



# Dinamička analiza 3D scena

*procjena parametara modela*

Zoran Kalafatić i Siniša Šegvić

Zavod za elektroniku, mikroelektroniku,  
računalne i inteligentne sustave  
Fakultet elektrotehnike i računarstva  
Sveučilište u Zagrebu

# UVOD

**Procjena (estimacija) parametara modela:** jedna od uspješnih paradigmi modernog računalnog vida

# UVOD

**Procjena** (estimacija) **parametara modela**: jedna od uspješnih paradigmi modernog računalnog vida

**Vid**: ekstrakcija informacije iz slika

- transformacija 2D objekta: translacija, sličnost, homografija
- položaj kamere: relativni (relative), apsolutni (absolute pose)
- geometrija svijeta (scene reconstruction, structure from motion)
- položaj objekata: pronalaženje (detection), praćenje (tracking)
- identitet objekta: prepoznavanje (recognition)

# UVOD

**Procjena** (estimacija) **parametara modela**: jedna od uspješnih paradigmi modernog računalnog vida

**Vid**: ekstrakcija informacije iz slika

- transformacija 2D objekta: translacija, sličnost, homografija
- položaj kamere: relativni (relative), apsolutni (absolute pose)
- geometrija svijeta (scene reconstruction, structure from motion)
- položaj objekata: pronalaženje (detection), praćenje (tracking)
- identitet objekta: prepoznavanje (recognition)

**Ideja**:

- informaciju predstaviti parametrima matematičkog modela
- **estimirati** iz velikog skupa opažanja statističkim metodama!

# UVOD (2)

Što bi bio **model**?

## UVOD (2)

Što bi bio **model**? — **apriorno znanje** o sceni ili efektu

## UVOD (2)

Što bi bio **model**? — **apriorno znanje** o sceni ili efektu

Npr, afina trans. kao model prividnog kretanja planarne značajke

$$I_n(\mathbf{x}) = I_0(\mathbf{A} \cdot \mathbf{x} + \mathbf{d})$$

## UVOD (2)

Što bi bio **model**? — **apriorno znanje** o sceni ili efektu

Npr, afina trans. kao model prividnog kretanja planarne značajke

$$I_n(\mathbf{x}) = I_0(\mathbf{A} \cdot \mathbf{x} + \mathbf{d})$$

Npr, Euklidska trans. kao model gibanja nepokretne scene

$$\mathbf{X}_2 = \mathbf{R} \cdot \mathbf{X}_1 + \mathbf{T}$$



## UVOD (2)

Što bi bio **model**? — **apriorno znanje** o sceni ili efektu

Npr, afina trans. kao model prividnog kretanja planarne značajke

$$I_n(\mathbf{x}) = I_0(\mathbf{A} \cdot \mathbf{x} + \mathbf{d})$$

Npr, Euklidska trans. kao model gibanja nepokretne scene

$$\mathbf{X}_2 = \mathbf{R} \cdot \mathbf{X}_1 + \mathbf{T}$$

Npr, epipolarno ograničenje kao model odnosa korespondentnih značajki nepokretne scene

$$\mathbf{x}_2^\top \cdot \mathbf{F} \cdot \mathbf{x}_1 = 0$$

## UVOD (3)

Estimacijska teorija se bavi **procjenjivanjem** parametara modela iz mnoštva podataka degradiranih **šumom**

## UVOD (3)

Estimacijska teorija se bavi **procjenjivanjem** parametara modela iz mnoštva podataka degradiranih **šumom**

Šum obično modelira odstupanja uslijed nesavršenog modela

- 2D transformacija ne može precizno objasniti deformacije značajki koje nisu planarne
- pronalaženje korespondencija ne može biti točno u piksel (transformacija izgleda ovisi o paralaksi i 3D strukturi)
- vanjski utjecaji koji ne uzrokuju velika odstupanja: osvjetljenje, zamućenje, termalni šum :-), ...

## UVOD (3)

Estimacijska teorija se bavi **procjenjivanjem** parametara modela iz mnoštva podataka degradiranih **šumom**

Šum obično modelira odstupanja uslijed nesavršenog modela

- 2D transformacija ne može precizno objasniti deformacije značajki koje nisu planarne
- pronalaženje korespondencija ne može biti točno u piksel (transformacija izgleda ovisi o paralaksi i 3D strukturi)
- vanjski utjecaji koji ne uzrokuju velika odstupanja: osvjetljenje, zamućenje, termalni šum :-), ...

**Ideja:** iz mnoštva djelomično kontradiktornih podataka izvući **najvjerodostojniju** ili **najvjerojatniju** interpretaciju!

## UVOD (4)

Često pretpostavljamo normalni nepristrani šum  
(normalna razdioba obično dobar model znanja o neznanju)

## UVOD (4)

Često pretpostavljamo normalni nepristrani šum  
(normalna razdioba obično dobar model znanja o neznanju)

Npr, kod stereo vida, položaj značajke često označavamo:

$$\mathbf{q}_i = \bar{\mathbf{q}}_i + \Delta \mathbf{q}_i, \text{ uz } q_x, q_y \sim \mathcal{N}(0, \sigma^2)$$

## UVOD (4)

Često pretpostavljamo normalni nepristrani šum  
(normalna razdioba obično dobar model znanja o neznanju)

Npr, kod stereo vida, položaj značajke često označavamo:

$$\mathbf{q}_i = \bar{\mathbf{q}}_i + \Delta \mathbf{q}_i, \text{ uz } q_x, q_y \sim \mathcal{N}(0, \sigma^2)$$

**Ideja:** dizajnirati metode koje će rezultirati **statistički boljim** rezultatima uz pretpostavljeni model šuma!!

# UVOD (5)

Koncept šuma primjenljiv samo za umjerena odstupanja



## UVOD (5)

Koncept šuma primjenljiv samo za umjerena odstupanja

Za veća odstupanja potrebno uvesti koncept **izvanpopulacijskih** podataka (outliera) koji se ne pokoravaju dominantnom modelu

## UVOD (5)

Koncept šuma primjenljiv samo za umjerena odstupanja

Za veća odstupanja potrebno uvesti koncept **izvanpopulacijskih** podataka (outliera) koji se ne pokoravaju dominantnom modelu

Izvanpopulacijske korespondencije za model nepokretne scene:

- korepondencija nastala **asocijacijskom pogreškom** (upareni su različiti objekti sličnog izgleda)
- ispravna korespondencija projekcije s pokretnog objekta

## UVOD (5)

Koncept šuma primjenljiv samo za umjerena odstupanja

Za veća odstupanja potrebno uvesti koncept **izvanpopulacijskih** podataka (outliera) koji se ne pokoravaju dominantnom modelu

Izvanpopulacijske korespondencije za model nepokretne scene:

- korepondencija nastala **asocijacijskom pogreškom** (upareni su različiti objekti sličnog izgleda)
- ispravna korespondencija projekcije s pokretnog objekta

**Ideja:** dizajnirati **robustne** metode koje mogu **detektirati** i **zanemariti** izvanpopulacijska mjerenja!

# UVOD (6)

**Motivacija** za teoriju estimacije:

# UVOD (6)

## **Motivacija** za teoriju estimacije:

Računalni vid je disciplina u kojoj obično obrađujemo redundantne podatke, u prisustvu šuma i outliera (dobivamo sustav jednažbi s viškom ograničenja)

# Uvod (6)

## Motivacija za teoriju estimacije:

Računalni vid je disciplina u kojoj obično obrađujemo redundantne podatke, u prisustvu šuma i outliera (dobivamo sustav jednažbi s viškom ograničenja)

Želimo **gledati** (izlučivati parametre) na način da:

1. **svi** unutarpopulacijski podatci doprinose rješenju
2. rezultat u prisustvu plauzibilnog šuma bude **statistički** povoljan
3. vanpopulacijski parametri **ne ometaju** točan rezultat

# Uvod (6)

## Motivacija za teoriju estimacije:

Računalni vid je disciplina u kojoj obično obrađujemo redundantne podatke, u prisustvu šuma i outliera (dobivamo sustav jednažbi s viškom ograničenja)

Želimo **gledati** (izlučivati parametre) na način da:

1. **svi** unutarpopulacijski podatci doprinose rješenju
2. rezultat u prisustvu plauzibilnog šuma bude **statistički** povoljan
3. vanpopulacijski parametri **ne ometaju** točan rezultat

Okvir za postizanje tih svojstava daje **teorija estimacije**.

# LINEARNI SUSTAVI

Primjer broj jedan: provući pravac kroz zadani skup 2D točaka



# LINEARNI SUSTAVI

Primjer broj jedan: provući pravac kroz zadani skup 2D točaka


Model **podataka**: pravac

# LINEARNI SUSTAVI

Primjer broj jedan: provući pravac kroz zadani skup 2D točaka

Model **podataka**: pravac

Model **šuma**: djeluje na koordinatu  $y$ , nezavisan, identično distribuiran prema  $\mathcal{N}(0, \sigma)$



## LINEARNI SUSTAVI (2)

Obično je ovakve probleme **najlakše** i **najnepreciznije** rješavati u projekcijskoj domeni

## LINEARNI SUSTAVI (2)

Obično je ovakve probleme **najlakše** i **najnepreciznije** rješavati u projekcijskoj domeni

Ako  $i$ -ta točka  $q_i$  prolazi kroz traženi pravac  $p$ , vrijedi:

$$q_{Hi}^T \cdot p = p_1 q_x + p_2 q_y + p_3 = 0$$

## LINEARNI SUSTAVI (2)

Obično je ovakve probleme **najlakše** i **najnepreciznije** rješavati u projekcijskoj domeni

Ako  $i$ -ta točka  $\mathbf{q}_i$  prolazi kroz traženi pravac  $\mathbf{p}$ , vrijedi:

$$\mathbf{q}_i^T \cdot \mathbf{p} = p_1 q_x + p_2 q_y + p_3 = 0$$

Ako su sve točke  $\mathbf{q}_i, i = 1, 2, \dots, n$  elementi pravca  $\mathbf{p}$ , vrijedi:

$$\mathbf{A}_{m \times 3} \cdot \mathbf{p} = \mathbf{0}, \quad \text{gdje je } \mathbf{A}_{i,:} = \mathbf{q}_i^T$$

## LINEARNI SUSTAVI (2)

Obično je ovakve probleme **najlakše** i **najnepreciznije** rješavati u projekcijskoj domeni

Ako  $i$ -ta točka  $\mathbf{q}_i$  prolazi kroz traženi pravac  $\mathbf{p}$ , vrijedi:

$$\mathbf{q}_i^T \cdot \mathbf{p} = p_1 q_x + p_2 q_y + p_3 = 0$$

Ako su sve točke  $\mathbf{q}_i, i = 1, 2, \dots, n$  elementi pravca  $\mathbf{p}$ , vrijedi:

$$\mathbf{A}_{m \times 3} \cdot \mathbf{p} = \mathbf{0}, \quad \text{gdje je } \mathbf{A}_{i,:} = \mathbf{q}_i^T$$

U prisustvu šuma, gornja jednažba nema rješenja.

Ima stoga smisla tražiti rješenje koje minimizira rezidual:

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} (\|\mathbf{A}_{m \times 3} \cdot \mathbf{p}\|), \quad \text{uz uvjet } \|\mathbf{p}\| = 1$$

## LINEARNI SUSTAVI (3)

Dobili smo **linearni homogeni sustav** s viškom ograničenja

- homogeneous linear least squares
- overconstrained homogeneous linear system

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1}\|), \quad \text{uz uvjet } \|\mathbf{x}\| = 1$$

## LINEARNI SUSTAVI (3)

Dobili smo **linearni homogeni sustav** s viškom ograničenja

- homogeneous linear least squares
- overconstrained homogeneous linear system

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1}\|), \quad \text{uz uvjet } \|\mathbf{x}\| = 1$$

Rješenje odgovara desnom singularnom vektoru matrice  $\mathbf{A}$  koji odgovara najmanjoj singularnoj vrijednosti!



## LINEARNI SUSTAVI (3)

Dobili smo **linearni homogeni sustav** s viškom ograničenja

- homogeneous linear least squares
- overconstrained homogeneous linear system

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1}\|), \quad \text{uz uvjet } \|\mathbf{x}\| = 1$$

Rješenje odgovara desnom singularnom vektoru matrice  $\mathbf{A}$  koji odgovara najmanjoj singularnoj vrijednosti!

Singularne vrijednosti i vektore dobivamo **singularnom dekompozicijom**.

## LINEARNI SUSTAVI (3)

Dobili smo **linearni homogeni sustav** s viškom ograničenja

- homogeneous linear least squares
- overconstrained homogeneous linear system

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1}\|), \quad \text{uz uvjet } \|\mathbf{x}\| = 1$$

Rješenje odgovara desnom singularnom vektoru matrice  $\mathbf{A}$  koji odgovara najmanjoj singularnoj vrijednosti!

Singularne vrijednosti i vektore dobivamo **singularnom dekompozicijom**.

Ekvivalentan rezultat dobivamo **svojstvenom dekompozicijom** simetrične matrice  $\mathbf{A}^T \mathbf{A}$

# LINEARNI SUSTAVI (4)

Linearni nehomogeni sustav s viškom ograničenja:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\| \mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1} - \mathbf{b}_{n \times 1} \|)$$

## LINEARNI SUSTAVI (4)

Linearni nehomogeni sustav s viškom ograničenja:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1} - \mathbf{b}_{n \times 1}\|)$$

Rješenje je umnožak pseudoinverza matrice  $\mathbf{A}$  i vektora  $\mathbf{b}$ :

$$\hat{\mathbf{x}} = \mathbf{A}^+ \cdot \mathbf{b}$$

## LINEARNI SUSTAVI (4)

Linearni nehomogeni sustav s viškom ograničenja:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} (\|\mathbf{A}_{m \times n} \cdot \mathbf{x}_{n \times 1} - \mathbf{b}_{n \times 1}\|)$$

Rješenje je umnožak pseudoinverza matrice  $\mathbf{A}$  i vektora  $\mathbf{b}$ :

$$\hat{\mathbf{x}} = \mathbf{A}^+ \cdot \mathbf{b}$$

Moore-Penroseov inverz  $\mathbf{A}^+$  dobivamo **singularnom dekompozicijom**, ili nekim drugim metodama koje su nešto brže i nešto manje točne

# LINEARNA ALGEBRA

Svaka matrica  $A_{m \times n}$  ima singularnu dekompoziciju:

$$A = U \cdot D \cdot V^T$$

- $U_{m \times m}$  ( $U_{m \times n}$ ) ... ortogonalna matrica (ili ortogonalni stupci)
- $D_{m \times n}$  ( $D_{n \times n}$ ) ... dijagonalna pozitivno semidefinitna matrica
- $V_{n \times n}$  ... ortogonalna matrica

# LINEARNA ALGEBRA

Svaka matrica  $\mathbf{A}_{m \times n}$  ima singularnu dekompoziciju:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top$$

- $\mathbf{U}_{m \times m}$  ( $\mathbf{U}_{m \times n}$ ) ... ortogonalna matrica (ili ortogonalni stupci)
- $\mathbf{D}_{m \times n}$  ( $\mathbf{D}_{n \times n}$ ) ... dijagonalna pozitivno semidefinitna matrica
- $\mathbf{V}_{n \times n}$  ... ortogonalna matrica

Vrijedi:

- $\mathbf{D}_{i,i} = d_i$  —  $i$ -ta singularna vrijednost ( $d_i \in \mathbb{R}_0^+$ ,  $d_i > d_{i+1}$ )
- $\mathbf{V}_{:,i} = \mathbf{v}_i$  —  $i$ -ti desni singularni vektor ( $\mathbf{v}_i^\top \mathbf{v}_j = \delta_{ij}$ )
- $\mathbf{U}_{:,i} = \mathbf{u}_i$  —  $i$ -ti lijevi singularni vektor ( $\mathbf{u}_i^\top \mathbf{u}_j = \delta_{ij}$ )
  - $\|\mathbf{U}\mathbf{x}\| = (\mathbf{U}\mathbf{x})^\top (\mathbf{U}\mathbf{x}) = \mathbf{x}^\top \mathbf{U}^\top \mathbf{U}\mathbf{x} = \mathbf{x}^\top (\mathbf{U}^\top \mathbf{U})\mathbf{x} = \|\mathbf{x}\|$

## LINEARNA ALGEBRA (2)

Malo intuicije: u kakvoj je vezi SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top$  sa svojstvenom dekompozicijom simetrične matrice

$$\mathbf{M} = \mathbf{V} \cdot \mathbf{\Lambda} \cdot \mathbf{V}^\top?$$



## LINEARNA ALGEBRA (2)

Malo intuicije: u kakvoj je vezi SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top$  sa svojstvenom dekompozicijom simetrične matrice

$$\mathbf{M} = \mathbf{V} \cdot \mathbf{\Lambda} \cdot \mathbf{V}^\top?$$

Za simetrične matrice, SVD odgovara svojstvenoj dekompoziciji:

$$\mathbf{A} = \mathbf{A}^\top \Leftrightarrow \mathbf{U} = \mathbf{V}$$

## LINEARNA ALGEBRA (2)

Malo intuicije: u kakvoj je vezi SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top$  sa svojstvenom dekompozicijom simetrične matrice

$$\mathbf{M} = \mathbf{V} \cdot \mathbf{\Lambda} \cdot \mathbf{V}^\top?$$

Za simetrične matrice, SVD odgovara svojstvenoj dekompoziciji:

$$\mathbf{A} = \mathbf{A}^\top \Leftrightarrow \mathbf{U} = \mathbf{V}$$

Uvrštavanjem SVD dekompozicije matrice  $\mathbf{A}$  dobivamo:

- $\mathbf{V}$  figurira u svojstvenoj dekompoziciji  $\mathbf{A}^\top \mathbf{A} = \mathbf{V}(\mathbf{D}^\top \mathbf{D})\mathbf{V}^\top$
- $\mathbf{U}$  figurira u svojstvenoj dekompoziciji  $\mathbf{A}\mathbf{A}^\top = \mathbf{U}(\mathbf{D}\mathbf{D}^\top)\mathbf{U}^\top$
- $d_i^2 = \lambda_i(\mathbf{A}^\top \mathbf{A}) = \lambda_i(\mathbf{A}\mathbf{A}^\top)$

# LINEARNA ALGEBRA (3)

Svojstva SVD:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^{\top} = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^{\top}$$

# LINEARNA ALGEBRA (3)

Svojstva SVD:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^{\top} = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^{\top}$$

SVD pruža osnovne informacije o matrici:

- neka je  $d_i > 0, \forall i \leq r$ , te  $d_i = 0, \forall i > r$
- kodomena (slika) matrice:  $\mathcal{K}(\mathbf{A}) = \text{span}\{\mathbf{u}_i, i = 1, 2, \dots, r\}$
- nulprostor (jezgra) matrice:  $\text{null}(\mathbf{A}) = \text{span}\{\mathbf{v}_i, i = r + 1, \dots, n\}$
- rang matrice:  $\text{rang}(\mathbf{A}) = r$

# LINEARNA ALGEBRA (3)

Svojstva SVD:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^{\top} = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^{\top}$$

SVD pruža osnovne informacije o matrici:

- neka je  $d_i > 0, \forall i \leq r$ , te  $d_i = 0, \forall i > r$
- kodomena (slika) matrice:  $\mathcal{K}(\mathbf{A}) = \text{span}\{\mathbf{u}_i, i = 1, 2, \dots, r\}$
- nulprostor (jezgra) matrice:  $\text{null}(\mathbf{A}) = \text{span}\{\mathbf{v}_i, i = r + 1, \dots, n\}$
- rang matrice:  $\text{rang}(\mathbf{A}) = r$
- uvjetovanost matrice ( $\delta(\mathbf{x})/\delta(\mathbf{b})$ ):  $\kappa(\mathbf{A}) = d_1/d_n$

# LINEARNA ALGEBRA (4)

Svojstva SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^\top$  (2):

SVD predstavlja djelovanje matrice kao:

- rotaciju u odredišnom prostoru ( $\mathbf{U}_{m \times m}$ )
- neravnomjerno skaliranje + pad ranga ( $\mathbf{D}_{m \times n}$ )
- rotaciju u izvornom prostoru ( $\mathbf{V}_{n \times n}$ )

# LINEARNA ALGEBRA (4)

Svojstva SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^\top$  (2):

SVD predstavlja djelovanje matrice kao:

- rotaciju u odredišnom prostoru ( $\mathbf{U}_{m \times m}$ )
- neravnomjerno skaliranje + pad ranga ( $\mathbf{D}_{m \times n}$ )
- rotaciju u izvornom prostoru ( $\mathbf{V}_{n \times n}$ )

Optimalna  $\|\cdot\|_F$  aproksimacija najbližom matricom nižeg ranga  $r_a$

- dovoljno je postaviti  $d_i = 0, i = r_a, \dots, \max(m, n)$ !

# LINEARNA ALGEBRA (4)

Svojstva SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^\top$  (2):

SVD predstavlja djelovanje matrice kao:

- rotaciju u odredišnom prostoru ( $\mathbf{U}_{m \times m}$ )
- neravnomjerno skaliranje + pad ranga ( $\mathbf{D}_{m \times n}$ )
- rotaciju u izvornom prostoru ( $\mathbf{V}_{n \times n}$ )

Optimalna  $\|\cdot\|_F$  aproksimacija najbližom matricom nižeg ranga  $r_a$

- dovoljno je postaviti  $d_i = 0, i = r_a, \dots, \max(m, n)$ !
- redci matrice  $\mathbf{U}$  — sortirana verzija redaka  $\mathbf{A}$ ,



## LINEARNA ALGEBRA (4)

Svojstva SVD  $\mathbf{A} = \mathbf{U} \cdot \mathbf{D} \cdot \mathbf{V}^\top = \sum_i d_i \cdot \mathbf{u}_i \mathbf{v}_i^\top$  (2):

SVD predstavlja djelovanje matrice kao:

- rotaciju u odredišnom prostoru ( $\mathbf{U}_{m \times m}$ )
- neravnomjerno skaliranje + pad ranga ( $\mathbf{D}_{m \times n}$ )
- rotaciju u izvornom prostoru ( $\mathbf{V}_{n \times n}$ )

Optimalna  $\| \cdot \|_F$  aproksimacija najbližom matricom nižeg ranga  $r_a$

- dovoljno je postaviti  $d_i = 0, i = r_a, \dots, \max(m, n)$ !
- redci matrice  $\mathbf{U}$  — sortirana verzija redaka  $\mathbf{A}$ ,
- redci matrice  $\mathbf{V}$  — sortirane osi varijabilnosti redaka  $\mathbf{A}$
- kriterij sortiranja: istaknutost, značaj pri raspoznavanju
- primjene: PCA, kompresija, analiza linearnih sustava

# LINEARNA ALGEBRA (5)

Zašto i kako SVD optimalno (L2) “rješava” homogene sustave?

## LINEARNA ALGEBRA (5)

Zašto i kako SVD optimalno (L2) “rješava” homogene sustave?

Neka je  $A = \mathbf{U}\mathbf{D}\mathbf{V}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \min_x \|\mathbf{D}\mathbf{V}^\top \mathbf{x}\|, \text{ uz } \|\mathbf{x}\| = 1$$

## LINEARNA ALGEBRA (5)

Zašto i kako SVD optimalno (L2) “rješava” homogene sustave?

Neka je  $A = \mathbf{U}\mathbf{D}\mathbf{V}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \min_x \|\mathbf{D}\mathbf{V}^\top \mathbf{x}\|, \text{ uz } \|\mathbf{x}\| = 1$$

Neka je  $\mathbf{q} = \mathbf{V}^\top \mathbf{x}$ ; tada vrijedi:

$$\|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \|\mathbf{D}\mathbf{q}\|, \text{ uz } \|\mathbf{q}\| = 1 \quad (*)$$

## LINEARNA ALGEBRA (5)

Zašto i kako SVD optimalno (L2) “rješava” homogene sustave?

Neka je  $A = \mathbf{U}\mathbf{D}\mathbf{V}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \min_x \|\mathbf{D}\mathbf{V}^\top \mathbf{x}\|, \text{ uz } \|\mathbf{x}\| = 1$$

Neka je  $\mathbf{q} = \mathbf{V}^\top \mathbf{x}$ ; tada vrijedi:

$$\|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \|\mathbf{D}\mathbf{q}\|, \text{ uz } \|\mathbf{q}\| = 1 \quad (*)$$

Elementi  $\mathbf{D}$  su pozitivni i padajući, pa  $\mathbf{q}$  koji minimizira (\*) iznosi

$$\mathbf{q} = \begin{bmatrix} 0 & 0 & \dots & 1 \end{bmatrix}^\top$$

## LINEARNA ALGEBRA (5)

Zašto i kako SVD optimalno (L2) “rješava” homogene sustave?

Neka je  $A = \mathbf{U}\mathbf{D}\mathbf{V}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \min_x \|\mathbf{D}\mathbf{V}^\top \mathbf{x}\|, \text{ uz } \|\mathbf{x}\| = 1$$

Neka je  $\mathbf{q} = \mathbf{V}^\top \mathbf{x}$ ; tada vrijedi:

$$\|\mathbf{U}\mathbf{D}\mathbf{V}^\top \mathbf{x}\| = \|\mathbf{D}\mathbf{q}\|, \text{ uz } \|\mathbf{q}\| = 1 \quad (*)$$

Elementi  $\mathbf{D}$  su pozitivni i padajući, pa  $\mathbf{q}$  koji minimizira (\*) iznosi

$$\mathbf{q} = \begin{bmatrix} 0 & 0 & \dots & 1 \end{bmatrix}^\top$$

Odatle slijedi ono što je trebalo dokazati:  $\mathbf{x} = \mathbf{V}\mathbf{q} = \mathbf{V}_{:,n}$   $\square$

# LINEARNA ALGEBRA (6)

Zašto i kako SVD optimalno (L2) “rješava” nehomogene sustave?

## LINEARNA ALGEBRA (6)

Zašto i kako SVD optimalno (L2) “rješava” **nehomogene** sustave?

Promotrimo sustav  $\mathbf{Ax} - \mathbf{b} \rightarrow \min$ .

Neka je  $\mathbf{A} = \mathbf{UDV}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{UDV}^\top \mathbf{x} - \mathbf{b}\| = \min_x \|\mathbf{Dq} - \mathbf{U}^\top \mathbf{b}\|, \text{ uz } \mathbf{q} = \mathbf{V}^\top \mathbf{x}$$



## LINEARNA ALGEBRA (6)

Zašto i kako SVD optimalno (L2) “rješava” nehomogene sustave?

Promotrimo sustav  $\mathbf{Ax} - \mathbf{b} \rightarrow \min$ .

Neka je  $\mathbf{A} = \mathbf{UDV}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{UDV}^\top \mathbf{x} - \mathbf{b}\| = \min_x \|\mathbf{Dq} - \mathbf{U}^\top \mathbf{b}\|, \text{ uz } \mathbf{q} = \mathbf{V}^\top \mathbf{x}$$

Izrazimo traženi rezidual zbrojem kvadrata komponenata (L2):

$$\|\mathbf{Dq} - \mathbf{U}^\top \mathbf{b}\| = \sum_i (d_i q_i - \mathbf{u}_i^\top \mathbf{b})^2 = \sum_{i=1}^r (d_i q_i - \mathbf{u}_i^\top \mathbf{b})^2 + \sum_{i=r+1}^n (\mathbf{u}_i^\top \mathbf{b})^2$$

## LINEARNA ALGEBRA (6)

Zašto i kako SVD optimalno (L2) “rješava” nehomogene sustave?

Promotrimo sustav  $\mathbf{Ax} - \mathbf{b} \rightarrow \min$ .

Neka je  $\mathbf{A} = \mathbf{UDV}^\top$ ; tada tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_x \|\mathbf{UDV}^\top \mathbf{x} - \mathbf{b}\| = \min_x \|\mathbf{Dq} - \mathbf{U}^\top \mathbf{b}\|, \text{ uz } \mathbf{q} = \mathbf{V}^\top \mathbf{x}$$

Izrazimo traženi rezidual zbrojem kvadrata komponenata (L2):

$$\|\mathbf{Dq} - \mathbf{U}^\top \mathbf{b}\| = \sum_i (d_i q_i - \mathbf{u}_i^\top \mathbf{b})^2 = \sum_{i=1}^r (d_i q_i - \mathbf{u}_i^\top \mathbf{b})^2 + \sum_{i=r+1}^n (\mathbf{u}_i^\top \mathbf{b})^2$$

Sad se vidi da za minimum mora biti  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i, i = 1 : r$   
(za ostale  $i$ , proizvoljno odabiremo  $q_i = 0$ )

# LINEARNA ALGEBRA (7)

Kako SVD optimalno (L2) “rješava” nehomogene sustave? (2)

Pronašli smo  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i, i = 1 : r$ , koliki je  $\mathbf{x} = \mathbf{V}\mathbf{q}$ ?

# LINEARNA ALGEBRA (7)

Kako SVD optimalno (L2) “rješava” nehomogene sustave? (2)

Pronašli smo  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i, i = 1 : r$ , koliki je  $\mathbf{x} = \mathbf{V}\mathbf{q}$ ?

Uvrštavamo  $q_i$  i žongliramo skalarnim produktom...

$$\mathbf{x} = \sum_{i=1}^r q_i \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{u}_i^\top \mathbf{b}}{d_i} \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{v}_i \mathbf{u}_i^\top}{d_i} \cdot \mathbf{b}$$

## LINEARNA ALGEBRA (7)

Kako SVD optimalno (L2) “rješava” nehomogene sustave? (2)

Pronašli smo  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i, i = 1 : r$ , koliki je  $\mathbf{x} = \mathbf{V}\mathbf{q}$ ?

Uvrštavamo  $q_i$  i žongliramo skalarnim produktom...

$$\mathbf{x} = \sum_{i=1}^r q_i \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{u}_i^\top \mathbf{b}}{d_i} \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{v}_i \mathbf{u}_i^\top}{d_i} \cdot \mathbf{b}$$

Konačno, rješenje sustava  $\mathbf{A}\mathbf{x} = \mathbf{b} \rightarrow \min$  je:

$$\mathbf{x} = \mathbf{V}\mathbf{D}^+ \mathbf{U}^\top \cdot \mathbf{b} = \mathbf{A}^+ \mathbf{b}$$

## LINEARNA ALGEBRA (7)

Kako SVD optimalno (L2) “rješava” nehomogene sustave? (2)

Pronašli smo  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i, i = 1 : r$ , koliki je  $\mathbf{x} = \mathbf{V}\mathbf{q}$ ?

Uvrštavamo  $q_i$  i žongliramo skalarnim produktom...

$$\mathbf{x} = \sum_{i=1}^r q_i \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{u}_i^\top \mathbf{b}}{d_i} \cdot \mathbf{v}_i = \sum_{i=1}^r \frac{\mathbf{v}_i \mathbf{u}_i^\top}{d_i} \cdot \mathbf{b}$$

Konačno, rješenje sustava  $\mathbf{A}\mathbf{x} = \mathbf{b} \rightarrow \min$  je:

$$\mathbf{x} = \mathbf{V}\mathbf{D}^+ \mathbf{U}^\top \cdot \mathbf{b} = \mathbf{A}^+ \mathbf{b}$$

$\mathbf{A}^+$  ... pseudoinverz od  $\mathbf{A}$  (Moore - Penrose)

# LINEARNA ALGEBRA (8)

Kako SVD “rješava” sustave s **manjkom** ograničenja?

## LINEARNA ALGEBRA (8)

Kako SVD “rješava” sustave s **manjkom** ograničenja?

Npr: koje sve ravnine prolaze kroz zadane dvije točke?



## LINEARNA ALGEBRA (8)

Kako SVD “rješava” sustave s **manjkom** ograničenja?

Npr: koje sve ravnine prolaze kroz zadane dvije točke?

Homogeni sustav  $\min_x \|\mathbf{A}_{m \times n} \cdot \mathbf{x}\|$ , uz  $\|\mathbf{x}\| = 1$  može imati:

- rješenje u smislu LS, ako  $\text{rang}(\mathbf{A}) = n$
- točno rješenje, ako  $\text{rang}(\mathbf{A}) = n - 1$
- beskonačno rješenja, ako  $\text{rang}(\mathbf{A}) < n - 1$

## LINEARNA ALGEBRA (8)

Kako SVD “rješava” sustave s **manjkom** ograničenja?

Npr: koje sve ravnine prolaze kroz zadane dvije točke?

Homogeni sustav  $\min_x \|\mathbf{A}_{m \times n} \cdot \mathbf{x}\|$ , uz  $\|\mathbf{x}\| = 1$  može imati:

- rješenje u smislu LS, ako  $\text{rang}(\mathbf{A}) = n$
- točno rješenje, ako  $\text{rang}(\mathbf{A}) = n - 1$
- beskonačno rješenja, ako  $\text{rang}(\mathbf{A}) < n - 1$

U posljednjem slučaju, potprostor rješenja je:

$$\text{null}(\mathbf{A}) = \text{span}\{\mathbf{v}_i, i = r + 1, \dots, n\}$$

## LINEARNA ALGEBRA (8)

Kako SVD “rješava” sustave s **manjkom** ograničenja?

Npr: koje sve ravnine prolaze kroz zadane dvije točke?

Homogeni sustav  $\min_x \|\mathbf{A}_{m \times n} \cdot \mathbf{x}\|$ , uz  $\|\mathbf{x}\| = 1$  može imati:

- rješenje u smislu LS, ako  $\text{rang}(\mathbf{A}) = n$
- točno rješenje, ako  $\text{rang}(\mathbf{A}) = n - 1$
- beskonačno rješenja, ako  $\text{rang}(\mathbf{A}) < n - 1$

U posljednjem slučaju, potprostor rješenja je:

$$\text{null}(\mathbf{A}) = \text{span}\{\mathbf{v}_i, i = r + 1, \dots, n\}$$

Rješenja nehomogenog sustava dobivamo kao zbroj:

- potprostora rješenja homogenog sustava, i
- nekog partikularnog rješenja

# KONDICIONIRANJE LINEARNOG SUSTAVA

Razmotrimo homogeni preograničeni sustav (koji minimizira algebarski kriterij):

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A} \cdot \mathbf{x}|, \text{ uz } |\mathbf{x}| = 1$$

# KONDICIONIRANJE LINEARNOG SUSTAVA

Razmotrimo homogeni preograničeni sustav (koji minimizira algebarski kriterij):

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A} \cdot \mathbf{x}|, \text{ uz } |\mathbf{x}| = 1$$

$\hat{\mathbf{x}}$  je rješenje sustava  $\mathbf{A}_F \cdot \mathbf{x} = 0$ , gdje je  $\mathbf{A}_F$  defektna matrica najbliža  $\mathbf{A}$  (u smislu Frobeniusove norme)

# KONDICIONIRANJE LINEARNOG SUSTAVA

Razmotrimo homogeni preograničeni sustav (koji minimizira algebarski kriterij):

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A} \cdot \mathbf{x}|, \text{ uz } |\mathbf{x}| = 1$$

$\hat{\mathbf{x}}$  je rješenje sustava  $\mathbf{A}_F \cdot \mathbf{x} = 0$ , gdje je  $\mathbf{A}_F$  defektna matrica najbliža  $\mathbf{A}$  (u smislu Frobeniusove norme)

Ključ kvalitete rješenja je u razdiobi šuma  $\mathbf{D}$  u matrici sustava  $\mathbf{A}$ :

$$\mathbf{D} = \mathbf{A} - \hat{\mathbf{A}}$$

# KONDICIONIRANJE LINEARNOG SUSTAVA

Razmotrimo homogeni preograničeni sustav (koji minimizira algebarski kriterij):

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A} \cdot \mathbf{x}|, \text{ uz } |\mathbf{x}| = 1$$

$\hat{\mathbf{x}}$  je rješenje sustava  $\mathbf{A}_F \cdot \mathbf{x} = 0$ , gdje je  $\mathbf{A}_F$  defektna matrica najbliža  $\mathbf{A}$  (u smislu Frobeniusove norme)

Ključ kvalitete rješenja je u razdiobi šuma  $\mathbf{D}$  u matrici sustava  $\mathbf{A}$ :

$$\mathbf{D} = \mathbf{A} - \hat{\mathbf{A}}$$

Neravnomjerno raspoređen šum  $\Rightarrow$  **pristrano** rješenje!

# KONDICIONIRANJE LINEARNOG SUSTAVA

Razmotrimo homogeni preograničeni sustav (koji minimizira algebarski kriterij):

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A} \cdot \mathbf{x}|, \text{ uz } |\mathbf{x}| = 1$$

$\hat{\mathbf{x}}$  je rješenje sustava  $\mathbf{A}_F \cdot \mathbf{x} = 0$ , gdje je  $\mathbf{A}_F$  defektna matrica najbliža  $\mathbf{A}$  (u smislu Frobeniusove norme)

Ključ kvalitete rješenja je u razdiobi šuma  $\mathbf{D}$  u matrici sustava  $\mathbf{A}$ :

$$\mathbf{D} = \mathbf{A} - \hat{\mathbf{A}}$$

Neravnomjerno raspoređen šum  $\Rightarrow$  **pristrano** rješenje!

Obratiti pažnju na razdiobu šuma po stupcima i po redcima matrice sustava!



# KONDICIONIRANJE LINEARNOG SUSTAVA (2)

Razdioba šuma u matrici sustava pospješuje se **kondicioniranjem**

# KONDICIONIRANJE LINEARNOG SUSTAVA (2)

Razdioba šuma u matrici sustava pospješuje se **kondicioniranjem**

Teorijski dobro utemeljen pristup je **uravnoteživanje** [Muehlich98]

## KONDICIONIRANJE LINEARNOG SUSTAVA (2)

Razdioba šuma u matrici sustava pospješuje se **kondicioniranjem**

Teorijski dobro utemeljen pristup je **uravnoteživanje** [Muehlich98]

Matrica sustava se množi s lijeva i s desne prikladnim kvadratnim matricama punog ranga:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A}_{eq} \cdot \mathbf{x}'|, \text{ gdje su} \quad (7)$$

$$\mathbf{A}_{eq} = \mathbf{W}_L \cdot \mathbf{A} \cdot \mathbf{W}_R, \quad (8)$$

$$\mathbf{x}' = \mathbf{W}_R^{-1} \cdot \mathbf{x} \quad (9)$$

## KONDICIONIRANJE LINEARNOG SUSTAVA (2)

Razdioba šuma u matrici sustava pospješuje se **kondicioniranjem**

Teorijski dobro utemeljen pristup je **uravnoteživanje** [Muehlich98]

Matrica sustava se množi s lijeva i s desne prikladnim kvadratnim matricama punog ranga:

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} |\mathbf{A}_{eq} \cdot \mathbf{x}'|, \text{ gdje su} \quad (10)$$

$$\mathbf{A}_{eq} = \mathbf{W}_L \cdot \mathbf{A} \cdot \mathbf{W}_R, \quad (11)$$


$$\mathbf{x}' = \mathbf{W}_R^{-1} \cdot \mathbf{x} \quad (12)$$

Cilj je **ravnomjerno** raspoređen **šum** u  $\mathbf{A}_{eq}$ :

$$E[\mathbf{D}_{eq}^\top \mathbf{D}_{eq}] = c \cdot \mathbf{I}, \text{ gdje je } \mathbf{D}_{eq} = \mathbf{A}_{eq} - \hat{\mathbf{A}}_{eq}$$

# KRITERIJI ESTIMACIJE

Vratimo se na problem provlačenja  $p(q_i)$




# KRITERIJI ESTIMACIJE

Vratimo se na problem provlačenja  $p(q_i)$

Što fali **algebarskom** projekcijskom kriteriju:

$$\hat{\mathbf{p}}_{alg} = \arg \min_{\mathbf{p}} \mathbf{A}_{m \times 3} \cdot \mathbf{p}, \quad \text{gdje je } \mathbf{A}_{i,:} = \mathbf{q}_i^\top$$

- nema eksplicitnog modela šuma
- ne minimizira smislenu funkciju cilja




# KRITERIJI ESTIMACIJE

Vratimo se na problem provlačenja  $p(q_i)$

Što fali **algebarskom** projekcijskom kriteriju:

$$\hat{\mathbf{p}}_{alg} = \arg \min_{\mathbf{p}} \mathbf{A}_{m \times 3} \cdot \mathbf{p}, \quad \text{gdje je } \mathbf{A}_{i,:} = \mathbf{q}_i^\top$$

- nema eksplicitnog modela šuma
- ne minimizira smislenu funkciju cilja



Kriterij optimizacije dobivamo uvrštanjem podataka s eksplicitno modeliranim šumom  $(x_i, \bar{y}_i + \delta y_i)$ :

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} p_2 \cdot \sum \Delta y_i^2, \quad \text{uz } \sqrt{p_1^2 + p_2^2 + p_3^2} = 1$$


# KRITERIJI ESTIMACIJE

Vratimo se na problem provlačenja  $p(q_i)$

Što fali **algebarskom** projekcijskom kriteriju:

$$\hat{\mathbf{p}}_{alg} = \arg \min_{\mathbf{p}} \mathbf{A}_{m \times 3} \cdot \mathbf{p}, \quad \text{gdje je } \mathbf{A}_{i,:} = \mathbf{q}_i^\top$$

- nema eksplicitnog modela šuma
- ne minimizira smislenu funkciju cilja



Kriterij optimizacije dobivamo uvrštanjem podataka s eksplicitno modeliranim šumom  $(x_i, \bar{y}_i + \delta y_i)$ :

$$\hat{\mathbf{p}} = \arg \min_{\mathbf{p}} p_2 \cdot \sum \Delta y_i^2, \quad \text{uz } \sqrt{p_1^2 + p_2^2 + p_3^2} = 1$$

Kriterij je **pristran** jer favorizira pravce s malim  $p_2$ !



## KRITERIJI ESTIMACIJE (2)

Bolje rješenje dobivamo parametrizacijom  $\mathbf{p} = (k, l)$ , koja dozvoljava modeliranje **geometrijskog** kriterija:

$$\hat{\mathbf{p}}_{g1} = \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\| \quad (13)$$

$$= \mathbf{A}_{m \times 2} \cdot \mathbf{p}_2 - \mathbf{y}_m, \quad \text{gdje je } \mathbf{A}_{i,:} = \begin{bmatrix} x_i & 1 \end{bmatrix} \quad (14)$$

## KRITERIJI ESTIMACIJE (2)

Bolje rješenje dobivamo parametrizacijom  $\mathbf{p} = (k, l)$ , koja dozvoljava modeliranje **geometrijskog** kriterija:

$$\hat{\mathbf{p}}_{g1} = \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\| \quad (15)$$

$$= \mathbf{A}_{m \times 2} \cdot \mathbf{p}_2 - \mathbf{y}_m, \quad \text{gdje je } \mathbf{A}_{i,:} = \begin{bmatrix} x_i & 1 \end{bmatrix} \quad (16)$$

Kad uvrstimo degradirani podatak  $(x_i, \bar{y}_i + \delta y_i)$ : vidimo da  $i$ -ti rezidual  $r_i$  iznosi upravo  $\delta y_i$

## KRITERIJI ESTIMACIJE (2)

Bolje rješenje dobivamo parametrizacijom  $\mathbf{p} = (k, l)$ , koja dozvoljava modeliranje **geometrijskog** kriterija:

$$\hat{\mathbf{p}}_{g1} = \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\| \quad (17)$$

$$= \mathbf{A}_{m \times 2} \cdot \mathbf{p}_2 - \mathbf{y}_m, \quad \text{gdje je } \mathbf{A}_{i,:} = \begin{bmatrix} x_i & 1 \end{bmatrix} \quad (18)$$

Kad uvrstimo degradirani podatak  $(x_i, \bar{y}_i + \delta y_i)$ : vidimo da  $i$ -ti rezidual  $r_i$  iznosi upravo  $\delta y_i$


Stoga će rješenje

$$\mathbf{p} = \mathbf{A}^+ \mathbf{y}$$

biti pravac s minimalnim ukupnim kvadratnim odstupanjem od zadanih točaka (pravac s najvećom *vjerodostojnošću*)

# KRITERIJI ESTIMACIJE (3)

Idemo provjeriti teoriju za točke sa slike:  
(1,6); (2,5); (3,7); (4,10)




# KRITERIJI ESTIMACIJE (3)

Idemo provjeriti teoriju za točke sa slike:  
(1,6); (2,5); (3,7); (4,10)

$\mathbf{A}_A$  — matrica algebarske formulacije ( $4 \times 3$ )

$\mathbf{A}_G$  — matrica geometrijske formulacije ( $4 \times 2$ )




# KRITERIJI ESTIMACIJE (3)

Idemo provjeriti teoriju za točke sa slike:  
(1,6); (2,5); (3,7); (4,10)

$\mathbf{A}_A$  — matrica algebarske formulacije ( $4 \times 3$ )

$\mathbf{A}_G$  — matrica geometrijske formulacije ( $4 \times 2$ )



Izvorni kod u octaveu:

```
Aa=[1 6 1; 2 5 1; 3 7 1; 4 10 1];  
[U,D,V]=svd(Aa); v3=V(:,3);  
kla=[-v3(1)/v3(2); -v3(3)/v3(2)];
```


```
Ag=[1 1; 2 1; 3 1; 4 1];  
y=[6;5;7;10];  
klg=pinv(Ag)*y;
```

# KRITERIJI ESTIMACIJE (3)

Idemo provjeriti teoriju za točke sa slike:  
(1,6); (2,5); (3,7); (4,10)

$\mathbf{A}_A$  — matrica algebarske formulacije ( $4 \times 3$ )

$\mathbf{A}_G$  — matrica geometrijske formulacije ( $4 \times 2$ )



Izvorni kod u octaveu:

```
Aa=[1 6 1; 2 5 1; 3 7 1; 4 10 1];  
[U,D,V]=svd(Aa); v3=V(:,3);  
kla=[-v3(1)/v3(2); -v3(3)/v3(2)];
```

```
Ag=[1 1; 2 1; 3 1; 4 1];  
y=[6;5;7;10];  
klg=pinv(Ag)*y;
```

```
disp(kla) // [ 0.9; 5.0 ]
```

```
disp(klg) // [ 1.4; 3.5 ]
```

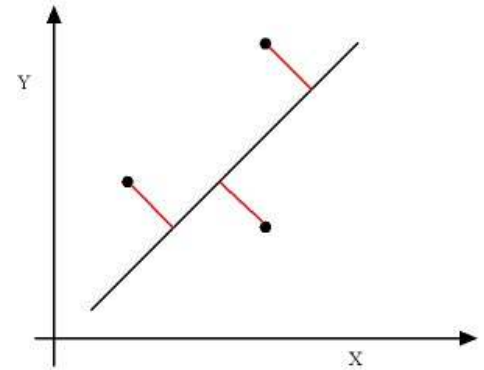
```
disp(norm(Ag*kla-y)) // 2.4
```

```
disp(norm(Ag*klg-y)) // 2.0
```

# KRITERIJI ESTIMACIJE (4)

Ali što ako šum djeluje na obje koordinate (TLS)

$$\delta x, \delta y \sim \mathcal{N}(0, \sigma^2)?$$






## KRITERIJI ESTIMACIJE (4)

Ali što ako šum djeluje na obje koordinate (TLS)

$$\delta x, \delta y \sim \mathcal{N}(0, \sigma^2)?$$




Onda nam prošli kriteriji (alg, g1) neće dati optimalno rješenje

$$\begin{aligned}\hat{\mathbf{p}}_{g2} &= \arg \min_{\mathbf{p}} \sum_i d^2(\mathbf{p}, \mathbf{q}_i) \\ &= \arg \min_{\mathbf{p}} \sum_i \frac{(p_1 q_x + p_2 q_y + p_3)^2}{p_1^2 + p_2^2}\end{aligned}$$

## KRITERIJI ESTIMACIJE (4)

Ali što ako šum djeluje na obje koordinate (TLS)

$$\delta x, \delta y \sim \mathcal{N}(0, \sigma^2)?$$



Onda nam prošli kriteriji (alg, g1) neće dati optimalno rješenje

$$\begin{aligned}\hat{\mathbf{p}}_{g2} &= \arg \min_{\mathbf{p}} \sum_i d^2(\mathbf{p}, \mathbf{q}_i) \\ &= \arg \min_{\mathbf{p}} \sum_i \frac{(p_1 q_x + p_2 q_y + p_3)^2}{p_1^2 + p_2^2}\end{aligned}$$

Novi kriterij (g2) je **nelinearan** pa ga **ne možemo** optimirati algebarskom minimizacijom!

## KRITERIJI ESTIMACIJE (5)

Situacija da se geometrijski kriterij ne da izraziti u okviru linearnog sustava je vrlo **česta!**

## KRITERIJI ESTIMACIJE (5)

Situacija da se geometrijski kriterij ne da izraziti u okviru linearnog sustava je vrlo **česta!**

Nameće se zaključak da najbolje rezultate nećemo moći dobiti bez **nelinearne optimizacije** (npr, gradijentni spust)

## KRITERIJI ESTIMACIJE (5)

Situacija da se geometrijski kriterij ne da izraziti u okviru linearnog sustava je vrlo **česta!**

Nameće se zaključak da najbolje rezultate nećemo moći dobiti bez **nelinearne optimizacije** (npr, gradijentni spust)

Da li su linearne metode estimacije beskorisne?  
(Projective geometry considered harmful, IJCV99)

## KRITERIJI ESTIMACIJE (5)

Situacija da se geometrijski kriterij ne da izraziti u okviru linearnog sustava je vrlo **česta!**

Nameće se zaključak da najbolje rezultate nećemo moći dobiti bez **nelinearne optimizacije** (npr, gradijentni spust)

Da li su linearne metode estimacije beskorisne?  
(Projective geometry considered harmful, IJCV99)

Ipak, odgovor je po svoj prilici ne, jer:


- linearna metoda je često jedini izbor kad nemamo početnu aproksimaciju
- ovisno o problemu, linearni rezultat može biti gotovo jednako upotrebljiv kao i geometrijski
- linearne metode mogu se dramatično poboljšati kondicioniranjem (In Defense of the Eight-Point Algorithm, DAM11007)

# KRITERIJI ESTIMACIJE (6)

Za radoznale, u slučaju pravca, kriterij  $g_2$  se da izraziti metodom PCA.

Program u Octave-u (dolje), te tri pravca (desno)

```
A_alg=[1 6 1; 2 5 1; 3 7 1; 4 10 1];  
A_g2=A_alg(:,1:2);  
mu_g2=mean(A_g2);  
A_g2_mu=A_g2 - [1;1;1;1]*mu_g2;  
[U_g2,D_g2,V_g2]=svd(A_g2_mu);  
k_g2=V_g2(2,1)/V_g2(1,1)  
l_g2=mu_g2(2)-k_g2*mu_g2(1)
```



	alg	g1	g2
$\hat{k}$	0.9	1.4	1.8
$\hat{l}$	5.0	3.5	2.4

# KRITERIJI ESTIMACIJE (7)

## **Statistički kriteriji estimacije**



# KRITERIJI ESTIMACIJE (7)

## Statistički kriteriji estimacije

Pretpostavimo model  $\mathcal{M}(\mathbf{p})$ , npr,  $\mathbf{p} = (k, l)$ , te da na temelju mjerenja  $\mathbf{o}$  (npr,  $\mathbf{o} = \mathbf{y}$ ) želimo ocijeniti parametre modela  $\mathbf{p}$

# KRITERIJI ESTIMACIJE (7)

## Statistički kriteriji estimacije

Pretpostavimo model  $\mathcal{M}(\mathbf{p})$ , npr,  $\mathbf{p} = (k, l)$ , te da na temelju mjerenja  $\mathbf{o}$  (npr,  $\mathbf{o} = \mathbf{y}$ ) želimo ocijeniti parametre modela  $\mathbf{p}$

Statistički kriterij za vrednovanje  $\mathbf{p}$ : **maksimizirati** vjerojatnost opažanja  $\mathbf{o}$  pod pretpostavkom  $\mathcal{M}(\mathbf{p})$ !

# KRITERIJI ESTIMACIJE (7)

## Statistički kriteriji estimacije

Pretpostavimo model  $\mathcal{M}(\mathbf{p})$ , npr,  $\mathbf{p} = (k, l)$ , te da na temelju mjerenja  $\mathbf{o}$  (npr,  $\mathbf{o} = \mathbf{y}$ ) želimo ocijeniti parametre modela  $\mathbf{p}$

Statistički kriterij za vrednovanje  $\mathbf{p}$ : **maksimizirati** vjerojatnost opažanja  $\mathbf{o}$  pod pretpostavkom  $\mathcal{M}(\mathbf{p})$ !

Uvjetnu vjerojatnost opažanja s obzirom na model nazivamo **vjerodostojnošću** modela:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o} | \mathcal{M}(\mathbf{p}))$$

# KRITERIJI ESTIMACIJE (7)

## Statistički kriteriji estimacije

Pretpostavimo model  $\mathcal{M}(\mathbf{p})$ , npr,  $\mathbf{p} = (k, l)$ , te da na temelju mjerenja  $\mathbf{o}$  (npr,  $\mathbf{o} = \mathbf{y}$ ) želimo ocijeniti parametre modela  $\mathbf{p}$

Statistički kriterij za vrednovanje  $\mathbf{p}$ : **maksimizirati** vjerojatnost opažanja  $\mathbf{o}$  pod pretpostavkom  $\mathcal{M}(\mathbf{p})$ !

Uvjetnu vjerojatnost opažanja s obzirom na model nazivamo **vjerodostojnošću** modela:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o} | \mathcal{M}(\mathbf{p}))$$

Kriterij **maksimalne vjerodostojnosti (MLE)** izražavamo:

$$\hat{\mathbf{p}}_{MLE} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p})$$

## KRITERIJI ESTIMACIJE (8)

Izvedimo MLE kriterij za provlačenje pravca kroz skup točaka

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} p(\mathbf{y} | \mathcal{M}(\mathbf{p}))$$

## KRITERIJI ESTIMACIJE (8)

Izvedimo MLE kriterij za provlačenje pravca kroz skup točaka

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} p(\mathbf{y} | \mathcal{M}(\mathbf{p}))$$

Izrazimo gustoću vjerojatnosti pojedinačnog mjerenja  $y_i$ ;  
pretp.  $y_i \sim \mathcal{N}(\bar{y}_i, \sigma)$  (**normalno distribuirani, nepristrani**):

$$p(y_i | \bar{y}_i) \sim e^{-\frac{(y_i - \bar{y}_i)^2}{2\sigma^2}}$$

## KRITERIJI ESTIMACIJE (8)

Izvedimo MLE kriterij za provlačenje pravca kroz skup točaka

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} p(\mathbf{y} | \mathcal{M}(\mathbf{p}))$$

Izrazimo gustoću vjerojatnosti pojedinačnog mjerenja  $y_i$ ;  
pretp.  $y_i \sim \mathcal{N}(\bar{y}_i, \sigma)$  (**normalno distribuirani, nepristrani**):

$$p(y_i | \bar{y}_i) \sim e^{-\frac{(y_i - \bar{y}_i)^2}{2\sigma^2}}$$

Izrazimo sada gustoću vjerojatnosti cijelog skupa mjerenja, pod pretpostavkama **jednake disperzije i nezavisnosti**:

$$p(\mathbf{y} | \mathbf{p}, \mathbf{x}) \sim \prod_i e^{-\frac{(y_i - p_1 \cdot x_i - p_2)^2}{2\sigma^2}}$$

## KRITERIJI ESTIMACIJE (9)

Logaritam vjerodostojnosti sada je:

$$\log \mathcal{L}(\mathbf{p}) \sim -(y_i - p_1 \cdot x_i - p_2)^2$$



## KRITERIJI ESTIMACIJE (9)

Logaritam vjerodostojnosti sada je:

$$\log \mathcal{L}(\mathbf{p}) \sim -(y_i - p_1 \cdot x_i - p_2)^2$$

Pravac koji maksimira vjerodostojnost sad je:

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) = \arg \min_{\mathbf{p}} (-\log \mathcal{L}(\mathbf{p}))$$

## KRITERIJI ESTIMACIJE (9)

Logaritam vjerodostojnosti sada je:

$$\log \mathcal{L}(\mathbf{p}) \sim -(y_i - p_1 \cdot x_i - p_2)^2$$

Pravac koji maksimira vjerodostojnost sad je:

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) = \arg \min_{\mathbf{p}} (-\log \mathcal{L}(\mathbf{p}))$$

Dolazimo do **ekvivalencije** geometrijskog i MLE kriterija!

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) = \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\|$$

## KRITERIJI ESTIMACIJE (9)

Logaritam vjerodostojnosti sada je:

$$\log \mathcal{L}(\mathbf{p}) \sim -(y_i - p_1 \cdot x_i - p_2)^2$$

Pravac koji maksimira vjerodostojnost sad je:

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) = \arg \min_{\mathbf{p}} (-\log \mathcal{L}(\mathbf{p}))$$

Dolazimo do **ekvivalencije** geometrijskog i MLE kriterija!

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) = \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\|$$

Geometrijski kriterij **nije MLE**, kad god se šum ne može opisati dekorreliranim i identičnim normalnim razdiobama!

## KRITERIJI ESTIMACIJE (10)

Kriterij MLE —  $\mathbf{p}$  maksimira uvjetnu vjerojatnost opažanja  $\mathbf{o}$ , neovisno o apriornoj vjerojatnosti parametara:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o}|\mathcal{M}(\mathbf{p}))$$

## KRITERIJI ESTIMACIJE (10)

Kriterij MLE —  $\mathbf{p}$  maksimira uvjetnu vjerojatnost opažanja  $\mathbf{o}$ , neovisno o apriornoj vjerojatnosti parametara:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o}|\mathcal{M}(\mathbf{p}))$$

Ako se  $p(\mathbf{p})$  može modelirati, estimaciju možemo poboljšati!

## KRITERIJI ESTIMACIJE (10)

Kriterij MLE —  $\mathbf{p}$  maksimira uvjetnu vjerojatnost opažanja  $\mathbf{o}$ , neovisno o apriornoj vjerojatnosti parametara:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o}|\mathcal{M}(\mathbf{p}))$$

Ako se  $p(\mathbf{p})$  može modelirati, estimaciju možemo poboljšati!

Kriterij **MAP** —  $\mathbf{p}$  maksimira svoju posteriornu distribuciju:

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} p(\mathcal{M}(\mathbf{p})|\mathbf{o})$$

## KRITERIJI ESTIMACIJE (10)

Kriterij MLE —  $\mathbf{p}$  maksimira uvjetnu vjerojatnost opažanja  $\mathbf{o}$ , neovisno o apriornoj vjerojatnosti parametara:

$$\mathcal{L}(\mathbf{p}) = p(\mathbf{o}|\mathcal{M}(\mathbf{p}))$$

Ako se  $p(\mathbf{p})$  može modelirati, estimaciju možemo poboljšati!

Kriterij **MAP** —  $\mathbf{p}$  maksimira svoju posteriornu distribuciju:

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} p(\mathcal{M}(\mathbf{p})|\mathbf{o})$$

Gustoću vjerojatnosti  $p(\mathbf{p}|\mathbf{o})$  kriterija MAP (max. a posteriori) dobivamo primjenom Bayesovog teorema:

$$P(M|O) = \frac{P(O|M) P(M)}{P(O)}$$

## KRITERIJI ESTIMACIJE (11)

U našem slučaju, u brojniku imamo **vjerodostojnost** i **apriornu vjerojatnost**, a u nazivniku **normalizacijski faktor**

$$p(\mathbf{p}|\mathbf{o}) = \frac{p(\mathbf{o}|\mathbf{p}) \cdot p(\mathbf{p})}{p(\mathbf{o})} \sim \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$



## KRITERIJI ESTIMACIJE (11)

U našem slučaju, u brojniku imamo **vjerodostojnost** i **apriornu vjerojatnost**, a u nazivniku **normalizacijski faktor**

$$p(\mathbf{p}|\mathbf{o}) = \frac{p(\mathbf{o}|\mathbf{p}) \cdot p(\mathbf{p})}{p(\mathbf{o})} \sim \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$

Konačan izraz za estimator MAP je:

$$\hat{\mathbf{p}}_{MAP} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$

## KRITERIJI ESTIMACIJE (11)

U našem slučaju, u brojniku imamo **vjerodostojnost** i **apriornu vjerojatnost**, a u nazivniku **normalizacijski faktor**

$$p(\mathbf{p}|\mathbf{o}) = \frac{p(\mathbf{o}|\mathbf{p}) \cdot p(\mathbf{p})}{p(\mathbf{o})} \sim \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$

Konačan izraz za estimator MAP je:

$$\hat{\mathbf{p}}_{MAP} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$

MLE: model =  $\max p(\text{slika}|\text{model})$

MAP: model =  $\max p(\text{slika}|\text{model}) \cdot p(\text{model})$

## KRITERIJI ESTIMACIJE (11)

U našem slučaju, u brojniku imamo **vjerodostojnost** i **apriornu vjerojatnost**, a u nazivniku **normalizacijski faktor**

$$p(\mathbf{p}|\mathbf{o}) = \frac{p(\mathbf{o}|\mathbf{p}) \cdot p(\mathbf{p})}{p(\mathbf{o})} \sim \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$

Konačan izraz za estimator MAP je:

$$\hat{\mathbf{p}}_{MAP} = \arg \max_{\mathbf{p}} \mathcal{L}(\mathbf{p}) \cdot p(\mathbf{p})$$


MLE: model = max p(slika|model)

MAP: model = max p(slika|model) · p(model)

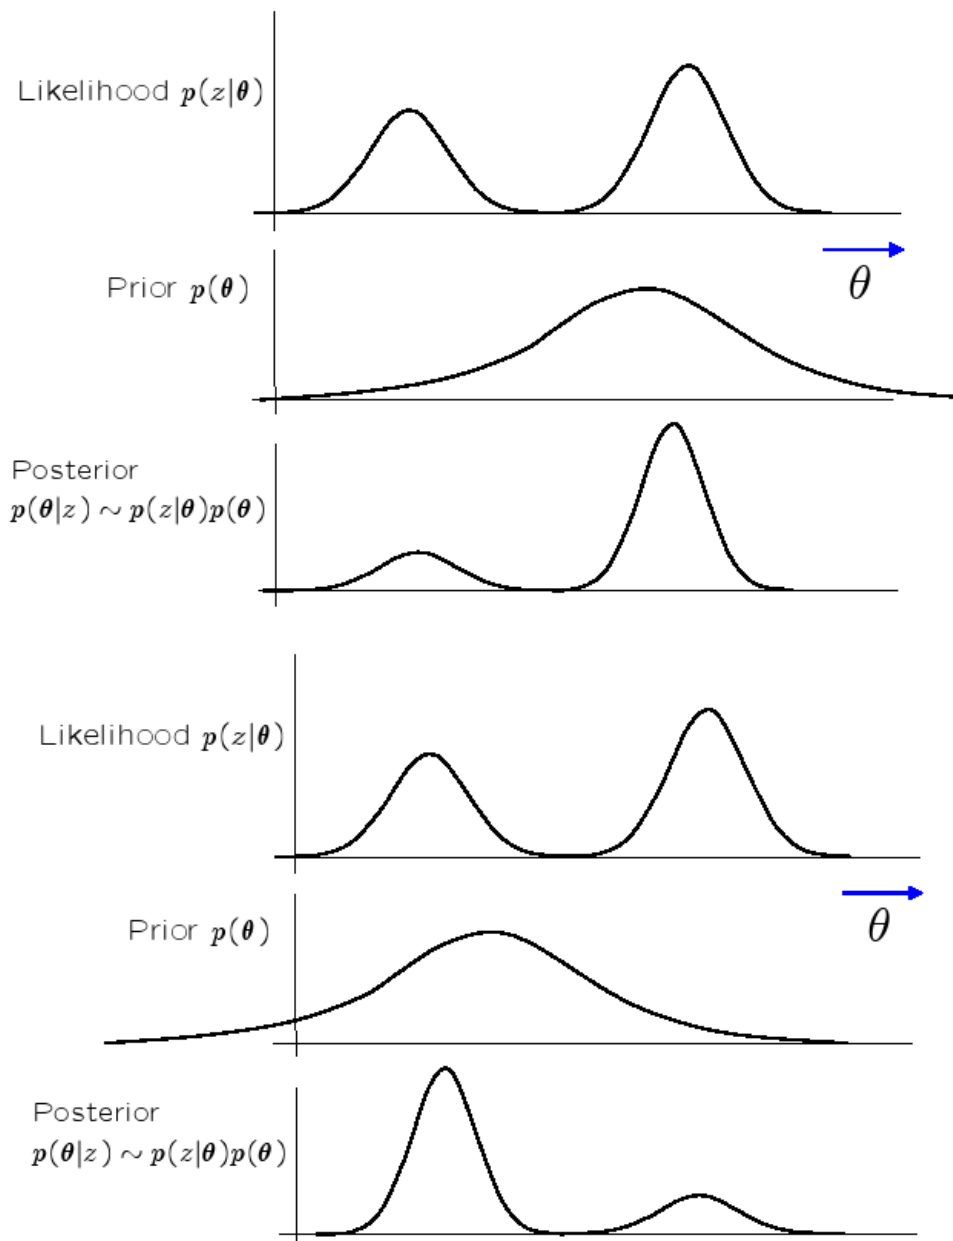
Vidjeli smo klokana. Jesmo li u Australiji?

Vidjeli smo nešto što podsjeća na znak. Da li je pokraj ceste?

# KRITERIJI ESTIMACIJE (12)



# KRITERIJI ESTIMACIJE (12)



[Zisserman01]

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju ✓

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju ✓
2. rezultat u prisustvu plauzibilnog šuma **statistički** povoljan



# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju ✓
2. rezultat u prisustvu plauzibilnog šuma **statistički** povoljan ✓

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju ✓
2. rezultat u prisustvu plauzibilnog šuma **statistički** povoljan ✓
3. vanpopulacijski parametri **ne ometaju** točan rezultat

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:



1. **svi** unutarpopulacijski podatci doprinose rješenju ✓
2. rezultat u prisustvu plauzibilnog šuma **statistički** povoljan ✓
3. vanpopulacijski parametri **ne ometaju** točan rezultat  
(to bismo sada, nažalost vrlo ukratko)

# ROBUSTNA ESTIMACIJA

Prisjetimo se **motivacije**:

1. **svi** unutarpopulacijski podatci doprinose rješenju ✓
2. rezultat u prisustvu plauzibilnog šuma **statistički** povoljan ✓
3. vanpopulacijski parametri **ne ometaju** točan rezultat (to bismo sada, nažalost vrlo ukratko)

Zašto outlieri mogu biti problem [Stewart99]?



## ROBUSTNA ESTIMACIJA (2)

Robustni pristupi u računalnom vidu:

1. Houghova transformacija
2. Evaluacija hipoteza dobivenih nad minimalnim slučajnim uzorkom  
Monte Carlo analiza, RANSAC, MLESAC, \*\*\*SAC, LMedSqr
3. Iterativno poboljšanje korištenjem robustnih normi:  
IRLS, M-estimacija

## ROBUSTNA ESTIMACIJA (2)

Robustni pristupi u računalnom vidu:

1. Houghova transformacija
2. Evaluacija hipoteza dobivenih nad minimalnim slučajnim uzorkom  
Monte Carlo analiza, RANSAC, MLESAC, \*\*\*SAC, LMedSqr
3. Iterativno poboljšanje korištenjem robustnih normi:  
IRLS, M-estimacija

(I to je sve...)