

Zaporedje slik in sledenje gibanja

slika razlik: $\Delta I_k = I_{k+1} - I_k$

za statično ozadje: $\Delta I_k = I_k - I_{Ozadje}$

Postopki tvorjenja statičnega ozadja:

2. povprečje, a ne upoštevamo vrednosti, kjer se je vrednost piksla močno spremenila

3. kadar imajo vsi istoležni piksli znotraj **drsečega okna** vrednost v preddefiniranem območju, potem prištejemo povprečje teh pikslov k skupni vsoti in povečamo število elementov. Na koncu $px_ozadje = vsota / \text{št_elem}$

Optični pretok:

$$[I_x, I_y][u_x, u_y]^T + I_t = 0$$

$\frac{\partial}{\partial x} \cdot u_x + \frac{\partial}{\partial y} \cdot u_y + \frac{\partial}{\partial t} = 0$
 I_x in I_y – prostorska odvoda
 I_t – odvod po času
(razlika nazaj, naprej, simetrična)

Kako določimo vektor premika **u** za en piksel?

$$A = \begin{bmatrix} I_x(p_1) & I_y(p_1) \\ I_x(p_2) & I_y(p_2) \\ \vdots & \vdots \\ I_x(p_Q) & I_y(p_Q) \end{bmatrix} \quad \text{in} \quad b = \begin{bmatrix} I_t(p_1) \\ I_t(p_2) \\ \vdots \\ I_t(p_Q) \end{bmatrix}$$

$$\underbrace{u}_{2 \times 1} = \begin{bmatrix} u_x \\ u_y \end{bmatrix} = \underbrace{-A^{-g}}_{2 \times Q} \underbrace{b}_{Q \times 1}$$

$$A^{-g} = (A^T A)^{-1} A^T$$

Geometrija več pogledov

DVA POGLEDA

Umerjene oz. kalibrirane razmere:

$$p^T E p' = 0, \quad \text{kjer} \quad p = [u, v, 1] \text{ in } p' = [u', v', 1]$$

$$E p' = [a, b, c]' \quad \text{premica } l : au + bv + c = 0$$

$$E = [t_{\times}] R \quad [a_{\times}] = \begin{bmatrix} 0 & -a_3 & a_2 \\ a_3 & 0 & -a_1 \\ -a_2 & a_1 & 0 \end{bmatrix}$$

E-osnovna matrika, t-translacijski vektor, R-rotacijska matrika

Neumerjene oz. nekalibrirane razmere:

$$p^T F p' = 0 \quad F = K^{-T} E K'^{-1}$$

$$F p' = [a, b, c]' \quad \text{premica } l : au + bv + c = 0$$

F-temeljna matrika, K in K' matriki notranjih parametrov oz. kalibracijski matriki.

$$p = [u, v, 1] \text{ in } p' = [u', v', 1]$$

Umerjanje oz. kalibracija: (korespondenčne pare)

$$\begin{bmatrix} u_1 u'_1 & u_1 v'_1 & u_1 & v_1 u'_1 & v_1 v'_1 & v_1 & u'_1 & v'_1 \\ u_2 u'_2 & u_2 v'_2 & u_2 & v_2 u'_2 & v_2 v'_2 & v_2 & u'_2 & v'_2 \end{bmatrix} \begin{bmatrix} F_{11} \\ F_{12} \end{bmatrix} \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

...

$$F_{33}=1$$

Normaliziranje:

1. Podatke (točke) premaknemo tako, da je center podatkov v koordinatnem izhodišču.

2. Podatke skaliramo

TRIJE POGLEDI:

$$p_1^T E_{12} p_2 = 0$$

$$p_2^T E_{23} p_3 = 0$$

$$p_3^T E_{31} p_1 = 0$$

Kako določiti položaj točke P?

rešitev 1:

Za dva kameri:

P določimo na sredini najkrajše razdalje med žarkoma.

Za tri kamere:

Za vsak par uporabimo postopek za 2 kameri. Dobimo 3 približke točke P. P določimo kot **težišče** trikotnika $T\left(\frac{x_1 + x_2 + x_3}{3}, \frac{y_1 + y_2 + y_3}{3}, \frac{z_1 + z_2 + z_3}{3}\right)$

rešitev 2:

$$\begin{bmatrix} [p_{\times}]^M \\ [p'_{\times}]^{M'} \end{bmatrix} P = 0_{4 \times 1}$$

M in M'-projekcijski matriki, $[p_{\times}]$ (formula $[a_{\times}]$)

STEREO VID:

Primer paralelnih kamer:

$$p = [u, v] \quad p' = [u', v']_{u=u'} \quad z = \frac{fB}{d}$$

$$d = v' - v$$

d-razlika med točkama, z-absolutna oddaljenost,

B(osnovnica)-razdalja med OO' (luknicama)

Rektifikacija:

Rekonstrukcija točke P v koordinatni sistem 1. kamere po:

$$P = z p = -\frac{fB}{d} p, \quad p = [u, v, 1]$$

Uvod v razpoznavanje vzorcev:

$$\text{Evklidska razdalja: } d(x_i, x_j) = \|x_i - x_j\|_2 = \sqrt{\sum_{k=1}^n (x_{i,k} - x_{j,k})^2}, \quad x_i, x_j \in \mathbb{R}^n$$

$$\text{Manhattan razdalja: } d(x_i, x_j) = |x_i - x_j| = \sum_{k=1}^n |x_{i,k} - x_{j,k}|$$

Predobdelava množice vzorcev:

$$\mu_j = \frac{1}{N} \sum_{i=1}^N x_{i,j}, \quad \sigma_j^2 = \frac{1}{N} \sum_{i=1}^N (x_{i,j} - \mu_j)^2, \quad j = 1, 2, \dots, n$$

$$\Upsilon_j = \frac{\frac{1}{N} \sum_{i=1}^N (x_{i,j} - \mu_j)^3}{\sigma_j^3}$$

μ_j -povprečna vrednost, varianca σ_j , koeficient poševnosti

Vrednost značilnice "zelo" odstopa od povprečne vrednosti, če je izraz

$$\frac{|x_j - \mu_j|}{\sigma_j}$$

★ ≥ 3 , če gre za simetrične porazdelitve (tj. $|\Upsilon_j| < 0,5$)

★ ≥ 5 , če gre za asimetrične porazdelitve (tj. $|\Upsilon_j| > 0,5$).

Normiranje vrednosti značilnic vzorcev:

a) vrednosti značilni porazdeljene simetrično

$$x_{i,j} = \frac{x_{i,j}^* - \mu_j}{\sigma_j}$$

-skaliranje/linearizacija:

$$x'_{i,j} = s_{\min} + \frac{x_{i,j} - x_j^{\min}}{x_j^{\max} - x_j^{\min}} (1 - s_{\min})$$

$x_j^{\min}$ in $x_j^{\max}$ – minimalna ter maksimalna vrednost j-te značilnice

$s_{\min} = 0$ za interval $[0,1]$ oz. -1 za interval $[-1,1]$

b) vrednosti značilnic simetrično porazdeljene

$$z_{i,j} = \frac{x_{i,j}^* - \mu_j}{\sigma_j} \quad x_{i,j} = \frac{1}{1 + e^{-z_{i,j}}}$$

Razvrščanje vzorcev po pravilu najbližji sosed:

Znanje o posameznem vzorcu shranjeno v obliki vseh vzorcev:

$$x \in C_i, \quad \text{če} \quad \min_{k=1, \dots, N_i} d(x, x_{ik}) < \min_{l=1, \dots, N_j} d(x, x_{jl}), \quad \forall j = 1, \dots, M \wedge j \neq i$$

Znanje o posameznih razredih shranjeno v obliki tipičnih predstavnikov:

$$x \in C_i, \quad \text{če} \quad d(x, c_i) < d(x, c_j), \quad \forall j = 1, \dots, M \wedge j \neq i$$

Razvrščanje z odločitvenimi funkcijami:

$$\text{Meja med razredoma: } \varphi_{ij}(x) = \varphi_i(x) - \varphi_j(x) = 0$$

$$\varphi_{ij}(x) : (w_i - w_j)x^T = -w_{i0} + w_{j0}$$

$$\varphi(x) = w_0 + w_1 x_1 + w_2 x_2 + \dots + w_n x_n = w_0 + w x$$

Preizkušanje razvrščevalnika vzorcev (zgornja meja napake)

$$\hat{P}_e = \frac{1}{N} \sum_i \hat{P}_e^{(x_i)}$$

$\hat{P}_e^{(x_i)} = 1$, če smo vzorec x_i napačno razvrstili z razvrščevalnikom (naučili ga brez vzorca x_i), sicer pa 0.

Zvezni večplastni perceptron Razvrš. s hiperravninsko ločilno mejo z oznč. z enojn. prag.

Linearna prenosna funkcija:

$$y = f(s) = k_1 s + k_0$$

Sigmoidna prenosna funkcija

$$y = f(s) = \frac{1}{1 + e^{-s}} \quad \left(\frac{1}{1 + e^{-s}} \right)' = f(s)(1 - f(s))$$

Srednja kvadratna napaka (MSE)

$$E = \frac{1}{2} \sum_{\mathbf{x}_i \in \mathcal{S}_N} \sum_{j=1}^{n_3} (t_j(\mathbf{x}_i) - y_j(\mathbf{x}_i))^2$$

Pravilo za izračun spremembe sinaptične uteži

$$\Delta w_i = -\epsilon \frac{\partial E}{\partial w_i} = \sum_{\mathbf{x}_k \in \mathcal{S}_N} \sum_{j=1}^{n_3} (t_j(\mathbf{x}_k) - y_j(\mathbf{x}_k)) \frac{\partial y_j}{\partial w_i}$$

Obteženi vhod

$$s(\mathbf{x}_i) = \hat{\mathbf{x}} \hat{\mathbf{w}} = \sum_{j=0}^n w_j x_{i,j}$$

Enonevronske zvezne perceptrone

Srednja kvadratna napaka $\text{input} \mid t(\mathbf{x}) \mid \mathcal{S} \mid \gamma \mid \frac{df}{ds}$ Normalizacija Hebba

$$E = \frac{1}{2} \sum_{\mathbf{x}_i \in \mathcal{S}_N} (t(\mathbf{x}_i) - y(\mathbf{x}_i))^2$$

Adaptacija posamezne sinaptične uteži

$$\Delta w_j = \epsilon \sum_{\mathbf{x}_i \in \mathcal{S}_N} (t(\mathbf{x}_i) - y(\mathbf{x}_i)) \frac{df}{ds} x_{i,j}$$

Adaptacija razširjenega vektorja uteži:

$$\Delta \hat{\mathbf{w}} = \epsilon \sum_{\mathbf{x}_i \in \mathcal{S}_N} (t(\mathbf{x}_i) - y(\mathbf{x}_i)) \frac{df}{ds} \hat{\mathbf{x}}_i$$

Trinevronske dvoplastne perceptrone:

$$\Delta w_{30} = -\epsilon \frac{\partial E}{\partial w_{30}} = \epsilon \sum_{\mathbf{x} \in \mathcal{S}_N} (t(\mathbf{x}) - y_3(\mathbf{x})) \frac{df_3}{ds_3}$$

$$\Delta w_{31} = -\epsilon \frac{\partial E}{\partial w_{31}} = \epsilon \sum_{\mathbf{x} \in \mathcal{S}_N} (t(\mathbf{x}) - y_3(\mathbf{x})) \frac{df_3}{ds_3} y_1(\mathbf{x})$$

$$\Delta w_{32} = -\epsilon \frac{\partial E}{\partial w_{32}} = \epsilon \sum_{\mathbf{x} \in \mathcal{S}_N} (t(\mathbf{x}) - y_3(\mathbf{x})) \frac{df_3}{ds_3} y_2(\mathbf{x})$$

Razvrščanje s hiperravninsko ločilno mejo z ena in nič oznč.

$$t(\mathbf{x}) = 1, \quad \forall \mathbf{x} \in \mathcal{S}_A \quad \mathcal{C}_A, \text{ če } y(\mathbf{x}) > 0,5$$

$$t(\mathbf{x}) = 0, \quad \forall \mathbf{x} \in \mathcal{S}_B \quad \mathcal{C}_B, \text{ če } y(\mathbf{x}) \leq 0,5$$

Razvrš. s hiperravninsko ločilno mejo z oznč. z dvojnim pragom

$$\mathcal{C}_A, \text{ če } y(\mathbf{x}) > 0,5 \quad t(\mathbf{x}) \geq a, \quad 0,5 < a < 1, \quad \forall \mathbf{x} \in \mathcal{S}_A$$

$$\mathcal{C}_B, \text{ če } y(\mathbf{x}) \leq 0,5 \quad t(\mathbf{x}) \leq b, \quad 0 < b < 0,5, \quad \forall \mathbf{x} \in \mathcal{S}_B$$

Če je med učenjem izhod $y(\mathbf{x}) \geq a$ za vzorec $\mathbf{x} \in \mathcal{S}_A$, potem je napaka $E = 0$, sicer pa $E = (a - y(\mathbf{x}))^2$.

Če je med učenjem izhod $y(\mathbf{x}) \leq b$ za vzorec $\mathbf{x} \in \mathcal{S}_B$, potem je napaka $E = 0$, sicer pa $E = (b - y(\mathbf{x}))^2$.

Razvrš. s hiperravninsko ločilno mejo z oznč. z enojn. prag.

$$t(\mathbf{x}) > 0,5, \quad \forall \mathbf{x} \in \mathcal{S}_A \quad \mathcal{C}_A, \text{ če } y(\mathbf{x}) > 0,5$$

$$t(\mathbf{x}) \leq 0,5, \quad \forall \mathbf{x} \in \mathcal{S}_B \quad \mathcal{C}_B, \text{ če } y(\mathbf{x}) \leq 0,5$$

Hitrost učenja

Metoda momenta

$$\Delta \hat{\mathbf{w}}_{nov}(k) = \Delta \hat{\mathbf{w}}(k) + \alpha \Delta \hat{\mathbf{w}}(k-1)$$

Samoorganizirajoče se nevronske mreže (SOM)

Obtežen vhod v nevron u_r

$$s_r(t) = \sum_j w_{rj}(t) x_j(t) + \sum_k \gamma_{rk} y_k(t)$$

Izhod y_r nevrona u_r :

$$y_r(t + \Delta) = \lambda_r \{s_r(t)\}$$

funkcija λ_r – nelinearna monotona naraščajoča funkcija

Sinaptične uteži w spreminjamo po Hebba:

$$\mathbf{w}_{r,nov}(t) = \mathbf{w}_{r,star}(t) + \epsilon(t) y_r(t) \mathbf{x}(t)$$

Normalizacija Hebba

$$\sum_j w_{rj} = 1$$

Iskanje zmagovalnega nevrona

$$d(\mathbf{w}_s(t), \mathbf{x}(t)) = \min_r d(\mathbf{w}_r(t), \mathbf{x}(t))$$

d – mera razdalje za vhodni prostor

Dejansko ažuriranje uteži

$$\mathbf{w}_r(t+1) = \mathbf{w}_r(t) + g(r, s, t) \cdot (\mathbf{x}(t) - \mathbf{w}_r(t))$$

t – čas oz. učni korak $g(r, s, t)$ – skalarna funkcija $[0, 1]$

$$g(r, s, t) = \epsilon(t) \cdot h(r, s, t)$$

$e(t)$ stopnja učenja

$$h(r, s, t) = e^{\frac{-d_L^2(u_r, u_s)}{\sigma^2(t)}}$$

$\sigma(t) = \frac{\sigma_0}{\sqrt{1+t}}$, z izrazom $d_L(u_r, u_s)$ pa merimo razdaljo med nevronoma u_r in u_s v rešetki SOM.

Energija kvantizacijskega šuma

$$E_{\text{kvant_sum}} = \frac{1}{N} \sum_{\mathbf{w}_s} \sum_{\mathbf{x}_i \in \mathcal{R}_s} \|\mathbf{x}_i - \mathbf{w}_s\|^2$$