

# Studentská Vědecká Konference 2011

## SEGMENTACE JATER Z CT POMOCÍ STATISTICKÝCH MOMENTŮ

Ivan PIRNER<sup>1</sup>

### 1 ÚVOD

Segmentace je jednou z nejdůležitějších technik počítačového vidění. Jejím úkolem je oddělit v digitálním obraze jednotlivé oblasti, které logicky odpovídají objektům reálného světa. Bez tohoto zpracování není možné scéně „porozumět“. Segmentace jater ze snímků CT je poměrně náročná úloha, při které selhává většina používaných metod, a pokud fungují, je třeba nastavit, ideálně natrénovat, velké množství parametrů. Při řešení této úlohy použili zcela nový přístup založený na hledání spojitých oblastí nezávisle na jejich jasů.

### 2 PŘEHLED

K řešení této úlohy se nabízí několik možných přístupů - viz. Šonka (2007) - *prahování, detekce hran, narůstání oblastí, minimalizace energie řezem grafu* a další složitější metody založené na *tvaru objektu*.

Prahování samotné nelze použít, protože v obraze se vyskytuje mnoho objektů o stejné denzitě (rentgenové odrazivosti). Hodí se však jako hrubé předzpracování pro další metody. Detekce hran konvenčním způsobem je zcela nepoužitelná, protože povrch jater není ostře ohraničen vůči okolí, a neposkytuje tedy žádné smysluplné výsledky. Narůstání oblastí sice spolehlivě najde játra, ovšem vždy v určitých místech přesahuje do oblastí žebíř a srdce. Přebytkové oblasti by se musely velice pracně odstraňovat ručně. Použití metody graphcut se ukázalo rovněž jako komplikované, stejně jako u metod založených na tvaru segmentované oblasti je třeba dobrá apriorní informace o objektu a nastavení mnoha obtížně interpretovatelných parametrů.

### 3 NOVÝ PŘÍSTUP


Při studiu histogramů četnosti denzit pixelů v okolí rozhraní játra-ostatní tkáň jsme zjistili jistou korelaci mezi tvarem histogramů uvnitř jater. Uvnitř spojitě oblasti bylo rozdělení hodnot gaussovské, nevychýlené, zatímco na okrajích oblasti bylo vychýlené na kladnou či zápornou stranu. Nejjednodušší popis této skutečnosti poskytuje tzv. „koeficient špičatosti“ (anglicky skewness) statistického výběru.

$$\text{skew}(i, j) = \frac{\mu_{U(i,j)}^3}{\sigma_{U(i,j)}^3}, \quad (1)$$

$$U(i, j) = \{[x, y]; x, y \in Z, i - k \leq x \leq i + k, j - k \leq y \leq j + k\},$$

---

<sup>1</sup>Ing. Ivan Pirner, student doktorského studijního programu Aplikované vědy a informatika, obor Kybernetika, specializace Umělá inteligence, e-mail: pirner@kkz.zcu.cz



**Obrázek 1:** Ukázka segmentovaného řezu

kde  $\mu$  je střední hodnota a  $\sigma$  směrodatná odchylka statického výběru  $U(i,j)$ , který zahrnuje okolí pixelu  $(i,j)$ . Matici  $\mathbf{abs}(\mathbf{skew}(\mathbf{i},\mathbf{j}))$  nyní můžeme považovat za matici příznaků pixelů  $(i,j)$  a pixely klasifikovat lineárním klasifikátorem. Hodnotu klasifikačního kritéria jsme nastavili ručně, není však problém ji strojově naučit.

#### 4 VÝSLEDKY

Nasegmentovali jsme játra z 0.6 mm silných axiálních řezů. Příklad takové segmentace je zobrazen na obrázku 1.

#### 5 ZÁVĚR

Vyvinuli jsme nový přístup pro segmentaci obrazových dat, jehož použití může být širší než pouze segmentace lékařských obrázků. Dal by se například použít i pro inteligentní odšumování fotografií. Tento postup chceme v budoucnu ještě zdokonalit, veškeré parametry trénovat strojově a zrychlit samotný výpočet.

**Poděkování:** Tento výzkum byl podpořen granty ZČU „Inteligentní metody strojového vnímání a porozumění“, project No. SGS-2010-054 a uvPodpora biomechaniky na FAV, project No. SGS-2010-077

#### REFERENCE

Sonka M., Hlavac V., Boyle R. 2007. *Image Processing, Analysis and Machine Vision*. Thomson Learning, Toronto.