

Zpracování digitalizovaného obrazu (ZDO) - Segmentace II

Další metody segmentace

Ing. Zdeněk Krňoul, Ph.D.

Katedra Kybernetiky
Fakulta aplikovaných věd
Západočeská univerzita v Plzni



Obsah:

- ▶ Segmentace na základě detekce hran
 - ▶ Určení hranice s využitím znalosti její polohy
 - ▶ Postupné dělení spojnic
 - ▶ Aktivní kontury
- ▶ Segmentace analýzou oblastí
 - ▶ Algoritmus Split&Merge
 - ▶ Markov random field
- ▶ Srovnávání se vzorem



Segmentace na základě detekce hran

Hrany místa obrazu, kde dochází k určité nespojitosti, většinou v jasu, ale také v barvě, textuře, hloubce apod.

Obraz hran vznikne aplikací některého hranového operátoru.

Hranice je popis okraje segmentovaného objektu.

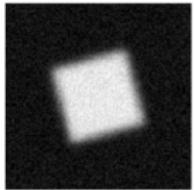
- ▶ Úkolem segmentace je v tomto případě spojení hran do řetězců, které lépe odpovídají průběhu hranic;
- ▶ Často je využita apriorní informace o tom, kde jsou hrany a jaký je jejich vztahy k ostatním částem obrazu;
- ▶ Pokud není apriorní informace k dispozici, musí segmentační metoda brát v úvahu lokální vlastnosti spolu s obecnými znalostmi specifickými pro danou aplikační oblast.



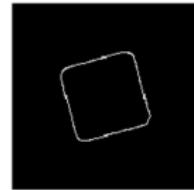
Prahování obrazu hran

- ▶ obvykle jen velmi málo míst v obrazu má nulovou hodnotu velikosti hrany. Důvodem je přítomnost šumu
- ▶ metoda prahování obrazu hran potlačí nevýrazné hrany malé velikosti a zachová pouze významné hrany (význam slov „malé“, „významné“ souvisí s velikostí prahu)
- ▶ hodnotu prahu lze určovat např. metodami procentního prahování
- ▶ někdy se aplikuje následné zpracování výsledku – např. vypuštění **hran** kratších než jistá hodnota

noisy image

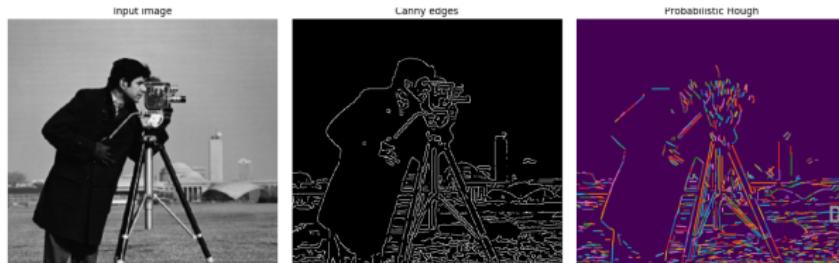


Canny filter, $\sigma = 1$



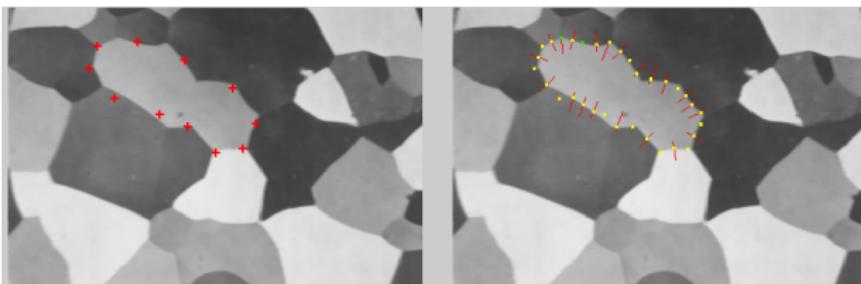
Určení hranice s využitím znalosti její polohy

- ▶ Předpokládáme informaci o pravděpodobné **poloze a tvaru** hranice, získanou např. díky znalostem vyšší úrovně nebo jako výsledek segmentačních metod aplikovaných na obraz nižšího rozlišení;
- ▶ Jednou z možností je určovat polohu hranice jako polohu významných hranových buněk, které se nacházejí v blízkosti předpokládaného umístění hranice a které mají směr blízký předpokládanému směru hranice v daném místě;
- ▶ Podaří-li se najít dostatečný počet obrazových bodů, vyhovujících těmto podmínkám, je těmito body proložena vhodná aproximační křivka – *zpřesněná hranice*



Postupné dělení spojnic

- ▶ Využijeme pokud známe koncové body hranice a předpokládáme malý šum a malé zakřivení hranice;
- ▶ Možný přístup je postupné dělení spojnic již detekovaných sousedních elementů hranice a hledání dalšího hraničního elementu na **normále** vedené středem této spojnice;
- ▶ Hranový element, který je nejblíže spojnici dosud detekovaných bodů a má **nadprahovou** velikost hrany, je považován za nový element hranice a iterační proces se opakuje ([demo](#))



Aktivní kontury - Active Contour Model

Model zpřesňuje hranici deformovatelnou otevřenou/uzavřenou spline funkcí (snake) ... r.1987

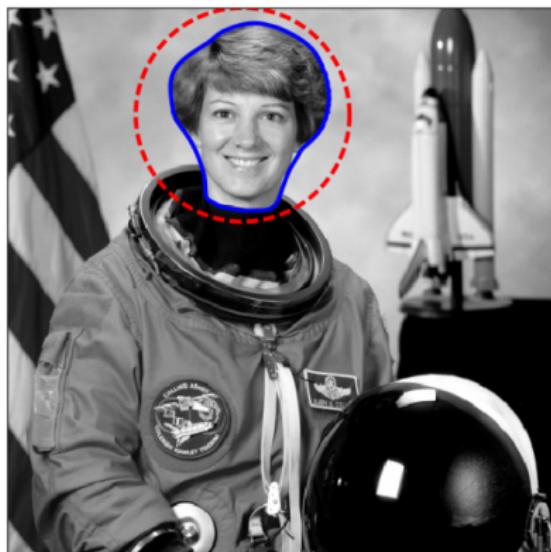
Minimalizace energie je z části určena z **energií obrazu** pod spline funkcí a z části z **energie tvaru** spline funkce (délka, hladkost, ...)

Použití segmentace je pro zašuměná data, častá je iterace s uživatelem (inicializace polohy popř. energie) nebo s jinou segmentační/detekční technikou

Například. segmentace tváře osoby od pozadí tak, že je nalezne obklopující (uzavřená) spline funkce v místech největších hran po obvodě, inicializace s nejprve aplikovaným detektorem tváře.



Aktivní kontury - Active Contour Model



demo¹

¹Tim Cootes, University of Manchester

Segmentace narůstáním oblastí - Region Growing

- ▶ Lze uplatnit v obrazech se šumem, kde se obtížně hledají hranice
- ▶ Významnou vlastností **HOMOGENITA**
- ▶ Rozdelení obrazu do maximálních souvislých oblastí tak, aby tyto oblasti byly z určitého hlediska homogenní.

Kritérium homogeneity

- ▶ založeno na jasových vlastnostech, komplexnějších způsobech popisu nebo dokonce na vytvářeném modelu segmentovaného obrazu
- ▶ většinou pro oblasti požadujeme splnění těchto podmínek:
 1. $H(R_i) = \text{TRUE}$ pro $i = 1, 2, \dots, I$
 2. $H(R_i \cup R_j) = \text{FALSE}$ pro $i, j = 1, 2, \dots, I$ $i \neq j$ R_i soused R_j

Kde: I počet oblastí R_i jednotlivé oblasti $H(R_i)$

dvouhodnotové vyjádření kritéria homogeneity → oblasti musí být (1) homogenní a (2) maximální



Algoritmus spojování oblastí

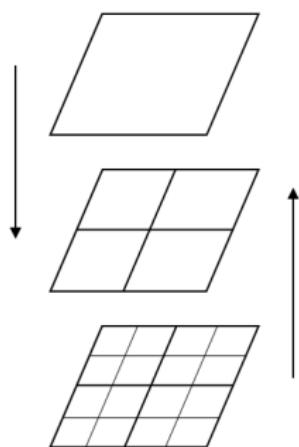
Nejpřirozenější metoda spojování oblastí vychází z počátečního rozložení, kdy každý obrazový element představuje **samostatnou oblast**, čímž při splnění (1) nesplní (2). Dále spojujeme vždy dvě sousední oblasti, pokud oblast vzniklá spojením těchto dvou oblastí bude vyhovovat kritériu homogenity.

- ▶ Výsledek spojování závisí na pořadí, v jakém jsou oblasti předkládány k spojování.
- ▶ Nejjednodušší metody vycházejí z počáteční segmentace obrazu na oblasti 2x2, 4x4 nebo 8x8.
- ▶ Popis homogenity většinou založen na statistických jasových vlastnostech (např. histogram jasu v oblasti).
- ▶ Popis oblasti je srovnáván pomocí statistických testů s popisem sousední oblasti.
 - ▶ při shodě dojde ke spojení obou oblastí a vznikne nová oblast
 - ▶ v okamžiku, kdy nelze spojit žádné dvě oblasti, proces končí



Štěpení a spojování - Split and Merge

- ▶ Tato metoda zachovává dobré vlastnosti obou uvedených přístupů.
- ▶ Využívá pyramidální reprezentaci obrazu.
- ▶ Oblasti jsou čtvercové a odpovídají elementu dané úrovně pyramidální datové struktury.



1. Na počátku určíme nějaké počáteční rozložení obrazu.
2. Platí-li pro oblast R k-té úrovně pyramidální struktury $H(R) = FALSE$ (oblast není homogenní), rozdělíme R na 4 oblasti ($k + 1$). úrovně.
3. Existují-li sousední oblasti R_i a R_j takové, že $H(R_i \cup R_j) = TRUE$, spojíme R_i a R_j do jedné oblasti.
4. Nelze-li žádnou oblast spojit ani rozdělit,



Markov random field (MRF)

- ▶ **kontext** = souvislost sousedních bodů, tj. význam bodu je závislý na významech bodů sousedních ... Markovianita
- ▶ využití kontextu je velmi cenné pro analýzu obrazu - založeno na **podmíněné pravděpodobnosti**

Problém přiřazení labelů

- ▶ každý pixel p je definován příznakovým vektorem \vec{f}_p (v základu jeho jas) a množina všech příznakových vektorů
$$\dots f = \{\vec{f}_p : p \in \mathcal{I}\}$$
- ▶ množina labelů \mathcal{L} určuje segmentaci např.
$$\mathcal{L} = \{\text{objekt, pozadí}\}$$
- ▶ z hlediska Markovských modelů představuje label „skrytou“ proměnnou
- ▶ každému pixelu p je přiřazen jeden label ω_p
- ▶ **konfigurace pole** $\dots \omega = \{\omega_p : p \in \mathcal{I}\}$

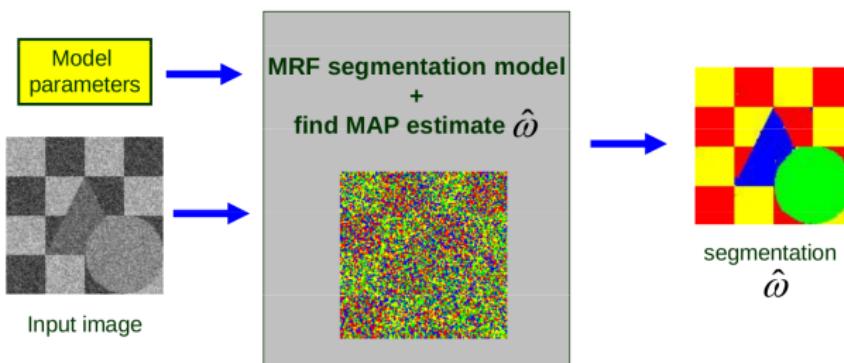
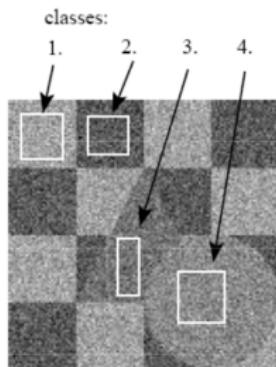


- obrázek o rozměrech NxM → $|\mathcal{L}|^{NM} = |\Omega|$ možných výsledků
- jak vybrat ten správný?

Odhad maximální aposteriorní pravděpodobnosti (MAP):

- **Cíl:** definovat pravděpodobnostní míru (pravděpodobnost olabelování)
- pravděpodobnost konfigurace ω je určena jako $P(\omega|f)$
- chceme najít ω^* maximalizující $P(\omega|f)$
- $\omega^{*\text{MAP}} = \arg \max_{\omega \in \Omega} P(\omega|f)$
- Bayesovo pravidlo: $P(\omega|f) = \frac{P(f|\omega)P(\omega)}{P(f)}$
- pro neměnná data f je $P(f)$ konstanta ⇒
 $P(\omega|f) \propto P(f|\omega)P(\omega)$
- určení $P(\omega)$ a $P(f|\omega)$ → je úkolem **MRF**
- MRF převádí na úlohu optimalizace minimální energie (energie dat + energie spojitosti)
- náhodné pole může být definováno jako graf (nejčastěji metoda Graph-Cut)





Segmentace srovnáváním se vzorem - Template Matching

- ▶ Úloha má za úkol nalézt známé objekty (vzory) v obrazu.
- ▶ Objekty (vzory) mají většinou charakter obrazu.
- ▶ Další možnosti kromě hledání objektů – srovnávání dvou snímků z různých míst (stereoskopie), určování relativního pohybu objektů
- ▶ Pokud by obraz byl bez šumu, úloha by byla velmi snadná, protože bychom v obraze nalezli přesnou kopii hledaného vzoru
- ▶ Jako míru souhlasu většinou používáme vzájemnou korelací:

$$C(u, v) = \frac{1}{\sum_{(i,j) \in V} (f(i+u, j+v) - h(i, j))^2} \quad (1)$$

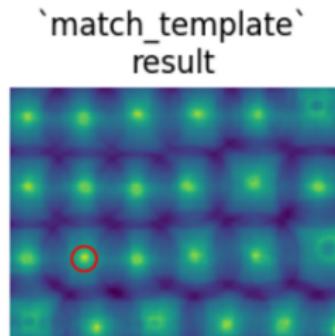
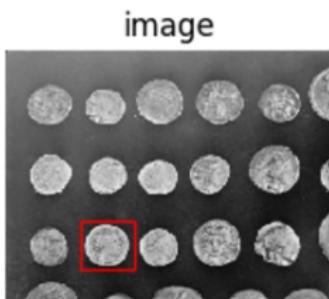


- ▶ Testujeme souhlas obrazu f se vzorem h umístěným v poloze (u, v) .
- ▶ Pro každou polohu vzoru h v obraze f určíme hodnotu míry souhlasu vzoru C s danou částí obrazu
- ▶ Lokální maxima, která jsou větší než určený práh, reprezentují polohu v obraze
- ▶ Problémy nastanou, pokud se vzor v obraze vyskytuje natočený, s jinou velikostí nebo s geometrickým zkreslením.
- ▶ V takovém případě musíme testovat míru souhlasu pro všechna možná natočení, velikosti, geometrická zkreslení ap.
pozn. Tento problém lze částečně řešit v případě, kdy je hledaný vzor složen z několika částí spojených pružnými spojkami. Pak testujeme nejprve jednotlivé (menší) části a pak teprve hledáme pružná spojení



Segmentace srovnáváním se vzorem - Template Matching

- ▶ Metodu lze urychlit zrychleným prováděním testů v hrubším rozlišení a v místě lokálního maxima pak přesným doměřením polohy $(u, v)^*$, pro kterou nastává největší hodnota míry souhlasu vzoru s částí obrazu.
- ▶ výpočet korelace ve frekvenčním spektru (viz [demo doc matlab](#))



Segmentace srovnáváním se vzorem - Key-Point Matching

- ▶ Srovnávání se vzorem probíhá výběrem shodných bodů nalezených v obraze i ve vzoru
- ▶ Použije se detektor významných bodů (detektor rohů: Harris, Moravec, aj. + deskriptory SIFT, SURF, KAZE)
- ▶ hledání platné transformace mezi vzorem a podoblastí analyzovaného obrazu (např. posun, rotace, affinní transformace, homografie) vhodnou metodou (např. RANSAC)

