MatchingCostType** enumeracija koja sadrži vrijednosti **Census**, **SSD**, **ZSAD**), *frame\_width* i *frame\_height* je veličina okna za podudaranje, *disp\_max* je maksimalni disparitet i *dmin* je vrijednost koju je potrebno dodati svakom disparitetu kako bi mogli izračunati udaljenost jer su slike odrezane (datoteka *dmin.txt* u skupu *Middlebury*[5]).

Nakon poziva konstruktora prvo se računaju vrijednosti kriterija korespondencije polimofnim pozivom metode **calculate** konkretnim razredom koji nasljeđuje **MatchingCostFunction**, a zatim se pozivaju sljedeće metode:

**void calculateDisparities()** - Metoda računa mapu dispariteta uz pomoć vrijednosti kriterija korespondencije i pohranjuje mapu u *disparity\_map*[y][x].

**void calculateDistance()** - Podaci o žarišnoj daljini i baznoj duljini su podatkovni članovi header datoteke ovog razreda. Metoda pomoću mape dispariteta i ranije izveden formule za računanje udaljenosti uz razliku da se disparitetu dodaje predana vrijednost ("dmin") pohranjuje dubinsku mapu u *distance\_map*[y][x].

**void createOutputImage()** - Metoda iz dobivene mape dispariteta sprema izlaznu sliku stereo rekonstrukcije u sivoj skali piksela. Slika je pohranjena u izlaznoj datoteci **output.png**.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Pseudokod metode **calculateDisparities** je sljedeći:

```

za svaki piksel p(x, y) lijeve slike
    najmanja_cijena =  $\infty$ 
    za svaki disparitet d
        ako je najmanja_cijena > cijena[y][x][d]
            najmanja_cijena = cijena[y][x][d]
            mapa_dispariteta[y][x] = d

```

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## 4. Evaluacija i rezultati


Svaki od kriterija korespondencije smo evaluirali na skupu Middleburry Stereo Dataset iz 2006 [5], na slikama veličine od 1240x1110 do 1396x1110 piksela. Prvi dio evaluacije je izvršavanje naše implementacije guste stereoskopske rekonstrukcije nad cijelim skupom. Jedan od primjera je dan u nastavku. Odabrana je slika *Aloe* (slika 4.1) i prozor 15x15.




(a)



(b)




(c)



(d)

Slika 4.1.: Prikaz slika iz skupa Middlebury - *Aloe*: (a) Originalna slika (lijeva slika), (b) Originalna slika (desna slika), (c) Slika točnih dispariteta (lijeva slika), (d) Slika točnih dispariteta (desna slika)

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |



Slika 4.2.: Prikaz stereoskopske rekonstrukcije nad slikom *Aloe* (samo lijeva slika): (a) *Census*, (b) *SSD*, (c) *ZSAD*


Na slikama 4.2. (a), (b) i (c) možemo vidjeti rezultat izvršavanja naše implementacije stereoskopske rekonstrukcije uz korištenje kriterija korespondencije *Census*, *SSD* i *ZSAD*. Dodatno, na legendi možemo povezati prikazani intenzitet s udaljenostima scene od stereo sustava - ono što je bliže je svjetlije, ono što je dalje je tamnije.

Drugi dio evaluacije je prikaz ovisnosti parametara i pogreške. Pogreška rekonstrukcije se računa u tri koraka:

- 1) izdvoje se zajednički pikseli slike točnih dispariteta lijeve i desne slike (*zajednički pikseli*)
- 2) računa se broj svih *loših* piksela - oni čija je razlika izračunatog dispariteta i točnog dispariteta unutar granice tolerancije (kod nas je granica tolerancije 1)
- 3) na kraju, izračuna se omjer broja *loših* piksela i broja *zajedničkih* piksela i dobiva se pogreška


|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Evaluiramo ovisnost veličine prozora i pogreške, uzimajući sve neparne kvadratne prozore od 1x1 do 63x63.




Slika 4.3.: Prikaz grafa ovisnosti pogreške o veličini prozora za svaki kriterij korespondencije.


Na slici 4.3. možemo vidjeti da kriterij korespondencije *ZSAD* postiže znatno bolje rezultate od *SSD*-a i *Census*-a. Također, *SSD* kod manjih prozora postigne bolje rezultate od *Census*-a, ali *Census* postigne bolje rezultate kod većih prozora. Da smo evaluirali pogrešku na još većim prozorima, moguće je da bi se dogodilo da *Census* postigne manju pogrešku od *ZSAD*-a i *SSD*-a, ako procjenjujemo po gornjem grafu.



(a)



(b)



(c)


Slika 4.4.: Prikaz ovisnosti pogreške i veličine prozora za svaku sliku u skupu za kriterije korespondencije: (a) *Census*, (b) *SSD*, (c) *ZSAD*

Na slikama 4.4. (a), (b) i (c) možemo vidjeti raznolikost pogrešaka koje postiže korištenje kriterija korespondencije. Tako možemo vidjeti da slike *Midd1*, *Midd2* i *Plastic* postižu najgore rezultate, dok za sliku *Cloth1* postižu najbolje rezultate.


U nastavku su izvorne slike, slike točnih dispariteta i rezultatne slike *Midd1*, *Plastic* i *Cloth1*, kako bi nam pomogle u objašnjavanju ovakvih rezultata. Stavljene su samo rezultatne slike dobivene korištenjem kriterija korespondencije *ZSAD*, ali je objašnjenje analogno i za ostale kriterije.



|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |



Slika 4.5.: Slike kod kojih dobivamo najveće pogreške. (a) Originalna slika (*Midd1*), (b) Slika točnih dispariteta (*Midd1*), (c) Rezultantna slika (*ZSAD*, *Midd1*), (d) Originalna slika (*Plastic*), (e) Slika točnih dispariteta (*Plastic*), (f) Rezultantna slika (*ZSAD*, *Plastic*)



Slika 4.6.: Slika kod koje dobijemo najmanju pogrešku. (a) Originalna slika (*Cloth1*), (b) Slika točnih dispariteta (*Cloth1*), (c) Rezultantna slika (*ZSAD*, *Cloth1*)

Na slici 4.5. možemo primijetiti da je loš rezultat dobiven zbog jednolikog uzorka objekata na slici. U slučaju *Midd1* to je zid, a u slučaju *Plastic* to su svi objekti na slici. Na slici 4.6. možemo primijetiti da je dobar rezultat dobiven zbog raznolikog uzorka stolnjaka na slici. Primijetimo i da je veći dio pogrešaka napravljen na lijevom rubu slike, zbog načina na koji radimo s prozorima.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## 5. Zaključak

Postupci guste stereoskopske rekonstrukcije scene lokalnim podudaranjem slikovnih okana koje smo koristili daju nam rezultate koji pokazuju što se može očekivati od korištenja lokalnih metoda za izračun korespondencije. Temeljem dobivenih rezultata zaključujemo da kriterij korespondencije *ZSAD* postiže puno bolje rezultate od *SSD*-a i *Censusa*. *SSD* kod manjih okana postiže bolje rezultate od *Censusa*, dok *Census* ima bolje rezultate u radu s većim oknom. Na temelju prikaza scene pomoću parova stereo slika, osim stereoskopske rekonstrukcije može se dobiti i informacija o dubini, odnosno informacija o prostornosti scene.

Osim kalibracijskog uzorka na LCD ekranu, isti smo snimili i na plakatu. Uzorak snimljen na plakatu nismo uzeli u obzir u okviru ovog projekta jer detekcija kutova na njemu nije bila zadovoljavajuća - najvjerojatnije zbog neodgovarajuće površine samog plakata. Unatoč korištenju uzorka samo s LCD ekrana, kalibraciju smo proveli sa zadovoljavajućom pogreškom.

Nadalje, prilikom rekonstrukcije smo očekivali da će, od tri lokalne metode koje smo koristili, *Census* dati najbolje rezultate, pa nas je iznenadilo što su metode *ZSAD* i *SSD* u nekim slučajevima dale bolji rezultat. Uočili smo da pogreška ovisi i o veličini prozora pa smo varirajući njen iznos pokazali da preciznost postupka ne ovisi samo o korištenoj metodi. Osim toga, iznenadilo nas je veliko vrijeme potrebno za izračun vrijednosti kriterija korespondencije za svaki piksel lijeve slike i svaki disparitet. Osim što smo paralelizirali petlje, korištenjem integralnog akumulatorskog polja značajno smo smanjili složenost implementacije te drastično ubrzali izvođenje. Time smo također postigli da vrijeme izvođenja kod *SSD*-a te *ZSAD*-a ne ovisi o veličini prozora, dok je kod *Censusa* ono proporcionalno kvadratu veličine prozora.

Za oba postupka potrebna nam je što veća preciznost pronalaženja korespondentnih značajki i izračuna dispariteta pa se budući rad može temeljiti na korištenju globalnih metoda podudaranja za razliku od lokalnih korištenih u ovom radu. U globalnim metodama podudaranja, podudaranje piksela lijeve slike i desne slike ne ovisi samo o njihovim susjedima nego i o podudaranju njihovih susjeda. Ovakve metode podudaranja daju poboljšanja, ali također kao posljedicu imaju duže vrijeme izvođenja i veću algoritamsku složenost.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## 6. Upute za korištenje

### 6.1. Upute za instalaciju

Potrebno je imati instalirano:

- GCC 4.9.2 ili MSVC 2013
- OpenCV 2.4.10
- png++ 0.2.5<sup>6</sup>
- Python 2.7.9
- Matplotlib

Nakon instalacije biblioteke png++, moguće je da će biti potrebno prilagoditi datoteku koja se na operacijskom sustavu Linux može nalaziti na putanji `/usr/include/png++/error.hpp`. Potrebno je dodati uključivanje *cstringa* uz ostale *includeove*.

Na početku je potrebno kreirati izvršne datoteke pomoću alata *make*<sup>7</sup> i priložene *Makefile* datoteke izvršavanjem sljedeće naredbe: `make all`

Nakon toga, u direktoriju *bin* će biti kreirano 4 izvršnih datoteka, koje će biti opisane u nastavku.

### 6.2. Kalibracija i rektifikacija

U glavnom direktoriju projekta nalazi se arhiva *camera\_capture.zip* koja sadrži parove slika snimljenih u laboratoriju. Raspakiranjem arhive pojavljuje se direktorij: *camera\_data*, unutar njega *basler\_calib\_lcd*, *basler\_indoor* i *basler\_outdoor*, a unutar *basler\_calib\_lcd* nalaze se direktoriji *left* i *right*.

Program za kalibraciju i rektifikaciju možemo pozvati pomoću:

```
build/kalibracija [putanja do slika lijeve kamere] [putanja
do slika desne kamere] [putanja do rektificiranih slika lijeve
kamere] [putanja do rektificiranih slika desne kamere] [broj
slika] [dimenzije šahovske ploce] [dimenzija kvadrata sahovnice]
```

Pomoću sljedećih naredba možemo pokrenuti kalibraciju i rektifikaciju nad skupom slika za kalibraciju:

```
build/kalibracija camera_data/basler_calib_lcd/left
camera_data/basler_calib_lcd/right rectified/left
rectified/right 17 8 6 0.040725
```

<sup>6</sup> <http://www.nongnu.org/pngpp/>

<sup>7</sup> <http://www.gnu.org/software/make/>

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Na standardni izlaz ćemo dobiti parametre kamera, nakon čega će se prikazati rektificirane slike.

### 6.3. Stereoskopska rekonstrukcija

U glavnom direktoriju projekta nalazi se direktorij *middlebury\_slike*, u kojem se nalaze već preuzete slike iz skupa *Middlebury*.


Program za stereoskopsku rekonstrukciju možemo pozvati pomoću:

```
build/rekonstrukcija [putanja do lijeve slike] [putanja do
desne slike] [putanja do izlazne slike] [kriterij
korespondencije] [veličina prozora]
```

Podržani kriteriji korespondencije su: *Census*, *SSD* i *ZSAD*. Možemo pokrenuti stereoskopsku rekonstrukciju nad slikom *Aloe* iz skupa *Middlebury*, koristeći kriterij korespondencije *Census* i prozor veličine 15x15 na sljedeći način:

```
build/rekonstrukcija middlebury_slike/2006/Aloe/view1.png
middlebury_slike/2006/Aloe/view5.png output.png Census 15 15
```

Kao rezultat, dobit ćemo sliku *output.png*, koja je prikazana u nastavku:



Slika 6.1.: Izlaz stereoskopske rekonstrukcije za sliku *Aloe*, kriterij korespondencije *Census* i prozor veličine 15x15

Uz to, dostupan je i program koji omogućava generiranje izlaznih datoteka nad većim skupom slika:

```
build/generiraj_izlaze [kriterij korespondencije] [veličina
prozora] [putanja do podatkovnog skupa] [putanja do izlaznog
direktorija]
```

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

Sve izlaze za kriterij korespondencije *Census* i veličinu prozora 15x15 generiramo s:  
`build/generiraj_izlaze Census 15 15 middlebury_slike/2006`  
`outputs`

Nakon kraja izvršavanje, u direktoriju `outputs` dobivamo po 4 datoteke za svaki par slika u podatkovnom skupu: *.input.png* (slika s lijeve kamere), *.output.png* (rezultat stereoskopske rekonstrukcije), *.truth.png* (*ground truth* slike s lijeve kamere) i *.legend.txt* (datoteka koja sadrži detalje o legendi).

Dodatno, možemo izvršiti Python skriptu koja uz pomoć svih *.output.png* i *.legend.txt* generira slike *.image.png*, koje prikazuju izlazne slike s legendom intenzitete piksela i udaljenosti u metrima. Primjer slike možete vidjeti u poglavlju 4, slika 4.2.:

Na kraju, dostupan je i program kojim možemo evaluirati preciznost pojedinih kriterija korespondencije. Njega pozivamo pomoću:

```
build/evaluira [putanja do podatkovnog skupa] [putanja do
izlaznog direktorija] [najmanji prozor] [najveći prozor]
```

Za dobivanje podataka potrebnih za generiranje grafova prikazanih na slikama 4.3. i 4.4., koristili smo naredbu:

```
build/evaluira middlebury_slike/2006 outputs 1 63
```

Time u direktoriju `outputs` dobivamo 4 datoteke: *all.graph.input*, *Census.graph.input*, *SSD.graph.input* i *ZSAD.graph.input*. Datoteka *all.graph.input* sadrži prosječnu pogrešku nad cijelim podatkovnim skupom za svaki kriterij korespondencije i veličinu prozora. Ostale datoteke sadrže pogrešku za svaki par slika i veličinu prozora, korištenjem pojedinog kriterija korespondencije.

Nakon izvršavanja evaluacije možemo stvoriti grafove prikazane na slikama 4.3. i 4.4. pokretanjem Python skripti:

```
python2.7 stereorekonstrukcija/GenerateGraph.py
outputs/all.graph.input outputs/all.graph.png "Kriterij
korespondencije"
python2.7 stereorekonstrukcija/GenerateGraph.py
outputs/Census.graph.input outputs/Census.graph.png Census
python2.7 stereorekonstrukcija/GenerateGraph.py
outputs/SSD.graph.input outputs/SSD.graph.png SSD
python2.7 stereorekonstrukcija/GenerateGraph.py
outputs/ZSAD.graph.input outputs/ZSAD.graph.png ZSAD
```

Time smo dobili sliku *outputs/all.graph.output* koja bi trebala biti slična onoj na slici 4.3., te slike *outputs/Census.graph.png*, *outputs/SSD.graph.png* i *outputs/ZSAD.graph.png* koje bi trebale biti slične onima na slici 4.4.

|                                                                          |                    |
|--------------------------------------------------------------------------|--------------------|
| Gusta stereoskopska rekonstrukcija lokalnim podudaranjem slikovnih okana | Verzija: 1.1       |
| Tehnička dokumentacija                                                   | Datum: 13.01.2015. |

## Literatura

1. Ivan Krešo. Napredno estimiranje strukture i gibanja kalibriranim parom kamera, 2013.  
URL: <http://www.zemris.fer.hr/~ssegvic/project/pubs/kreso13ms.pdf>
2. Heiko Hirschmuller, Daniel Scharstein. Evaluation of Stereo Matching Costs on Images with Radiometric Differences, 2008.  
URL: <http://vision.middlebury.edu/~schar/papers/evalcosts-pami08.pdf>
3. Daniel Scharstein, Richard Szeliski. A Taxonomy and Evaluation of Dense Two-Frame Stereo Correspondence Algorithms.  
URL: <http://vision.middlebury.edu/stereo/taxonomy-IJCV.pdf>
4. C. Stentoumis, L. Grammatikopoulos, I. Kalisperakis, E. Petsa, G. Karras. A Local Adaptive Approach for Dense Stereo Matching in Architectural Scene Reconstruction, 2013.  
URL: [http://portal.survey.ntua.gr/main/labs/photo/staff/gkarras/Karras\\_3DArch\\_2013.pdf](http://portal.survey.ntua.gr/main/labs/photo/staff/gkarras/Karras_3DArch_2013.pdf)
5. URL: <http://vision.middlebury.edu/stereo/>