

2.9

Moravec & Harrison edge detector

$$E(u) = \sum_i w(p_i) \cdot (I(p_i+u) - I(p_i))^2$$

$$E_{\text{wssd}} \approx \sum_i w(p_i) \cdot (\nabla I(p_i)^T \cdot u)^2 = u^T A u, \text{ kde}$$

$$\hookrightarrow \text{Taylorův rozvoj} \quad A = \sum_i w(p_i) \cdot \begin{pmatrix} I_x^2 & I_{xy} \\ I_{xy} & I_y^2 \end{pmatrix}$$

= poměr vlastních čísel uvěří, zdali je tam hrana nebo ne.

Můžeme počítat $D = \det - \propto \text{trace}$. Pak je stejná D správně odpracovat.

2.10

Pro jednotlivé pozice zkusím přiblížit template a dívám se, jak moc se objekt (ne) liší.

Kvantifikují pomocí:

rychlost, nevhodnost

rychlost, kvalita

méně rychlost, citlivost na změnu intenzity

Kolemce, kolevace s nulovým průměrem, suma vzdáleností, normalizovaná kolevace.

$\hookrightarrow$ koutovost/citlivost invariantní, pomalá

$$\frac{df}{dx} \frac{dx}{dt} + \frac{df}{dy} \frac{dy}{dt} + \frac{df}{dt} = 0$$

$$\begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} \frac{dx}{dt} \\ \frac{dy}{dt} \end{pmatrix}^T$$

$$\nabla f^T \cdot \begin{pmatrix} u \\ v \end{pmatrix} + \frac{df}{dt} = 0$$

$$\frac{(f_x, f_y)}{\|(f_x, f_y)\|} \cdot \begin{pmatrix} u \\ v \end{pmatrix} = - \frac{f_t}{\|(f_x, f_y)\|}$$

$$e^T \cdot \begin{pmatrix} u \\ v \end{pmatrix} = - \frac{f_t}{\|(f_x, f_y)\|}$$

$$v_\nabla = - \frac{f_t}{\|(f_x, f_y)\|} \cdot e_\nabla$$

6 kram'ů:

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

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

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

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

$$I: (r+g+b)/3$$

$$O: O(r, \theta)$$

$$\sum_{\theta \in \{0, 45, 90, 132\}, r: \{0 \dots q\}^2}$$

$$c \in \{2, 3, 4\}, s = c + d: d \in \{3, 4\}$$

center

surround

Model se v jednotlivých kramcích liší na intenzity center-surround,

kte rozdíl mezi z rozdílu gaussovských pyramid daného kramce.

Označím-li takovou operaci „ θ “, pak:

$$I(c, s) = |I(c) \theta I(s)|$$

$$RG(c, s) = |(R(c) - G(c)) \theta (R(s) - G(s))|$$

stejně pro BY

$$O(s, c, \theta) = |O(c, \theta) - O(s, \theta)|$$

Nyní mám celkem 42 map, které musím všechny normalizovat
a následně si pod nimi vytvořím vhodné váhové funkce, se kterými
budu mapy vyhodnocovat.

to je pak jeden z užívaných pyram. modelů.

(např.: jak moc se soustředím na kraj vs. boky)

Kalmanův filter -> predikce pohybu sledovaného objektu:

Predikce:

$$\bar{x}_k = A \bar{x}_{k-1} + \underbrace{B_k u_k}_{\text{šum}}$$

$$\bar{P}_k = A \bar{P}_{k-1} A^T + \underbrace{Q}_{\text{šum}}$$

Upravení: $\rightarrow$ kalmanův zisk


$$K = \bar{P}_k H^T (H \bar{P}_k H^T + R)^{-1}$$

$\rightarrow$ váhový koeficient

$$\bar{x}_k = \bar{x}_k + \underbrace{K}_{\text{váha}} \cdot (\underbrace{z_k}_{\text{měřený stav}} - \underbrace{H \bar{x}_k}_{\text{měřený stav}})$$

$$\bar{P}_k = (I - KH) \bar{P}_k$$


kalmanův koeficient



Využitím goniometrické vyjádření přímek pro identifikaci vertikality.

$p = x \cdot \cos \theta + y \cdot \sin \theta$. Pokud máme množinu dat (p, θ) , která mi reprezentuje přímku. Zvolím si několik bodů na přímce, tak jejich rovnice se pootočí v nějakém bodě x, y , pro který existuje dvojice (p, θ) . To mi dává přímku reprezentující.

Pak si pouze odpracuji počet přímek v průsečíku na signifikantnost jevu.



SIFT: $\Theta(x, y) = \arctg \frac{J(x, y+1) - J(x, y-1)}{J(x+1, y) - J(x-1, y)}$

→ tato máno lundiditg na angimavé bodg.

- Následně ještě odřihují hodnoty 0 pro málo kontinuitní matice
- Pak odřihují bodg ležící na hranicích

Hessho matice $H = \begin{pmatrix} D_{xx} & D_{xy} \\ D_{xy} & D_{yy} \end{pmatrix}$

ponují pomocí $\frac{\text{trac}(H)^2}{\det(H)}$

SURF $\rightarrow$ používá ID na identifikaci bodů

Následně používá blob detector založený na Hessho matici:

$H_{\text{Approx}}^{\text{SURF}} = \begin{pmatrix} \hat{L}_{xx} & \hat{L}_{xy} \\ \hat{L}_{xy} & \hat{L}_{yy} \end{pmatrix}$, kde $\hat{L}$ je další derivace gaussianu

další obráz. To má vyřihuje lundiditg, které mají signifikantní změny relativně ke svému okolí, a tudíž jsou local feature

Jako descriptor používám Haar Wavelet

Harris corner detector:

$$E(u) \approx \sum_i w(p_i) \cdot (\nabla I(p_i)^T u)^2 = u^T A u,$$

$$\text{tedy } A = \sum_i w(p_i) \cdot \begin{pmatrix} I_x^2 & I_x \cdot I_y \\ I_x \cdot I_y & I_y^2 \end{pmatrix}$$

← posízení váhovou funkcí (Gaussian filter)

Pak díky poměr vlastních čísel λ_1 a λ_2 matice nám udáje response, jestli jde o roh nebo ne.

Object search using template matching:

h hlavní metody určení podobnosti:

- korelace — rychlá, ale nespektrální
- korelace s nulovým průměrem — spolehlivější, ale pomalejší
- suma čtverců vzáhllosti — rychlá, ale citlivá na šum
- normalizovaná korelace — dobrá, ale pomalá

Optical flow:

$$\frac{\partial f(x(t), y(t), t)}{\partial t} = 0$$

$$\frac{\partial f}{\partial x} \frac{dx}{dt} + \frac{\partial f}{\partial y} \frac{dy}{dt} + \frac{\partial f}{\partial t} = 0$$

$$\nabla f = \begin{pmatrix} \frac{\partial f}{\partial x} & \frac{\partial f}{\partial y} \end{pmatrix}$$

$$\begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} \frac{dx}{dt} \\ \frac{dy}{dt} \end{pmatrix}$$

$$\begin{pmatrix} f_x & f_y \end{pmatrix} \cdot \begin{pmatrix} u \\ v \end{pmatrix} = -f_t$$

$$\frac{\begin{pmatrix} f_x & f_y \end{pmatrix}}{\| \begin{pmatrix} f_x & f_y \end{pmatrix} \|} \cdot \begin{pmatrix} u \\ v \end{pmatrix} = \frac{-f_t}{\| \begin{pmatrix} f_x & f_y \end{pmatrix} \|}$$

$$v_{\nabla} = \frac{-f_t}{\| \begin{pmatrix} f_x & f_y \end{pmatrix} \|} \cdot e_{\nabla}$$

$$e_{\nabla}^T \cdot \begin{pmatrix} u \\ v \end{pmatrix} = \frac{-f_t}{\| \begin{pmatrix} f_x & f_y \end{pmatrix} \|}$$

→ nám rovnici o dvou neznámých

To symbolizuje problém efektu clong. $\rightarrow$
Nejsm schopný měřit přesný pohyb objektu.

~~(u, v)~~ (f_x, f_y)

Předpoklady:

- intenzita objektu se nemění
- objekt se pohybuje plynule (mám vysoké FPS)
- objekt se pohybuje společně s prondím.

Pak platí vztah s hodnotou 0.

Lucas - Kanade se to snaží řešit iterativním způsobem.

K-means metoda

Snažíme se clusterovat data do nejvhodnějších regionálních skupin.

Při clusterování chceme minimalizovat intra-cluster rozptyl:

$$W = \sum_{l=1}^K \sum_{i \in C_l} \sum_{j \in C_l} \|x_i - x_j\|^2$$

Rozdělování do clusterů vypadá u nás:

$$C(x) = \underset{h}{\operatorname{argmin}} \|x - m_h\|^2 \quad \rightarrow \text{ kde } m_h \text{ je centroid clusteru } C_h.$$

Následně přepočítám pozice centroidů clusterů:

$$m_h = \frac{\sum_{x: C(x)=h} x}{N_h}$$

$\rightarrow$ To opakuji, dokud MSE nedosáhne prahové hodnoty.

$\oplus \ominus \circ \bullet$

$A \oplus E = \bigcup \{a + e \mid a \in A, e \in E\}$, veličnost množiny zisků
 počtem, spojnici máli výše uvedených výstupů množiny

$$A \ominus E = \bigcap \{a - e \mid a \in A, e \in E\} = \{x \mid E_x \subseteq A\}$$


Velikost množiny zisků počtem, ořezání, jsmu" na hranicích

$$A \circ E = (A \ominus E) \oplus E$$



- chodí po vnitřní hranici

$$A \bullet E = (A \oplus E) \ominus E$$




- chodí po vnější hranici

$$A \circ E \subseteq A$$

$$A \bullet E \supseteq A$$

Pro vhodné strukturované prvky E jsou schopný použít tyto metody
 pro rozpořádání objektů v oboru.

Hloubka ostrosti, ohnisková vzdálenost, circle of confusion:



$$\frac{1}{f} = \frac{1}{a} + \frac{1}{a'}$$

ohnisková vzdálenost $\rightarrow$
jak daleko se mi putovaní paprsků
procházející čočkou

$$DOF = \frac{2a^2 Nc}{f^2}$$

a : vzdálenost objektu

f : ohnisková vzdálenost

N : clona

c : circle of confusion

Chyby objektivu:

- chromatické (chromatická aberace)

- podélná : různé vln. délky se zastaví v jiné vzdálenosti

- příčná : všechny vln. délky se zastaví ve stejné vzd., ale na jiném místě

- kombinace : je to spojení s tím, že různé vln. délky
mají jiný index lomu.

- sférická:

- fixní vln. čočky : lze řešit soustavou čoček.

- ve všech paprsků jsou soustředěny
do jednoho bodu

- vlnetec:

- přirození : způsobem ztvárnění objektu na rovinu

- mechanická : vytvořené způsobem přiložením tlaku

- optické : všechny paprsky jsou zachyceny na líně čočky.

- mřížka: součinitel / polárnízační

hodně spjím s obnovením a měřením, lze transformovat.

Otsu thresholding:

intra-class minimalizace:

$$\sigma_b(t) = P_0(t) \sigma_0^2(t) + P_1(t) \sigma_1^2(t)$$

interclass maximalizace

$$\sigma_w(t) = P_0(t) \cdot P_1(t) \cdot (\mu_0(t) - \mu_1(t))^2$$

$$\sigma(t) = \sigma_b(t) + \sigma_w(t)$$

↓
je o centrid daného obrazu

$$A d = b$$

Metoda nejmenších čtverců

$$A^T A d = A^T b$$



$$\begin{pmatrix} \sum l_x l_x & \sum l_x l_y \\ \sum l_x l_y & \sum l_y l_y \end{pmatrix} \begin{pmatrix} u \\ v \end{pmatrix} = - \begin{pmatrix} \sum l_x l_t \\ \sum l_y l_t \end{pmatrix}$$

↓
má řešení, pokud je invertovatelná:

- všechny vlastní zčty jsou dostatečně velké
- jsou podobně velké
- jsou všechny kladné