

RANSAC = RANdom SAmple Consensus

iteratívna metóda na určenie parametrov
matematického modelu z množiny nameraných
bodov, ktorá obsahuje odľahlé dáta

Využíva sa:

Párovanie lokálnych príznakov

- Spájanie panorám

3D rekonštrukcia


Rozpoznávanie obrazcov

Augmented reality


RANSAC

1. Náhodný výber minimálnej podmnožiny bodov na určenie parametrov modelu (vzorka - *sample*)
2. Určenie podporovateľov modelu – body v určenej vzdialenosti od modelu (*consensus set*)
3. Opakujeme pre N vzoriek


Vyhráva model
s najviac podporovateľmi



RANSAC na určenie čiar




RANSAC na určenie čiar



Metóda najmenších
štvorcov

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky

Výpočet parametrov
modelu


Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar

Nekontaminovaná vzorka



Náhodný výber
vzorky


Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

RANSAC na určenie čiar



Náhodný výber
vzorky

Výpočet parametrov
modelu

Výpočet chybovej
funkcie

Určenie bodov
konzistentných s
modelom

Opakuj

Voľba parametrov

Veľkosť vzorky s

Typicky – minimálny počet potrebný na výpočet parametrov modelu

Prah vzdialenosti t

Tak, aby napr. 95% bodov podporovalo víťaznú vzorku

Pre $N(0, \sigma^2)$: $t^2 = 3.84\sigma^2$

Počet opakovaní N

Tolko, aby s pravdepodobnosťou p aspoň jedna vzorka neobsahovala odľahlé dáta (napr. $p=0.99$) (podiel odľahlých dát: e)

Počet opakovaní N

Tol'ko, aby s pravdepodobnosťou p aspoň jedna vzorka neobsahovala odľahlé dáta (napr. $p=0.99$) (podiel odľahlých dát: e)

$1 - p$ = pravdepodobnosť N kontaminovaných vzoriek

$1 - p$ = {(pravdepodobnosť, že daná vzorka je kontaminovaná)} N

$1 - p$ = (1 - pravdepodobnosť, že daná vzorka nie je kontaminovaná) N


$1 - p$ = [1 - (pravdepodobnosť, že bod nepatrí medzi odľahlé dáta) s] N

$$1 - p = \left(1 - (1 - e)^s\right)^N \quad N = \log(1 - p) / \log\left(1 - (1 - e)^s\right)$$


RANSAC: N pre $p = 0.99$

	e						
S	5%	10%	20%	25%	30%	40%	50%
2	2	3	5	6	7	11	17
3	3	4	7	9	11	19	35
4	3	5	9	13	17	34	72
5	4	6	12	17	26	57	146
6	4	7	16	24	37	97	293
7	4	8	20	33	54	163	588
8	5	9	26	44	78	272	1177


RANSAC – hľadanie objektov



$$\sum \text{residual}(x_i, M)$$



T



$$\sum_i \text{residual}(T(x_i), x'_i)$$

Porovnanie deskriptorov

Euklidovská vzdialenosť

$$d(\mathbf{p}, \mathbf{q}) = \sqrt{\sum_i (p_i - q_i)^2}$$



Kosínusová podobnosť

$$\text{sim}(\mathbf{p}, \mathbf{d}) = \cos(\mathbf{p}, \mathbf{d}) = \frac{\mathbf{p} \cdot \mathbf{d}}{\|\mathbf{p}\| \|\mathbf{d}\|}$$

Hammingova vzdialenosť

$$d(\mathbf{p}, \mathbf{q}) = \frac{1}{n} \sum_i (1 - \delta(p_i, q_i))$$

Korešpondencia lokálnych príznakov



p



q

Korešpondencia lokálnych príznakov



$p \rightarrow p'1, p'2, p'3 \dots$

$q \rightarrow q'1, q'2, q'3 \dots$

$r \rightarrow r'1, r'2, r'3 \dots$

+ prahovanie





d: 0.34, 0.30, 0.40

d: 0.61
d: 1.22

Korešpondencia lokálnych príznakov


$p \rightarrow p'1, p'2, p'3 \dots$

$q \rightarrow q'1, q'2, q'3 \dots$

$r \rightarrow r'1, r'2, r'3 \dots$

Podiel

1. a 2. v poradí



RANSAC


Máme páry príznačkov

Hľadáme afinnú transformáciu T , ktorá minimalizuje

$$\sum_i \text{residual}(T(x_i), x'_i)$$



T



$$\begin{bmatrix} x'_i \\ y'_i \end{bmatrix} = \begin{bmatrix} m_1 & m_2 \\ m_3 & m_4 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \end{bmatrix} + \begin{bmatrix} t_1 \\ t_2 \end{bmatrix}$$

RANSAC

$$\begin{bmatrix} x'_i \\ y'_i \end{bmatrix} = \begin{bmatrix} m_1 & m_2 \\ m_3 & m_4 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \end{bmatrix} + \begin{bmatrix} t_1 \\ t_2 \end{bmatrix}$$
$$\begin{bmatrix} \dots & \dots & \dots & \dots & \dots & \dots \\ x_i & y_i & 0 & 0 & 1 & 0 \\ 0 & 0 & x_i & y_i & 0 & 1 \\ \dots & \dots & \dots & \dots & \dots & \dots \end{bmatrix} \begin{bmatrix} m_1 \\ m_2 \\ m_3 \\ m_4 \\ t_1 \\ t_2 \end{bmatrix} = \begin{bmatrix} \dots \\ x'_i \\ y'_i \\ \dots \end{bmatrix}$$

Lineárny systém, 6 neznámych

Každý pár – dve rovnice


Potrebuje aspoň 3 páry

RANSAC

Homografia = projektívna transformácia


$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}$$

RANSAC


1. Náhodný výber množiny korešpondujúcich príznakov
 2. Výpočet koeficientov transformácie
 3. Zistenie počtu podporovateľov
 4. Ak je dosť podporovateľov, určenie parametrov z celej množiny podporovateľov
 5. Opakovanie
 6. Výsledná transformácia = najviac podporovateľov
- 

Detekcia objektov


1. Detekcia lokálnych príznakov
Vypočítanie deskriptorov




1. Párovanie príznakov




1. Nájdenie transformácie
Identifikácia okrajov objektu



Bag of visual words



Významné oblasti Sledovanie pohybu očí



Významné oblasti = zreteľné lokálne zmeny
v obraze

Nízko-úrovňová významnosť – pozornosť je
podvedome priťahovaná k lokálnym
zmenám v obraze


- Vysoko-úrovňová významnosť – pozornosť
reaguje na pridelené úlohy

Modely vizuálnej pozornosti

2 prístupy

Zdola nahor

Zhora nadol





Zdola nahor

Podvedomá reakcia na podnety

príklady:

Horiaca sviečka v temnej miestnosti

Červené jablko na zelenom strome

Oči a pery na ľudskej tvári



kontrast, farba, orientácia, textúra, pohyb...

Spracovanie zdola nahor:


obraz sa rozdelí na 3 paralelné kanály
(farba, intenzita a orientácia), kde sa
hľadajú zmeny

Prídavná vlastnosť - “zákaz návratu”

významnosť oblasti sa postupne
zmenšuje, čo umožní presun pozornosti
na ďalšie oblasti



centrum – okolie



gangliové bunky – približne kruhové receptívne pole

centrum-okolie organizácia (angl. center-surround)

dva typy gangliových neurónov:


ON-center OFF-surround neuróny, u ktorých prítomnosť stimulu (svetla) v strede ich receptívneho poľa spôsobuje excitáciu neurónu a prítomnosť svetla v prstencovom okolí spôsobuje jeho inhibíciu.

OFF-center ON-surround neuróny, u ktorých naopak prítomnosť stimulu (svetla) v strede ich receptívneho poľa spôsobuje inhibíciu neurónu a prítomnosť svetla v prstencovom okolí spôsobuje jeho excitáciu.


M bunky (magno - veľké) – citlivé na veľké objekty, vedia sledovať rýchle zmeny v podnetoch, nesú najmä informáciu o hrubých črtách predmetov a pohybe


P bunky (parvo - malé) – je ich viac, majú menšie receptívne polia, nesú najmä informáciu o farbe a detailoch rôzne miešajú informáciu z čapíkov

M bunky



P bunky






$$R = r - (g + b)/2$$

$$G = g - (r + b)/2$$

$$B = b - (r + g)/2$$

$$Y = (r + g)/2 - |r - g|/2 - b$$

Gaussovské pyramídy $R(\sigma)$, $G(\sigma)$, $B(\sigma)$, $Y(\sigma)$




$$\text{Intenzita } I = (r + g + b)/3$$

Gaussovská pyramída $I(\sigma)$

Orientácia – orientované Gaborove pyramídy $O(\sigma, \theta)$ z I

$$\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}$$

$$\sigma \in [0..8]$$



Centrum-okolie: rozdiel medzi vrstvami Gaussovských pyramíd

Centrum: škály $c \in \{2, 3, 4\}$

Okolie: škály $s = c + d$, kde $d \in \{3, 4\}$

- ⊖ Interpolácia jemnejšej škály na veľkosť hrubej škály, bodové očítanie obrazov

Mapy intenzít: $I(c, s) = |I(c) \ominus I(s)|$

Mapy farieb: $\mathcal{RG}(c, s) = |(R(c) - G(c)) \ominus (G(s) - R(s))|$
 $\mathcal{BY}(c, s) = |(B(c) - Y(c)) \ominus (Y(s) - B(s))|$

Mapy orientácií: $O(c, s, \theta) = |O(c, \theta) \ominus O(s, \theta)|$


Celkovo 42 máp:

6 – intenzita

12 – farba

24 – orientácia


Stimulus





x

y


Intensity map



$\mathcal{N}(\cdot)$




$\mathcal{N}(\cdot)$



normalizácia

operator $\mathcal{N}(\cdot)$

- 1) Mapovanie hodnôt do intervalu $\langle 0, M \rangle$
- 2) Priemer lokálnych maxím m (okrem globálneho maxima M)
- 3) Normalizácia mapy pre násobením $(M - m)^2$




⊕ zmena veľkosti na škálu 4, bodové sčítanie

Mapy nápadnosti:


$$\bar{I} = \bigoplus_{c=2}^4 \bigoplus_{s=c+3}^{c+4} \mathcal{N}(I(c, s))$$

$$\bar{C} = \bigoplus_{c=2}^4 \bigoplus_{s=c+3}^{c+4} \left[\mathcal{N}(\mathcal{R}\mathcal{G}(c, s)) + \mathcal{N}(\mathcal{B}\mathcal{Y}(c, s)) \right]$$

$$\bar{O} = \sum_{\theta \in \{0^\circ, 45^\circ, 90^\circ, 135^\circ\}} \mathcal{N} \left(\bigoplus_{c=2}^4 \bigoplus_{s=c+3}^{c+4} \mathcal{N}(O(c, s, \theta)) \right)$$










$$S = \frac{1}{3}(\mathcal{N}(\bar{I}) + \mathcal{N}(\bar{C}) + \mathcal{N}(\bar{O}))$$



Output (FOA)


SM




príklad




intenzita




farba




orientácia




SM





Významné frekvencie



Frequency-tuned Salient Region Detection

Radhakrishna Achanta[†], Sheila Hemami[‡], Francisco Estrada[†], and Sabine Süsstrunk[†]

[†]School of Computer and Communication Sciences (IC)


Ecole Polytechnique Fédérale de Lausanne (EPFL), CH-1015, Switzerland.

[radhakrishna.achanta, francisco.estrada, sabine.susstrunk]@epfl.ch

[‡]School of Electrical and Computer Engineering

Cornell University, Ithaca, NY 14853, U.S.A.

hemami@ece.cornell.edu




Spektrálne reziduá

Source Image



Log Spectrum




2277 obrázkov

Source Image



Log Spectrum



Škálovaný obraz na 64x64

```
FI = fft2(I)
P = angle(FI)
M = abs(FI);
L = log(M);
SR = L - imfilter(L, h);
S = abs(ifft2(exp(SR + 1i*P))) .^ 2;
```

$$h_n(f) = \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Rozmazanie SM gaussovským filtrom $g(x)$ ($\sigma=8$)

