Procjena kretanja kamere na temelju korespondencija kroz veći broj slika

Ivan Krešo

Mentor: Prof. dr. sc. Siniša Šegvić

31. siječnja 2014.

Sažetak

Stereo vid

- Procjena gibanja kamere iz videa (eng. *visual odometry*)
- Procjena dubinske slike - rekonstrukcija strukture scene (eng. *dense stereo*)
- Primjene u okviru projekta VISTA:
  - Položaj kamere u odnosu na ravninu ceste
  - Položaj vozila u odnosu na prometni trak (rub ceste)
  - Geometrijske indicije za položaj razdjelne linije, prometnih znakova, prepreka na cesti

Epipolarno ograničenje

- Epipolarno ograničenje - značajku x_L iz lijeve slike pretražujemo u desnoj slici na pravcu gdje ravnina određena točkama x_L, e_L, e_R siječe projekcijsku ravninu desne kamere.

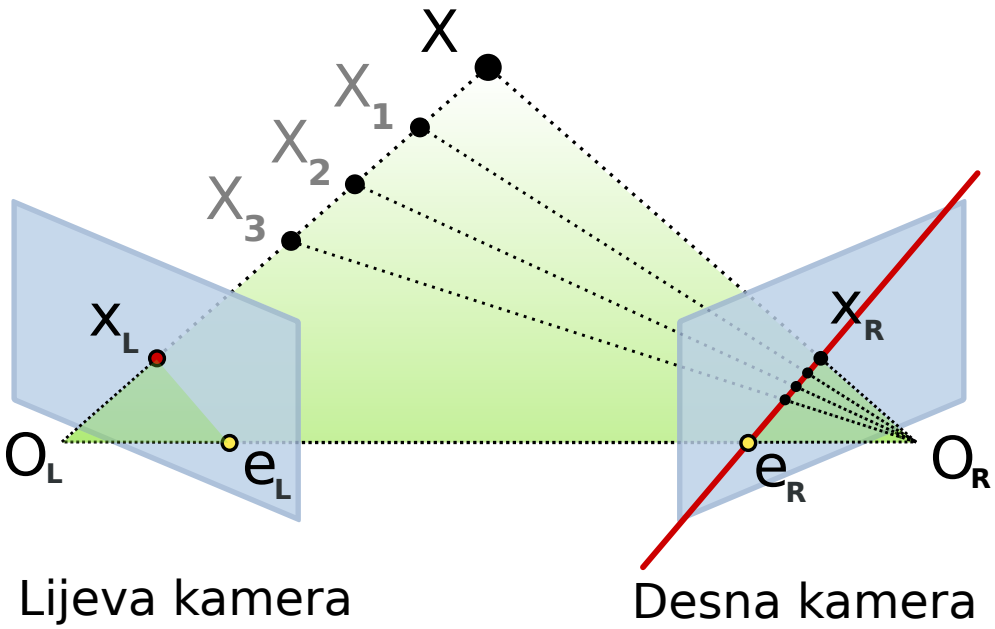

- $X \rightarrow$ promatrana točka
- $\mathrm{O_L}$ i $\mathrm{O_R} \rightarrow$ točke centara projekcije
- $\mathrm{x_L}$ i $\mathrm{x_R} \rightarrow$ projekcije točke X
- $\mathrm{e_L}$ i $\mathrm{e_R} \rightarrow$ epipolovi

Rektificiranje stereoskopskih slika

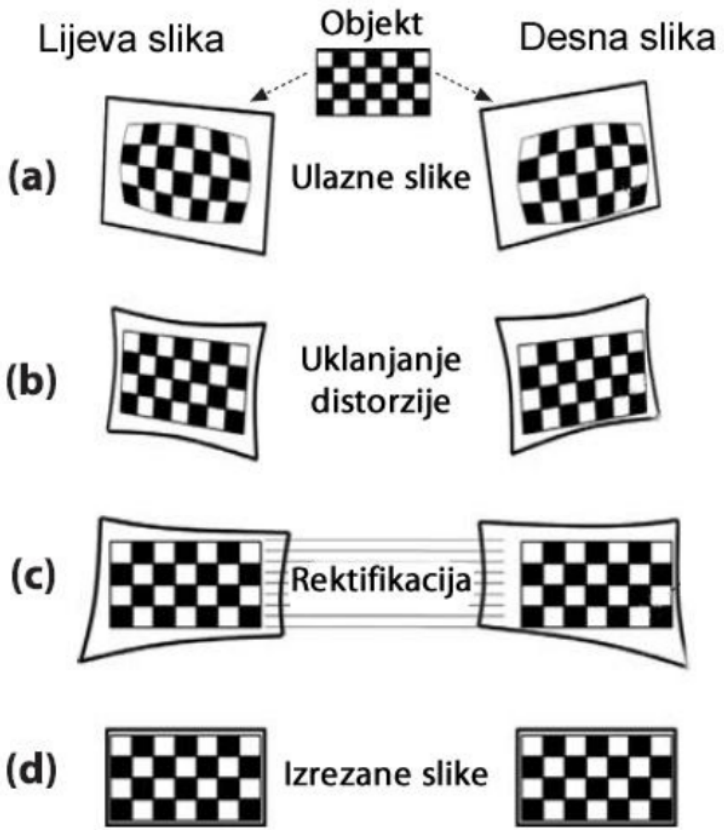

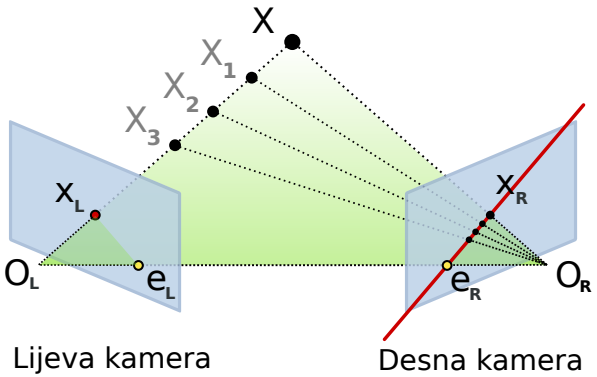

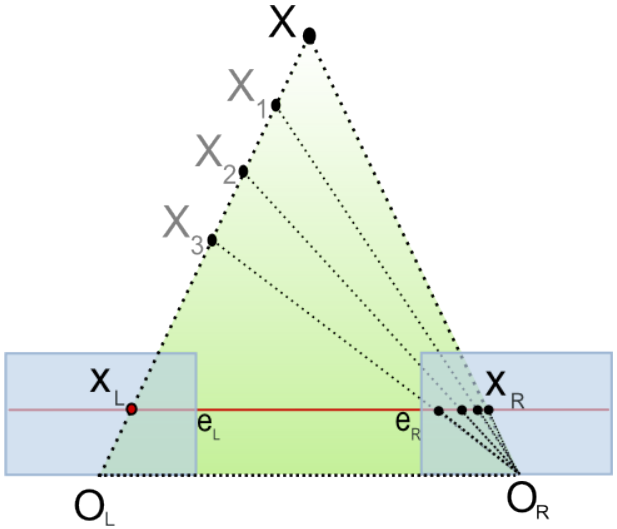

Rektificirana triangulacija

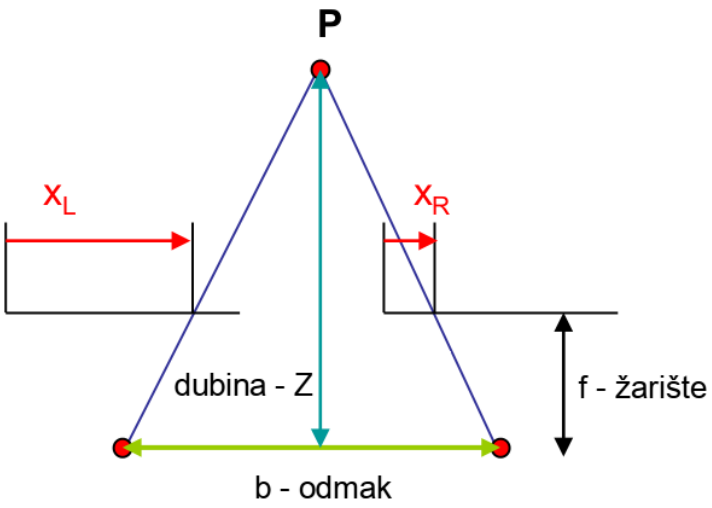

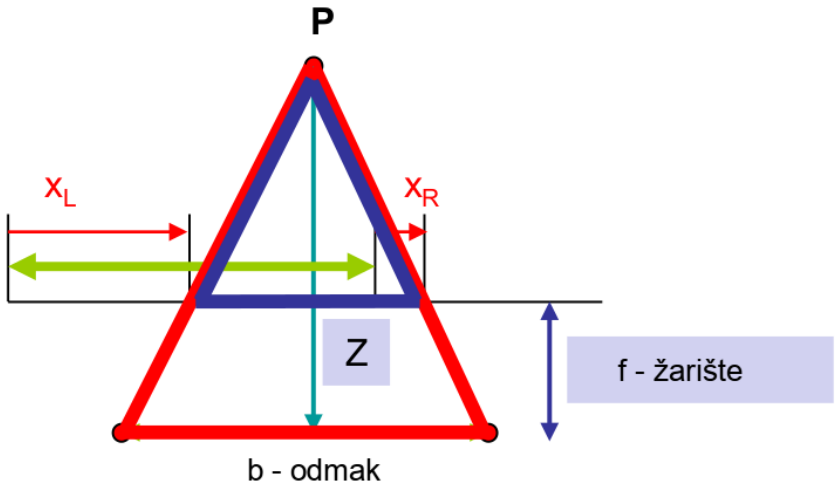

$$\frac{b}{Z} = \frac{b + x_R - x_L}{Z - f}$$

$$Z = \frac{f \cdot b}{x_L - x_R} = \frac{f \cdot b}{d}$$

Rektificirana triangulacija

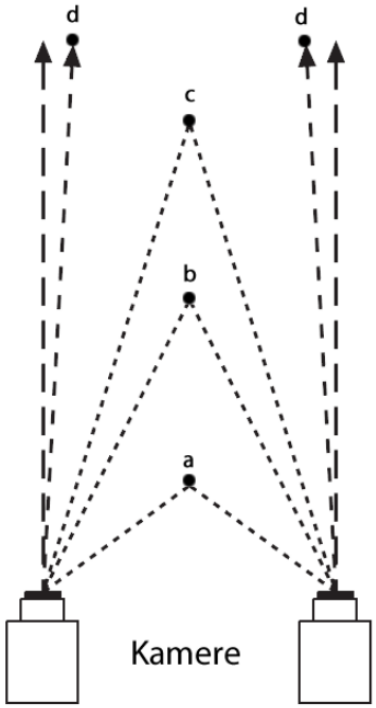

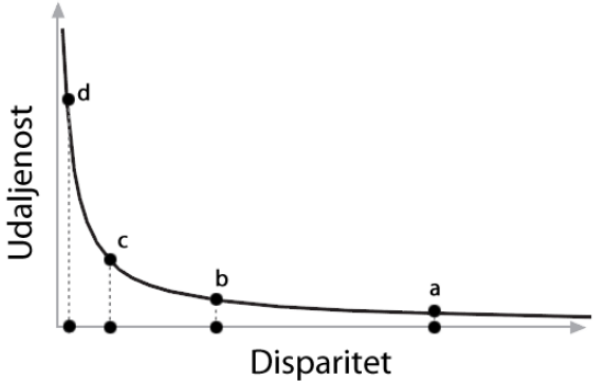

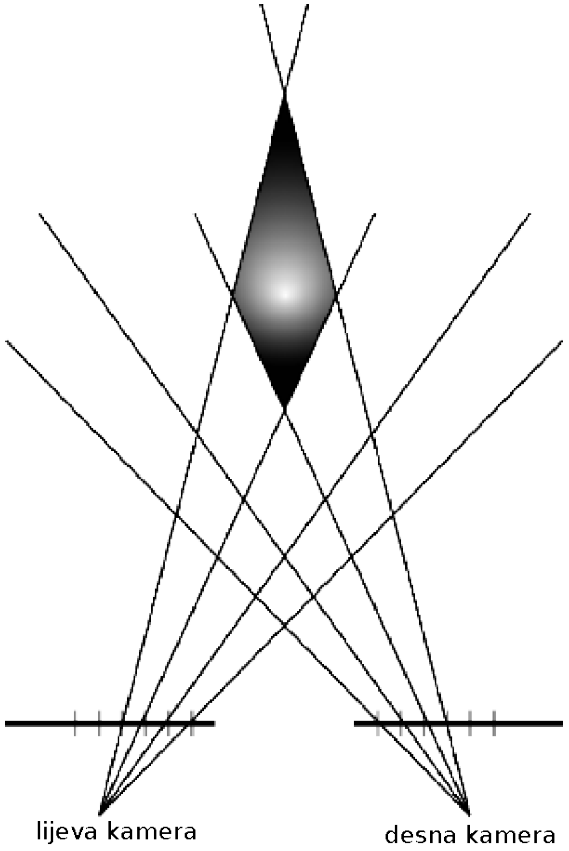

Kalibriranje stereoskopskog sustava

Kalibracijom stereo sustava dobivaju se:

- linearni intrinsični parametri:

$$\mathbf{K} = \begin{pmatrix} f & 0 & u_0 \\ 0 & f & v_0 \\ 0 & 0 & 1 \end{pmatrix}$$

  - kamera matrice **K** opisuje pretvaranje normaliziranih koordinata projekcije u koordinate slike
- nelinearni intrinsični parametri: distorzija leće
- položaj desne kamere u odnosu na lijevu: **R**, **t**
- rektifikacijske matrice: $\mathbf{H}_l$, $\mathbf{H}_r$
- udaljenost između kamera (*baseline*) u rektificiranom sustavu: b

Model kamere

Geometrijski prikaz modela kamere uz $\mathbf{K} = \begin{pmatrix} f & 0 & 0 \\ 0 & f & 0 \\ 0 & 0 & 1 \end{pmatrix}$

$$z\,\mathbf{x} = z \begin{pmatrix} f\frac{x}{z} \\ f\frac{y}{z} \\ 1 \end{pmatrix} = \begin{pmatrix} f & 0 & 0 \\ 0 & f & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

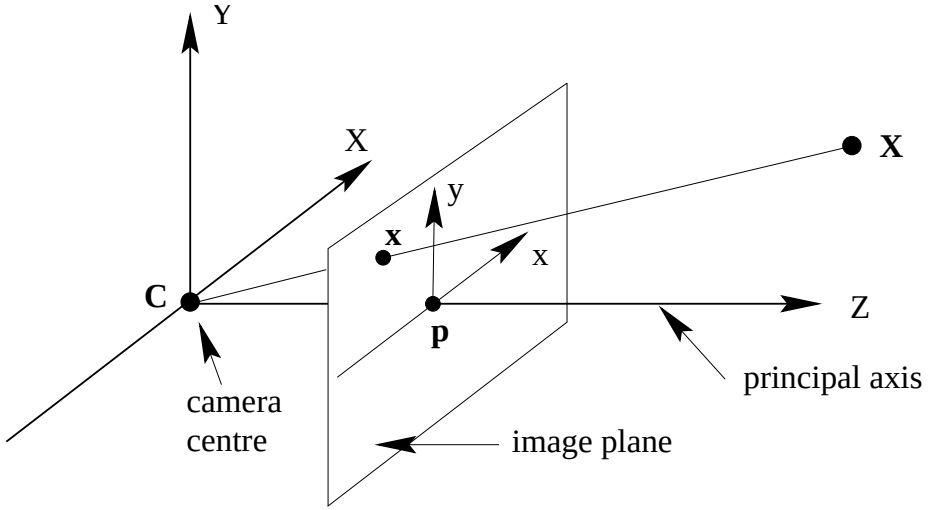

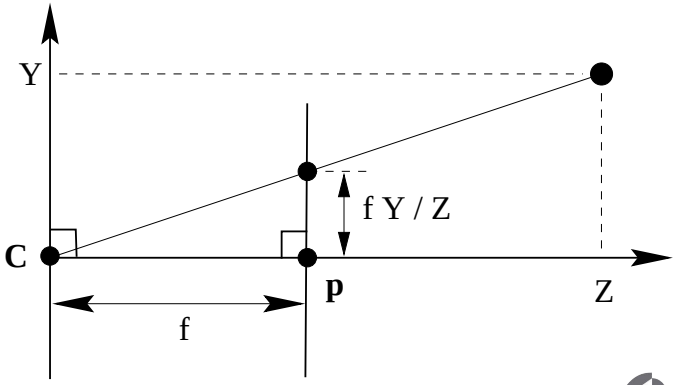

Model kamere

Projekcijska funkcija kamere

$$\lambda \begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \pi(\mathbf{X}, \mathbf{R}, \mathbf{t}) = \begin{pmatrix} f & 0 & u_0 \\ 0 & f & v_0 \\ 0 & 0 & 1 \end{pmatrix} \left[\begin{bmatrix} \mathbf{R} & \mathbf{t} \end{bmatrix} \begin{pmatrix} x \\ y \\ z \\ 1 \end{pmatrix} - \begin{pmatrix} b \\ 0 \\ 0 \end{pmatrix} \right]$$

- 3D koordinate točke $\mathbf{X} = (x, y, z)^T$
- pomak za lijevu kameru $b = 0$, za desnu kameru b je jednak odmaku desne kamere u rektificiranom sustavu
- rotacijska i translacijska matrica $[\mathbf{Rt}]$ dimenzija 3x4
- žarišna udaljenost f
- centralna točka (u_0, v_0)
- koordinate projicirane točke u slici $(u, v, 1)^T$
- λ - informacija o dubini točke koju gubimo projiciranjem

Određivanje korespondentnih značajki

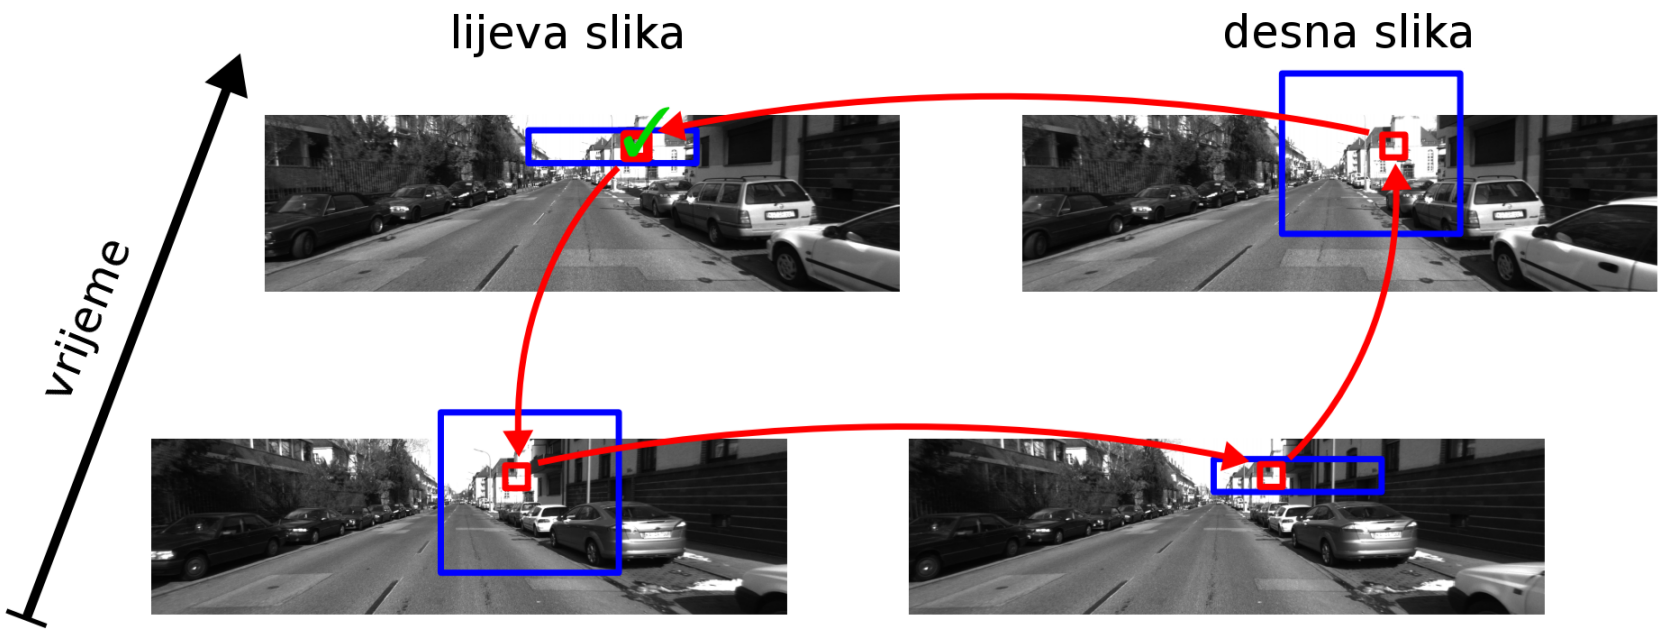

- značajke se dobivaju cikličkim podudaranjem između četiri slike:
  - prethodne lijeve i desne te trenutne lijeve i desne.

Određivanje gibanja kamere

- Obavlja se triangulacija značajki iz para prethodnih slika:
  - N - broj značajki.
  - $\mathbf{X_i}$ - točka dobivena triangulacijom i-te značajke.
- Iterativnom gradijentnom minimizacijom izraza

$$\underset{\mathbf{Rt}}{\operatorname{argmin}} \sum_{i=1}^{N} \left[\|\mathbf{x_i}^{(l)} - \pi^{(l)}(\mathbf{X_i}, \mathbf{R}, \mathbf{t})\|^2 + \|\mathbf{x_i}^{(r)} - \pi^{(r)}(\mathbf{X_i}, \mathbf{R}, \mathbf{t})\|^2 \right]$$

s obzirom na parametre $(\mathbf{R}, \mathbf{t})$ dobivamo one vrijednosti parametara za koje je pogreška projekcije minimalna.

  - $\pi^{(l)}$ - funkcija projiciranja na lijevu kameru, $b = 0$.
  - $\pi^{(r)}$ - funkcija projiciranja na desnu kameru, $b =$ udaljenost između kamera.
  - $\mathbf{x_i}$ - (u, v) koordinate i-te značajke u trenutnom paru slika.

Dobiveni $[\mathbf{Rt}]$ je transformacija točaka između dva trenutka u odnosu na kameru (koja je uvijek u ishodištu), a $[\mathbf{Rt}]^{-1}$ je tada gibanje kamere u odnosu na točke.

Detekcija značajki

1. Harrisovi kutevi - uniformna selekcija značajki
   - 10 x 10 blokova - 15 značajki po bloku
   - Rezultat: uniformno praćenje uz ubrzano podudaranje

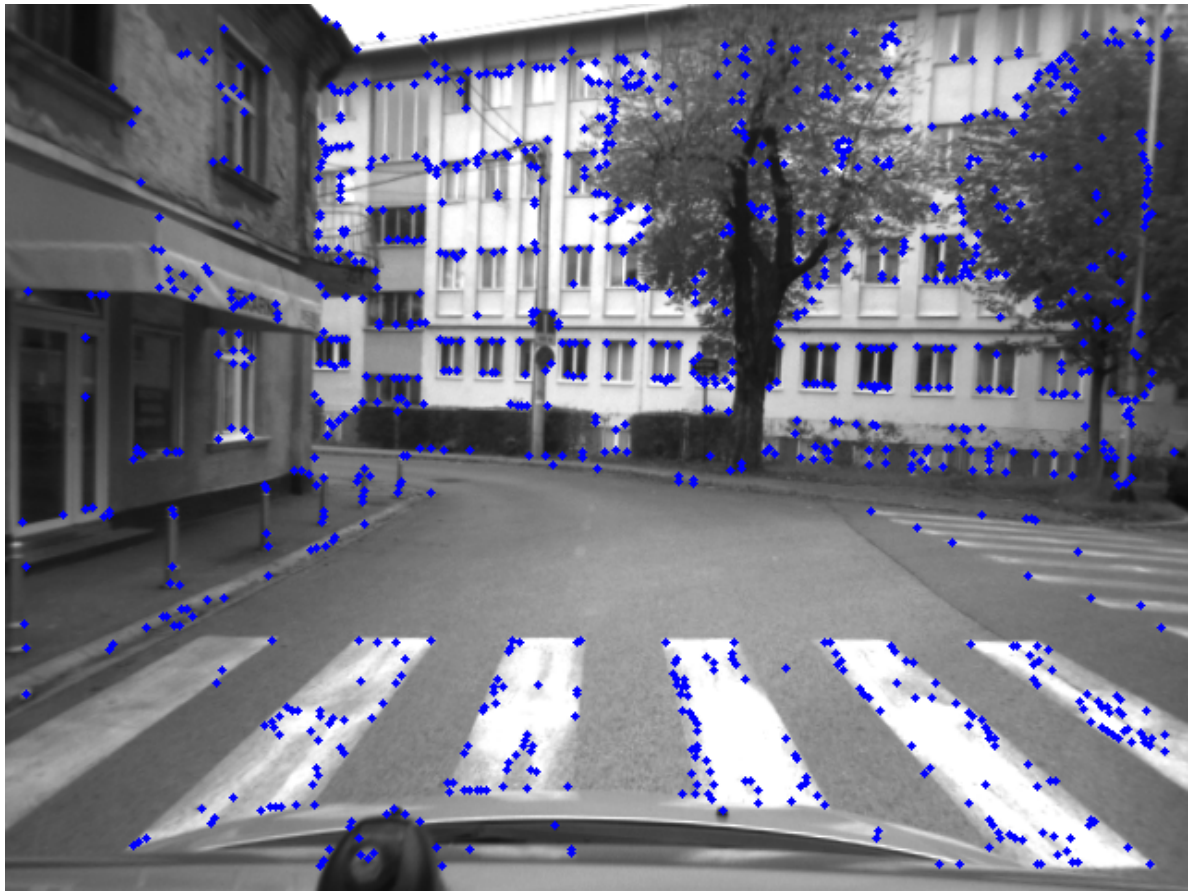

Praćenje značajki

- Praćenje kroz više okvira podudaranjem deskriptora značajki (11x11)
- Mjera sličnosti - normalizirana unakrsna korelacija
- Invarijacija na linearne promjene intenziteta - prednost u odnosu na SSD i SAD
- Mala složenost izračuna - usporediva sa SSD i SAD

$$NCC = \frac{\sum_{k=1}^{n}(I_1(k) - \widehat{I}_1)(I_2(k) - \widehat{I}_2)}{\sqrt{\sum_{k=1}^{n}(I_1(k) - \widehat{I}_1)^2(I_2(k) - \widehat{I}_2)^2}}$$

$$A = \sum_{k=1}^{N} I(k) \qquad B = \sum_{k=1}^{N} I(k)^2 \qquad C = \frac{1}{\sqrt{nB - A^2}}$$

$$D = I_1 \bullet I_2 \qquad NCC = (nD - A_1 A_2) C_1 C_2$$

Praćenje značajki

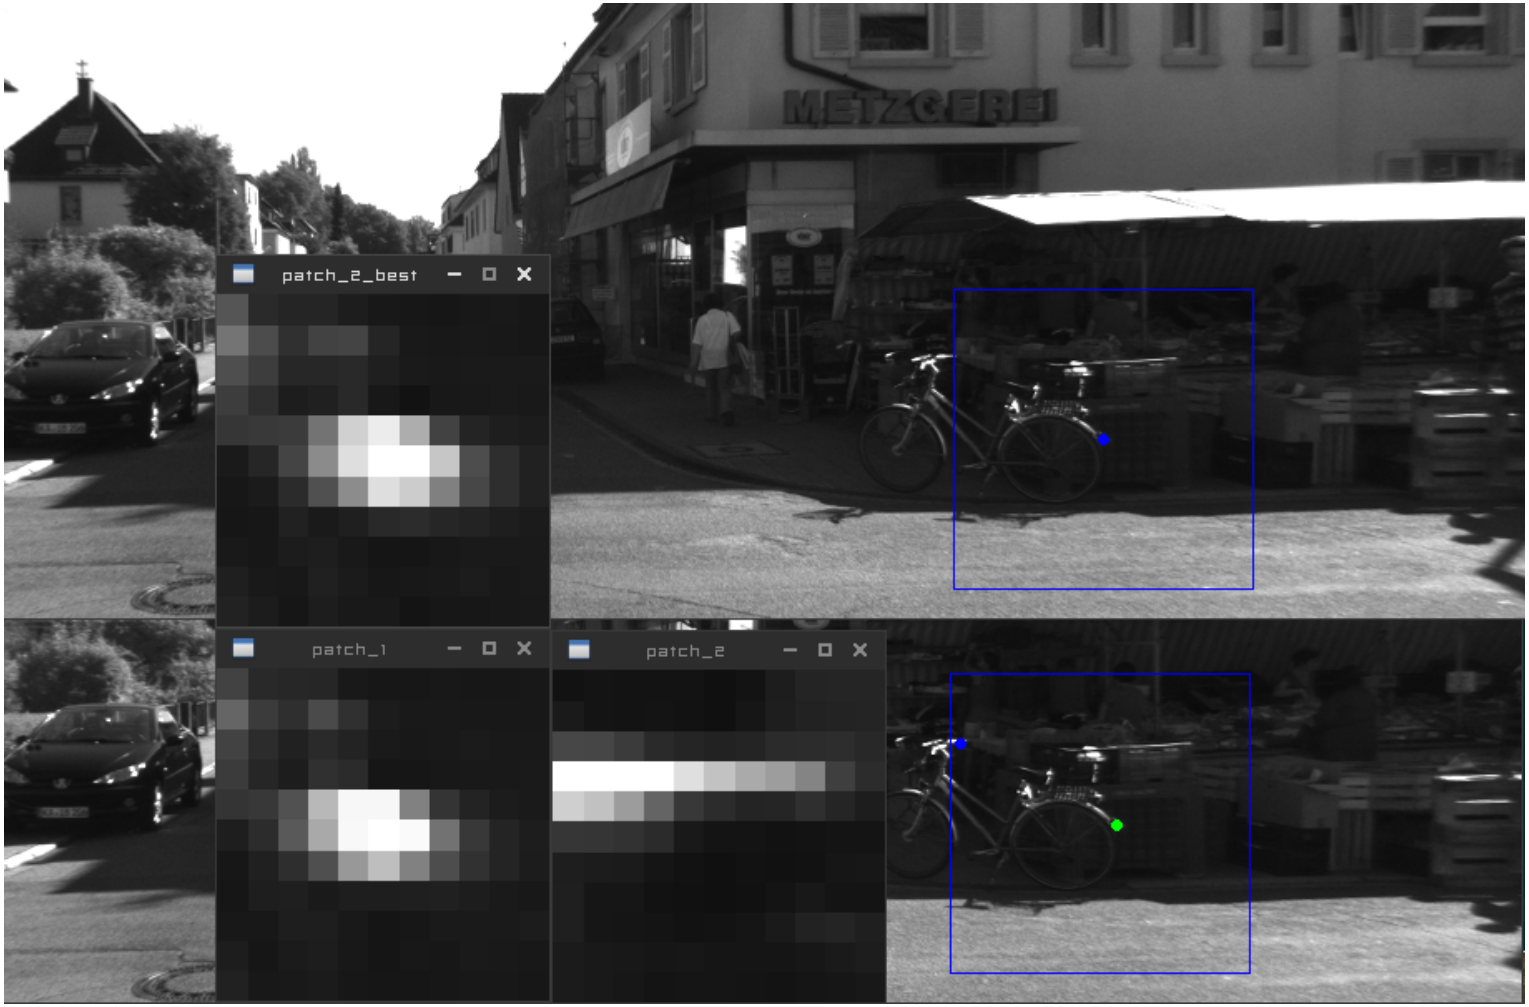

$NCC_1 = 0.9545$, $NCC_2 = 0.0047$, Prag odbacivanja = 0.9

Praćenje značajki

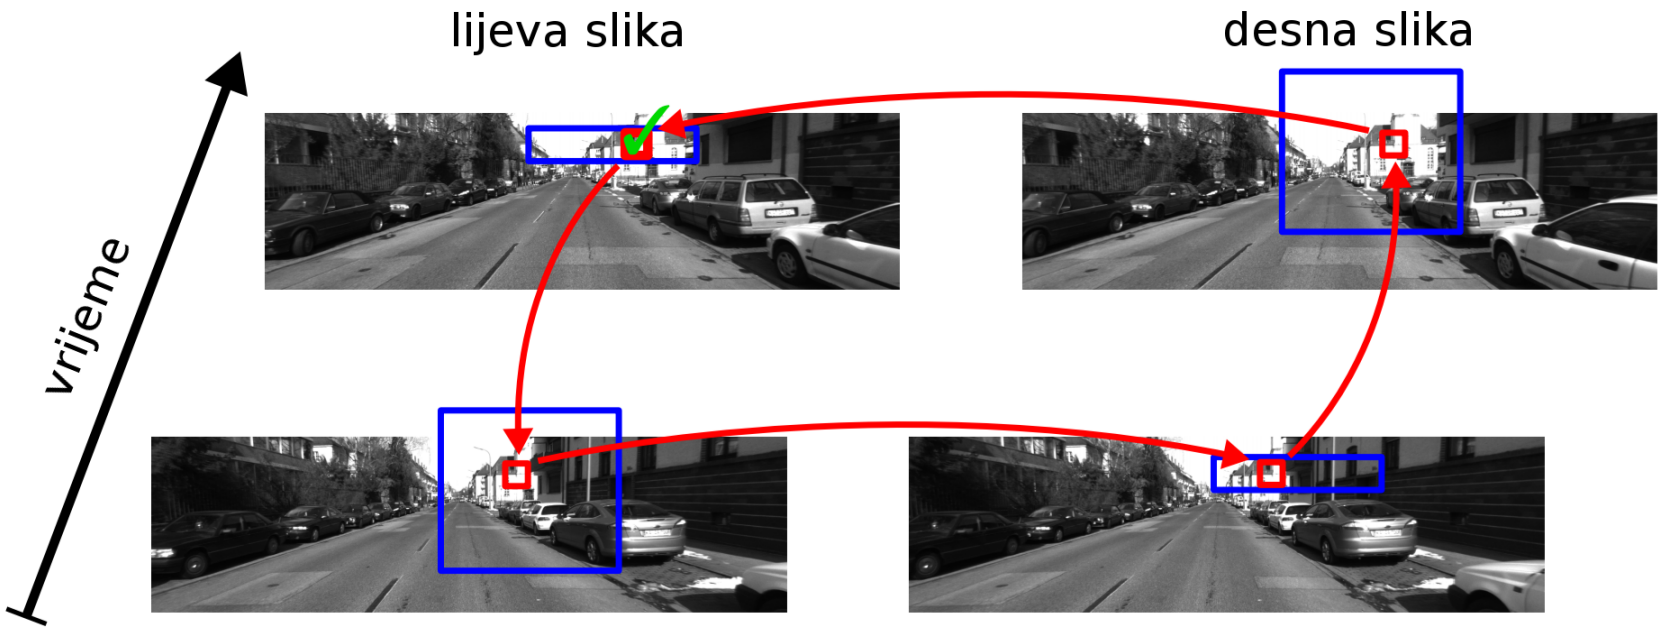

Ciklička provjera konzistencije

Podudaranje između dvije slike:

1. Podudaraju se sve značajke prve slike sa značajkama druge slike u zadanom prozoru pretraživanja
2. Na isti način podudaramo sve značajke iz druge sa prvom slikom
3. Prihvaćamo korespondencije samo onda kada se dvije značajke međusobno podudare

Podudaranje u stereo slikama:

1. Podudaramo slike najprije u vremenskoj domeni
2. Nezavisno podudaramo u prostornoj domeni
3. Prihvaćamo samo one značajke kojima se i vremenske i prostorne korespondencije poklapaju

RANdom SAmple Consensus - RANSAC

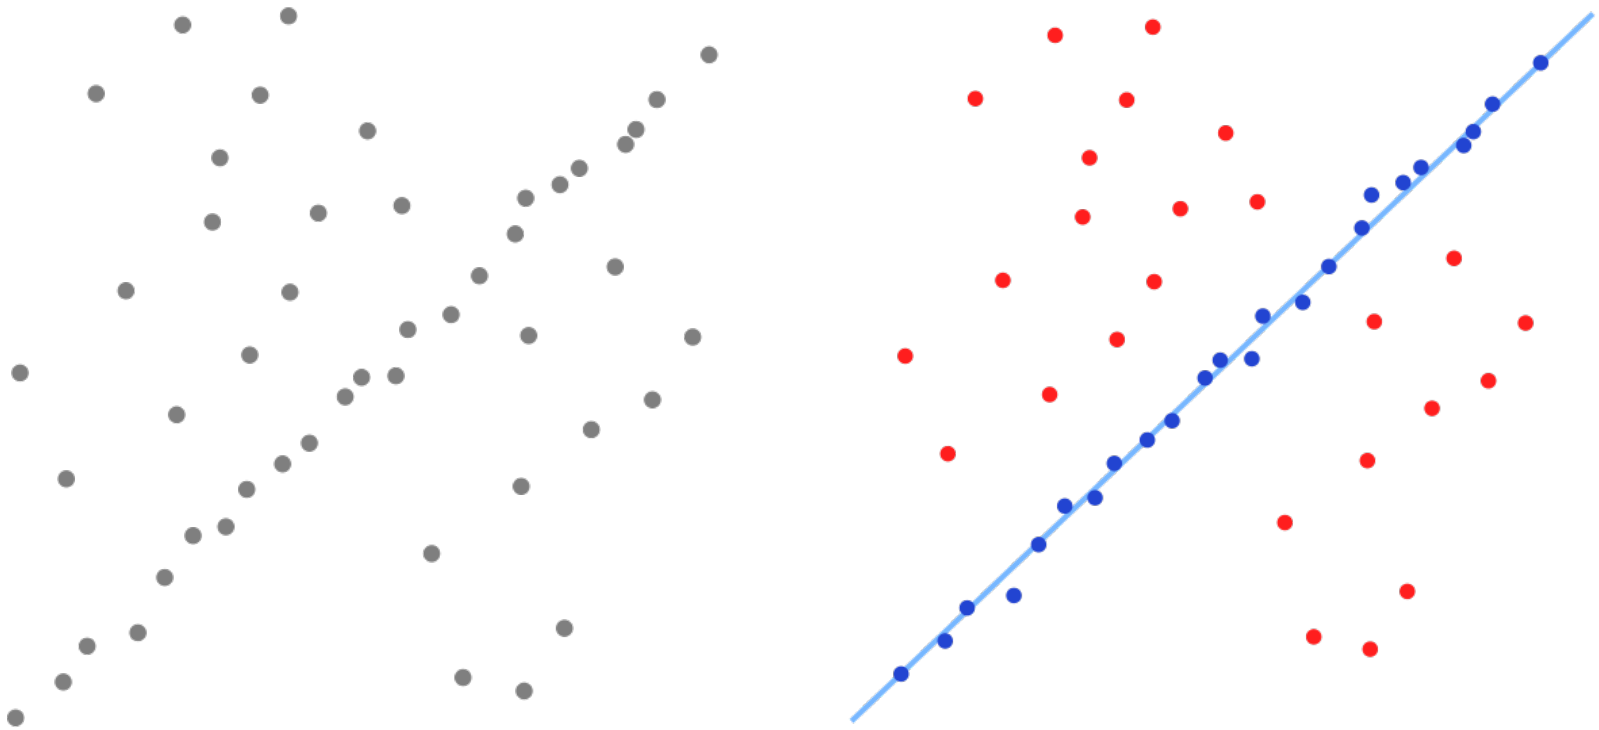

RANSAC - filtriranje značajki

1. Nasumično odeberemo tri cikličke korespondencije
2. Pronađemo **R** i **t**
3. Primijenimo pronađene **R** i **t** na sve korespondencije
4. Odaberemo značajke čija je udaljenost reprojekcije od stvarnih koordinata u trenutnom okviru manja ili jednaka nekom iznosu granične greške - nazivamo ih potpornim skupom trenutne hipoteze (eng. *inliers*)
5. Ako generirani model ima više *inliera* od svih prethodno generiranih modela, trenutni model pamtimo kao najbolji i nastavljamo algoritam od koraka 1
6. Glavni kriterij zaustavljanja je unaprijed zadani broj iteracija

- RANSAC očekuje uniformne značajke
- konačna optimizacija provodi se na filtriranom skupu značajki koji je dobiven metodom RANSAC

Praćenje značajki

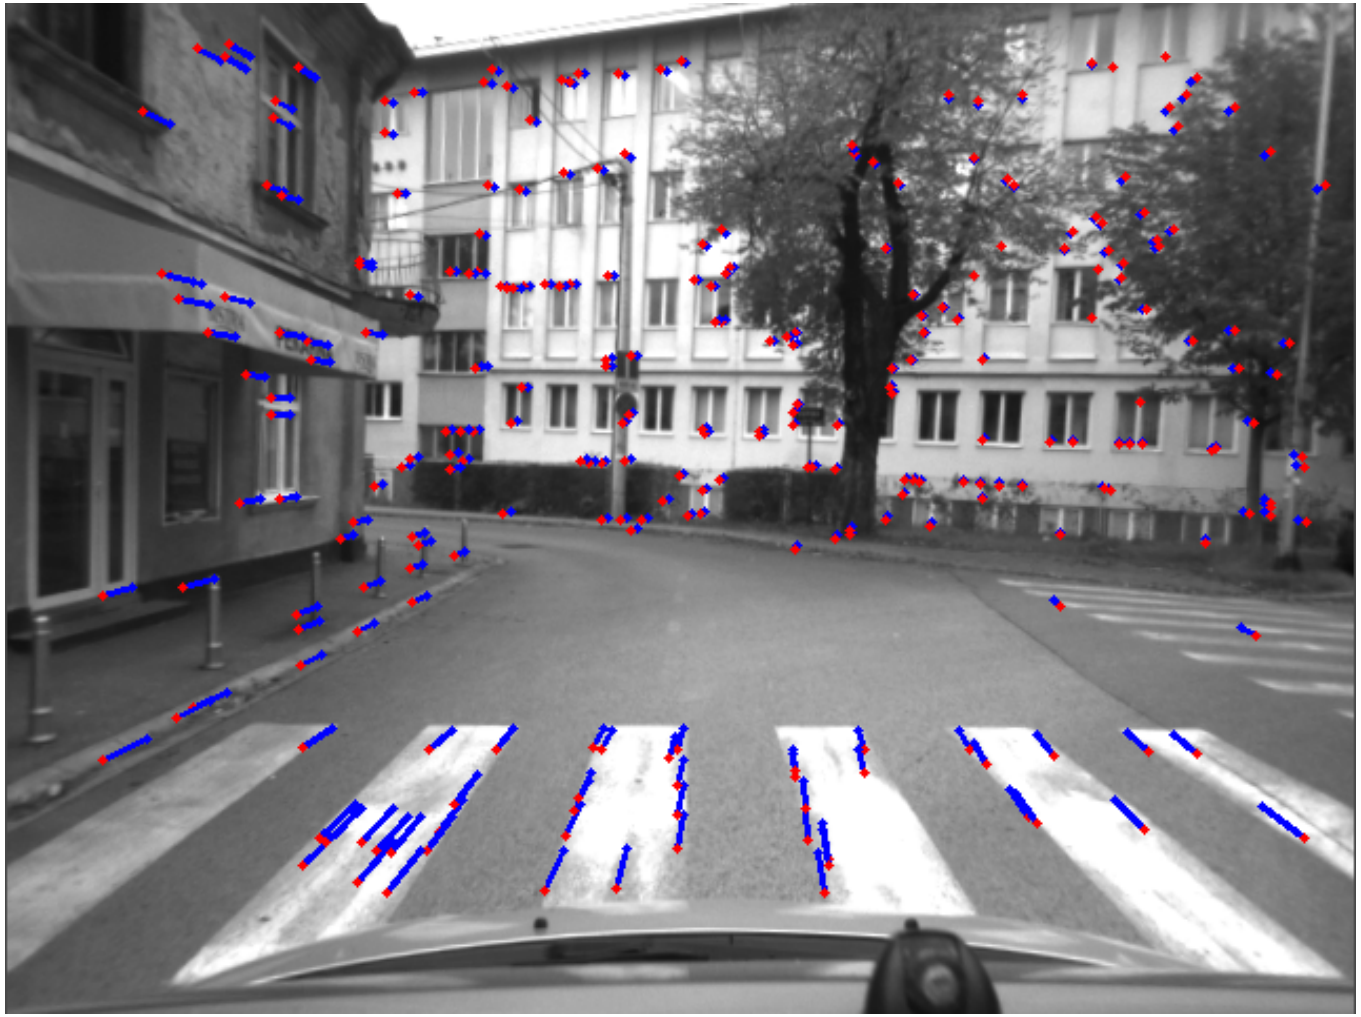

Podpikselska preciznost praćenja

1. Ideja: upotrijebiti Lucas Kanade metodu diferencijalnog praćenja i postići podpikselsku preciznost
2. Srednja reprojekcijska pogreška u filtriranom skupu točaka za *groundtruth* (KITTI) se smanjila

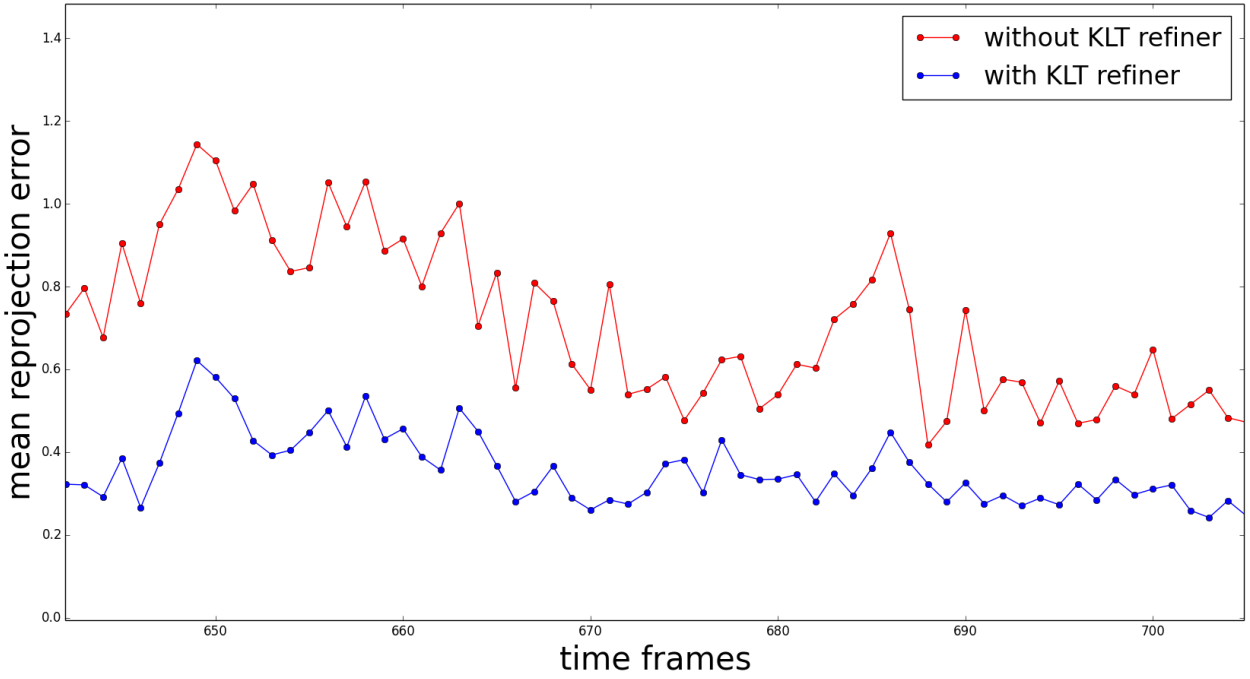

Podpikselska preciznost praćenja

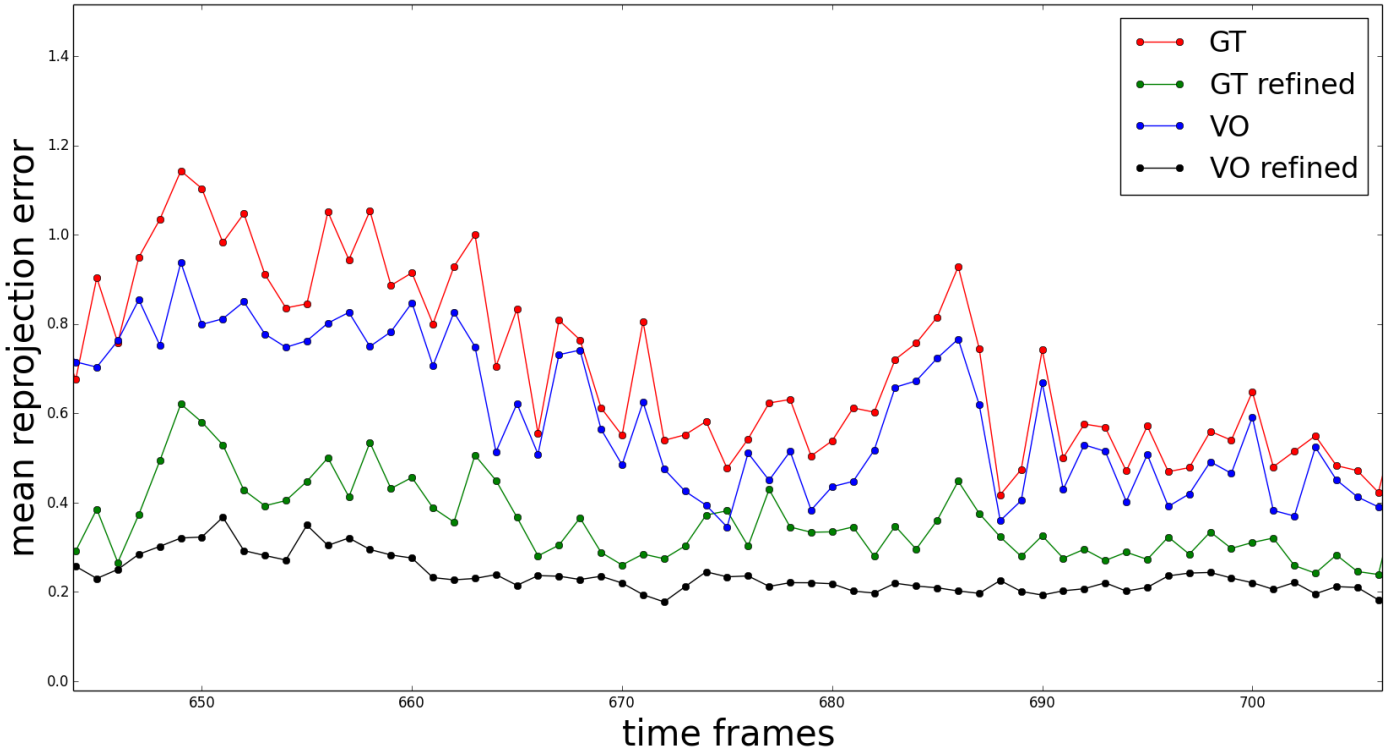

Podpikselska preciznost praćenja

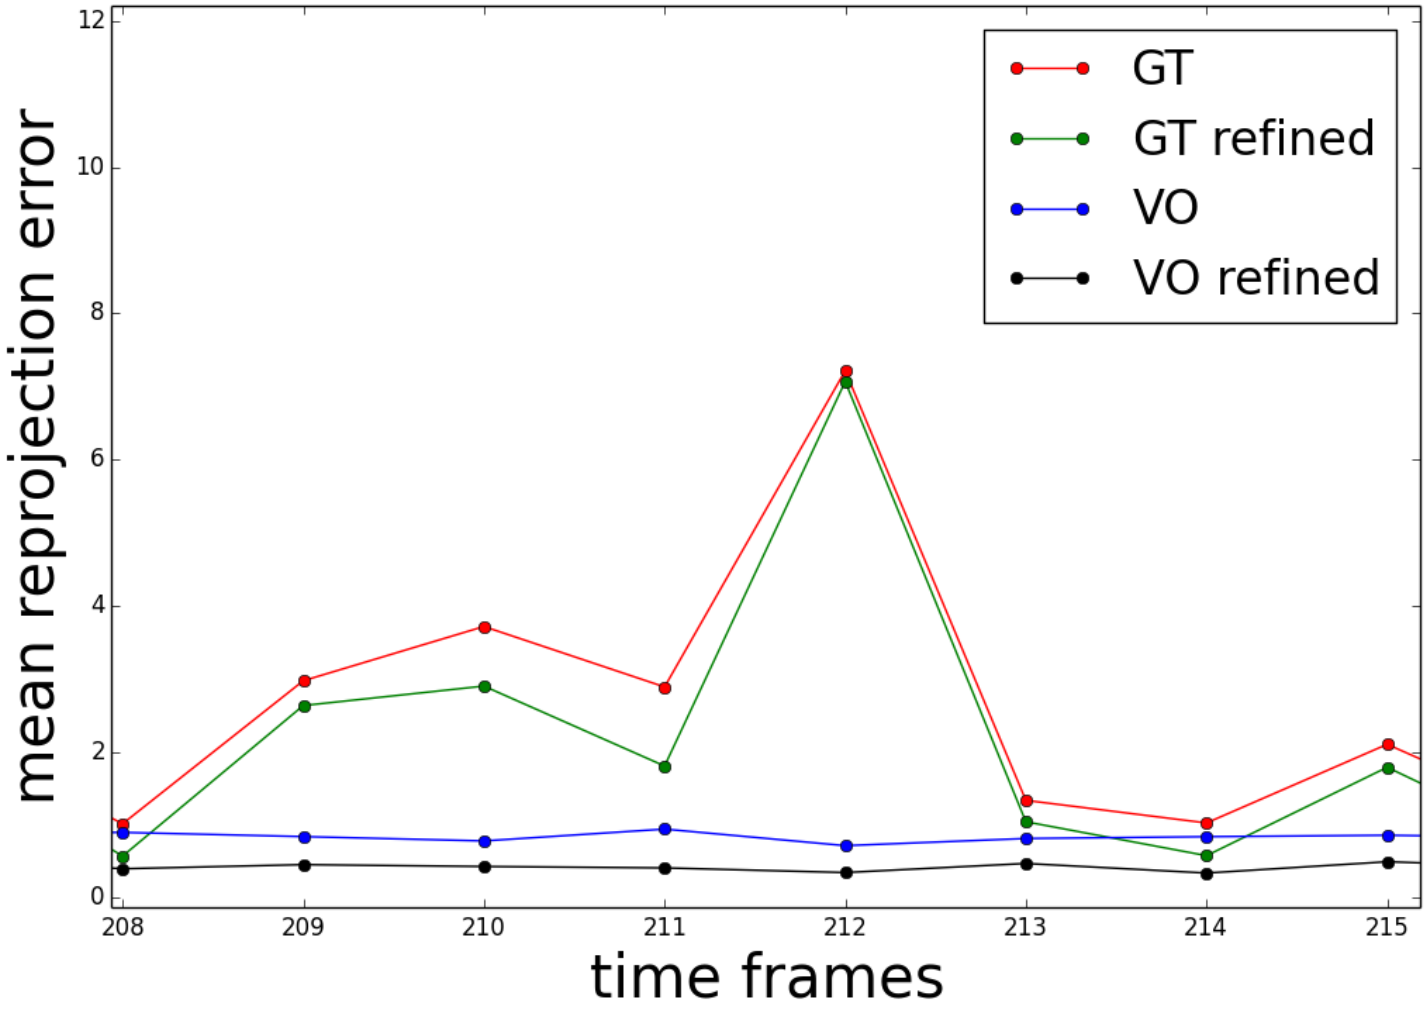

Sparse Bundle Adjustment

1. Minimizira reprojekcijsku pogrešku u N točaka kroz M vremenskih okvira.

$$\underset{\mathbf{X_i}\mathbf{R}_j\mathbf{t}_j}{\operatorname{argmin}} \sum_{i=1}^{N}\sum_{j=1}^{M} v_{ij}\|\mathbf{x}_{ij}^{(l)} - \pi^{(l)}(\mathbf{X_i}, \mathbf{R}_j, \mathbf{t}_j)\|^2 + \|\mathbf{x}_{ij}^{(r)} - \pi^{(r)}(\mathbf{X_i}, \mathbf{R}_j, \mathbf{t}_j)\|^2$$

$$\underset{\mathbf{X_i}\mathbf{R}_j\mathbf{t}_j}{\operatorname{argmin}} \sum_{i=1}^{N}\sum_{j=1}^{M}\sum_{k}^{\{L,R\}} v_{ij}\|\mathbf{x}_{ij}^{(k)} - \pi(\mathbf{X_i}, \mathbf{R}_j, \mathbf{t}_{jk})\|^2$$

$$\mathbf{t}_{jR} = \mathbf{t}_{jL} - \begin{pmatrix} b \\ 0 \\ 0 \end{pmatrix}$$

Sparse Bundle Adjustment

1. Obično se riješenje pronalazi Levenberg–Marquardt optimizacijskom metodom:

$$S(\beta) = \sum_{i=1}^{m} [y_i - f(x_i,\ \beta)]^2$$

$$f(x_i, \beta + \boldsymbol{\delta}) \approx f(x_i, \beta) + J_i \boldsymbol{\delta}$$

$$J_i = \frac{\partial f(x_i, \beta)}{\partial \beta}$$

$$S(\beta + \boldsymbol{\delta}) \approx \sum_{i=1}^{m} (y_i - f(x_i, \beta) - J_i \boldsymbol{\delta})^2$$

$$S(\beta + \boldsymbol{\delta}) \approx \|\mathbf{y} - \mathbf{f}(\beta) - \mathbf{J}\boldsymbol{\delta}\|^2$$

$$(\mathbf{J}^\mathbf{T}\mathbf{J})\boldsymbol{\delta} = \mathbf{J}^\mathbf{T}[\mathbf{y} - \mathbf{f}(\beta)]$$

$$(\mathbf{J}^\mathbf{T}\mathbf{J} + \lambda \mathbf{I})\boldsymbol{\delta} = \mathbf{J}^\mathbf{T}[\mathbf{y} - \mathbf{f}(\beta)]$$

Sparse Bundle Adjustment

- Jakobijan je rijetka matrica. Primjer za 3 točke vidljive u 3 stereo kamere:

$$\frac{\partial \pi}{\partial \mathbf{P}} = \begin{pmatrix} \mathbf{A}_{11} & 0 & 0 & \mathbf{B}_{11} & 0 & 0 \\ 0 & \mathbf{A}_{12} & 0 & \mathbf{B}_{12} & 0 & 0 \\ 0 & 0 & \mathbf{A}_{13} & \mathbf{B}_{13} & 0 & 0 \\ \mathbf{A}_{21} & 0 & 0 & 0 & \mathbf{B}_{21} & 0 \\ 0 & \mathbf{A}_{22} & 0 & 0 & \mathbf{B}_{22} & 0 \\ 0 & 0 & \mathbf{A}_{23} & 0 & \mathbf{B}_{23} & 0 \\ \mathbf{A}_{31} & 0 & 0 & 0 & 0 & \mathbf{B}_{31} \\ 0 & \mathbf{A}_{32} & 0 & 0 & 0 & \mathbf{B}_{32} \\ 0 & 0 & \mathbf{A}_{33} & 0 & 0 & \mathbf{B}_{33} \end{pmatrix}$$

Sparse Bundle Adjustment

$$\mathbf{A} = \begin{pmatrix} \frac{\partial \pi_u^L}{\partial \alpha} & \frac{\partial \pi_u^L}{\partial \beta} & \frac{\partial \pi_u^L}{\partial \gamma} & \frac{\partial \pi_u^L}{\partial x} & \frac{\partial \pi_u^L}{\partial y} & \frac{\partial \pi_u^L}{\partial z} \\ \frac{\partial \pi_v^L}{\partial \alpha} & \frac{\partial \pi_v^L}{\partial \beta} & \frac{\partial \pi_v^L}{\partial \gamma} & \frac{\partial \pi_v^L}{\partial x} & \frac{\partial \pi_v^L}{\partial y} & \frac{\partial \pi_v^L}{\partial z} \\ \frac{\partial \pi_u^R}{\partial \alpha} & \frac{\partial \pi_u^R}{\partial \beta} & \frac{\partial \pi_u^R}{\partial \gamma} & \frac{\partial \pi_u^R}{\partial x} & \frac{\partial \pi_u^R}{\partial y} & \frac{\partial \pi_u^R}{\partial z} \\ \frac{\partial \pi_v^R}{\partial \alpha} & \frac{\partial \pi_v^R}{\partial \beta} & \frac{\partial \pi_v^R}{\partial \gamma} & \frac{\partial \pi_v^R}{\partial x} & \frac{\partial \pi_v^R}{\partial y} & \frac{\partial \pi_v^R}{\partial z} \end{pmatrix}$$

$$\mathbf{B} = \begin{pmatrix} \frac{\partial \pi_u^L}{\partial X} & \frac{\partial \pi_u^L}{\partial Y} & \frac{\partial \pi_u^L}{\partial Z} \\ \frac{\partial \pi_v^L}{\partial X} & \frac{\partial \pi_v^L}{\partial Y} & \frac{\partial \pi_v^L}{\partial Z} \\ \frac{\partial \pi_u^R}{\partial X} & \frac{\partial \pi_u^R}{\partial Y} & \frac{\partial \pi_u^R}{\partial Z} \\ \frac{\partial \pi_{v,R}}{\partial X} & \frac{\partial \pi_v^R}{\partial Y} & \frac{\partial \pi_v^R}{\partial Z} \end{pmatrix}$$

Sparse bundle adjustment

- Ideja je ubrzati postupak i izbjeći lokalne optimume inicijaliziranjem parametara na vrijednosti dobivene analitičkom ili iterativnom procjenom gibanja u dva vremenska okvira
- Odabirati samo one ključne okvire u kojima je akumulirano gibanje u odnosu na prethodni ključni okvir veće od granične vrijednosti.
- Biblioteke s monokularnim SBA:
  - ROS (www.ros.org)
  - openMVG (Ceres Solver) (github.com/openMVG/)
  - Lourakis SBA (users.ics.forth.gr/ lourakis/sba/)

Budući ciljevi

- Ispitati utjecaj podpikselske preciznosti praćenja značajki
- Usporediti odometriju kroz dva okvira i više okvira (SBA) na umjetnom ispitnom skupu
- Ispitati utjecaj SBA metode na kvalitetu procjena za stereo kameru

Hvala na pažnji!