

# Dinamička analiza scena

## robusna procjena parametara

Siniša Šegvić i Zoran Kalafatić

UniZg-FER ZEMRIS

# Uvod

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

korisna kod **rekonstrukcijskih** pristupa:

- poravnavanje 2D objekata: translacija, sličnost, homografija
- položaj kamere: relativni (relative), absolutni (absolute pose)
- 3D geometrija scene.

**Ideja:**

- stvarni svijet predstaviti parametriziranim modelom
- **estimirati** (procijeniti) parametre iz velikog skupa opažanja statističkim metodama
- slično učenju, ali ovdje optimizaciju provodimo prilikom "zaključivanja".

## Uvod: MODEL

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

Npr, afinost 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

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

## Uvod: aproksimacija

Naši modeli često prepostavljaju pojednostavnjenu stvarnost:

- naša rješenja su aproksimacije
- odstupanja od prepostavki nazivamo šumom.

Afina i projekcijska poravnavanja prepostavljaju ravninske objekte.

Euklidska transformacija i epipolarno ograničenje prepostavljaju savršene korespondencije i nepokretnu scenu.

Algoritmi praćenja prepostavljaju konstantnu brzinu ili konstantnu akceleraciju itd.

## Uvod: MLE

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

Šum predstavlja odstupanja uslijed nesavršenog modela:

- 2D transformacija ne može objasniti deformacije objekata koji nisu planarni odnomo deformacije 3D objekata u prisustvu paralakse
- pronalaženje korespondencija ne može biti točno u piksel
- vanjski utjecaji: osvjetljenje, zamućenje, termalni šum, refleksije, prozirnosti, odsjaji...

**Ideja:** iz mnoštva djelomično kontradiktornih podataka izvući najizgledniju interpretaciju  $\theta$ :

$$\theta = \arg \max p(x_i|\theta)$$

## UVOD: ŠUM

Često prepostavljamo normalni nepristrani šum  
(normalna razdioba obično dobro opisuje znanje 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 u prisustvu šuma koji se ravna prema prepostavljenom modelu!

## UVOD: IZNIMKE

Koncept šuma primjenljiv samo za umjerena odstupanja

Za veća odstupanja potrebno uvesti koncept **izvanpopulacijskih** podataka (iznimke, anomalije, novine) 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 **robusne** metode koje mogu **detektirati** i **zanemariti** izvanpopulacijska mjerenja!

## UVOD: TEORIJA ESTIMACIJE

U računalnom vidu često obrađujemo redundantne podatke  
(dobivamo sustav jednadžbi s viškom ograničenja)

Naša obrada često napreduje u prisustvu šuma i iznimki.

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

Model **ovisnosti**:  $y = a \cdot x + b$

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



## LINEARNI SUSTAVI: VIŠAK OGRANIČENJA

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

Ako  $i$ -ta točka  $\mathbf{q}_i = [x, y, 1]$  prolazi kroz pravac  $\mathbf{p}$ , vrijedi:

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

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

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

U prisustvu šuma, gornja jednadžba 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: HOMOGENI SLUČAJ

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

- homogeneous linear least squares
- overconstrained homogeneous linear system

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

Rješenje odgovara desnom singularnom vektoru matrice **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: NEHOMOGENI SLUČAJ

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

# SVD: uvod

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

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

- $\mathbf{U}_{m \times m}$  ( $\mathbf{U}_{m \times n}$ ) ... 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 ( $\mathbf{v}_i^T \mathbf{v}_j = \delta_{ij}$ )
- $\mathbf{U}_{:,i} = \mathbf{u}_i$  ---  $i$ -ti lijevi singularni vektor ( $\mathbf{u}_i^T \mathbf{u}_j = \delta_{ij}$ )
  - $\|\mathbf{Ux}\| = (\mathbf{Ux})^T (\mathbf{Ux}) = \mathbf{x}^T \mathbf{U}^T \mathbf{Ux} = \mathbf{x}^T (\mathbf{U}^T \mathbf{U}) \mathbf{x} = \|\mathbf{x}\|$

## SVD: vs SVOJSTVENA

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

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

Za simetrične matrice, SVD odgovara svojstvenoj dekompoziciji:

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

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

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

## SVD: svojstva

SVD kao otežani zbroj vanjskih produkata:

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

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:  $\kappa(\mathbf{A}) = d_1/d_n$

## SVD: svojstva (2)

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

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  $d_i = 0, i = r_a, \dots, \max(m, n)!$
- retci matrice  $\mathbf{U}$  --- koeficijenti redaka  $\mathbf{A}$  u koordinatama rastegnutog prostora matrice  $\mathbf{V}$ ,
- kriterij sortiranja: istaknutost, značaj pri raspoznavanju
- primjene: PCA, kompresija, analiza linearnih sustava

## SVD: HOMOGENI SUSTAVI, VIŠAK OGRANIČENJA

Zašto i kako SVD **optimalno** (L2) ``rješava'' **homogene** sustave?

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

$$\min_{\mathbf{x}} \|\mathbf{UDV}^T \mathbf{x}\| = \min_{\mathbf{x}} \|\mathbf{DV}^T \mathbf{x}\|, \text{ uz } \|\mathbf{x}\| = 1$$

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

$$\|\mathbf{UDV}^T \mathbf{x}\| = \|\mathbf{Dq}\|, \text{ uz } \|\mathbf{q}\| = 1 \quad (*)$$

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

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

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

## SVD: NEHOMOGENI SUSTAVI, VIŠAK OGRANIČENJA

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

Rastavimo  $\mathbf{A}$  potpunim SVD-om ( $\mathbf{U}_{m \times m}$ ,  $\mathbf{D}_{m \times n}$ ):  $\mathbf{A} = \mathbf{UDV}^T$

- sada je  $\mathbf{U}$  kvadratna matrica pa lako dobivamo  $\mathbf{U}^{-1} = \mathbf{U}^T$ .

Tražimo  $\mathbf{x}$  koji zadovoljava:

$$\min_{\mathbf{x}} \|\mathbf{UDV}^T \mathbf{x} - \mathbf{b}\| = \min_{\mathbf{q}} \|\mathbf{D}\mathbf{q} - \mathbf{U}^T \mathbf{b}\|, \text{ uz } \mathbf{q} = \mathbf{V}^T \mathbf{x}$$

Dobili smo sustav  $m \times n$  u  $\mathbf{q}$ :

- veza između  $\mathbf{q}$  i  $\mathbf{x}$  je izravna i dvosmjerna jer se  $\mathbf{V}$  lako invertira
- treba uzeti u obzir da je  $\mathbf{D}$  pravokutna i možda defektna ( $r < n$ ).

## SVD: NEHOMOGENI SUSTAVI, VIŠAK OGRANIČENJA (2)

Raspišimo normu reziduala uz pokrate  $\mathbf{q} = \mathbf{V}^\top \mathbf{x}$  i  $\mathbf{c} = \mathbf{U}^\top \mathbf{b}$ :

$$\begin{aligned}\|\mathbf{A}\mathbf{x} - \mathbf{b}\|^2 &= \|\mathbf{U}^\top(\mathbf{A}\mathbf{x} - \mathbf{b})\|^2 = \|\mathbf{D}\mathbf{q} - \mathbf{c}\|^2 \\ &= \sum_{i=0}^r (d_i q_i - c_i)^2 + \sum_{i=r+1}^m (0 - c_i)^2 \\ &= \sum_i^r (d_i q_i - c_i)^2 + \sum_{i=r+1}^m c_i^2\end{aligned}$$

Norma zarotiranog reziduala sastoji se od dva člana:

- naše rješenje može utjecati samo na prvi član!
- drugi član odgovara projekciji vektora  $\mathbf{b}$  na null( $\mathbf{A}$ ).

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

## SVD: NEHOMOGENI SUSTAVI, VIŠAK OGRANIČENJA (2)

Vidjeli smo da mora biti:  $q_i = \mathbf{u}_i^\top \mathbf{b} / d_i$ ,  $i = 1 : r$ .

Koliki je  $\mathbf{x} = \mathbf{V}\mathbf{q}$ ?

Uvrštavamo  $q_i$  i žongliramo skalarnim produktom...

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

Odatle iščitavamo rješenje sustava  $\mathbf{Ax} - \mathbf{b} \rightarrow \min$ :

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

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

## SVD: MANJAK OGRANIČENJA

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

## SVD: KONDICIONIRANJE

Razmotrimo homogeni preograničeni sustav:

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

$\hat{\mathbf{x}}$  je rješenje sustava  $\hat{\mathbf{A}} \cdot \mathbf{x} = 0$ , gdje je  $\hat{\mathbf{A}}$  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!

## SVD: KONDICIONIRANJE (2)

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

Teorijski dobro utemeljen pristup je **uravnoteživanje** [hartley97pami, muehlich98eccv]

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

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

$$\mathbf{A}_{eq} = \mathbf{W}_L \cdot \mathbf{A} \cdot \mathbf{W}_R,$$

$$\mathbf{x}' = \mathbf{W}_R^{-1} \cdot \mathbf{x}$$

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

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


## KRITERIJI: ALGEBARSKI REZIDUAL

Vratimo se na algebarski projekcijski kriterij:

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

Nedostatak takvog rješenja:

- ne minimizira se smislena funkcija cilja



Projekcijski algebarski kriterij možemo razjasniti uvrštanjem podataka s eksplicitno modeliranim šumom  $\mathbf{q}_i = (x_i, y_i + \delta y_i, 1)$ :

$$\hat{\mathbf{p}}_{\text{alg}} = \arg \min_{\mathbf{p}} \sum_i (\mathbf{p}^\top (x_i, y_i, 1) + p_2 \cdot \delta y_i)^2 \quad \text{uz } \sqrt{p_1^2 + p_2^2 + p_3^2} = 1$$

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

## KRITERIJI: GEOMETRIJSKI REZIDUAL

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

$$\begin{aligned}\widehat{\mathbf{p}}_{g1} &= \arg \min_{\mathbf{p}} \sum_i \|p_1 \cdot x_i + p_2 - y_i\| \\ &= \mathbf{A}_{m \times 2} \cdot \mathbf{p}_2 - \mathbf{y}_m, \quad \text{gdje je } \mathbf{A}_{i,:} = \left[ \begin{array}{cc} x_i & 1 \end{array} \right]\end{aligned}$$

Ako uvrstimo degradirane podatke  $(x_i, y_i + \delta y_i)$  u **točan** pravac  $\mathbf{p}$ , 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

- vidjet ćemo da taj pravac maksimira *izglednost* pod pretpostavkom nezavisnog normalnog šuma


## KRITERIJI: EKSPERIMENT

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]; disp(kla) // [ 0.9; 5.0 ]
[U,D,V]=svd(Aa); v3=V(:,3);
kla=[-v3(1)/v3(2); -v3(3)/v3(2)]; disp(klg) // [ 1.4; 3.5 ]


Ag=[1 1; 2 1; 3 1; 4 1]; disp(norm(Ag*kla-y)) // 2.4
y=[6;5;7;10];
klg=pinv(Ag)*y; disp(norm(Ag*klg-y)) // 2.0
```

## KRITERIJI: TLS

Ako šum djeluje na obje koordinate, onda imamo problem najmanjih "potpunih" kvadrata

- eng. total least squares:

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



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

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

Novi kriterij (g2) je **nelinearan** iako je model linearan:

- na prvi pogled, **ne možemo** ga optimirati algebarski
- preostaje numerička optimizacija (SGD, Gauss-Newton, ...)

## KRITERIJI: NELINEARNA OPTIMIZACIJA

Optimizacija geometrijskih kriterija **često** se ne da izraziti linearnim jednadžbama!

U takvim slučajevima, najbolje rezultate nećemo moći dobiti bez **nelinearne optimizacije** (npr. gradijentni spust)

Jesu li onda linearne metode estimacije beskorisne?  
(Projective geometry considered harmful, IJCV99)

Ipak, odgovor je po svoj prilici ne, jer:


- linearna metoda jedini izbor kad nemamo početnu aproksimaciju
- linearni rezultat može biti jednako upotrebljiv kao i geometrijski
- linearne metode mogu se dramatično poboljšati kondicioniranjem  
(In Defense of the Eight-Point Algorithm, PAMI1997)

## KRITERIJI: TLS (2)

Pažljivija analiza pokazuje da u ovom slučaju kriterij g2 možemo optimirati u zatvorenom obliku metodom PCA.

Program u Octave-u (dolje), te tri provučena 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: TLS (3)

```
Ag2 = np.array([[1,6],[2,5],[3,7],[4,10]])  
center = np.mean(Ag2, axis=0)
```

```
[U,D,Vt]=np.linalg.svd(Ag2 - center)
```

```
nabc_g2 = np.append(Vt[1,:], -np.dot(Vt[1,:],center))
```

```
Aa = np.array([[1,6,1],[2,5,1],[3,7,1],[4,10,1]])
```

```
[U,D,Vt] = np.linalg.svd(Ag1)
```

```
kla = [-Vt[2,0]/Vt[2,1], -Vt[2,2]/Vt[2,1]]
```

```
nabc_a = Vt[2,:]/np.linalg.norm(Vt[2,0:2])
```

```
Ag = np.array([[1,1],[2,1],[3,1],[4,1]])
```

```
yg = [6,5,7,10];
```

```
klg= np.linalg.pinv(Ag)@yg
```

```
nabc_g1 = np.array([klg[0],-1,klg[1]])/np.linalg.norm([klg[0],-1])
```

```
print("TLS norm alg:", np.linalg.norm(Aa @ nabc_a)) # 1.8
```

```
print("TLS norm geom 1:", np.linalg.norm(Aa @ nabc_g1)) # 1.2
```

```
print("TLS norm geom 2:", np.linalg.norm(Aa @ nabc_g2)) # 1.1
```

## MLE: IZGLEDNOST

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

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

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

$$\hat{\mathbf{p}}_{MLE} = \arg \max_{\mathbf{p}} \text{Lik}(\mathbf{p})$$

## MLE: LINEARNI MODEL

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 mjerena  $\hat{y}_i$

- pretp.  $y_i \sim \mathcal{N}(y_i^T, \sigma)$ : **nezavisni, jednako raspodijeljeni**

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

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

$$p(\mathbf{y} | \mathbf{p}, \mathbf{x}) \sim \prod_i e^{-\frac{(p_1 \cdot x'_i + p_2 - y_i^T)^2}{2\sigma^2}}$$

## MLE: LINEARNI MODEL (2)

Kad logaritmiramo izglednost, desno dobivamo L2 normu reziduala:

$$-\log \text{Lik}(\mathbf{p}) \sim \sum_i (p_1 \cdot x_i + p_2 - y_i^T)^2$$

Pravac koji maksimira izglednost sada je (logaritam je monotona f.ja):

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \text{Lik}(\mathbf{p}) = \arg \min_{\mathbf{p}} (-\log \text{Lik}(\mathbf{p}))$$

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

$$\hat{\mathbf{p}} = \arg \max_{\mathbf{p}} \text{Lik}(\mathbf{p}) = \arg \min_{\mathbf{p}} \sum_i (p_1 \cdot x_i + p_2 - y_i^T)^2$$

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

## MLE: MAP

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

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

Ako se apiorna razdioba parametara modela  $p(\mathcal{M}(\mathbf{p}))$  može modelirati, estimaciju možemo poboljšati!

Kriterij **MAP** (maximum a posteriori): tražimo model  $\mathbf{p}$  koji maksimizira svoju posteriornu razdiobu:

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

## MLE: MAP (2)

Posteriornu razdiobu  $p(\mathbf{p}|\mathbf{o})$  dobivamo primjenom Bayesovog teorema:

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

U brojniku imamo **izglednost** i **apriornu vjerojatnost**, a u nazivniku **normalizacijski faktor**:

Normalizacijski faktor nije važan za optimizaciju (ne ovisi o parametrima modela) pa ga možemo izostaviti iz kriterija:

$$\begin{aligned} p(\mathbf{p}|\mathbf{o}) &= \frac{p(\mathbf{o}|\mathbf{p}) \cdot p(\mathbf{p})}{p(\mathbf{o})} \\ &\sim \text{Lik}(\mathbf{p}) \cdot p(\mathbf{p}) . \end{aligned}$$

## MLE: MAP (3)

Konačan izraz za estimator MAP je:

$$\hat{\mathbf{p}}_{MAP} = \arg \max_{\mathbf{p}} \text{Lik}(\mathbf{p}) \cdot p(\mathbf{p})$$



Zaključak:

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

Vidjeli smo sliku koja podsjeća na klokana. Jesmo li u Australiji?

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

# MLE: MAP ZAKLJUČIVANJE





[Zisserman01]

## ROBUSNA ESTIMACIJA

Prisjetimo se **motivacije**, odnosno željenih svojstava algoritma:

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

Problem: maksimiziranje izglednosti loše se ponaša u prisustvu iznimki [Stewart99].



## ROBUSNA ESTIMACIJA: RANSAC


Given a model that requires a minimum of  $n$  data points to instantiate its free parameters, and a set of data points  $P$  such that the number of points in  $P$  is greater than  $n$  [ $\#(P) \geq n$ ], randomly select a subset  $S1$  of  $n$  data points from  $P$  and instantiate the model. Use the instantiated model  $M1$  to determine the subset  $S1^*$  of points in  $P$  that are within some error tolerance of  $M1$ . The set  $S1^*$  is called the consensus set of  $S1$ .

If  $\#(S1^*)$  is greater than some threshold  $t$ , which is a function of the estimate of the number of gross errors in  $P$ , use  $S1^*$  to compute (possibly using least squares) a new model  $M1^*$ .

If  $\#(S1^*)$  is less than  $t$ , randomly select a new subset  $S2$  and repeat the above process. If, after some predetermined number of trials, no consensus set with  $t$  or more members has been found, either solve the model with the largest consensus set found, or terminate in failure.

[fischler81c ACM]

## ROBUSNA ESTIMACIJA: RANSAC - ITERACIJA



[Wikipedia]

## ROBUSNA ESTIMACIJA: SAŽETAK

Robusni 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 robusnih normi:  
IRLS, M-estimacija

(I to je sve...)

Hvala na pažnji!

Pitanja?