

SEGMENTATION OF RIBS IN THORACIC CT SCANS

Ondřej Kašík

Master Degree Programme (2), FEEC BUT

E-mail: xkasik01@stud.feec.vutbr.cz

Supervised by: Roman Jakubíček

E-mail: jakubicek@feec.vutbr.cz

Abstract:

This paper deals with rib segmentation in thoracic CT data. For the segmentation method of rib centerlines detection is chosen. The first step of this approach is to extract the centerlines of all the bones located in the scan. These centerlines are divided into short primitives, which are subsequently classified into couple of categories, depending on whether they represent the centerline of the rib. More than 95% of all primitives are classified correctly. In the last step, the rib centerlines are used as the seed points of the region growing algorithm in three-dimensional space.

Keywords:

Computed tomography, segmentation, ribs, centrelines, classification, region growing


1 ÚVOD

Výpočetní tomografie je v posledních letech populární a hojně využívaná zobrazovací modalita. Se zlepšující se technologií se snižuje tloušťka jednotlivých řezů v tomografických datech a přímo úměrně tomu se navyšuje počet získaných snímků. Manuální vyhodnocení výsledků CT vyšetření lékařem může být časově náročné, z toho důvodu začaly vznikat automatické metody pro zpracování objemových dat lidského těla, mezi které může být mimo jiné zařazena i segmentace žeber z hrudních CT snímků.

Vysegmentovaná žebra mohou sloužit například pro lepší vizualizaci hrudního koše při poranění hrudníku a jejich poloha může být využita pro následnou detekci dalších struktur lidského těla, především se však segmentace žeber uplatňuje při detekci anatomických abnormalit, nejčastěji metastáz, které na žebrech vznikají jako důsledek rakovinného onemocnění pacienta.

2 PŘÍSTUP K SEGMENTACI ŽEBER

Pro realizaci segmentace žeber z hrudních CT dat byl zvolen přístup založený na detekci středových linií žeber popsány ve článku [1]. Prvotním krokem tohoto postupu je předzpracování vstupních dat, na které navazuje nalezení středových linií veškerých kostí hrudního koše, rozdělení těchto linií na krátká primitiva, následná klasifikace získaných primitiv a konečně, finální segmentace žeber s využitím metody narůstání oblastí. Dílčí výstupy jednotlivých kroků popsány v následujících kapitolách jsou zobrazeny na obrázku 3.



a)



b)



c)

Obrázek 1: a) Řez žebrem ve vstupních CT datech b) Řez žebrem v naprahaném snímku c) Rozmazaný řez žebrem v naprahaném snímku (s maximální intenzitou jasu ve svém středu)

2.1 PŘEDZPRACOVÁNÍ VSTUPNÍCH DAT

Prvním krokem popsaného segmentačního přístupu je převzorkování vstupních dat na požadovanou velikost. Je žádoucí, aby velikost jednotlivých snímků byla právě 256 x 256 pixelů a aby data obsahovala tomu odpovídající počet řezů a nedošlo tak k jejich deformaci ve směru vertikální osy lidského těla.


Následně jsou CT data naprahována, čímž dojde k segmentaci kostí. Velikost prahu je stanovena pevně, a to na hodnotu 1250 HU [2]. Po naprahování jsou ve snímcích v popředí patrné převážně kosti, kterým je přiřazena hodnota 1, měkkým tkáním je naopak přiřazena hodnota 0 a v naprahovaných snímcích představují pozadí.

Posledním krokem předzpracování je rozmazání vstupních dat ve všech třech směrech s využitím Gaussovského vyhlazovacího filtru. [2] To má za následek změnu intenzity jasu v řezech žebra. Jelikož naprahovaná žebra se jeví jako dutá, jsou hodnoty intenzity jasu jejich středů před rozmazáním nižší hodnoty než hodnoty intenzity jasu na jejich okrajích, po rozmazání je tomu naopak, což je žádoucí. Původní, naprahovaný a rozmazaný řez žebrem jsou zobrazeny na obrázku **Chyba! Nenalezen zdroj odkazů.**

2.2 DETEKCE STŘEDOVÝCH LINIÍ KOSTÍ

Po předzpracování vstupních dat následuje nalezení středových linií kostí, tvořených hřebenovými voxely – ty jsou definovány jako pozice lokálního maxima v rovině kolmé na osu kosti (respektive žebra). Tato rovina je definována dvěma vlastními vektory Hessovy matice \mathbf{H} , která sestává z hodnot druhých parciálních derivací v posuzovaném bodě. Vlastní vektory Hessovy matice jsou seřazeny sestupně podle velikosti jejich vlastních čísel, přičemž vektory \mathbf{v}_1 a \mathbf{v}_2 definují zmíněnou rovinu a vektor \mathbf{v}_3 je na ni pak kolmý, jak je vidět na obrázku 2. [1]

Výše popsaná rovina je definována pro každý nenulový voxel předzpracovaných vstupních dat. V této rovině je nalezeno 8-okolí posuzovaného voxelu, který je označen jako lokální maximum (respektive hřebenový voxel), je-li jeho hodnota intenzity jasu vyšší, než hodnota intenzity jasu všech voxelů v jeho okolí. Jelikož souřadnice sousedních bodů mohou nabývat libovolných reálných hodnot, a tudíž mohou spadat mimo definované body vzorkovací mřížky, jejich hodnota intenzity jasu je získána s využitím interpolace.



Obrázek 2: Rovina kolmá na podlouhlou strukturu, definovaná vlastními vektory \mathbf{v}_1 a \mathbf{v}_2 Hessovy matice [1]

2.3 TVORBA PRIMITIV

Dalším krokem algoritmu je rozdělení středových linií kostí na krátká primitiva. Každé primitivum představuje sadu několika hřebenových voxelů s podobnou polohou a obdobnými vlastnostmi. Primitiva vznikají tak, že ze souboru veškerých nalezených hřebenových voxelů je náhodně vybrán jeden bod, jehož okolí je následně prohledáváno. Ke vznikajícímu primitivu mohou být přidány ty hřebenové voxely nalezené v okolí, které mají podobné vlastnosti jako body, které již jsou součástí primitiva. Pro přidání k primitivu musí nový kandidát splňovat následující tři podmínky.

První podmínka udává maximální možnou vzdálenost nového kandidáta od referenčního voxelu. Tato vzdálenost může nabývat libovolné kladné hodnoty a udává maximální velikost mezery mezi dvěma voxely středových linií, která může být při tvorbě primitiv tolerována. Další podmínka ověřuje prostorovou orientaci vlákna (respektive středové linie), ze kterého daný voxel pochází. Je žá-

doucí, aby orientace vlákna referenčního voxelu a vlákna kandidáta pro přidání byla co nejpodobnější. Poslední podmínka zajišťuje, že referenční voxel i kandidát pro přidání pocházejí z totožného vlákna – mohlo by se stát, že nový kandidát splňuje obě předešlé podmínky, avšak nachází se na vlákně, které je rovnoběžné s vláknem, ze kterého pochází voxel referenční, což je nežádoucí. [1]


K primitivu jsou opakovaně přidávány hřebenové voxely splňující definované podmínky, dokud se v okolí primitiva nacházejí vyhovující voxely nebo dokud není dosaženo maximální velikosti primitiva, která byla stanovena na 25 voxelů. Poté je ze zbývajících hřebenových voxelů náhodně vybrán nový počáteční bod další sady hřebenových voxelů. Tento proces se opakuje tak dlouho, dokud nejsou všechny hřebenové voxely součástí nějakého primitiva.

2.4 KLASIFIKACE PRIMITIV

V tomto kroce jsou vytvořená primitiva klasifikována do dvou kategorií podle toho, zdali reprezentují část žebra či nikoliv. Pro účely klasifikace je třeba z jednotlivých primitiv vyextrahovat příznaky, na základě kterých je rozhodnuto tom, do jaké ze dvou kategorií primitivum spadá.

Příznaky mohou být rozděleny do dvou skupin – *lokální*, popisující obecné vlastnosti primitiva a *vzájemné*, popisující interakce mezi dvěma sousedními primitivy. Mezi lokální příznaky patří délka a zakřivení primitiva, délka jeho projekce do jednotlivých os, průměrná hodnota jasu primitiva, hodnoty parciálních derivací v poloze primitiva a mnoho dalších. Vzájemnými příznaky jsou pak úhel a vzdálenost mezi dvěma sousedními primitivy, průměrná hodnota jejich délek či zakřivení nebo například absolutní rozdíl souřadnic jejich středů. Pro každé primitivum je odvozeno celkem 61 příznaků. [3]

Samotná klasifikace je realizována klasifikátorem k-nejbližších sousedů, který se pro tento účel ukázal jako nejvhodnější. Nejlepších výsledků bylo dosaženo v případě, že v příznakovém prostoru byli v úvahu bráni právě tři nejbližší sousedi klasifikovaného primitiva a počet příznaků byl na základě jejich důležitosti redukován na 34. Důležitost jednotlivých příznaků byla získána pomocí ROC křivek, odstraněny byly taktéž příznaky jejichž vzájemný korelační koeficient byl vyšší než 0,8. Zbylé příznaky byly transformovány tak, aby měly nulový průměr a směrodatnou odchylku rovnou jedné. Pro účely učení klasifikátoru bylo použito 9 ručně anotovaných CT skenů.



Obrázek 3: Jednotlivé mezivýsledky popsání algoritmu

a) Vstupní, naprahaná data **b)** Středové linie kostí **c)** Soubor všech primitiv **d)** Primitiva klasifikovaná do dvou tříd (žebro / ostatní) **e)** Finální segmentace žebor

2.5 FINÁLNÍ SEGMENTACE ŽEBER

Po odstranění nežádoucích primitiv ze setu se zbylá primitiva (středové linie žebor) stanou počátečními body (seedy) metody narůstání oblastí v trojrozměrném prostoru. V průběhu narůstání oblastí je prohledáváno okolí iniciačních bodů, přičemž k vysegmentované oblasti jsou přidávány ty voxely, které splňují dvě podmínky pro přidání. Při prohledávání okolí je uvažováno 18-okolí posuzovaného bodu.

Primárním parametrem pro přidání nového voxelu je hodnota intenzity jeho jasu, která se nesmí lišit od referenční hodnoty o více než ± 60 HU. Průměrná hodnota jasu již vysegmentované oblasti (referenční hodnota) je aktualizována vždy po přidání 100 nových voxelů, čímž je zajištěna povolená změna podmínek pro přidání dalších bodů.

Aby nedocházelo k případné segmentaci okolních měkkých tkání, mohou být k vysegmentované oblasti přidány pouze ty voxely, jejichž euklidovská vzdálenost od některého z prvotních, iniciačních bodů je nižší než 25.

3 VÝSLEDKY

První tři kroky realizované metody segmentace žeber je obtížné objektivně vyhodnotit. Jako kritérium pro popis úspěšnosti klasifikace primitiv byla zvolena senzitivita a specifická. Senzitivita udává počet správně označených primitiv reprezentujících středové linie žeber, naopak specifická popisuje počet primitiv náležících ostatním strukturám (páteř, lopatky, klíční kosti, ...), která jako žebra označena nebyla. Hodnota specifické ovlivňuje kvalitu finálního výsledku více než hodnota senzitivity, jelikož na klasifikaci primitiv navazuje krok narůstání oblastí a je žádoucí, aby se počáteční body této metody nacházely pouze v oblasti žeber, nikoliv v okolních strukturách, a nedocházelo tak k nežádoucí segmentaci těchto struktur. Bylo dosaženo následujících hodnot úspěšnosti:

- senzitivita: 93,42%
- specifická: 97,63%

Hodnoty úspěšnosti klasifikace byly získány formou křížové validace – soubor 10 ručně označených CT skenů byl vždy rozdělen na 9 trénovacích a 1 testovací CT sken, přičemž uvedené hodnoty úspěšnosti jsou průměrem hodnot získaných ve všech 10 dílčích cyklech křížové validace.

Úspěšnost finální segmentace žeber byla zhodnocena pouze subjektivně. Z obrázku 3e) je patrné, že popsaný algoritmus selhává zejména během segmentace počátků žeber a jejich napojení na páteř, což je způsobeno absencí počátečních bodů v této oblasti během finální segmentace. Naopak těla žeber, konce žeber a jejich napojení na hrudní kost jsou vysegmentována správně.

4 ZÁVĚR

Tento článek se zabývá metodou segmentace žeber založenou na detekci jejich středových linií a následném narůstání oblastí. Popsaná metoda je odolná vůči případným patologiím ve vstupních CT datech jako jsou například zlomeniny žeber. Vysegmentovaná žebra mají vysoký potenciál pro zrychlení a usnadnění diagnostického procesu pro lékařský personál například při detekci nádorů.

Postup segmentace byl zrealizován dílčími funkcemi v programovacím prostředí Matlab. Funkce realizující finální segmentaci metodou narůstání oblastí vykazuje jisté nedostatky a to především při segmentaci počátků žeber, zbylé části žeber jsou vysegmentovány kvalitně. Výsledná segmentace je do značné míry ovlivněna vhodným nastavením parametrů jednotlivých funkcí algoritmu.

Pro účely klasifikace primitiv bylo použito 10 ručně anotovaných CT skenů a bylo dosaženo celkové úspěšnosti klasifikace přibližně 95,5%. Použité CT skeny pocházejí z volně dostupné databáze RIDER Lung CT Dataset.

REFERENCE

- [1] STAAL, Joes, Bram VAN GINNEKEN a Max A. VIERGEVER. Automatic rib segmentation and labeling in computed tomography scans using a general framework for detection, recognition and segmentation of objects in volumetric data. *Medical Image Analysis*. 2007, **11**(1), 35-46 [cit. 2020-03-11]. DOI: 10.1016/j.media.2006.10.001. ISSN 13618415.
- [2] JAN, Jiří. Medical image processing, reconstruction, and restoration: Concepts and Methods. Boca Raton, FL: Taylor & Francis, 2006. ISBN 9780824758493.
- [3] STAAL, Joes, Bram VAN GINNEKEN a Max A. VIERGEVER. Automatic Rib Segmentation in CT Data. *Computer Vision and Mathematical Methods in Medical and Biomedical Image Analysis*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004, 2004, s. 193-204 [cit. 2020-03-11]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-540-27816-0_17.