

SEGMENTATION OF HIPPOCAMPUS IN MRI DATA

Oldřich Kodym

Bachelor Degree Programme (3), FEEC BUT

E-mail: xkodym01@stud.feec.vutbr.cz

Supervised by: Petr Walek

E-mail: xwalek01@stud.feec.vutbr.cz

Abstract: This project deals with application of graph-based methods in segmentation of low contrast image data, specifically hippocampus in MRI data. Using graph cuts for the segmentation allows the software to utilize high accuracy, robustness and an ability to interact with the user.

Keywords: Graph theory, Graph cut, Min-cut/Max-flow theorem, Hippocampus segmentation

1 ÚVOD

Hipokampus je párový orgán limbického systému, který hraje důležitou roli při zpracování informací a uchovávání krátkodobé paměti. Segmentace hipokampu, tedy rozdělení obrazu na oblast obsahující hipokampus a oblast obsahující okolní tkáň, má význam především pro diagnostiku onemocnění, která způsobují ztrátu objemu hipokampu. Klíčovou roli hraje především při diagnostice Alzheimerovy choroby, při které lze změnu objemu sledovat již ve velmi časných stádiích onemocnění a diagnózu lze provést presymptomaticky.

Tkáň hipokampu je však morfologicky velmi podobná okolním tkáním mozku a jeho segmentace je tedy velmi obtížná. I mezi odborníky panuje neshoda ve vymezení jistých velmi nejasných hranic orgánu a ruční segmentace je proto časově náročná. Z tohoto důvodu je snaha segmentaci aspoň částečně automatizovat. Tento projekt využívá pro segmentaci poznatky z teorie grafů, konkrétně nalezení minimálního řezu grafem.

2 ZÁKLADNÍ POJMY TEORIE GRAFŮ


Graf můžeme chápat jako strukturu tvořenou dvěma prvky; množinou vrcholů či uzlů (*vertices*, *nodes*) a množinou hran (*edges*), které tyto vrcholy propojují. Takovou situaci si můžeme představit jako krajinu s městy reprezentovanými vrcholy, které jsou propojeny cestami reprezentovanými hranami. Matematicky je graf G s vrcholy V a hranami E definován jako uspořádaná dvojice množin $G = (V, E)$, kde $E \subseteq V \times V$, tedy prvky množiny E jsou dvojprvkové podmnožiny množiny V .

Pro účely tohoto projektu vždy uvažujeme u grafu také následující vlastnosti: Graf je vždy váhovaný (každá hrana má reálnou váhu, která vyjadřuje její hodnotu vůči ostatním prvkům), orientovaný (rozlišujeme hranu z vrcholu v_i do v_j a hranu z vrcholu v_j do v_i) a směřovaný (hrany mezi stejnými vrcholy v opačném směru mohou mít různé váhy). Příklad jednoduchého grafu je na obr. 1(a).

Sít' (*network*) je potom speciálním případem grafu, kde hrany považujeme za soustavu pomyslných trubek, kterými může procházet jistý tok. Váhy hran zde vyjadřují kapacitu, tedy největší možný tok, který může danou hranou téct. Platí, že celkový součet všech přicházejících a odcházejících toků je v každém vrcholu stejný s výjimkou jednoho zdroje (vrchol, ze kterého tok pouze vychází) a jednoho stoku (tok pouze přichází).

V síti můžeme taky zavést pojem řez (*cut*), což je množina hran, která plně odděluje zdroj od stoku. Po odstranění těchto hran ze sítě by se tedy tok ze zdroje do stoku nemohl dostat. Sečteme-li váhy všech

hran řezu, dostáváme energii řezu. Nalezení řezu s minimální energií představuje při vhodné reprezentaci obrazových dat právě nalezení optimální hranice mezi objektem a pozadím v segmentovaném obrazu. Příklad řezu v síti s toky a kapacitami je na obr. 1(b).



Obrázek 1: Příklad jednoduchého grafu (a), síť s řezu (b) a reprezentace 2D obrazu (c).

3 KONVERZE OBRAZOVÝCH DAT NA GRAF

V sestaveném grafu bude každý voxel (*volume element*) snímku reprezentován jedním vrcholem. Propojen bude se sousedními voxely (určeném ve 2D snímku 4- nebo 8-okolím, ve 3D snímku potom 6-, 18- nebo 26-okolím) tzv. *n-hranami*. Váha hrany mezi sousedními voxely p a q má hodnotu

$$B_{p,q} = \exp\left(-\frac{(I_p - I_q)^2}{2\sigma^2}\right) \cdot \frac{1}{\text{dist}(p,q)} \quad (1)$$

a vyjadřuje tedy normalizovaný rozdíl intenzit sousedních voxelů, tzv. *boundary term*. Sigma je lokální směrodatná odchylka intenzit.

Kromě těchto hran je v grafu ke každému voxelu připojen tzv. *t-hranami* zdroj představující objekt segmentace a stok představující pozadí. Váhy těchto hran mají v pixelu p hodnotu

$$R_p(\text{„obj“}) = -\ln \Pr(I_p \mid \text{„obj“}) \quad (2)$$

$$R_p(\text{„bkg“}) = -\ln \Pr(I_p \mid \text{„bkg“}) \quad (3)$$

a vyjadřují pravděpodobnost, že daný voxel patří do objektu (obj) či pozadí (bkg), tzv. *region term*. Na každý voxel ve snímku se tedy v případě 6-okolí připojuje šest *n-hran*, jedna *t-hrana* objektu a jedna *t-hrana* pozadí. Příklad 2D snímku vyjádřeného grafem je na obr. 1(c).

Celková energie řezu je potom definována jako


$$E(A) = \lambda \cdot R(A) + B(A), \quad (4)$$

kde A je množina hran tvořící řez. V $R(A)$ jsou započteny hrany vedoucí z každého voxelu objektu do zdroje a z každého voxelu pozadí do stoku a v $B(A)$ všechny hrany na rozhraní objekt/pozadí. Koeficient lambda umožňuje upřednostňovat při segmentaci složku *boundary term* či *region term* [2].

4 ALGORITMUS NALEZENÍ MINIMÁLNÍHO ŘEZU GRAFEM


Tento projekt využívá Boykov-Kolmogorovu implementaci Ford-Fulkersonova *augmenting path* algoritmu. Ten po každém nalezení cesty toku ze zdroje do stoku tuto cestu naplní největším možným jednotným tokem (takový tok, který saturuje hranu s nejmenší kapacitou) a poté se vrátí k hledání další cesty. Jakmile vyčerpá všechny cesty, které by se daly takto naplnit, byl nalezen maximální možný tok sítě. Maximální tok je potom podle *min-cut/max-flow* teorému využit k určení minimálního řezu tak, že v každé cestě ze zdroje do stoku se odstraní první saturovaná hrana. Množina těchto odstraněných hran odpovídá minimálnímu řezu [1].

5 NAVRŽENÁ STRUKTURA PROGRAMU



Obrázek 2: Schéma navrženého programu.

Navržený segmentační program je shrnut ve schématu v obrázku 2. Po načtení dat a volbě řezu poskytuje uživateli možnost vyznačit interaktivním štětcem část oblasti hipokampu a jeho okolí, viz obr. 3(a). Takto označené voxely jsou následně použity jednak pro výpočet σ a sestavení histogramu objektu a pozadí pro *region term* podmínku, viz obr. 3(b), a jednak jako pevná omezení pro výslednou segmentaci, takže voxely označené jako objekt nikdy nemohou být segmentovány jako pozadí a naopak. Po označení lze provést grafovou segmentaci, jejíž výsledek se promítne do označeného snímku, viz obr. 3(c). Výsledek segmentace lze v jakémkoliv řezu upravit označením chybných či dodatečných voxelů a opětovně segmentovat. Takto lze postup opakovat, dokud není celý hipokampus správně segmentován.



Obrázek 3: Způsob označení hipokampu (a), vzniklý histogram (b), výsledek segmentace po první iteraci (c) a výsledek po jedné opravné iteraci (d).

6 ZÁVĚR

Program byl realizován v programovém prostředí MATLAB[®] a implementován jako modul pro software 3D Slicer. Použito je 6-okolí a volitelná lambda, která byla v ukázkové segmentaci zvolena 0,05. Na obr. 3(c) je výsledek segmentace po označení hipokampu podobným způsobem v 8 ze 20 řezů v první iteraci a na obr. 3(d) po upravení výsledku v 5 řezech ve druhé iteraci. Výpočetní doba každé iterace se pohybuje kolem 20 sekund. Po každé grafové segmentaci se odstraní všechny segmentované objekty, které nejsou přímo napojeny na vyznačené voxely.

Teprve následné testování na neurologickém pracovišti posoudí přesnost programu, už nyní je však ze srovnání s lékařem označenými daty zřejmé, že program je schopen úspěšně provést náročnou segmentaci, a to nejen hipokampu. Ačkoliv je vyžadována jistá míra interakce uživatele, na rozdíl od plně automatických metod je zde možnost dostat se dodatečnými kroky vždy k výsledku dostatečně přesnému k objektivnímu hodnocení změny objemu orgánu.

REFERENCE

- [1] FORD, L a D FULKERSON. Flows in networks. New Jersey: Princeton University Press, 2011, xix, 194 s. princeton landmarks in mathematics. ISBN 978-0-691-14667-6.
- [2] BOYKOV, Y a G FUNKA-LEA. Graph Cuts and Efficient N-D Image Segmentation. International Journal of Computer Vision. 2006, vol. 70, issue 2, s. 109-131. DOI: 10.1007/s11263-006-7934-5. Dostupné z: <http://link.springer.com/10.1007/s11263-006-7934-5>