

AUTOMATIC SEGMENTATION AND CLASSIFICATION OF INTERNAL CALIBRATION TISSUES

Jakub Šalplachta

Master Degree Programme (2), FEEC BUT

E-mail: xsalpl02@stud.feec.vutbr.cz

Supervised by: Jiří Jan

E-mail: jan@feec.vutbr.cz

Abstract: The aim of this work is finding a way to make calculation of bone mineral density of vertebrae with the use of internal calibration tissues fully automatic procedure. To accomplish that several methods for segmentation and classification of paraspinal muscle and subcutaneous fat were tested. For the testing and learning procedure of this work manually labelled database of tissues of interest was created and medically verified.

Keywords: computed tomography, texture analysis, cluster analysis, random forest classification, principal component analysis, bone mineral density

1. ÚVOD

Nutnost včasného odhalení osteoporózy vedla k vytvoření metod umožňujících výpočet minerální denzity (BMD – z anglického „Bone Mineral Density“) na základě jakýchkoliv CT dat pořizovaných obecně pro jinou diagnostiku. Tyto metody využívají interní kalibrační tkáně (paraspinnální sval a podkožní tuková tkáň) pro kalibraci CT hodnot tomografických dat a pro výpočet BMD těla obratle. Funkčnost těchto postupů byla již v praxi testována v lékařských studiích, přičemž tyto metody dosahovaly vysoké korelace s metodami v praxi považovanými jako zlatý standard [1]. Metody s využitím interních kalibračních tkání mají řadu výhod, z nichž největší je možnost jejich využití pro screeningovou diagnostiku osteoporózy. Jejich velkou limitací je však nutnost přesné segmentace paraspinnálního svalu a podkožní tukové tkáně, jež je v praxi realizována manuálně či semi-automaticky. V rámci této práce jsou testovány vybrané segmentační a klasifikační metody, jež jsou popsány v následující sekci a které by mohly být využity pro automatizaci celého postupu výpočtu BMD obratlů.

2. SEGMENTACE A KLASIFIKACE INTERNÍCH KALIBRAČNÍCH TKÁNÍ

V rámci vlastní realizace automatické klasifikace a segmentace interních kalibračních tkání byly testovány tři vybrané přístupy. Konkrétně byly zvoleny globální prahování, texturní analýza s klasifikací texturních příznaků algoritmem *k*-means a metoda náhodného lesa. Ty byly testovány na databázi obsahující 3D CT data lumbálních páteří pro 12 pacientů, z nichž 7 prodělalo vyšetření bez aplikace kontrastní látky a 5 pacientů s její aplikací. Jedná se o tomografická data s vysokým rozlišením, jež byla nasnímána na CT systému Philips – Healthcare Brilliance iCT skener s 256-řadým dektektorem. Na dané databázi dat bylo provedeno manuální, voxelové označování tkání zájmu, kdy pro každý obratel bylo označeno pět řezů (celkově 270 řezů). Správnost takto označených dat byla následně lékařsky ověřena. Označená data byla rozdělena na učební a testovací množinu, přičemž data z učební množiny byla využita pro učení náhodného lesa a také pro získání charakteristik tkání zájmu, jež byly dále využity.

2.1. GLOBÁLNÍ PRAHOVÁNÍ NA ZÁKLADĚ ANALÝZY DATABÁZE OZNAČENÝCH DAT

Nejjednodušším testovaným přístupem byla segmentace a klasifikace tkání zájmu na základě prosté jasové informace, a to s využitím charakteristik získaných na základě analýzy databáze označených dat. Pro každou tkáň zájmu byl na základě analýzy histogramu odvozen její charakteristický interval HU (z anglického „Hounsfield Unit“), a to pro kontrastní i nativní data zvlášť, jež byl využit v procesu prahování.

2.2. TEXTURNÍ ANALÝZA A KLASIFIKACE ALGORITMEM *K*-MEANS


V rámci realizace texturní analýzy byl pro každý voxel získán vektor příznaků, který obsahoval příznaky vypočtené na základě lokálních statistik prvního i druhého řádu, lokální frekvenční analýzy a mikrotextrní analýzy. Celkově bylo pro každý voxel získáno 198 příznaků. U statistických metod druhého řádu, kam náleží příznaky vypočtené na základě matic současného výskytu a matic délky běhu, bylo optimální nastavení pro výpočet zmiňovaných matic určeno s využitím korelační analýzy a analýzy hlavních komponent. Tyto analýzy byly také využity spolu s lineární diskriminační analýzou pro redukci vektoru příznaků, přičemž tato redukce byla provedena pro kontrastní a nativní data zvlášť. Pro následnou klasifikaci redukovaného vektoru příznaků byl využit algoritmus *k*-means, jež náleží mezi nehierarchické metody shlukové analýzy. Optimální počet shluků pro dělení byl definován metodou silhouette [2]. Klasifikace výsledných shluků odpovídajících tkáním zájmu byla realizována metodou minimální vzdálenosti, a to konkrétně výpočtem Euklidovské vzdálenosti ve více rozměrném prostoru s využitím charakteristik tkání zájmu na základě databáze označených dat. Těmito charakteristikami jsou myšleny statistické parametry tkání zájmu, a to konkrétně modus, medián, průměr a směrodatná odchylka.

2.3. KLASIFIKACE ALGORITMEM NÁHODNÉHO LESA

Náhodný les [3] patří mezi metody strojového učení s učitelem, kdy v rámci učební fáze je vytvářen soubor rozhodovacích stromů o definovaném počtu stromů a velikosti. Tento algoritmus může být využit pro klasifikační i regresní úlohy, přičemž pro klasifikaci je výstupní hodnota získána jako modus rozhodnutí všech stromů. Náhodný les je robustní metodou, kdy v průběhu učební fáze je prostor příznaků náhodně dělen pro vytváření jednotlivých stromů. V procesu učení náhodného lesa pro segmentaci interních kalibračních tkání byla použita učební množina z databáze označených dat, přičemž pro každý voxel byly brány jasové příznaky z jeho 3D okolí (velikost okolí: 5x5x5).

3. DOSAVADNÍ VÝSLEDKY

Funkčnost testovaných metod byla prozatím testována na testovací databázi bezkontrastních dat, jež obsahuje 3D tomografická data lumbálních páteří dvou pacientů (celkově 9 obratlů). Hodnocení funkčnosti bylo provedeno voxelově, a to na základě překryvů manuálně označených dat a výstupů jednotlivých metod. Jak je z dosavadních výsledků patrné (viz. Obrázek 2 a Tabulka 1), na základě žádného z testovaných přístupů nedošlo k úspěšné klasifikaci interních kalibračních tkání a jejich segmentaci od okolních tkání. Do výsledných segmentů tkání zájmu byly zahrnuty i okolní tkáně (viz. Obrázek 2). Konkrétně nedošlo k úspěšnému odlišení paraspinálního svalu od jiných měkkých tkání a také k odlišení podkožního tuku od tuku viscerálního. To může být způsobeno překrývajícími se intervaly HU jednotek těchto tkání a vzájemnou podobností z hlediska texturních příznaků. Na základě výsledků uvedených v Tabulce 1 je patrné, že nejnižší celkové úspěšnosti dosáhla právě texturní analýza s klasifikací algoritmem *k*-means. Tento přístup dosáhl sice vysokých hodnot senzitivity ale nižší specificity. Globální prahování dosáhlo průměrných výsledků, avšak nejnižší specificity pro paraspinální sval. Celkově nejlepších výsledků dosáhla klasifikace a segmentace s využitím algoritmu náhodného lesa. Tento algoritmus dosáhl vyrovnaných výsledků z hlediska senzitivity a specificity pro obě tkáně zájmu, jež dosáhli vysoké hodnoty. Z jeho výsledků je patrné, že jasová informace z okolí daného voxelu měla pozitivní vliv na celkovou úspěšnost dané segmentace.



Obrázek 1: Výsledky testovaných metod – řez bezkontrastním lumbálním obratlem: a) Překrytí označených dat a vstupních dat; b) Globální prahování; c) Texturní analýza + algoritmus *k*-means d) Náhodný les. **Legenda:** šedá barva – paraspinální sval, bílá barva – podkožní tuk

	Globální prahování	Texturní analýza + <i>k</i> -means	Náhodný les
Senzitivita tuk	0.76	0.99	0.84
Specifická tuk	0.72	0.62	0.90
Senzitivita sval	0.82	0.87	0.78
Specifická sval	0.66	0.68	0.79
Celková úspěšnost [%]	41.84	36.65	68.77

Tabulka 1: Dosažené výsledky testovaných segmentačních a klasifikačních metod na testovací databázi bezkontrastních patientských dat.

4. ZÁVĚR

Na základě dosavadních výsledků nelze žádný z testovaných přístupů považovat za plně funkční pro segmentaci a klasifikaci interních kalibračních tkání. Zlepšení by mohlo přinést využití informace o pozici daného obratle. Tím by bylo možné vymezit oblast pro detekci tkání zájmu pouze v jeho okolí, a to v oblastech, kde lze výskyt kalibračních tkání očekávat. Dalším možným zlepšením by mohlo být zamýšlené využití texturních příznaků v rámci klasifikace algoritmem náhodného lesa. Přínosem by mohla být i filtrace šumu, jejíž vliv na výslednou segmentaci a klasifikaci bude v dalším průběhu práce také testován.

REFERENCE

- [1] MUELLER, Dirk K., Alex KUTSCHERENKO, Hans BARTEL, Alain VLASSEN BROEK, Petr OURED NICEK a Joachim ERCKENBRECHT. Phantom-less QCT BMD system as screening tool for osteoporosis without additional radiation. *European Journal of Radiology*. 2011, **79**(3), 375-381. DOI: 10.1016/j.ejrad.2010.02.008. ISSN 0720048x.
- [2] ROUSSEEUW, Peter J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*. 1987, **20**, 53-65. DOI: 10.1016/0377-0427(87)90125-7. ISSN 03770427.
- [3] BREIMAN, Leo. *Machine Learning*. **45**(1), 5-32. DOI: 10.1023/A:1010933404324. ISSN 08856125.