

# Segmentace obrazu

Lukáš Cerman

19. listopadu 2009

## 1 Úvod

Označme

$$X_i = \{x_1^i, x_2^i, \dots, x_N^i\} \quad (1)$$

rozdíl  $i$ -tého snímku od referenčního snímku, kde  $x_j^i$  je rozdíl  $j$ -tého pixelu,  $X_i$  říkáme pozorování (měření). Dále označme

$$S_i = \{s_1^i, s_2^i, \dots, s_N^i\} \quad (2)$$

segmentaci  $i$ -tého snímku, kde  $s_j^i \in \{0, 1\}$  je segmentace  $j$ -tého pixelu,  $s_j^i = 0$  značí pozadí,  $s_j^i = 1$  značí popředí,  $s$  říkáme třída.

Hledáme takovou segmentaci, která maximalizuje pravěpodobnost  $p(S_i, X_i)$ , tedy:

$$S_i^* = \operatorname{argmax}_{S_i} p(S_i, X_i) = \operatorname{argmax}_{S_i} p(X_i|S_i)p(S_i). \quad (3)$$

Předpokládáme-li nezávislost jednotlivých pixelů, platí dále:

$$S_i^* = \operatorname{argmax}_{S_i} \prod_j p(x_j^i|s_j^i)p(s_j^i). \quad (4)$$

Z (4) je vidět, že optimální segmentace bude taková, která maximalizuje pravděpodobnost pozorování  $x_j^i$  v každém pixelu  $j$ , tedy:

$$s_j^i = \begin{cases} 0 & \text{pro } p(x_j^i|s_j^i = 0)p(s_j^i = 0) \geq p(x_j^i|s_j^i = 1)p(s_j^i = 1) \\ 1 & \text{pro } p(x_j^i|s_j^i = 0)p(s_j^i = 0) < p(x_j^i|s_j^i = 1)p(s_j^i = 1) \end{cases}. \quad (5)$$

## 2 Učení

Z předchozí sekce je vidět, že k určení optimální segmentace potřebujeme pravděpodobnosti  $p(x_j^i | s_j^i)$  a  $p(s_j^i)$ . Ty neznáme, ale můžeme se je naučit. Označme ručně pořízené segmentace (trénovací data) jako

$$S_i^t = \{s_1^{t,i}, s_2^{t,i}, \dots, s_N^{t,i}\}, \quad (6)$$

kde  $i \in T$ ,  $T$  jsou čísla snímků vybraných pro trénování. Dále označme  $Q_i^1$  množinu pixelů, které jsou v trénovacím snímku  $i$  označeny jako popředí:

$$Q_i^1 = \{j : j \in \{1 \dots N\}, s_j^{t,i} = 1\} \quad (7)$$

a  $Q_i^0$  množinu pixelů, které jsou v trénovacím snímku  $i$  označeny jako pozadí:

$$Q_i^0 = \{j : j \in \{1 \dots N\}, s_j^{t,i} = 0\}. \quad (8)$$

Pravděpodobnost  $p(s = 0)$  určíme jako poměr počtu pixelů na pozadí k celkovému počtu pixelů v trénovacích datech. Pravděpodobnost  $p(s = 1)$  určíme jako poměr počtu pixelů na popředí k celkovému počtu pixelů v trénovacích datech. Tedy:

$$p(s) = \frac{\sum_{i \in T} |Q_i^s|}{|T|N}. \quad (9)$$

Pravděpodobnost  $p(x | s = 0)$  budem reprezentovat normalizovaným histogramem rozdílů mezi referenčním snímkem a trénovacími snímky na pixelech v pozadí. Pravděpodobnost  $p(x | s = 1)$  budem reprezentovat normalizovaným histogramem rozdílů mezi referenčním snímkem a trénovacími snímky na pixelech v popředí. Tedy:

$$p(x | s) = h_s(x), \quad (10)$$

kde  $h_s(x)$  je spočítán z hodnot:


$$x_j^i : j \in Q_i^s, i \in T. \quad (11)$$

## 3 Optimální segmentace

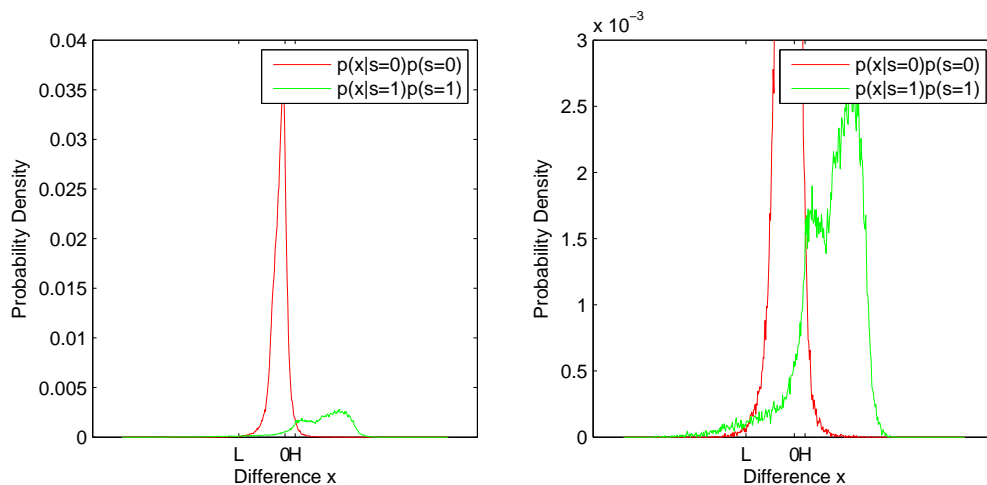
Podle vztahu (5) budeme rozhodovat o zařazení pixelu  $j$  v  $i$ -tém snímku do pozadí nebo do popředí (tj. volit hodnotu  $s$ ) tak, aby hodnota pravděpodobnosti:

$$p(x_j^i | s_j^i) p(s_j^i) \quad (12)$$

byla maximální. Z obrázku 2, je vidět, že



Obrázek 1: Trénovací data (pracujeme pouze s hodnotami uvnitř oblasti zájmu, tedy ve vybraném obdélníku na zdi).



Obrázek 2: Pravděpodobnostní model získaný učením z trénovacích dat,  $p(x|s)p(s) = h_s(x)p(s)$ , graf vpravo má pouze změněné měřítko svislé osy.



Obrázek 3: Výsledná segmentace, vpravo po filtraci.

1. pro hodnoty  $x_j^i$  větší než  $H$  přiřadíme daný pixel do třídy popředí ( $p(x|s=1)p(s=1)$  je větší než  $p(x|s=0)p(s=0)$ ),
2. pro hodnoty  $x_j^i$  menší než  $L$  přiřadíme daný pixel do třídy popředí ( $p(x|s=1)p(s=1)$  je větší než  $p(x|s=0)p(s=0)$ ),
3. pro hodnoty  $x_j^i$  mezi  $L$  a  $H$  přiřadíme daný pixel do třídy pozadí ( $p(x|s=0)p(s=0)$  je větší než  $p(x|s=1)p(s=1)$ ).

Z obrázku 3 je vidět, že výsledná segmentace může obsahovat šum, ten lze odstranit např. filtrací pomocí median filtru (`medfilt2`).

## 4 Závěr

Segmentaci obrazu lze provést prahováním rozdílu na dvou prazích  $L$  a  $H$ . Tyto prahy můžeme určit tak, že spočítáme histogramy rozdílů na pozadí a popředí ( $h_0(x)$  a  $h_1(x)$ ), které reprezentují pravděpodobnost  $p(x|s=0)$

a  $p(x|s = 1)$ , apriorní pravděpodobnosti  $p(s = 0)$  a  $p(s = 1)$  a porovnáme hodnoty  $p(x|s = 0)p(s = 0)$  a  $p(x|s = 1)p(s = 1)$  v grafu.