

Rozpoznávání tváří II

Vojtěch Franc





Centrum strojového vnímání, ČVUT FEL Praha



Biometrie ZS 2012

Poděkování Michalu Uříčarovi za obrázky popisující detekci významných bodů

Stavební bloky typického rozpoznávacího systému



Scarlett
Johansson


Detekce významných bodů na tváři

- ◆ Cíl: Lokalizovat předem definované významné body na lidské tváři
- ◆ Vstup: obrázek (nebo video)
- ◆ Výstup: pozice významných bodů



Nezávislý detektor pro každý významný bod

- ◆ $V = \{0, \dots, M - 1\}$ množina významných bodů
- ◆ $S_i \subset \{1, \dots, H\} \times \{1, \dots, W\}$ množina přípustných pozic i -tého významného bodu
- ◆ $q_i(I, s_i)$ “pravděpodobnost”, že i -tý významný bod je v obrázku I na souřadnici $s_i \in S_i$



- ◆ Odhady pozic $\{\hat{s}_0, \dots, \hat{s}_{M-1}\}$ významných bodů v obrázku I lze nalézt nezávislými detektory

$$\hat{s}_i = \underset{s \in S_i}{\operatorname{argmax}} q_i(I, s) \quad i \in V$$

- ◆ **Nevýhoda:** nevyužívá se toho, že pozice významných bodů nejsou nezávislé.

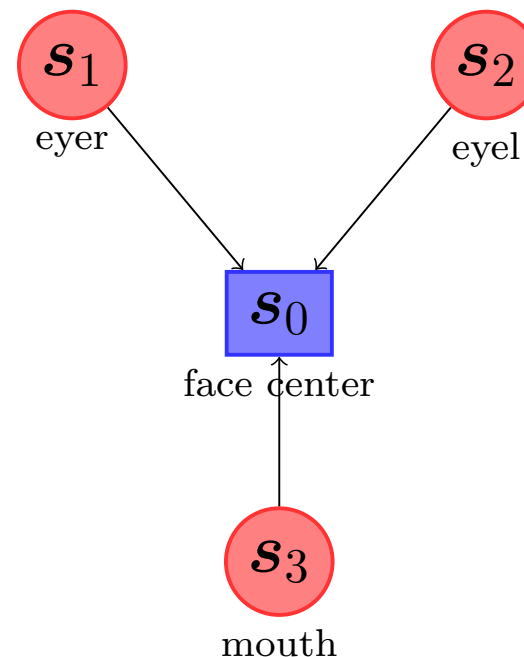

Deformable part model

- ◆ $G = (V, E)$ graf definující významné body a sousedství
- ◆ $g_{ij}(\mathbf{s}_i, \mathbf{s}_j)$ skóre konfigurace $(\mathbf{s}_i, \mathbf{s}_j)$ sousedících bodů $(i, j) \in E$
- ◆ $f(I, \mathbf{s})$ skóre pro konfiguraci pozic významných bodů $\mathbf{s} = (\mathbf{s}_0, \dots, \mathbf{s}_{M-1})$ v obrázku I

$$f(I, \mathbf{s}) = \sum_{i \in V} q_i(I, \mathbf{s}_i) + \sum_{(i, j) \in E} g_{ij}(\mathbf{s}_i, \mathbf{s}_j)$$

shoda
s obrázkem

deformační skóre



Deformable part model

- ◆ Odhad pozice významných bodů v obrázku I vede na hledání konfigurace


$$(\hat{\mathbf{s}}_0, \dots, \hat{\mathbf{s}}_{M-1}) = \underset{(\mathbf{s}_0, \dots, \mathbf{s}_{M-1}) \in S_0 \times \dots \times S_{M-1}}{\operatorname{argmax}} \left[\sum_{i \in V} q_i(I, \mathbf{s}_i) + \sum_{(i,j) \in E} g_{ij}(\mathbf{s}_i, \mathbf{s}_j) \right]$$

- ◆ Pro acyklický graf (V, E) lze nalézt maximální konfiguraci pomocí dynamického programování.

- ◆ Funkce q_i a g_{ij} lze učit z množiny $\{(I^1, \mathbf{s}^1), \dots, (I^m, \mathbf{s}^m)\}$, která obsahuje příklady obrázků I^j a jejich manuální anotaci \mathbf{s}^j .

- ◆ Cílem je naučit takové funkce q_i a g_{ij} , aby průměrná odchylka odhadu pozic byla minimální.

$$\text{odchylka} = \frac{\varepsilon_0 + \dots + \varepsilon_{M-1}}{M} \cdot \frac{1}{l_{face}}$$




Geometrická normalizace tváře

- ◆ Cíl: převést tvář do normalizované polohy
- ◆ Jeden z možných způsobů: nalezneme affinní transformaci (např. metodou nejmenších čtverců)

$$\mathbf{s}' = \mathbf{A}\mathbf{s} + \mathbf{b} \quad \mathbf{A} \in \mathbb{R}^{2 \times 2}, \mathbf{b} \in \mathbb{R}^{2 \times 1}, \mathbf{s} \in \mathbb{R}^{2 \times 1}$$

která promítne nalezené významné body $(\mathbf{s}_0, \dots, \mathbf{s}_{M-1})$ na jejich normalizovanou konfiguraci $(\mathbf{s}'_0, \dots, \mathbf{s}'_{M-1})$.



Vstupní obrázek



Normalizovaný obrázek

Holistický popis vs. lokální popis

- ◆ **Holistický popis:** celý výřez geometricky normalizované tváře.




- ◆ **Lokální popis:** geometricky normalizované výřezy kolem významných bodů.



Příznaková reprezentace obrázku - jasové hodnoty

- ◆ Nejjednodušší reprezentace obrázku je použít přímo jasové hodnoty v jednotlivých pixelech jako příznaky



- ◆ Tato příznaková reprezentace je citlivá na změnu osvětlení.
- ◆ Pro zvýšení invariance vůči změně osvětlení se používají jasové normalizace. Např:
 - Normalizace na nulovou střední hodnotu a jednotkovou varianci:


$$I'_{ij} = \frac{I_{ij} - \mu}{\sigma}, \quad \mu = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H I_{ij}, \quad \sigma = \frac{1}{WH} \sum_{i=1}^W \sum_{j=1}^H (I_{ij} - \mu)^2$$

- Ekvalizace histogramu.

Příznaková reprezentace obrázku - Local Binary Patterns

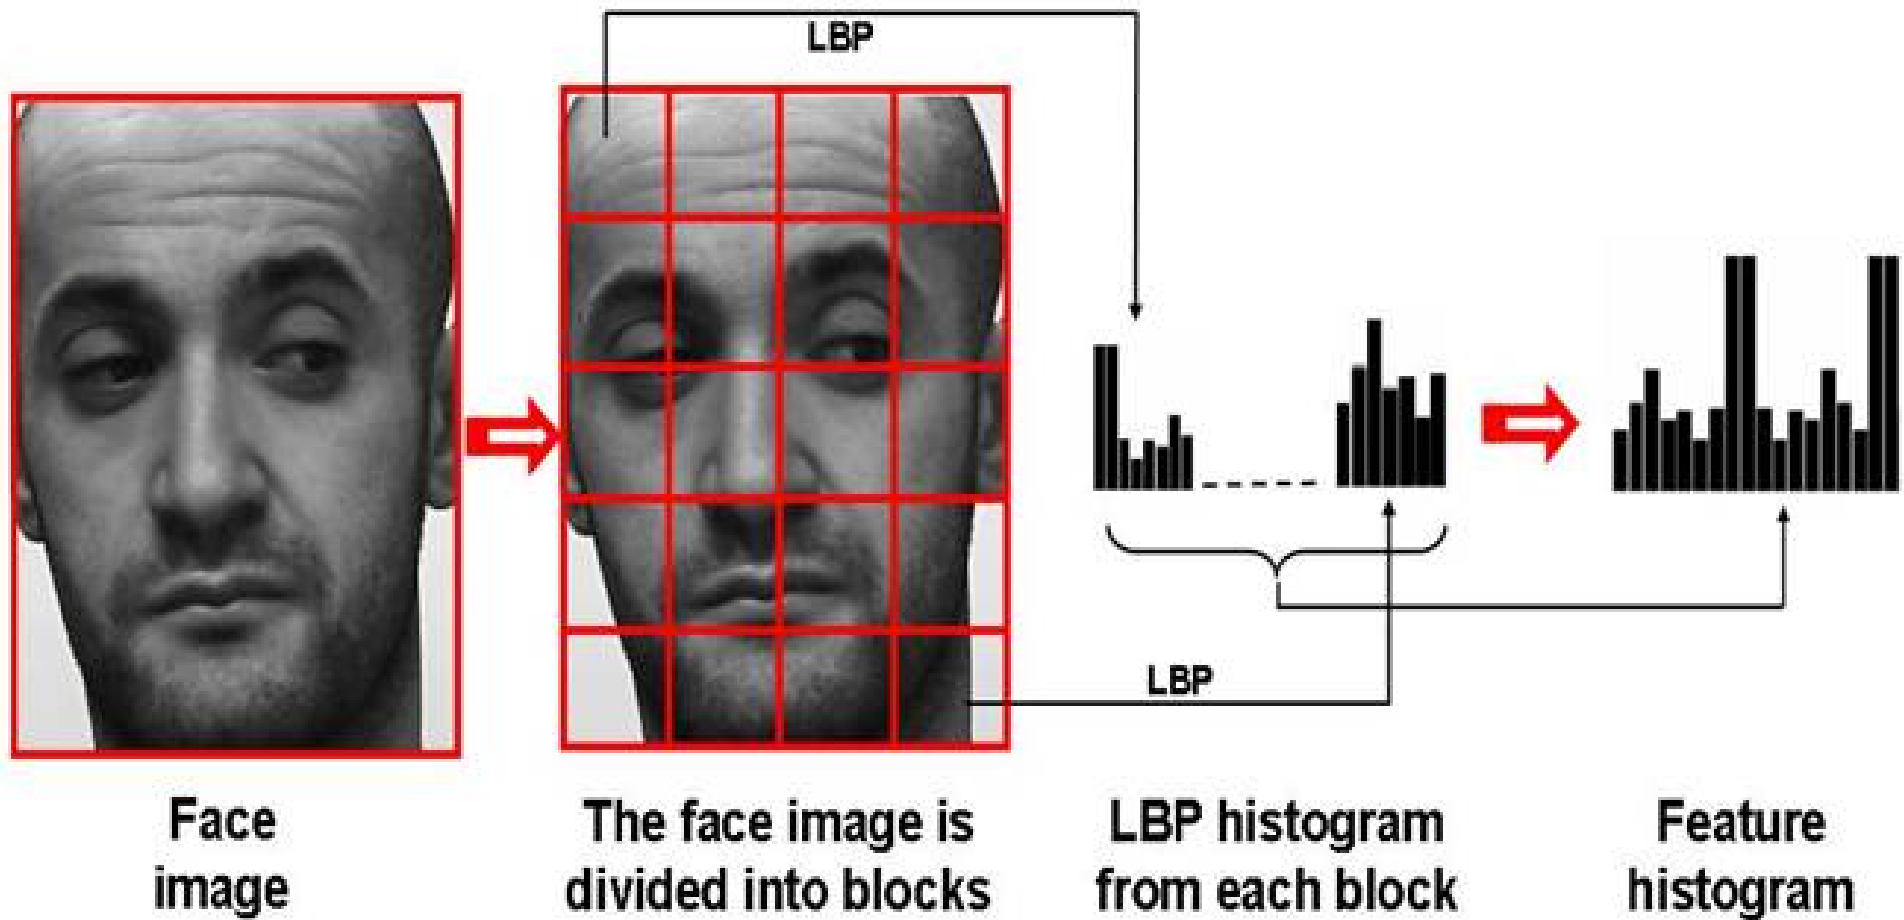
- ◆ LBP přiřadí oknu velikosti 3×3 pixelů 8-bitový kód

$$LBP = \sum_{p=0}^7 [I(c) \geq I(p)] 2^p$$



- ◆ LBP příznaky jsou invariantní vůči monotónní změně osvětlení obrázku.

Příznaková reprezentace obrázku - Local Binary Patterns



Metody extrakce příznaků

- ◆ Obrázek $H \times W$ je reprezentován v prostoru X .
- ◆ Rozhodovací funkce porovnává obrázky pomocí metriky $d: X \times X \rightarrow \mathbb{R}$. Např. klasifikátor tváří podle nejbližšího etalonu

$$h(x) = \operatorname{argmin}_{y=1,\dots,K} d(x, \mu_y)$$

kde μ_1, \dots, μ_K jsou etalony (reprezentanti) třídy 1 až K .

- ◆ Často se používá příznakový prostor $X = \mathbb{R}^n$ a Euklidovská metrika $d(\mathbf{x}, \mathbf{x}') = \|\mathbf{x} - \mathbf{x}'\|$.
- ◆ **Problémy:**
 - Vysoká dimenze příznakového prostoru $X = \mathbb{R}^n$ ($n = HW$ pro obrázek $H \times W$ pixelů).
 - Příznaky nejsou dostatečně diskriminabilní, tj. vzdálenost $d(\mathbf{x}, \mathbf{x}')$ je malá pro odlišné tváře a velká pro podobné tváře.
- ◆ **Metody extrakce příznaků:** transformuj prostor $X = \mathbb{R}^n$ na prostor $Z = \mathbb{R}^p$, tak aby
 1. rekostrukční chyba byla nízká – **Principal Component Analysis**
 2. příznaky byly lépe diskriminabilní – **Linear Discriminant Analysis**

Principal Component Analysis (PCA)

- ◆ Cíl: zadané body $\{\mathbf{x}_1, \dots, \mathbf{x}_m\} \in \mathbb{R}^{n \times m}$ chceme aproximovat v p -dimenzionálním affinním podprostoru

$$\tilde{X} = \left\{ \tilde{\mathbf{x}} \in \mathbb{R}^n \mid \tilde{\mathbf{x}} = \sum_{i=1}^p z_i \mathbf{a}_i + \mu \right\} \subseteq \mathbb{R}^n$$

kde $A = \{\mathbf{a}_1, \dots, \mathbf{a}_p\} \in \mathbb{R}^{n \times p}$, $\mu \in \mathbb{R}^n$ jsou parametry \tilde{X} .

- ◆ Projekce bodu \mathbf{x} na affinní podprostor \tilde{X} je bod

$$\tilde{\mathbf{x}} = \operatorname{argmin}_{\mathbf{x}' \in \tilde{X}} \|\mathbf{x} - \mathbf{x}'\|$$

K reprezentaci bodu $\tilde{\mathbf{x}} \in \mathbb{R}^n$ je potřeba pouze p souřadnic $\mathbf{z} = (z_1, \dots, z_p)^T \in \mathbb{R}^p$.

- ◆ Cílem je nalézt ortonormální bázi p -dimenzionálního affinního podprostoru \tilde{X} , pro něž je aproximační chyba

$$E(\tilde{X}) = \sum_{i=1}^m \|\mathbf{x}_i - \tilde{\mathbf{x}}_i\|^2$$

minimální.

Principal Component Analysis (PCA)

- ◆ Řešením je affinní podprostor jehož bázové vektory $A = \{\mathbf{a}_1, \dots, \mathbf{a}_p\}$ tvoří p vlastních vektorů kovarianční matice


$$\mathbf{C} = \frac{1}{m} \sum_{i=1}^m (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^T \quad \text{kde} \quad \mu = \frac{1}{m} \sum_{i=1}^m \mathbf{x}_i$$

- ◆ Projekce bodu \mathbf{x} na PCA prostor

$$\mathbf{z} = \mathbf{A}^T (\mathbf{x} - \mu)$$

- ◆ Zpětná projekce

$$\tilde{\mathbf{x}} = \mathbf{A}\mathbf{z} + \mu = \sum_{i=1}^p z_i \mathbf{a}_i + \mu$$



Eigen faces - Aplikace PCA na tváře

- ◆ Tvář \mathbf{x} se promítne do p -dimenzionálního PCA prostoru

$$\mathbf{z} = \mathbf{A}^T(\mathbf{x} - \mu) = (\underbrace{\mathbf{a}_1^T(\mathbf{x} - \mu)}_{z_1}, \dots, \underbrace{\mathbf{a}_p^T(\mathbf{x} - \mu)}_{z_p})^T$$

- ◆ Tvář \mathbf{x} lze aproximovat jako lineární kombinaci p bázových vektorů (“eigen tváří”)




Každý obrázek $\mathbf{x} \in \mathbb{R}^{H \times W}$ lze reprezentovat pomocí $H \cdot W$ čísel.


Každý obrázek $\tilde{\mathbf{x}} \in \mathbb{R}^{H \times W}$ lze reprezentovat pomocí $p = 8$ čísel.

Klasifikace a učení - neformální popis problému

- ◆ Příklad klasifikace tváří do tříd:



- ◆ Metody učení klasifikátorů z příkladů:



Klasifikace - formální (statistický) popis

Statistický model: objekt je popsán rozdělením pravděpodobnosti $p(x, y)$ kde

- ◆ $x \in X$... popis klasifikovaného obrázku.
Např. příznaky spočítané na geometricky normalizované tváři.
- ◆ $y \in Y$... skrytých stav klasifikovaného objektu.
Např. pohlaví osoby na obrázku, věk, identita.

Cílem je nalézt klasifikátor $h: X \rightarrow Y$, který pro danou ztrátovou funkci $\ell: Y \times Y \rightarrow \mathbb{R}$ minimalizuje očekávané riziko

$$R_{\text{exp}}(h) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \ell(y, h(x))$$

Problém je, že místo rozdělení $p(x, y)$ máme k dispozici jen příklady z něj náhodně a nezávisle generované

$$\{(x_1, y_1), \dots, (x_m, y_m)\} \in (X \times Y)^m$$

Příklad klasifikačního problému:

Odhad pohlaví z obrázku zaregistrované tváře

- ◆ $x \in X$... např. LBP příznaky spočítané na geometricky normalizované lidské tváři
- ◆ $y \in Y = \{\text{muž, žena}\}$
- ◆ Pokud chceme minimální pravděpodobnost chybné klasifikace zvolíme $\ell(y, h(x)) = [y \neq h(x)]$ a pak

$$\begin{aligned}
 R_{\text{exp}}(h) &= \sum_{x \in X} \sum_{y \in Y} p(x, y) \ell(y, h(x)) \\
 &= \sum_{x \in X} p(x, y = \text{muž}) [h(x) = \text{žena}] + \sum_{x \in X} p(x, y = \text{žena}) [h(x) = \text{muž}]
 \end{aligned}$$



Generativní učení

- ◆ Na základě příkladů $\{(x_1, y_1), \dots, (x_m, y_m)\}$ najdeme odhad $\hat{p}(x, y)$ skutečného rozdělení $p(x, y)$. Např. použijeme princip maxima věrohodnosti.
- ◆ Do vzorce pro očekávané riziko $R_{\text{exp}}(h)$ dosadíme $\hat{p}(x, y)$ a hledáme klasifikátor, který tuto aproximaci skutečného rizika minimalizuje

$$h^* \in \operatorname{argmin}_h \hat{R}(h) \quad \text{kde} \quad \hat{R}(h) = \sum_{x \in X} \sum_{y \in Y} \hat{p}(x, y) \ell(y, h(x))$$

Diskriminativní učení


- ◆ Předpokládáme, že známe tvar rozumného klasifikátoru. Tj. klasifikátor nemůže být libovolný, ale patří do množiny \mathcal{H} . Např. \mathcal{H} je množina všech lineárních klasifikátorů.
- ◆ V množině \mathcal{H} hledáme (učíme) klasifikátor, který dobře funguje na trénovacích příkladech, tj. minimalizujeme empirické riziko

$$h^* \in \operatorname{argmin}_{h \in \mathcal{H}} R_{\text{emp}}(h) \quad \text{kde} \quad R_{\text{emp}}(h) = \sum_{i=1}^m [\ell(y_i, h(x_i))]$$

Linear Support Vector Machines

- ◆ Klasifikátor $h: \mathbb{R}^n \rightarrow \{-1, +1\}$

$$h(\mathbf{x}; \mathbf{w}) = \text{sign}(\langle \mathbf{x}, \mathbf{w} \rangle)$$



- ◆ Učení parametrů \mathbf{w} z příkladů $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\} \in (\mathbb{R}^n \times \{+1, -1\})$ je formulováno jako konvexní problém


$$\mathbf{w}^* = \underset{\mathbf{w} \in \mathbb{R}^n}{\text{argmin}} \left[\frac{\lambda}{2} \|\mathbf{w}\|^2 + \sum_{i=1}^m \max\{0, 1 - y_i \langle \mathbf{w}, \mathbf{x}_i \rangle\} \right]$$

kde $\Omega(\mathbf{w})$ je kvadratický regularizátor a $R(\mathbf{w})$ je konvexní horní mez pro





$$\sum_{i=1}^m [y_i \neq h(\mathbf{x}_i; \mathbf{w})]$$

tj. počet chyb, kterých se klasifikátor $h(\mathbf{x}; \mathbf{w})$ dopustí na trénovací příkladech.


Konec




m p




Scarlett
Johansson




H




W





H






W











1	5	9	13
2	6	10	14
3	7	11	15
4	8	12	16




1
2
3
⋮
16


		0	1	2		
		3	c	4		
		5	6	7		




Face image




The face image is divided into blocks



LBP histogram from each block



Feature histogram








Objekt




Vstup




Klasifikátor




Výstup



Anotované příklady



Účící se algoritmus



Klasifikátor





