

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

IDENTIFIKACE TYPU OBRATLŮ Z CT DAT S VYUŽITÍM
METOD STROJOVÉHO UČENÍ

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

BARBORA MATOUŠKOVÁ

Brno 2019



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

IDENTIFIKACE TYPU OBRATLŮ Z CT DAT S VYUŽITÍM METOD STROJOVÉHO UČENÍ

IDENTIFICATION OF VERTEBRAE TYPE IN CT DATA BY MACHINE LEARNING METHODS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Barbora Matoušková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Chmelík

BRNO 2019

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Barbora Matoušková

ID: 195716

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Identifikace typu obratlů z CT dat s využitím metod strojového učení

POKYNY PRO VYPRACOVÁNÍ:

1) Nastudujte problematiku existujících metod strojového učení a proveďte literární rešerši jejich využití pro klasifikaci medicínských dat. 2) Navrhněte metodu vhodnou pro klasifikaci typu obratlů z dostupné databáze CT snímků páteří. 3) Realizujte a otestujte navrženou metodu v libovolném programovacím prostředí. 4) Metodu dle pokynů vedoucího otestujte na dostupných databázích. 5) Proveďte optimalizaci metody pro maximální úspěšnost klasifikace. 6) Dosažené výsledky vhodně prezentujte a diskutujte.

DOPORUČENÁ LITERATURA:

[1] LECUN, Yann, BENGIO Yoshua a HINTON Geoffrey. Deep learning. Nature. 2015-5-27, 521(7553), 436-444. DOI: 10.1038/nature14539. ISSN 0028-0836.

[2] THEODORIDIS, Sergios a KOUTROUMBAS Konstantinos. Pattern recognition. 4th ed. Burlington, Mass.: Academic Press, 2009, xvii, 961 s. ISBN 978-1-59749-272-0.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Jiří Chmelík

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Identifikace typu obratlů pomocí strojového učení je důležitý úkol pro usnadnění práce lékařů. Tento úkol je znesnadněn mnoha faktory. Za prvé se CT snímky páteře obvykle provádí u pacientů s patologiemi jako jsou léze, nádory, kyfóza, lordóza, skolióza či u pacientů s různými implantáty, které způsobují ve snímcích artefakty. Dále jsou si sousední obratle velmi podobné, což také tento úkol komplikuje. Tato práce se zabývá klasifikací již vysegmentovaných obratlů do skupin krční, hrudní a bederní. Pro klasifikaci je využita metoda podpůrných vektorů (SVM) a konvoluční neuronové sítě (CNN) AlexNet a VGG16. Dosažené výsledky jsou v závěru porovnány.

KLÍČOVÁ SLOVA

identifikace typu obratlů, strojové učení, výpočetní tomografie, klasifikace v medicíně, obratel, páteř, metoda podpůrných vektorů, konvoluční neuronové sítě

ABSTRACT

Identification of vertebrae type by machine learning is an important task to facilitate the work of medical doctors. This task is embarrassed by many factors. First, a spinal CT imagining is usually performed on patients with pathologies such as lesions, tumors, kyphosis, lordosis, scoliosis or patients with various implants that cause artifacts in the images. Furthermore, the neighboring vertebrae are very similar which also complicates this task. This paper deals with already segmented vertebrae classification into cervical, thoracic and lumbar groups. Support vector machines (SVM) and convolutional neural networks (CNN) AlexNet and VGG16 are used for classification. The results are compared in the conclusion.

KEYWORDS

identification of vertebrae type, machine learning, computed tomography, classification in medicine, vertebra, spine, support vector machine, convolution neural networks

MATOUŠKOVÁ, Barbora. *Identifikace typu obratlů z CT dat s využitím metod strojového učení*. Brno, 2019, 55 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Školitel: Ing. Jiří Chmelík,

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Identifikace typu obratlů z CT dat s využitím metod strojového učení“ jsem vypracoval(a) samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor(ka) uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil(a) autorská práva třetích osob, zejména jsem nezasáhl(a) nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom(a) následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora(-ky)

PODĚKOVÁNÍ

Velice děkuji svému vedoucímu bakalářské práce Ing. Jiřímu Chmelíkovi za jeho čas a energii, které do této práce vložil. Také mu děkuji, že na mne nezapomínal a veškeré podklady mi posílal co nejdřív. A obzvláště bych pak ráda poděkovala za jeho obsáhlé e-maily, kterými mě naváděl na správnou cestu.

Také děkuji mé rodině a přátelům, kteří se mnou jako obvykle v těžkých chvílích neztratili trpělivost, podporovali mě a dokonce projevili zájem o téma této práce.

Brno

.....

podpis autora(-ky)

OBSAH

Úvod	10
1 Teoretická část	11
1.1 Anatomie páteře	11
1.1.1 Obratel	12
1.1.2 Krční obratle	13
1.1.3 Hrudní obratle	14
1.1.4 Bederní obratle	14
1.1.5 Kost křížová a kostrční	15
1.1.6 Vybrané patologie ovlivňující správnou identifikaci typu obratle	15
1.2 Princip výpočetní tomografie	16
1.2.1 Jasová reprezentace denzity	16
1.2.2 Vývoj CT přístrojů	17
1.2.3 Moderní CT přístroje	17
1.2.4 Parametry při snímání CT přístrojem	18
1.3 Strojové učení	19
1.3.1 Metody učení	19
1.3.2 Modely strojového učení	20
1.3.3 Extrakce příznaků	26
1.4 Metody strojového učení užívané pro klasifikaci dat v medicíně	27
1.4.1 Nalezení zájmového objektu a následná identifikace dle známého pořadí obratlů	27
1.4.2 Pravděpodobnostní mapy	28
1.4.3 Modely	29
2 Vlastní řešení	31
2.1 Používaná data	31
2.2 Trénovací a testovací data	31
2.3 Identifikace typu obratlů pomocí SVM	32
2.3.1 Extrakce příznaků	32
2.3.2 Určení typu obratle pomocí SVM	33
2.3.3 Fáze trénování SVM	34
2.3.4 Fáze testování SVM	34
2.4 Identifikace typu obratlů pomocí CNN	35
2.4.1 Vstupní data do CNN	35
2.4.2 Augmentace dat	36
2.4.3 Vytvoření vstupních dat do CNN	36

2.4.4	Fáze trénování CNN	37
2.4.5	Fáze testování CNN	38
3	Výsledky a diskuze	40
3.1	Dosažené výsledky a diskuze u SVM	40
3.2	Dosažené výsledky a diskuze u CNN	42
3.3	Shrnutí dosažených výsledků	43
	Závěr	46
	Literatura	48
	Seznam symbolů, veličin a zkratk	51
	Seznam příloh	52
	A AlexNet	53
	B VGG16	55

SEZNAM OBRÁZKŮ

1.1	Páteř	11
1.2	Obecný popis obratle a jeho základních částí	12
1.3	Nosič a čepovec	14
1.4	Krční, hrudní a bederní obratel	15
1.5	Princip CT	16
1.6	Proces trénování u učení s učitelem	20
1.7	Určení vhodné hranice pro lineárně separabilní třídy u SVM	22
1.8	Řešení SVM pro lineárně neseperabilní třídy	23
2.1	Schéma sítě SVM	34
2.2	Schéma sítě AlexNet	39
2.3	Schéma sítě VGG16	39
3.1	Identifikované obratle ze souboru data3 u SVM	41
3.2	Identifikované obratle ze souboru data4 u SVM	42
3.3	Identifikované obratle pomocí sítě AlexNet	43
3.4	Identifikované obratle pomocí sítě VGG16	44

SEZNAM TABULEK

2.1	Trénovací a testovací data	32
3.1	Výsledky testování u SVM	40
3.2	Porovnání výsledků sítí	45

ÚVOD

Automatická identifikace obratlů je důležitým úkolem pro usnadnění práce lékařů. Ruční značení a identifikace obratlů zabírá lékařům mnoho času a může být ovlivněno i subjektivním názorem lékaře.

CT snímky páteře využívají hlavně ortopedi, neurologové, radiologové a chirurgové pro plánování operací, operace samotné, pooperační kontroly, plánování radioterapie, sledování odezvy na léčbu, biopsie či zavádění implantátů. Dále je přesná znalost polohy a identifikace obratle důležitá při využití chirurgických robotů. Lékaři z CT snímků páteře také diagnostikují tumory, léze či zlomeniny.

Úkol identifikace obratlů není snadný úkol, jelikož sousední obratle jsou si velmi podobné. Další komplikací při identifikaci je, že CT snímky páteře se provádí především u pacientů s různými patologiemi, a tak tvar, velikost či umístění obratle nemusí odpovídat obvyklým parametrům.


Tato práce se zabývá identifikací typu obratlů, tedy ne konkrétním pojmenováním jednotlivých obratlů, ale pouze jejich klasifikací do skupin krční, hrudní a bederní. Každá z těchto skupin má společné vlastnosti, díky nimž se dá typ obratle určit. V této práci je identifikace typu obratlů provedena pomocí Support Vector Machines (SVM) a konvolučních neuronových sítí (CNN) AlexNet a VGG16. V případě SVM je nejprve provedena extrakce příznaků a následně natrénování a otestování sítě. U CNN jsou z důvodu dané velikosti vstupních obrazů nejprve upraveny CT snímky páteře a následně jsou upravené sítě na tento konkrétní problém natrénovány a otestovány. Z důvodu poměrně malého datasetu bylo testování provedeno pomocí 5-násobné křížové validace. V závěru jsou porovnány dosažené výsledky všech tří přístupů.

1 TEORETICKÁ ČÁST

1.1 Anatomie páteře

Páteř (*lat. columna vertebralis*) člověka se skládá celkem ze 33 obratlů, které se dělí do 5 skupin. Konkrétně se jedná o 7 obratlů krčních $C_1 - C_7$ (*lat. vertebrae cervicales*), 12 obratlů hrudních $Th_1 - Th_{12}$ (*lat. vertebrae thoracicae*), 5 obratlů bederních $L_1 - L_5$ (*lat. vertebrae lumbales*), 5 obratlů křížových $S_1 - S_5$ (*lat. vertebrae sacrales*) a 2-5 obratlů kostrčních $Co_1 - Co_5$ (*lat. vertebrae coccygeae*), viz. Obr. 1.1. Holibková a Laichman (2010)

Rozlišujeme obratle pravé – krční, hrudní a bederní, které jsou samostatné, a obratle nepravé – křížové a kostrční, které sekundárně srůstají ve větší kost – kost křížovou (*lat. oss sacrum*) a kost kostrční (*lat. oss coccygis*). Při celkovém mediálním pohledu na páteř (Obr. 1.1 uprostřed) uvidíme její typická prohnutí tvaru dvou „S“. V krční a bederní oblasti je prohnuta ventrálně (lordóza) a v hrudní a křížokostrční je prohnuta dorsálně (kyfóza). Ve směru frontální roviny by páteř měla být prohnuta jen minimálně. Hanzlová a Hemza (2009); Luňáček (2007-2012)




Obr. 1.1: Páteř. Zleva anteriorní, mediální a posteriorní pohled. Rozdělení obratlů do skupin krční, hrudní, bederní a kost křížová a kostrční. U mediálního pohledu typické prohnutí do tvaru dvou „S“.

Zdroj: http://www.spondylo.cz/spine_anatomy.html

1.1.1 Obratel

Každý obratel se skládá ze tří hlavních částí, a to těla obratle, oblouku obratle a výběžků obratle, viz. Obr. 1.2 Pro každou skupinu obratlů i obratel samotný jsou tyto části specifické a různě veliké. Nejvíce rozdílné jsou první dva obratle, nosič a čepovec. Holibková a Laichman (2010)



Obr. 1.2: Obecný popis obratle a jeho základních částí (tělo, oblouk a výběžky). Zleva mediální a axiální pohled.

1 – tělo obratle, 2 – oblouk obratle, 3 – trnový výběžek, 4 – příčný výběžek, 5 – horní kloubní výběžek, 6 – obratlový otvor, 7 – dolní kloubní výběžek.

Zdroj: Holibková a Laichman (2010)

Tělo obratle

Tělo obratle (*lat. corpus vertebrae*) je nejmohutnější část obratle (Obr. 1.2 - 1). Díky jeho drsnému povrchu na horní a dolní části se na něj připojují meziobratlové ploténky, které zajišťují spojení sousedních obratlů. Luňáček (2007-2012)

Oblouk obratle

Obratlový oblouk (*lat. arcus vertebrae*) je umístěn dorsálně od těla obratle (Obr. 1.2 - 2) a společně s ním uzavírá obratlový otvor (Obr. 1.2 - 6) obsahující míchu, míšní obaly, míšní kořeny a cévy. U odstupů obratlových oblouků od obratlových těl se na horní i dolní ploše nachází zářezy, které nasedají na zářezy následujícího obratle, a vytváří tak meziobratlový otvor, kterým vystupují míšní nervy. Holibková a Laichman (2010); Luňáček (2007-2012)

Výběžky obratle

Obratlových výběžků (*lat. processus vertebrae*) je celkem 7 a všechny jsou až na trnový výběžek párové. Jedná se o dva páry kloubních výběžků (Obr. 1.2 - 5 a 7) umístěných na oblouku obratle. Výběžky jsou umístěny jak na horní, tak dolní straně a slouží ke vzájemnému skloubení se sousedními obratli. Dále jeden pár příčných výběžků (Obr. 1.2 - 4) vystupujících z oblouku obratle laterálně, na který se v hrudní oblasti napojují žebra. Posledním z výběžků je trnový výběžek (Obr. 1.2 - 3), který odstupuje ze středu oblouku obratle dorzálním směrem. Hanzlová a Hemza (2009); Holibková a Laichman (2010)

1.1.2 Krční obratle

V lidském těle je 7 krčních obratlů (*lat. vertebrae cervicales*) obvykle označovaných $C_1 - C_7$. Až na obratle C_1 a C_2 je jejich tvar podobný (Obr. 1.4 - vlevo). Mají malé nízké oválné tělo, které se směrem k C_7 postupně zvětšuje. Na terminální ploše je tělo konkávně prohnuté. Obratlový otvor je poměrně veliký a má tvar širokého trojúhelníku. Hanzlová a Hemza (2009); Luňáček (2007-2012)

Kloubní výběžky jsou ploché a dorzokaudálně zešíkmené. Příčné výběžky jsou krátké a mají na sobě přední a zadní hrboly, které jsou u C_6 výrazně větší. Mezi těmito hrboly je otvor, kudy prochází *arteria vertebralis*. Krátké trnové výběžky se vidlicovitě rozdvíjejí. Výjimkou je trnový výběžek obratle C_7 , který je výrazně dlouhý. Hanzlová a Hemza (2009); Luňáček (2007-2012)


Nosič

První krční obratel C_1 se nazývá nosič (*lat. atlas*) a společně s druhým krčním obratlem C_2 (čepovcem) má jiný tvar než ostatní krční obratle (Obr. 1.3). Jeho úkolem je podpírat lebku. Typické pro něj je, že nemá žádné obratlové tělo. Je tvořen z předního oblouku, který obsahuje na spodní straně jamku pro spojení se zubem čepovce, a zadního oblouku. Dále je tvořen dvěma postranními kostěnými bloky, které na horní plochách zajišťují spojení s kondyly týlní kosti a na spodních plochách spojení s čepovcem. Příčné výběžky jsou krátké a mají v sobě otvory pro *arteria vertebralis*. Trnové ani kloubní výběžky nosič nemá. Hanzlová a Hemza (2009); Luňáček (2007-2012)

Čepovec

Druhým krčním obratlem C_2 je čepovec (*lat. axis*). Jeho tvar je podobně jako u prvního krčního obratle C_1 (nosiče) také odlišný od ostatních krčních obratlů (Obr. 1.3). Na rozdíl od nosiče čepovec má tělo, které dokonce vybíhá kraniálním směrem

a tvoří oválný zub čepovce (*lat. dens axis*). Vrchol tohoto zubu je nejvýše kraniálně umístěným bodem celé páteře. Na horní ploše těla jsou plošky pro spojení s nosičem. Stavba trnového a příčných výběžků je podobná jako u obecného popisu krčního obratle. Hanzlová a Hemza (2009); Luňáček (2007-2012)



Obr. 1.3: Nosič a čepovec. První dva krční obratle. Mají odlišný tvar a stavbu než ostatní obratle.

Zdroj (upraveno): <https://www.wattpad.com/580694135-biologie-na-p%C5%99ij%C3%ADma%C4%8Dky-2-op%C4%9Brn%C3%A1-soustava-ii>

1.1.3 Hrudní obratle

Lidská páteř obsahuje 12 hrudních obratlů $Th_1 - Th_{12}$ (*lat. vertebrae thoracicae*), na které se připojují žebra (Obr. 1.4 - uprostřed). Těla obratlů mají oválný tvar a jsou poměrně vysoká, kdy se kaudálním směrem těla obratlů ještě zvyšují. Na krajích boku těla obratle jsou umístěny horní a dolní žeberní jamky, kam jsou připevněny hlavičky žebíř. Hlavička žebra tedy naléhá na dva sousední obratle. Otvor obratle, který je tvořen tělem a obloukem obratle, je menší než u obratlů krčních a má okrouhlý tvar. Holibková a Laichman (2010); Luňáček (2007-2012)


Kloubní výběžky jsou umístěny frontálně. Příčné výběžky se orientují dorzolaterálně, jsou dlouhé a zaoblené. Kromě obratlů Th_{11} a Th_{12} na příčném výběžku nalézáme další žebířní jamku, kam se napojují žebra svými hrbolky. Trnové výběžky směřují výrazně kaudálním směrem. Holibková a Laichman (2010); Luňáček (2007-2012)

1.1.4 Bederní obratle

Nejmohutnějšími obratli v celé páteři je 5 obratlů bederních (*lat. vertebrae lumbales*) označovaných jako $L_1 - L_5$ (Obr. 1.4 - vpravo). Mají velká a vysoká těla ledvinovitého tvaru. Otvor obratle je malý s trojúhelníkovým tvarem. Hanzlová a Hemza (2009); Luňáček (2007-2012)

Kloubní výběžky jsou uloženy ventrolaterosagitálně. Příčný výběžek se dělí hned u odstupu od těla na tři výběžky orientované do různých směrů. Jeden směřuje

kraniálním směrem, druhý, takzvaný bradavičkový hrbolek, směrem kaudálním a poslední nejvýraznější z nich je orientován laterálně. Tento nejvýraznější laterální výběžek označujeme jako trn a je rudimentem žebra. Čtyřhranný trnový výběžek je umístěn horizontálně. Hanzlová a Hemza (2009); Luňáček (2007-2012)



Obr. 1.4: Porovnání typického tvaru a velikosti zleva krčního, hrudního a bederního obratle. Axiální pohled.

Zdroj (upraveno): <https://aneskey.com/interlaminar-epidural-injection/>

1.1.5 Kost křížová a kostrční

Kost křížová (*lat. oss sacrum*) vznikla srůstem pěti obratlů křížových (*lat. vertebrae sacrales*). Má tvar pyramidy ze základnou orientovanou kraniálně a hrotem kaudálně. Přední plocha je zakřivena konkávně, vnější konvexně s pěti podélnými hranami, které vznikly srůstem obratlových výběžku a zakrnělých žebere. Na obou plochách se nachází 4 páry otvorů, kudy prochází křížové nervy. Uvnitř pozorujeme kanál křížový, který je pokračováním páteřního kanálu. Holibková a Laichman (2010); Luňáček (2007-2012)

Kost kostrční (*lat. oss coccygis*) vznikla také srůstem obratlů, tentokrát však posledních 4-5 obratlů kostrčních (*lat. vertebrae coccygeae*). Na lidském těle zbyla jako pozůstatek po páteři ocasní. Holibková a Laichman (2010); Luňáček (2007-2012)


1.1.6 Vybrané patologie ovlivňující správnou identifikaci typu obratle

Na páteři se může vyskytovat několik patologií či variací, které mohou negativně ovlivnit výsledek při identifikaci typu obratlů. Jedná se například o sakralizaci obratle L_5 , kdy poslední bederní obratel sroste s kostí křížovou, a tak se v páteři nachází o jeden obratel méně. Opačným příkladem je lumbalizace obratle S_1 , kdy naopak první křížový obratel nesroste se zbytkem kosti křížové, a vytvoří se tak 6 bederních obratlů. Další možnou variací je vytvoření bederního žebra, kdy dochází

buď ke zvýšení počtu volných obratlů výskytem jednoho bederního obratle navíc, nebo naopak ke snížení počtu volných obratlů, a to chybějícím jedním hrudním či volným bederním obratlem. Šrámek a kolektiv (2015)

1.2 Princip výpočetní tomografie

CT (*angl. Computed Tomography*, výpočetní tomografie) je jednou ze zobrazovacích diagnostických metod. Základním principem CT je, že v jednotlivých vrstvách širokých 1-10 mm snímá tomograf lidské tělo v mnoha úhlech. Toto snímání je prováděno podobně jako u planárního RTG zobrazování, tedy pomocí transmise rentgenového záření. Rentgenka naproti s detektorem rotují kolem snímaného objektu, podél kterého se zároveň i pomalu posouvají v podélné rovině, a vytváří tak snímky z mnoha úhlů. Následně jsou tyto snímky pomocí filtrace a rekonstrukce počítačem přepočítány a je vytvořen 3D obraz denzity snímaného objektu. Obraz si tak můžeme prohlížet po jednotlivých vrstvách a vidět vnitřní strukturu nasnímaného objektu. Seidl a Laichman (2012)



Obr. 1.5: Zobrazení principu snímání přístrojem výpočetní tomografie (CT). Naznačení rotace rentgenky a detektorů na gantry kolem snímaného objektu.

1.2.1 Jasová reprezentace denzity

Výsledný obraz CT snímku je reprezentován odstíny šedi. Každý odstín šedi udává denzitu tkáně, tedy míru oslabení rentgenového paprsku, kterou většinou porovná-

váme s denzitou vody. Základní jednotkou jsou Hounsfieldovy jednotky (HU), kdy se používá stupnice od -1000 HU do 1000 HU. Hodnota -1000 HU odpovídá denzitě vzduchu a na výsledném obrazu se zobrazuje černou barvou, hodnota 0 HU odpovídá denzitě vody, hodnota 1000 HU odpovídá denzitě kosti a na CT obrazech se zobrazuje barvou světlou. HU pro danou tkáň se vypočítá dle vzorce 1.1, kde μ je absorpční koeficient. Seidl a Laichman (2012)

$$HU = 1000 \cdot \frac{\mu_{tkáň} - \mu_{voda}}{\mu_{voda} - \mu_{vzduch}} \quad (1.1)$$

1.2.2 Vývoj CT přístrojů

CT přístroje prošly od svého vzniku velikým vývojem, který obvykle rozdělujeme na 5 generací. U přístrojů 1.generace se rentgenka otáčela spolu s detektorem. Paprsek byl kolimován do tenkého válcového tvaru a zaznamenán protilehlým detektorem. Poté se společně posunuly a po projetí celé šíře možného posunutí se společně otočily. Přínosem v 2.generaci bylo, že se paprsek z rentgenky kolimoval do tvaru vějíře a zaznamenával na několika protilehlých detektorech umístěných v jedné řadě. Rotace rentgenky a detektorů ovšem probíhala stále společně. U 3.generace zůstala kolimace do vějířového tvaru i současná rotace rentgenky s detektory, ovšem detektory byly umístěny již do několika řad, a tak bylo možné snímat několik řezů zároveň. Tento typ snímání v několika řadách najednou se nazývá *multi-slice CT* a je používán i v současných vysokorychlostních CT přístrojích. Další změnou u 4.generace bylo, že detektory byly umístěny po celém obvodu gantry a kolem pacienta rotovala pouze rentgenka. Poslední a tedy 5.generací jsou tomografy s elektronovým svazkem (*angl. Electron Beam CT*, EBT). Tato generace je ojedinělá v tom, že přístroje neobsahují rentgenku, ale rentgenové záření vzniká dopadem elektronů vystřelovaných z elektronového děla na kovový terčíkový prstenec, v němž je umístěn pacient. Elektronový paprsek dopadá postupně dokola na kolimátor, který tvaruje paprsek opět do vějířového tvaru. Výhodou je, že toto vychylování je mnohem rychlejší než u vychylování mechanického, čehož se využívá například při hradlovaném CT srdce. Seidl a Laichman (2012)

1.2.3 Moderní CT přístroje

Po mnoha letech výzkumu se v dnešní době nejvíce používají CT systémy 3.generace. Jedná se o systémy, kdy se po kruhu kolem CT přístroje pohybují proti sobě na gantry rentgenka a detektor. Paprsek vycházející z rentgenky je kolimován do vějířovitého tvaru a následně je po průchodu pacientem detekován řadami detektorů umístěných na druhé straně gantry. Celé gantry se otáčí, čímž se vytváří snímky v různých úhlech pro přepočítání do trojrozměrného obrazu. Seidl a Laichman (2012)

Jelikož bylo snahou vytvořit systém, který by co nejrychleji nasnímal celý prostor, začalo se využívat *multi-slice* CT přístroje. V podélném směru je uloženo několik řad detektorů (v současné době 4 – 640 řad), což umožňuje snímat více sousedních řezů najednou. Další urychlení nastalo, když se začal používat spirální (helikální) CT systém. Během snímání je celý systém rotován a zároveň je posouván stůl s pacientem. Rychlost tohoto posunu se dá nastavit a nazývá se faktor stoupání (*angl. pitch faktor*). Díky těmto všem zdokonalením je možné nasnímat celé tělo pacienta za desítky vteřin. Seidl a Laichman (2012); Akpayak a kol. (2017)

Během snímání se často také využívají kontrastní látky. Jedná se o případy, kdy chceme lépe zobrazit cévy, popřípadě rozlišit lépe a hůře se prokrvující tkáň, a určit tak patologie. Kontrastní látka se podává hlavně intravenózně, ale můžeme jí zavést i perorálně či perrektálně. Seidl a Laichman (2012)

1.2.4 Parametry při snímání CT přístrojem

Skenovací parametry výrazným způsobem ovlivňují způsob akvizice. Na jejich nastavení přímo závisí kvalita hrubých dat, a pokud se tedy skenovací parametry špatně nastaví, chybu nelze napravit bez opakovaného skenování. Řadíme mezi ně expozici, kolimaci, faktor stoupání (*angl. pitch faktor*) a periodu rotace. Vždy je potřeba předem zvážit, čeho chceme při daném snímání dosáhnout (kvalita, rychlost, radiační zátěž...), a podle toho parametry nastavit. Mírka (2009)

Expozice zahrnuje dva parametry, a to expoziční napětí a proud. Oba tyto parametry dohromady ovlivňují kvalitu obrazu a absorbovanou dávku, proto je potřeba je nastavit ve správném poměru, který se liší pro každé vyšetření. Expoziční napětí ovlivňuje energetické těžiště spektra rentgenového záření a jeho hodnoty se pohybují v rozmezí 80-140 kV. Při nižších hodnotách napětí se sníží penetrace, zvýší kontrast obrazu a rozdíl absorbcí jednotlivých materiálů. Expoziční proud se pohybuje v rozmezí 50-500 mAs a naopak ovlivňuje množství vyzářených fotonů rentgenového záření, což zvyšuje poměr signál šum ve výsledných obrazech, právě za cenu zvýšené patientské dávky. Při nižších hodnotách proudu se tedy snižuje dávka, ale v obrazu se zvyšuje šum. Mírka (2009)

Parametr kolimace je dán šířkou vějíře v *z-ose* vystupujícího z kolimátoru a ovlivňuje prostorové rozlišení a rychlost vyšetření. Pokud se tedy kolimace sníží, prodlouží se nejen čas vyšetření, ale také se zvýší radiační zátěž pro pacienta. Mírka (2009)

Faktor stoupání je dán hustotou závitů datové šroubovice, tedy rychlostí posunu stolu a šířkou svazku, neboli kolimací. Vypočítá se jako posun stolu během jedné úplné otáčky dělený úhrnnou kolimací. S nižší hodnotou faktoru stoupání se tedy zvyšuje kvalita datového pole, snižuje rychlost a zároveň se zvyšuje radiační zátěž

pro pacienta, u nízkodávkových snímků stoupá šum. Hodnoty se obvykle pohybují v rozmezí 0,3-1,5, jelikož při hodnotě 1,5 je pole bez speciálních algoritmů již neúplné. Mírka (2009)

Perioda rotace je čas jedné úplné otáčky rentgenky a její hodnoty se pohybují v rozmezí 0,27-1s. Při snižování hodnoty periody rotace se zrychluje vyšetření, zvyšuje časové rozlišení, snižuje radiační dávka, kvalita a náchylnost k pohybovým artefaktům. Mírka (2009)

1.3 Strojové učení


Strojové učení (*angl. Machine Learning*) je vědní disciplína v podoblasti umělé inteligence (*angl. Artificial Intelligency*). Díky algoritmům a programům, kterými se zabývá, umožňuje strojům „učit se“. Hlavním úkolem algoritmů provádějících strojové učení je převést pomocí správné transformace vstupní data na data výstupní. Právě díky učení se v transformaci změny parametry tak, že se systém postupně zlepšuje na základě zkušeností, a tak se výstup systému přibližuje požadovanému výstupu. Honzík (2006); LeCun a kol. (2015)

Strojové učení se velice prolíná s disciplínami dolování dat, statistika a optimalizace. Dolování dat (*angl. Data Mining*) je disciplína, která se pokouší z dostupných dat a databází získat potenciálně užitečné a netriviální informace. Statistické metody jsou běžně využívány k předzpracování vstupních dat a při vyhodnocování kvality systému, kdy se posuzuje míra zdařilosti. Proces optimalizace se projevuje během učení systému, kdy je snaha nastavit model co nejlépe na základě dostupných dat, a tak tedy vytvořit minimální odchylku mezi výstupními daty systému a požadovanými výstupními daty. Honzík (2006); LeCun a kol. (2015)

1.3.1 Metody učení

Rozlišujeme hlavní dva typy algoritmů učení. Více využívaným v praxi je učení s učitelem, kdy předem známe vstupy a jejich požadované výstupy. Proces trénování modelu během učení s učitelem je znázorněn na Obr. 1.6. Trénovací vstupní data X jsou předkládána modelu M , který vytvoří výstup modelu \hat{Y} . Tento výstup je porovnán s požadovaným výstupem Y , a to tak, že je pomocí chybové funkce (*angl. loss function*) LS vypočítána chyba (*angl. error*) Err . Tato chyba je předkládána jako vstup na optimalizační algoritmus UA , který vypočítá nové parametry b pro model M tak, aby byla chyba Err v příštím cyklu co nejmenší. Tyto parametry, často nazývané jako váhy, jsou reálná čísla, která definují funkci vstup-výstup. Jejich optimalizace nejčastěji probíhá metodou stochastického gradientního sestupu (SGD)

(LeCun a kol. (2015)), kdy je na vstup přivedeno několik příkladů vstupních dat, následně jsou vypočítány jejich výstupy a chyby, ze kterých se určí průměr gradientu. Parametry jsou upraveny podle vektoru průměru gradientu, a to přesně v opačném směru. Po takovémto natrénování modelu následuje fáze testování. K tomu se využívají testovací data, která systému nebyla předem předložena. Testování slouží k posouzení generalizační schopnosti modelu, tedy zda jsou na výstupu při podání neznámých vstupních dat rozumné odpovědi. Typicky se tyto modely využívají pro úlohy regrese (výstup je kvantitativní) a klasifikace (výstup je kvalitativní). Honzík (2006); LeCun a kol. (2015)



Obr. 1.6: Proces trénování u učení s učitelem.

X - vstupní data, M - model, \hat{Y} - výstup modelu, Y - požadovaný výstup, Err - chybová funkce, UA - optimalizační algoritmus, b - parametry

Druhým typem je učení bez učitele. V tomto případě jsou známy pouze vstupní hodnoty, výstupní nikoliv. V datech jsou hledané dosud neznámé souvislosti a podobnosti, na jejichž základě se poté vytváří nové třídy či hledané objekty. Tato metoda je využívána například pro úlohy shlukování. Honzík (2006)

1.3.2 Modely strojového učení

Vybrané modely pro učení s učitelem

- Perceptron

Perceptron (*angl. Perceptron*) je velice podobný neurofyziologickému neuronu a slouží k řešení základních lineárních problémů. Do neuronu vstupují proměnné, které se dají přirovnat k dendritům. Každý vstup je poté ohodnocen váhou, která určuje jeho propustnost. Takto ohodnocené vstupy jsou sečteny a je vypočten vnitřní potenciál, někdy označováno jako aktivace. Každý perceptron má práh, který se srovnává s vnitřním potenciálem perceptronu. Pokud

vnitřní potenciál překročí prahovou hodnotu, je pomocí aktivační funkce vypočten výstup perceptronu srovnatelný s axonem. Aktivační funkce může být například skoková, lineární či sigmoidální. Šíma a Neruda (1996)

- Neuronová síť

Neuronová síť (*angl. Neural Network*) je složena z několika vrstev vzájemně propojených perceptronů, a slouží tak k řešení složitějších úloh. První vrstva se nazývá vstupní vrstva, poslední se nazývá výstupní vrstva a všechny vrstvy mezi nimi jsou skryté vrstvy. Počet vrstev a počet neuronů v jednotlivých vrstvách určuje topologie neuronové sítě. Během fáze učení dochází k adaptaci vah a prahů tak, aby odpověď na vstupní hodnoty byla co nejpodobnější požadovaným výstupním hodnotám. Tato adaptace se nejčastěji provádí algoritmem zpětného šíření chyby (*angl. backpropagation*). Šíma a Neruda (1996)

- Support Vector Machines

SVM (*angl. Support Vector Machines*, metoda podpůrných vektorů) je soubor metod využívaných pro lineární klasifikaci do tříd. Jelikož nejlepší umístění hranice pro oddělení do tříd není vždy jednoznačné, bylo potřeba vymyslet algoritmus, který by tuto ideální pozici pomohl určit, a to právě SVM umožňuje. Holčík (2012); Theodoridis a kol. (2009)

Lineárně separabilní třídy


Předpokládejme nyní dvě lineárně oddělitelné třídy ω_1 a ω_2 obsahující celkem K prvků. Jejich dokonalé oddělení bude tedy možné pomocí hranice s rovnicí

$$h(x) = \omega^T \cdot x + \omega_0 = 0 \quad (1.2)$$

, kde ω určuje směrnici přímky a ω_0 umístění v prostoru.

Jak je vidět na Obr. 1.7, existuje mnoho možností, jak od sebe třídy oddělit. Na první pohled je ale zřejmé, že všechny možnosti nebudou vhodné. Přímka 1. má oproti přímce 2. mnohem menší toleranční pás (vyznačen tenkými čarami), a tak po přidání prvků mimo trénovací množinu může dojít k menší odchylce prvků, aby byla správnost klasifikace zachována. Je tedy jasné, že přímka 2. je vhodnější hranicí pro toto konkrétní zadání, jelikož má větší toleranční pás. Cílem SVM je tedy najít hraniční přímku s co největším tolerančním pásmem. Objekty, které leží na hranici tohoto tolerančního pásma, a tím ho vymezují, se nazývají podpůrné vektory. Holčík (2012); Theodoridis a kol. (2009)

Při vytváření tolerančního pásma počítá SVM s tím, že nově klasifikované objekty vyplňují stejný prostor, a tedy poměr vzdáleností skupin k hranici je



Obr. 1.7: Určení vhodné hranice pro lineárně separabilní třídy u SVM
Přímka 1. má menší toleranční pás, a proto je méně vhodnou hraniční přímkou než přímka 2., která má toleranční pás mnohem větší.

roven jedné. Pro objekty tedy platí

$$\begin{aligned} \omega^T \cdot x + \omega_0 &\geq 1 \text{ pro } \forall x \in \omega_1; \\ \omega^T \cdot x + \omega_0 &\leq -1 \text{ pro } \forall x \in \omega_2 \end{aligned} \quad (1.3)$$

Dále zavedeme pro zjednodušení pomocnou cílovou proměnnou δ_x , pro kterou platí, $\delta_x = 1$ pro vektory ze třídy ω_1 a $\delta_x = -1$ pro vektory ze třídy ω_2 . Nyní je možné definovat kriteriální funkci, kterou budeme minimalizovat, jako

$$\begin{aligned} J(\omega^T, \omega_0) &= \frac{\|x\|^2}{2} \\ \text{za podmínky } \delta_x \cdot (\omega^T \cdot x + \omega_0) &\geq 1 \end{aligned} \quad (1.4)$$

Jelikož se jedná o nelineárně podmíněnou optimalizační úlohu, k jejímu vyřešení se využívá Lagrangova součinitele pro hledání vázaného extrému. Holčík (2012); Theodoridis a kol. (2009)


Lineárně neseparabilní třídy

Pokud jsou třídy lineárně neseparovatelné, poté se objekty rozdělí na tři skupiny, což je znázorněno na Obr. 1.8. První skupinou jsou správně zařazené objekty mimo toleranční pás, druhou jsou správně zařazené objekty zasahující do tolerančního pásu a poslední skupinou jsou špatně zařazené objekty (ideálně spadající do tolerančního pásu v druhé polorovině). Z tohoto důvodu se

vytváří nová proměnná $\xi_k \geq 0$, která se nazývá relaxační proměnná, a vytvoří se rovnice

$$\delta_x \cdot (\omega^T \cdot x + \omega_0) = 1 - \xi_k \quad (1.5)$$

Správně klasifikované objekty nepatřící do tolerančního pásma mají $\xi_k = 0$, správně klasifikované objekty v tolerančním pásmu mají $0 < \xi_k \leq 1$ a špatně klasifikované objekty mají $\xi_k > 1$.



Obr. 1.8: Řešení SVM pro lineárně neseparabilní třídy

Plné body jsou správně zařazené objekty, nevyplněné body jsou správně zařazené objekty zasahující do tolerančního pásma a nevyplněné body ve čtverečku jsou špatně zařazené objekty

Cílem SVM je v tomto případě naléznout hraniční přímku s co největším tolerančním pásmem a zároveň co nejvíce snížit počet objektů s $\xi_k > 0$ (tedy správně zařazených v tolerančním pásmu a špatně zařazených). Toho docílíme minimalizací kritériální funkce

$$J(\omega^T, \omega_0, \xi) = \frac{\|x\|^2}{2} + C \sum_{k=1}^K \xi_k \quad (1.6)$$

za podmínky $\delta_{xk} \cdot (\omega^T \cdot x + \omega_0) \geq 1 - \xi_k, kde k = 1, 2 \dots K$

Řešení se opět provádí pomocí Langrangových součinitelů.

- Konvoluční neuronová síť

CNN (*angl. Convolution Neural Network*, konvoluční neuronová síť) je velmi podobná neuronové síti zmíněné dříve. Skládá se z neuronů, které pomocí svých vah a prahů upravují vstup na výstup. Na vstup neuronových sítí ovšem

přichází vektor, který je upraven v plně propojených neuronech ve skrytých vrstvách sítě, a v poslední výstupní vrstvě je vypočítáno skóre klasifikace. Na vstup CNN ovšem přichází obrazy, proto musí být vnitřní struktura upravena.Stanford (2019)

Hlavním rozdílem ve vnitřní struktuře je, že jsou neurony v jednotlivých vrstvách umístěny do 3 dimenzí, a to výška, šířka a hloubka, a že každý neuron není spojen se všemi neurony v předchozí vrstvě, ale pouze s menší oblastí. Cílem konvolučních neuronových sítí je převést vstupní obraz na vektor v dimenzi hloubky, kdy každé číslo ve vektoru určuje klasifikační skóre pro danou skupinu. Toho se dosahuje využitím několika typických vrstev. Jedná se o konvoluční, *pooling* a *ReLU* vrstvy, které jsou umístěny několikrát za sebou, a o *fully-connected* vrstvu, která je umístěna na konci sítě a slouží k vypočítání klasifikačních skóre. Některé z těchto vrstev (konvoluční, *fully-connected*) mají parametry měnící se během učení, tedy prahy a váhy, a některé vrstvy (*ReLU*, *pooling*) parametry měnící se během učení nemají a vykonávají stále stejnou funkci.Stanford (2019)

V konvoluční vrstvě probíhá většina výpočtů. Její parametry jsou sada učitelných filtrů, které jsou malé na výšku a šířku, ale hloubku mají stejnou jako vstupní obraz. Každý filtr je postupně posouván po vstupním obraze ve směru výšky a šířky a na každé pozici je vypočítána konvoluce mezi ním a překrývanou částí vstupního obrazu v plné hloubce. Takovýmto postupným posouváním vzniká dvoudimenzionální aktivační mapa, kdy aktivační mapy pro jednotlivé filtry zařadíme za sebe ve směru hloubky, a vytvoříme tak výstup vrstvy. Během učení se filtry naučí aktivovat při rozeznání různých druhů obrazových příznaků jako jsou hrany v určitém směru, barvy, atd. Po většině konvolučních vrstev se vkládá *ReLU* vrstva, která zavádí do sítě nelinearitu. Nejčastěji je prováděna jako funkce $\max(0, x)$.Stanford (2019)

Pooling vrstva se obvykle vkládá po několika opakováních konvolučních a *ReLU* vrstev a její funkce je snížit velikost výstupu konvoluční sítě. Důvodem jejího využití je zmenšení množství parametrů, tím pádem i snížení výpočetní náročnosti a možnosti přeučení sítě. Zmenšování objemu probíhá nezávisle na hloubce, tedy pouze ve výšce a šířce, a hloubka tedy zůstává zachována. Nejčastější formou je využití funkce maximum (*max-pooling* vrstva), kdy je na objem aplikován filtr s předem danou velikostí (nejčastěji 2x2, který snižuje velikost o 75%). Kromě funkce maximum se dá také využít například funkce průměr.Stanford (2019)

Na konci celé sítě je pak umístěna *fully-connected* vrstva, která je propojena s celým objemem z předchozí skupiny, což je stejné jako u standartní neuronové sítě. Jejím výstupem jsou klasifikační skóre vstupního obrazu pro

jednotlivé klasifikační skupiny. Během fáze učení sítě je za *fully-connected* vrstvou přidávána ještě *SofMax* vrstva, která přepočítá výstupní skóre *fully-connected* vrstvy na normalizované pravděpodobnosti zařazení do tříd a její záporně vzatý logaritmus je nejčastěji využit jako kriteriální funkce (*angl. loss function*). Stanford (2019)

Jako algoritmus pro optimalizaci konvolučních neuronových sítí se nejčastěji využívá SGD (*angl. Stochastic Gradient Descent*, stochastický gradientní sestup). Jeho častá varianta je *batch gradient descent*, kdy se parametry přepočítávají až po zjištění celkové chyby pro všechna trénovací data. Pro výpočet nové hodnoty parametru se používá vzorec 1.7, kde θ je hodnota parametrů (váhy a prahy), μ je krok učení určující rychlost konvergence a J je chybová funkce. Ruder (2016)

$$\theta = \theta - \mu \cdot \nabla_{\theta} J(\theta) \quad (1.7)$$

Pro výpočet se dá také využít metoda SGD with momentum, která sleduje vhodný směr a oscilaci. Vzorec se poté změní na 1.8, kde γ je parametr *momentum* a v rychlost. Ruder (2016)

$$\begin{aligned} v_t &= \gamma \cdot v_{t-1} + \mu \cdot \nabla_{\theta} J(\theta) \\ \theta &= \theta - v_t \end{aligned} \quad (1.8)$$

V praxi se často využívají předučných CNN, jejichž architektura je dána. Jedná se například o AlexNet, který představil Alex Krizhevsky Krizhevsky a kol. (2012), nebo o VGG16, který představili autoři z Visual Geometry Group Simonyan a Zisserman (2014). Obě sítě byli natrénovány na datasetu ImageNet ILSVRC-2012. Dále se dá zmínit GoogleNet představený v článku Szegedy a kol. (2015) a natrénovaný na datasetu ImageNet ILSVRC-2014 nebo ResNet představený v článku He a kol. (2016) a natrénovaný na datasetu ImageNet ILSVRC-2015. Stanford (2019)

- Algoritmus k-nejbližších sousedů
Algoritmus k-nejbližších sousedů (*angl. K-Nearest Neighbors*) rozhoduje o výstupní hodnotě dat na základě hodnot k-nejbližších sousedů vypočítaných pomocí euklidovské vzdálenosti. Fáze učení je pouze uložení trénovacích dat. Při klasifikaci algoritmus zjistí třídy k-nejbližších sousedů a objekt zařadí do nejvíce zastoupené. Pokud nastane situace, že nejbližší třídy mají stejný počet zastoupení, pak je objektu přiřazena ta, která obsahuje objektu nejbližšího souseda. Pokud je výstupní hodnotou kvantitativní veličina, poté se výstup počítá jako průměr hodnot k-nejbližších sousedů. V tomto případě se dá využít i váhová metoda, kdy je zohledněna nejen hodnota souseda, ale také jeho vzdálenost, díky čemuž bližší sousedi ovlivní výstupní hodnotu více a vzdálenější sousedi méně. Honzík (2006)

- Rozhodovací stromy

Rozhodovací strom (*angl. Decision Tree*) je hierarchistický nelineární systém, který nám umožňuje nalezení a uložení nových znalostí. Hlavními výhodami jsou hierarchické uspořádání, nelinearita, čitelnost a interpretovatelnost. Rozhodovací strom začíná v kořenovém uzlu, kam vstupují trénovací data, a na základě nalezené podmínky se rozdělují pomocí větví do nových uzlů. Toto rozdělování pokračuje až do chvíle, kdy je splněna ukončovací podmínka. V tu chvíli se uzel mění v list a rozdělování již dále nepokračuje. List je tedy výstupní veličina vedoucí především ke klasifikaci či predikci. Honzík (2006)

Vybrané modely pro učení bez učitele

- K-means

Algoritmus k-means má za úkol najít k shluků dat, které si jsou navzájem podobné. Každý shluk je reprezentován svým středem, který se hledá iterativně, a spadají do něj všechna taková data, jejichž vzdálenost je k jeho středu nejmenší. Na začátku je určen počet shluků, středy se zvolí náhodně a probíhá následující algoritmus. Data jsou přiřazena do shluku, ke kterému jsou nejbližší. Následně se určí nové souřadnice středu jako průměr dat spadajících do shluku tohoto středu. Přiřazování dat a přepočítání středů se počítá iterativně, dokud se shlukování neustálí. Materna (2016)

- Samoorganizační mapy

SOM (*angl. Self-Organizing Maps*, samoorganizující se mapy) patří mezi základní typy neuronových sítí. Samoorganizační mapa provádí shlukování, čímž je ideální k třídění, rozhodování či rozlišování. Jedná se o uspořádanou strukturu neuronů, kdy každý z nich má unikátní vektor koeficientů. Během učení se porovnávají váhy vstupních dat se všemi neurony a na základě euklidovské vzdálenosti se určuje ten nejbližší. Ten je potom i se svým okolím upraven dle vstupních dat, nejprve se upravuje více s větším okolím, na konci pak jen málo s minimálním okolím, kdy se může adaptovat i pouze sám nejpodobnější neuron. Výsledkem je poté struktura, ve které jsou znatelné shluky neuronů s podobnými vahami. Vojáček (2006)

1.3.3 Extrakce příznaků

Kvalitativní či kvantitativní vlastnosti objektu se ve strojovém učení vyjadřují pomocí příznaků. Pokud je vypočítáno více příznaků, vytváří se tzv. příznakový vektor objektu. Pro všechny objekty dohromady je poté vytvořen jeden příznakový prostor skládající se z příznakových vektorů. Šalplachta (2017); Novosadová (2014); Holčík (2012)

Pro správnou klasifikaci objektů do tříd potřebujeme dostatečné množství informací, tedy příznaků. Čím více příznaků zkoumáme, tím kvalitnější klasifikace bude. S rostoucím počtem informací ovšem také stoupá výpočetní náročnost a výpočetní čas klasifikátoru, a proto je nutné nalézt vhodný kompromis. Je tedy důležité počet příznaků zredukovat, k čemuž se většinou využívá statistických metod např. korelační analýzy, diskriminační analýzy či PCA (*angl. Principal Component Analysis*, analýza hlavních komponent). Extrakce příznaků je proces, kdy se z dat získávají příznaky. Selektce příznaků je založena na výběru příznaků, které nejméně přispívají ke klasifikaci, a jejich vynechání. Vhodnými jsou vzájemně nekorelované příznaky, které mají maximální vzdálenost mezi třídami a zároveň minimální rozptyl uvnitř tříd. Šalplachta (2017); Novosadová (2014); Holčík (2012)

1.4 Metody strojového učení užívané pro klasifikaci dat v medicíně

V nastudovaných článcích se objevilo několik metod klasifikace dat, konkrétně identifikace obratlů v CT snímcích. První skupinou jsou metody, kdy je nejprve nalezen jeden výrazný zájmový bod, většinou dvanácté žebro, obratel L_5 nebo obratel S_1 . Po identifikaci tohoto bodu se následně díky známému pořadí obratlů v páteři určí všechny ostatní obratle. Druhou skupinou je vytváření pravděpodobnostních map výskytu každého obratle. Poslední skupinou je porovnání nalezených obratlů s vytvořenými modely.

1.4.1 Nalezení zájmového objektu a následná identifikace dle známého pořadí obratlů

Pro identifikaci obratlů se mohou využít metody, které nejprve určí jeden konkrétní obratel, žebro, křížovou kost atd., a díky znalosti pořadí, ve kterém se obratle vyskytují, následně určí ostatní obratle. Jedna taková metoda, která má ovšem požadavek, aby se v CT snímku našla alespoň jedna z oblastí prvního žebra, dvanáctého žebra či vrchní části kosti křížové, je popsána v Major a kol. (2013). Metoda se nejprve pomocí PBT (*angl. Probabilistic Boosting Tree*) snaží najít první žebro, poslední žebro či křížovou kost. Pokud ani jednu z těchto struktur nenajde, pokračuje hledáním meziobratlových plotének pomocí *regular expression matching*. Jsou vytvořeny detektory pro krční, hrudní a bederní meziobratlové ploténky, dále detektor pro obratlový otvor a pro nalezení počátku šíření identifikace také detektory pro ploténky pod posledním krčním, hrudním a bederním obratlem. Po nalezení alespoň jedné z oblastí, kde se typ obratle mění, jsou ostatní obratle určeny díky známému pořadí

obratlů v páteři. Při testování na 36 CT snímcích, z nichž 13 bylo patologických, byla identifikace chybná pouze v jednom případě, a úspěšnost tak byla vyčíslena na 97,2%.

Podobnou formou jsou určeny obratle i ve článku Cai a kol. (2016), kdy autoři nejprve vytvořili pole ohraničující jednotlivé obratle, které ukazují jejich orientaci v sagitálním řezu. Tato pole jsou nalezena při detekci obratlů pomocí TDCN (*angl. Transformed Deep Convolution Network*), SVM (*angl. Support Vector Machines*) a *deep congealing*. Sousedící správně orientovaná pole jsou propojena, čímž se vytvoří přibližný tvar páteře. Z tohoto tvaru se následně určí obratle L_5 a S_1 a pomocí šíření po pospojovaných polích se postupně přiřadí typ každému obratli. Tato metoda identifikace byla testována na 60 snímcích MRI (*angl. Magnetic Resonance Imaging*, magnetická rezonance) a 90 CT snímcích s různými patologiemi, kdy dosáhla úspěšnosti 95%.

1.4.2 Pravděpodobnostní mapy

Další častou metodou je vytváření pravděpodobnostních map výskytu každého obratle. Pro vytvoření pravděpodobnostní mapy byl v Glocker a kol. (2012) použit algoritmus s využitím regresního lesa a pravděpodobnostních grafických modelů tvaru páteře a vzhledu obratlů. Identifikace obratle probíhá v tomto případě již při lokalizaci obratlů. Les je složen z mnoha rozhodovacích binárních stromů a jeho výstupem je pravděpodobnost rozložení pro každý typ obratle. V dalším kroku se už jen díky znalosti tvaru páteře a tvaru každého obratle určí jeho přesnější poloha. Metoda dosáhla 81% úspěšné identifikace obratlů při hodnocení na 200 CT snímcích s ručně označenými středy obratlů.

Vícevrstvou konvoluční sít zvanou hluboká *image-to-image* sít využívá také metoda Yang a kol. (2017a). Identifikace probíhá současně s lokalizací obratlů. Jako vstup do sítě vstupuje přímo 3D CT snímek, na výstupu jsou poté pravděpodobnostní mapy výskytu centroidu pro každý obratel zvlášť. Dalším krokem je vylepšení těchto map díky *message passing a sparsity representation* (Yang a kol. (2017a)), kdy jsou využívány informace i z ostatních pravděpodobnostních map a informace o struktuře páteře, což vede k odstranění falešně pozitivních výsledků. Úspěšnost identifikace typu obratle je 90%, kdy testování probíhalo na 302 CT snímcích s patologiemi.

Velice podobná metoda je popsána v článku Yang a kol. (2017b). Na počátku vstupuje do hluboké *image-to-image* sítě 3D CT snímek. Výstupem je pravděpodobnostní mapa výskytu centroidu pro každý obratel, stejně jako v metodě Yang a kol. (2017a). Vylepšení map zde ale probíhá metodou vícevrstvé konvoluční LSTM (*angl. Long Short-Term Memory*) sítě a *proposed shape basis* sítě (Yang a kol. (2017b)), což také vede k odstranění falešně pozitivních výsledků. Model byl testován opět na

302 CT patologických snímcích (není řečeno, zda jsou tato testovací data shodná s předchozí metodou). Úspěšnost se v důsledku těchto změn ovšem snížila na 89%.

V metodě popsané v článku Liao a kol. (2018) se využívá jak FCN (*angl. Fully Convolution Neural Network*, plně konvoluční neuronová síť), tak více-účelové dvou-směrné RNN (*angl. Recurrent Neural Network*, rekurentní neuronová síť). FCN je použita k identifikaci za pomoci pouze malého prostoru kolem obratle, RNN identifikuje na základě podobnosti s větším okolím. Během CNN je použita vzájemná entropie pro výpočet identifikační a lokalizační ztráty a je vytvořena 3D skórovací mapa. RNN následně dodá informace od horního či dolního sousedního obratle. Metoda dosáhla úspěšnosti při testování na 60 CT snímcích 88,3%.

1.4.3 Modely

Další častá možnost se zakládá na srovnání s modely. Pro vytvoření modelů v metodě Klinder a kol. (2009) byly využity komerční plastové fantomy naskenované CT přístrojem. Srovnání se provádí mezi všemi nalezenými obratli a všemi modely a následně je vytvořena tabulka podobností, kde v řádku jsou nalezené obratle a v sloupci modely obratlů. Pro každou diagonálu je proveden výpočet průměrné podobnosti a diagonála s nejvyšším průměrem je vybrána jako správný výsledek. Pro míru podobnosti je použita lokální korelační funkce, jelikož má lepší výsledky než korelace vzájemná či suma kvadratických odchylek. Při testování bylo správně identifikováno 56 z 59 CT patologických snímků a úspěšnost metody tak je 95%.

Další nalezenou metodou je Ma a Lu (2013), kde byli k identifikaci hrudních obratlů použity modely, které vznikly vypočítáním aritmetických průměrů obratlů z 40 CT snímků. Následně je zkoumáno, na jaký model má obratel největší odpověď. Postupně se tedy obratel srovnává s 12 zprůměrovanými modely a počítá se skóre hranové odpovědi bez deformace. Tyto odpovědi jsou vypočítány jako počet ploch, které jsou s vysokou pravděpodobností hraniční body. V metodě je také využita znalost, jak za sebou obratle následují. Metoda byla testována 4-násobnou křížovou validací na 40 CT snímcích, kdy úspěšnost identifikace samotného obratle je 73,1%, při využití alespoň 8 obratlů se zvýší na 95%.

Další identifikace obratlů je v článku Chen a kol. (2015) prováděna pomocí J-CNN (*angl. Joint Convolutional Neural Network*). Obsahuje 4 konvoluční a *max-pooling* vrstvy, dvě plně propojené a dvě klasifikační vrstvy. *Softmax* klasifikační vrstva provádí výpočet vzájemné entropie pro určení typu obratle na základě jedinečného vzhledu každého z nich. Druhá klasifikační vrstva určuje, zda spolu dva identifikované obratle sousedí, či nikoliv. Výsledky obou konvolučních vrstev jsou nakonec použity pro výpočet chybové funkce, na základě které se následně určí

konkrétní typ obrátle. Metoda dosáhla úspěšnosti 84,16% při testování na 60 patologických a pooperačních CT snímcích.

2 VLASTNÍ ŘEŠENÍ

2.1 Používaná data

Při bakalářské práci bylo k dispozici celkem 20 CT dat, kdy se jedná o méně závažně nemocné pacienty. CT snímky jsou již oříznuté celotělové snímky zahrnují pouze kvádr obsahující páteř a její nejbližší okolí. Originální CT obraz se v datech vyskytuje ve dvou rozlišeních, a to originálním rozlišení, ve kterém byl CT snímek pořízen, a dále převzorkovaný obraz na jednotné rozlišení stejné u všech dat. V bakalářské práci se pracuje s převzorkovaným obrazem z důvodu právě jednotného rozlišení ve všech CT datech.

Dále jsou v datech masky již vysegmentovaných obratlů vyskytujících se v CT snímku. Masky jsou provedeny následovně: číslem 100 jsou označeny těla obratlů, číslem 200 jsou označeny výběžky obratlů a číslem 300 jsou označena případná žebra přiléhající k obratli. K těmto číslům jsou následovně přičtena čísla označující pořadí obratle v páteři, čímž se odliší jednotlivé části pro každý obratel zvlášť. Např. číslem 105 bude tedy označeno tělo 5. obratle, tedy obratle C_5 , číslem 220 budou označeny výběžky 20. obratle, tedy L_1 a číslem 311 budou označena žebra přiléhající k 11. obratli, tedy Th_4 .

V datech se také vyskytují informace o poloze středů nalezených obratlů a čísla nalezených obratlů, kdy se obratel C_1 a C_2 považují za jeden obratel $C_{1,2}$. Další údaje nejsou v bakalářské práci využívány.

2.2 Trénovací a testovací data

K natrénování a otestování jak SVM, tak obou neuronových sítí bylo využito křížové validace. Jelikož bylo k dispozici celkem 20 CT dat, byla využita 5-násobná křížová validace. Data tedy byla vždy rozdělena na 16 CT dat jako trénovací množina a 4 CT data jako testovací množina. Při rozdělení na trénovací a testovací množinu byly nejprve všechny názvy CT dat seřazeny podle abecedy a následně byla po čtveřicích postupně vybírána CT data do testovací skupiny, kdy zbylých 16 CT dat bylo uloženo do trénovací množiny. Jelikož se ovšem počet obratlů u každého pacienta liší, tak i pro natrénování a otestování byl v každém případě využit jiný počet obratlů. V Tab. 2.1 je vidět rozdělení dat pro 5-násobnou křížovou validaci použitou pro všechny případy při trénování a testování.

Tab. 2.1: Trénovací a testovací data

Soubor	Trénovací data	Testovací data
data1	16 CT (344 obratlů)	4 CT (70 obratlů)
data2	16 CT (334 obratlů)	4 CT (80 obratlů)
data3	16 CT (331 obratlů)	4 CT (83 obratlů)
data4	16 CT (323 obratlů)	4 CT (91 obratlů)
data5	16 CT (324 obratlů)	4 CT (90 obratlů)

2.3 Identifikace typu obratlů pomocí SVM

Prvním cílem bakalářské práce bylo vytvořit program, který by z vložených CT snímků vypočítal příznaky pro každý obratel. Následně by měl program z těchto příznaků určit typ obratle, a to krční, hrudní nebo bederní. Řešení tohoto cíle je nakonec rozděleno do dvou skriptů v prostředí Matlab. První skript vypočítá příznaky pro všechny obratle z vloženého CT snímku. Následně je nutné tyto příznaky ručně uložit do matice a tu dát jako vstup do druhého skriptu. Druhý skript potřebuje 2 vstupy, a to matici trénovacích a testovacích příznaků. Na jeho výstupu jsou určeny typy krční, hrudní či bederní pro každý obratel a zároveň je řečeno, kolik obratlů z testovacích dat je určeno správně.

Při trénování modelu SVM, který klasifikuje do více než dvou skupin, se problém řeší nejčastěji jednou z následujících dvou metod. První možností je pro N skupin natrénovat N SVM modelů, kdy každý model řeší klasifikaci do dvou skupin, a to n -tá skupina, nebo ostatní skupiny. Jedná se tedy o N binárních klasifikací. Objekt poté dostává ohodnocení pro každý z natrénovaných N modelů, podle toho, zda spadá do klasifikační skupiny, či nikoliv. Tato možnost byla použita i pro řešení této bakalářské práce. Druhou možností je pro N klasifikačních skupin vytvořit $\frac{N \cdot (N-1)}{2}$ modelů. V tomto případě každý model provádí zařazení přímo do jedné ze dvou klasifikačních skupin, jedná se tedy opět o binární klasifikace. Theodoridis a kol. (2009)

2.3.1 Extrakce příznaků

Pro extrakci příznaků je určen skript *SVM_priznaky.m*. V něm se nejprve načte již předzpracovaný CT snímek, který obsahuje mimo jiné masky obratlů (s odlišením těla, výběžků a žeber), čísla obratlů a originální data. Následně jsou do proměnných uloženy vysegmentované obratle, u kterých je rozlišeno tělo, výběžky a žebra, dále originální CT snímek, středy obratlů a konkrétní pojmenování nalezených obratlů.

Následně jsou postupně pro všechny obratle vypočítány příznaky. Před samotnou extrakcí jsou obratle oříznuty podle kvádrového boxu, který je získán podle první

a poslední nenulové hodnoty segmentované masky. Do funkce vstupuje binární 3D obraz, který chceme oříznout, a počet voxelů, o které chceme oříznutý obraz zvětšit. Na výstupu funkce je poté oříznutý obraz a indexy, které odpovídají hranicím oříznutého obrazu v původním vloženém 3D obrazu. Příznaky jsou uloženy do vektoru, do kterého je poté na první pozici přidán typ obratle (1 - krční, 2 - hrudní, 3 - bederní). Výstupem je tedy matice, kdy na řádcích jsou jednotlivé obratle a ve sloupcích nejprve typ obratle a následně jeho příznaky.

Použité příznaky

Při testování SVM byly jako nejlepší pro identifikaci typu obratle určeny především ty příznaky, které jsou vypočítány z velikosti obratle a jeho výběžků, tedy především byly využívány masky obratlů. Jako nejvhodnější příznaky byly určeny:

- *zebro* - určení, zda se na obratel napojuje žebro
- *rozmer_tela1* - velikost těla v ose x
- *rozmer_tela2* - velikost těla v ose y
- *rozmer_tela3* - velikost těla v ose z
- *rozmer_bez_zeber1* - velikost obratle (těla a výběžků) v ose x
- *rozmer_bez_zeber2* - velikost obratle (těla a výběžků) v ose y
- *rozmer_bez_zeber3* - velikost obratle (těla a výběžků) v ose z

Nevyužité příznaky

Během trénování SVM bylo vypočítáno několik příznaků, které se ukázaly jako nevhodné při identifikaci typu obratlů. Jedná se především o příznaky vypočítané z jasových hodnot originálního CT snímku, což je důvod, proč byly nakonec pro identifikaci typu obratle využity pouze masky obratlů. Nevyužité příznaky jsou:

- *poradi* - pořadí obratle v konkrétním CT snímku
- *max_jas* - maximální jasová hodnota obratle v originálním CT snímku
- *min_jas* - minimální jasová hodnota obratle v originálním CT snímku
- *prumer_jas* - průměrná jasová hodnota obratle v originálním CT snímku

2.3.2 Určení typu obratle pomocí SVM

Ve druhém skriptu *SVM_typ_obratle.m* se nejprve načte soubor *priznaky_obratle-(číslo).mat*, který načte dvě matice, a to matici trénovacích dat a matici testovacích dat. U matice trénovacích dat se do proměnných rozdělí typy obratlů a příznaky jednotlivých obratlů, u testovacích dat do proměnné uložíme pouze příznaky obratlů.

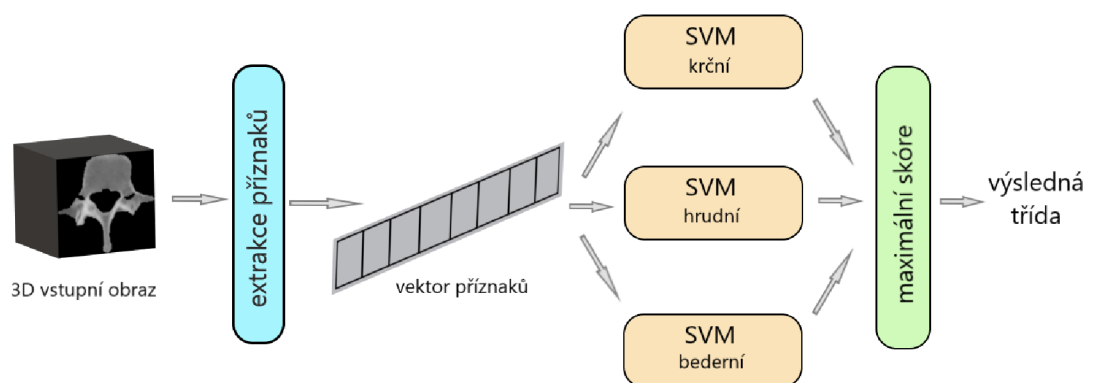
Pro určení typu obratlů byl vybrán model SVM. Nejprve tedy vytvoříme buňkové pole o velikosti 3, které bude poté v každé buňce obsahovat natrénovaný model pro jeden typ obratle. Také zjistíme, jaké typy obratlů se v trénovací množině vyskytují.

2.3.3 Fáze trénování SVM

Následuje fáze trénování SVM modelu. Na vstup je nutné přivádět příznaky a binární informaci o typu obratlů, proto se model pro každý typ obratle trénuje zvlášť. Nejprve je tedy nutné vytvořit vektor typu obratlů trénovacích dat, kde je jedničkou označen ten typ obratle, pro který chceme model natrénovat, a nulou jsou označeny ostatní typy obratlů. Následně pomocí funkce natrénujeme model pro jeden typ obratle a stejný postup uděláme i pro ostatní typy obratlů, přičemž každý model uložíme do jedné buňky.

2.3.4 Fáze testování SVM

Otestování modelu se provádí pomocí funkce, do které vstupuje postupně každý SVM model pro jeden typ obratle a příznaky testovacích dat. Výstupem je ohodnocení, zda obratel dle příznaků patří do této skupiny. Z tohoto ohodnocení je potřeba získat pozitivní skóre. Po vypočtení tohoto pozitivního skóre pro všechny modely a obratle najdeme pro každý obratel maximální pozitivní ohodnocení. Dá se předpokládat, že pokud má model nejvyšší pozitivní skóre oproti ostatním modelům, je obratel právě tohoto typu. Schéma testování modelu SVM je na Obr. 2.1.



Obr. 2.1: Schéma sítě SVM

2.4 Identifikace typu obratlů pomocí CNN

Další metoda použitá pro identifikaci typu obratlů je využití konvolučních neuronových sítí. Konkrétně bylo využito dvou předtrénovaných sítí, a to síť *AlexNet* Krizhevsky a kol. (2012) a *VGG16* Simonyan a Zisserman (2014). Jedná se tedy o síť s již připravenou strukturou a předučenými prahy a váhami, které mají danou velikost vstupního obrazu. Obě sítě byly upraveny tak, aby klasifikovaly vstupní obrazy, tedy obratle, do skupin krční, hrudní a bederní.

Pro natrénování obou sítí bylo nejprve potřeba vytvořit skript na vytvoření vstupních dat. Ve skriptu se vytváří tři druhy vstupních dat, která jsou postupně testována. Další skript slouží k vytvoření augmentovaných vstupních dat v ose z pro vytvoření většího počtu trénovacích dat. Pro natrénování každé sítě jsou pak vytvořeny další dva skripty, kdy v jednom je prováděno trénování pouze na datech předem vytvořených a v druhém je prováděna augmentace vstupních dat pomocí funkce. Všechny natrénované sítě jsou poté ve skriptech otestovány na testovacích datech.

2.4.1 Vstupní data do CNN

Obě předtrénované neuronové sítě požadují konkrétní velikost vstupních dat. U *AlexNetu* se jedná o velikost $224 \times 224 \times 3$, u *VGG16* o velikost $227 \times 227 \times 3$. Je tedy jasné, že jako vstup není možné dát ořezanou masku obratle, který chceme klasifikovat, ale pouze jeho 3 řezy. Prvním problémem je nalézt nejvhodnější řez obratlem. Pomocí pozorování bylo zjištěno, že u hrudních a bederních obratlů je nejlepší transverzální řez umístěn přibližně v jedné polovině osy z , ale u hrudních obratlů není v tomto místě patrné žebro. U hrudních obratlů by tedy nutné dělat řez přibližně v horní třetině osy z . Z tohoto důvodu nebylo možné využít provedení řezu v určité části osy z . Nejlepším řešením se během pozorování ukázalo provedení řezu obratlem v rovině, kde má obratel největší součet jasu. Tímto způsobem byl tedy proveden řez ve všech obratlích.

Jelikož je ale na vstupu obou sítí matice o 3 vrstvách, je možné využít pro jeden obratel více řezů. Při vytváření vstupních matic byly vytvořeny 3 druhy vstupních matic kvůli porovnání nejlepšího výsledku. Prvním druhem vstupních matic je řez obratlem v první vrstvě a nulové matice ve vrstvách ostatních, kdy tento druh vstupních matic byl nazván *1řez*. Druhým typem matic jsou matice *3řezy*, kde se v první vrstvě nachází řez obratlem v polovině osy z , ve druhé vrstvě řez ve čtvrtině osy z a ve třetí poslední vrstvě řez ve třech čtvrtinách osy z . Posledním typem vstupních matic jsou matice *okolo*, kdy je v první vrstvě řez klasifikovaným obratlem, v druhé vrstvě řez sousedícím horním obratlem a v poslední vrstvě řez sousedícím dolním

obratlem (pokud sousedící obratel v datech není, je řez nahrazen nulovou maticí).

2.4.2 Augmentace dat

K natrénování a otestování problému klasifikace bylo k dispozici poměrně málo dat. Z tohoto důvodu bylo využito v některých případech augmentace, kdy byla augmentovaná pouze trénovací a validační data. Všechna trénování tedy nejprve proběhla na datech bez augmentace a poté na dvou typech augmentovaných dat.

Prvním způsobem augmentace bylo využití funkce, která umožňuje ve svém parametru nastavení některých způsobů augmentace. V této bakalářské práci byla provedena augmentace s nastavením rotace $\pm 5^\circ$, translace v osách X a Y o ± 10 pixelů a změnou měřítka v osách X a Y o $\pm 10\%$.

Druhou využitou augmentací je augmentace v ose z . Pro všechny vytvořené vstupní matice tedy byly dodělané další dvě. První matice byla vytvořena z řezů vždy 2 pixely nad původním řezem a druhá matice naopak z řezů 2 pixely pod původním řezem. Tímto způsobem bylo tedy získáno třikrát více trénovacích dat než v množinách bez augmentace.

2.4.3 Vytvoření vstupních dat do CNN

K vytvoření vstupních dat slouží skripty *CNN_vstupy.m* a *CNN_vstupy_augmentovane.m*. Oba skripty postupně vytvoří 3 typy vstupních obrazů všech obratlů v CT snímku postupně pro všechna dostupná CT data.

Skript nejprve načte CT data jednoho pacienta a uloží si z nich originální CT snímek, vysegmentovaný snímek obratlů s rozlišením těla, výběžků a přiléhajících žeber, čísla nalezených obratlů a jejich středy. Následně pomocí for cyklu zpracuje jednotlivé obratle nalezené v CT snímku. Nejprve je funkcí obratel oříznut podle kvádrového boxu, který je získán podle první a poslední nenulové hodnoty segmentované masky. Na vstup funkce je nutné přivést binární masku obratle včetně případných přiléhajících žeber a počet voxelů, o který chceme kvádr na krajích rozšířit. Na výstupu dostaneme oříznutou vstupní binární masku a indexy, podle kterých vstupní obraz oříznut. Podle získaných indexů a oříznuté binární masky dále skript vytvoří oříznutý vysegmentovaný obratel v originálním CT snímku.

Jako první se vytvoří matice *3řezy*. Do první vrstvy matice je uložen řez ve čtvrtině výšky obratle, v druhé vrstvě je uložen řez v polovině výšky obratle a ve třetí vrstvě je uložen řez ve třech čtvrtinách obratle. Matice je nakonec uložena jako RGB obraz.

Následně je vytvořena matice *1řez*. Pomocí for cyklu je vytvořen vektor součtů jasových hodnot v jednotlivých vrstvách oříznutého obratle a následně nalezeno maximum z těchto součtů. Do matice se následně uloží do první vrstvy řez obratlem

s největším součtem jasových hodnot a do dalších dvou nulová matice. Matice je opět uložena jako RGB obraz.

Jako poslední je vytvořena matice *okolo*, kdy je nejprve vyhledán řez s největším součtem jasových hodnot jako v předchozím případě. Následně je stejný postup zopakován i pro sousedící obratel nahoře a sousedící obratel dole. Všechny řezy jsou uloženy do tří vrstev matice a ta je následně uložena jako RGB obraz. V případě, že obratli chybí sousední obratel, je místo řezu tímto obratlem uložena nulová matice.

Pro vytvoření augmentovaných dat je použit skript *CNN_vstupy_augmentovane.m*. V něm se stejně jako v předchozím skriptu vytváří pro jednotlivé obratle RGB obrazy typů *1řez*, *3řezy* a *okolo*. Výstupem funkce je ovšem 6 augmentovaných obrazů pro každý obratel, jelikož se do matic nejprve ukládají řezy o dva pixely výše a následně řezy o dva pixely níže než jsou řezy ve skriptu *CNN_vstupy.m*.

2.4.4 Fáze trénování CNN

Před samotným začátkem trénování sítě je potřeba vytvořená vstupní data rozřídít do složek pro jejich následovné správné načtení. Pro každou trénovací a testovací skupinu musí být vytvořena složka obsahující všechny potřebné obrazy. Jelikož je síť testována 5-násobnou křížovou validací, je potřeba pro každý typ obrazů vytvořit 5 dvojic složek. Ve výsledku tedy vznikne pro 3 typy obrazů celkem 30 složek, kdy polovina z nich obsahuje trénovací data a druhá polovina testovací data, jejichž rozdělení je popsáno v kapitole 2.2. V každé složce je třeba dále obrazy rozřídít do podsložek krční, hrudní a bederní podle jejich správného zařazení.

K natrénování a otestování sítí slouží skripty *CNN_sit_alexnet.m*, *CNN_sit_augmentace_alexnet.m*, *CNN_sit_vgg16.m* a *CNN_sit_augmentace_vgg16.m*. Skripty pro AlexNet a VGG16 jsou až na pár detailů, které budou následně zmíněny, shodné. Pro každou síť jsou vytvořeny 2 skripty, kdy ve skriptu *CNN_sit_augmentace* je využita augmentace pomocí funkce a ve druhém skriptu již augmentace ve skriptu neprobíhá.

Na začátku skriptu jsou nejprve definované kombinace parametrů, se kterými chceme síť postupně natrénovat. Konkrétně se jedná o parametry *MaxEpochs*, *MiniBatchSize*, *InitialLearnRate* a *L2Regularization*. Tyto parametry jsou postupně nastavovány pomocí vnějšího for cyklu. Dále následuje for cyklus, který pro nastavenou kombinaci parametrů sítě postupně vybírá typy obrazů *1řez*, *3řezy* a *okolo*. Pro každý typ obrazu se poté pomocí for cyklu provede 5 trénování a testování sítě pro dosažení 5-násobné křížové validace.

Pro každou validaci se nejprve načtou do proměnných složky s testovacími a trénovacími obrazy, které jsou správně zařazeny v podsložkách dle své klasifikace na krční, hrudní a bederní. Trénovací data se ještě následně rozdělí na trénovací a

validační data v poměru 7:3. Všechna načtená data je následně potřeba upravit na požadovanou velikost podle velikosti vstupní vrstvy jednotlivé sítě. U sítě AlexNet se data upravují na velikost 227x227x3 a u VGG16 na velikost 224x224x3. V případě, kdy před vstupem do sítě ještě provádíme augmentaci dat pomocí funkce, je potřeba předem definovat parametry augmentace a vložit je do funkce při úpravě velikosti dat.

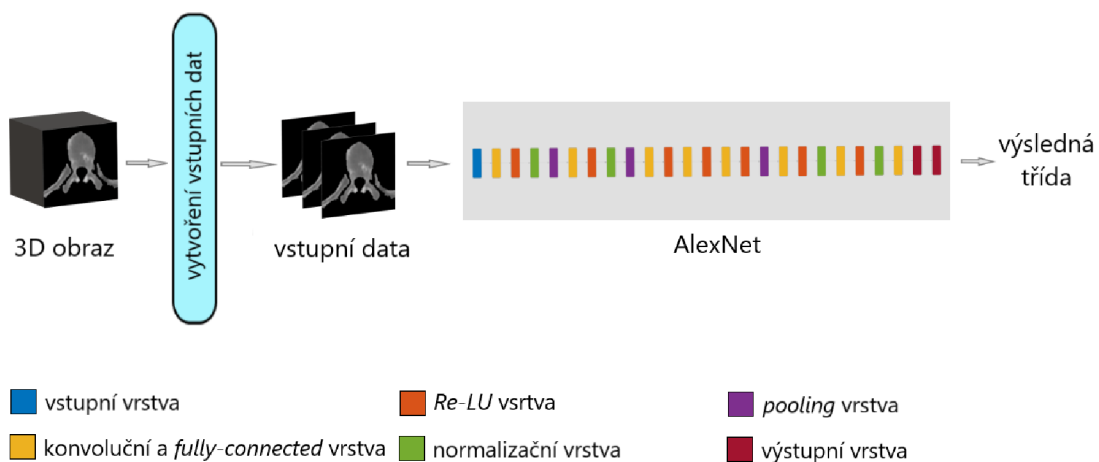
Po správném nastavení vstupních dat se načte předučená síť, a to buď AlexNet nebo VGG16. V předučené síti je potřeba změnit poslední 3 vrstvy, aby mohla probíhat klasifikace do skupin krční, hrudní a bederní. Do proměnné jsou tedy uloženy vrstvy předučené sítě kromě posledních tří vrstev. Za ně je nejprve přidána *FullyConnected* vrstva, jejíž velikost výstupu je nastavena na počet klasifikačních skupin, tedy tři, a váhy a prahy na hodnotu 20. Dále je přidána *SoftMax* vrstva a jako poslední klasifikační vrstva.

Dále je potřeba připravit do proměnné parametry sítě. Jako metoda učení je zvolena SGDM (*angl. Stochastic Gradient Descent With Momentum*, stochastický gradientní sestup s momentem). Dále jsou nastaveny předem definované parametry *MaxEpochs*, *MiniBatchSize*, *InitialLearnRate* a *L2Regularization*. Dále jsou přidána již dříve připravená validační data a parametr *Shuffle* je nastaven na *every-epoch*, tedy promíchání trénovacích obrazů se provádí po každé epoše. Zbytek parametrů je na přednastavené hodnotě.

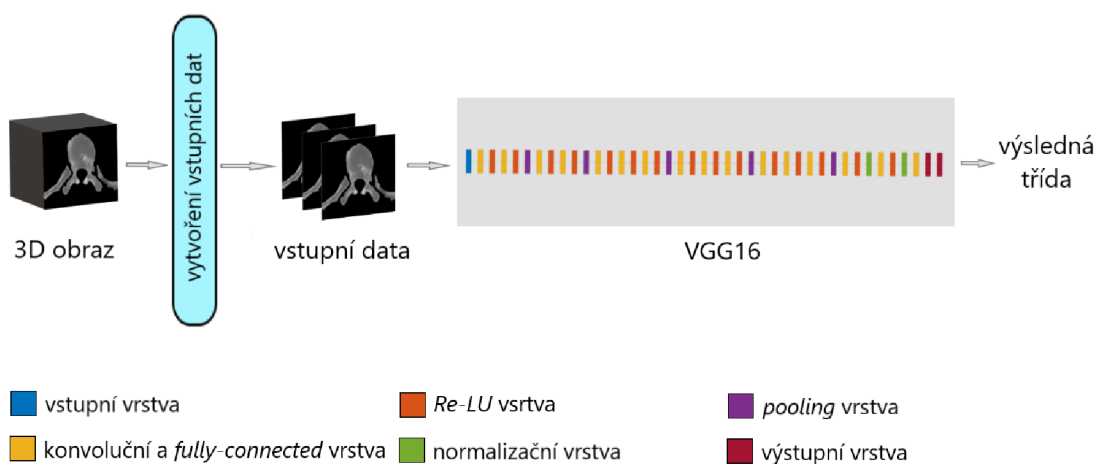
Sít je následně pomocí příkazu natrénována. Na vstupu této funkce jsou trénovací data ve správné velikosti, upravené vrstvy předučené sítě a nastavené parametry.

2.4.5 Fáze testování CNN

Testování sítě je provedeno pomocí funkce, kde se na vstup přivádí natrénovaná síť a testovací data. Výstupem funkce je predikovaná klasifikační třída obrazů a skóre každé predikce. Následně jsou porovnány predikovaná zařazení do tříd se správnými třídami obrazů a je vypočítáno, v kolika případech je klasifikace správná. Na konci je provedeno vyhodnocení úspěšnosti klasifikace. Schéma sítě Alexnet je na Obr. 2.2 a síť VGG16 na Obr. 2.3



Obr. 2.2: Schéma sítě AlexNet. Bloky "vytvoření vstupních dat" a "vstupní data" se liší dle použité metody (*1řez, 3řezy, okolo*)



Obr. 2.3: Schéma sítě VGG16. Bloky "vytvoření vstupních dat" a "vstupní data" se liší dle použité metody (*1řez, 3řezy, okolo*)

3 VÝSLEDKY A DISKUZE

3.1 Dosažené výsledky a diskuze u SVM

V rámci práce byl vytvořen SVM model, který zajišťuje identifikaci typu obratlů do tří skupin, a to krční, hrudní či bederní. Data byla otestována pomocí 5-násobné křížové validace, kdy je rozdělení dat na trénovací a testovací skupinu uvedeno v kapitole 2.2. Během testování natrénovaných SVM bylo správně určeno 411 obratlů z celkového počtu 414, a celková úspěšnost modelu tak byla stanovena na 99,28%. Výsledky testování jednotlivých validací jsou vidět v Tab. 3.1. Z tabulky vyplývá, že ve 3 validacích byly určeny všechny obratle správně, v jedné validaci byl určen špatně jeden obratel a v jedné validaci byly určeny 2 obratle špatně.

Tab. 3.1: Výsledek testování u SVM


Soubor	Trénovací data	Testovací data	Správně určeno	Úspěšnost
data1	344 obratlů	70 obratlů	70 obratlů	100%
data2	334 obratlů	80 obratlů	80 obratlů	100%
data3	331 obratlů	83 obratlů	81 obratlů	97,59%
data4	323 obratlů	91 obratlů	90 obratlů	98,90%
data5	324 obratlů	90 obratlů	90 obratlů	100%
celkem	1656 obratlů	414 obratlů	411 obratlů	99,28%

Při podrobnějším prozkoumání třetí testovací skupiny bylo zjištěno, že jeden špatně identifikovaný obratel je obratel $C_{1,2}$, který byl chybně určen jako obratel hrudní, a druhý chybně identifikovaný obratel je obratel L_5 jiného pacienta, který byl určen také jako obratel hrudní. Transverzální pohledy na správně i špatně identifikované obratle $C_{1,2}$ a L_5 jsou zobrazeny v Obr. 3.1.

Špatně identifikovaný krční obratel ve svých příznacích neměl nalezené žebro, ale oproti ostatním obratlům $C_{1,2}$ ze stejné testovací skupiny se zdál být ve většině rozměrech větší, což pravděpodobně vedlo k jeho špatnému zařazení do skupiny hrudní. V trénovacích datech se obratel $C_{1,2}$ vyskytoval celkem 6krát, což asi nebylo dostatečné množství k naučení SVM.


Špatně identifikovaný bederní obratel také neměl ve svých příznacích nalezeno žebro, ale zdálo se, že má oproti ostatním bederním obratlům větší tělo a naopak menší výběžky. V trénovacích datech se obratel L_5 vyskytoval 16krát, tedy v každém CT snímku. Obratel byl do skupiny hrudní tedy pravděpodobně zařazen z důvodu menšího rozměru těla společně s jeho výběžky.

Při prozkoumání čtvrté testovací skupiny byl zjištěn podobný problém jako u třetí testovací skupiny. Bederní obratel L_5 byl chybně identifikován jako obratel



Obr. 3.1: Transverzální pohled na obratle ze třetí testovací skupiny. Nahoře jsou zobrazeny obratle krční $C_{1,2}$, vlevo správně identifikovaný obratel, vpravo špatně identifikovaný krční obratel jako obratel hrudní. Dole jsou zobrazeny obratle bederní L_5 , opět vlevo správně identifikovaný obratel, vpravo špatně identifikovaný bederní obratel jako hrudní.

hrudní. Jeho transverzální pohled je zobrazen společně se správně zařazených obratlem na Obr. 3.2. V jeho příznacích nebylo nalezeno žebro, ale jeho 2 rozměry těla byly oproti ostatním bederním obratlům menší, což opět pravděpodobně vedlo k jeho chybnému určení na obratel hrudní.



Obr. 3.2: Transverzální pohled na obratle ze čtvrté testovací skupiny. Vlevo správně identifikovaný obratel, vpravo špatně identifikovaný bederní obratel jako hrudní.

Při prozkoumání pozitivních skóre všech špatně identifikovaných obratlů se ukázalo, že pro všechny skupiny (krční, hrudní, bederní) bylo pozitivní skóre záporné. U správně určených obratlů bylo pozitivní skóre u správně určené skupiny kladné a ostatní byly ve většině případů záporné, popřípadě nabývaly malých kladných hodnot. SVM tedy určil, že obratel nepatří pravděpodobně ani do jedné ze skupin, ovšem skriptem byl zařazen do skupiny s nejméně záporným pozitivním skóre.


Z dosažených výsledků lze tedy soudit, že natrénovaný SVM v některých případech klasifikoval obratle dle velikosti i bez přihlédnutí na výskyt žebra u obratle, ovšem výsledné pozitivní skóre bylo záporné. V datech se nevyskytoval žádný hrudní obratel bez žebra ani krční či bederní obratel se žebrem.

3.2 Dosažené výsledky a diskuze u CNN

Pro síť AlexNet bylo provedeno trénování a testování sítě pro 15 kombinací parametrů a pro síť VGG16 bylo provedeno trénování a testování pro 10 kombinací nastavených parametrů. Nejlepší dosažený výsledek u obou sítí je 99,8%, což znamená jeden chybně určený obratel z celkového počtu 414. Podrobné tabulky s výsledky jsou k nahlédnutí v příloze A a B.

V případě AlexNetu je tedy jako nejlepší nastavení sítě určeno $MaxEpochs = 10$, $MiniBatchSize = 28$, $InitialLearnRate = 3e - 5$ a $L2Regularization = 10e - 4$. V případě sítě VGG16 je jako nejlepší nastavení určeno $MaxEpochs = 7$, $MiniBatchSize = 25$, $InitialLearnRate = 3e - 5$ a $L2Regularization = 10e - 4$.


V případě sítě AlexNet byl špatně určen obratel ve čtvrté validační skupině. Konkrétně se jedná o obratel hrudní Th_{10} špatně klasifikovaný jako obratel bederní. Jeho zobrazení je vidět na Obr. 3.3(vpravo) společně se správně určeným shodným obratlem ze stejné validační skupiny (vlevo). U sítě VGG16 je špatně určený obratel z první validační skupiny a je jím obratel Th_9 , jehož všechny vrstvy RGB obrazu jsou zobrazeny na Obr.3.4 dole. Tento hrudní obratel byl chybně klasifikován jako obratel bederní. Nahoře je pak vidět RGB obraz shodného obratle, který byl ovšem správně klasifikován jako typ hrudní. Možným důvodem nesprávné klasifikace je v tomto případě pravděpodobně špatná segmentace žeber v první vrstvě. V obou případech je ovšem důvodů nesprávné klasifikace více.



Obr. 3.3: Zobrazení obrazů klasifikovaných obratlů pomocí sítě AlexNet. Vpravo je správně klasifikovaný hrudní obratel, vlevo je špatně určený obratel hrudní jako obratel bederní.

3.3 Shrnutí dosažených výsledků

Jak je tedy vidět v Tab. 3.2, výsledky všech tří metod mají podobnou úspěšnost. Obě konvoluční neuronové sítě dosáhli stejné úspěšnosti 99,8%, obě pochopitelně s jiným nastavením. U obou CNN sítí se ovšem ukázalo, že nejvhodnější pro trénování sítě bylo využití dat augmentovaných v ose z . U sítě AlexNet bylo této úspěšnosti dosaženo z využitím obrazů *řez*, které v první vrstvě obsahují transverzální řez obratlem v místě největšího součtu jasu a v ostatních dvou vrstvách nulovou maticí. U sítě VGG16 byly pro stejnou úspěšnost využity obrázky *okolo*, kde se v první vrstvě vyskytuje opět transverzální řez obratlem s největším součtem jasu a v dalších



Obr. 3.4: Zobrazení obrazů klasifikovaných obratlů pomocí sítě VGG16. Nahoře jsou zobrazeny všechny tři vrstvy správně klasifikovaného obratle hrudního, dole jsou zobrazeny vrstvy špatně klasifikovaného obratle hrudního na skupinu bederní.

dvou vrstvách také transversální řez obratle v místě největšího součtu jasů, ovšem ze sousedních obratlů. Důvodem lepších výsledků při augmentaci může být to, že trénovací data obsahují větší variabilitu dat způsobenou informacemi i z řezů v okolí původního řezu. Dalšího zlepšení by se tak pravděpodobně dosáhlo při zvětšení datasetu. U SVM bylo dosaženo úspěšnosti 99,3% při použití příznaků přítomnosti žebra, velikosti těla obratle a velikosti těla obratle společně s výběžky ve všech třech dimenzích. Lepšího výsledku by se pravděpodobně dalo opět dosáhnout s větším datasetem, popřípadě s využitím většího množství příznaků.

Z důvody podobné úspěšnosti u všech tří metod klasifikace typu obratlů byla stanovena časová náročnost. Časová náročnost byla počítána u SVM jako čas potřebný k extrakci příznaků a k následné klasifikaci, u CNN jako čas potřebný k získání vstupních obrazů a jejich následné klasifikaci. Výpočet probíhal na počítači s parametry: procesor Intel Core i5-6198DU, RAM 8GB, pevný disk SSD 512GB, grafická karta NVIDIA GEFORCE 930MX. Z Tab. 3.2 vyplývá, že výrazně nejméně časově náročná je síť AlexNet, u SVM a VGG16 je časová náročnost přibližně třikrát větší.

Při podrobnějším prozkoumání špatně určených obratlů bylo zjištěno, že se v každém případě špatně určeného obratle jednalo o jiný obratel. Chyba při určení tedy nenastala z důvodu odlišně vypadajícího obratle, ale z důvodu nedostatečného zobecnění problému sítí.

Při zohlednění tedy jak úspěšnosti sítě, tak její časové náročnosti je jako nej-

vhodnější z metod vyzkoušených v této práci určena předučená CNN AlexNet s parametry $MaxEpochs = 10$, $MiniBatchSize = 28$, $InitialLearnRate = 3e - 5$ a $L2Regularization = 10e - 4$, která byla natrénována na obrazech *1řez*, které v první vrstvě obsahují transversální řez obrátek s největším součtem jasů a ve zbylých dvou vrstvách nulové matice.

Tab. 3.2: Porovnání výsledků sítí

Sít	Parametry	Úspěšnost	Špatně určené	Časová náročnost
SVM	–	99,3%	3 z 414	0,1322 obratlů/s
AlexNet	<i>MaxEpochs = 10</i> <i>MiniBatchSize = 28</i> <i>InitialLearnRate = 3e-5</i> <i>L2Regularization = 10e-4</i> <i>okolo, augmentace v ose z</i>	99,8%	1 z 414	0,3279 obratlů/s
VGG16	<i>MaxEpochs = 7</i> <i>MiniBatchSize = 25</i> <i>InitialLearnRate = 3e-5</i> <i>L2Regularization = 10e-4</i> <i>1řez, augmentace v ose z</i>	99,8%	1 z 414	0,1161 obratlů/s

ZÁVĚR

Tato práce se zabývá identifikací typu obratlů v CT snímcích s využitím metod strojového učení. Tento úkol je důležitý pro usnadnění práce lékařů, kteří jinak musí identifikaci obratlů v CT snímcích provádět ručně, což jim zabírá čas.

Cílem této práce bylo nejprve zpracovat teorii související s tématem identifikace typu obratlů, tedy popsat anatomii páteře a obratlů, princip zobrazování CT, dále se měla zabývat strojovým učáním, popsat jeho základní metody a modely. Dalším bodem teorie byla literární rešerše odborných článků, které se zabývají problematikou identifikací obratlů v CT snímcích, jejich rozdělení do skupin a porovnání výsledků.

Dalším cílem bylo vybrat si na základě přečtených odborných článků metodu pro identifikaci typu obratlů do skupin krční, hrudní či bederní a realizovat ji v libovolném programovacím prostředí. Jako programovací prostředí byl vybrán Matlab. Identifikace typu obratlů byla provedena třemi metodami na 20 CT snímcích obsahujících celkem 414 obratlů.

První metodou bylo využití SVM. Nejprve bylo potřeba vybrat vhodné příznaky a následně provést jejich extrakci pro všechny obratle. Následně byla natrénována a otestována samotná síť, kdy testování sítě proběhlo formou 5-násobné křížové validace. Dosažená úspěšnost SVM je 99,28%.

Druhou metodou je využití předtrénované sítě AlexNet upravené pro klasifikaci do tří skupin. V tomto případě bylo nutné nejprve z 3D snímků obratlů vybrat vhodné 3 řezy a vytvořit z nich RGB obraz z důvodu dané velikosti vstupních dat do předtrénovaných sítí. Síť byla následně otestována 5-násobnou křížovou validací na 3 typech RGB obrazů a byly vyzkoušeny i dva typy augmentace dat. Dosažená výsledná úspěšnost sítě AlexNet je 99,8% při natrénování na obrazech typu *okolo* (v první vrstvě je transverzální řez obratlem s největším součtem jasu, v dalších dvou vrstvách jsou obdobně provedené řezy v sousedních obratlech) a s využitím augmentace v ose z .

Poslední metodou je otestování předučení sítě VGG16. Pro trénování a testování byly využity stejné obrazy a augmentace jako u sítě AlexNet opět 5-násobnou křížovou validací. Dosažená úspěšnost je 99,8% při natrénování sítě na obrazech opět s využitím augmentace v ose z , v tomto případě ovšem na obrazech *1řez* (v první vrstvě je transverzální řez obratlem s největším součtem jasu, ve zbylých dvou vrstvách jsou nulové matice).

Jelikož jsou dosažené úspěšnosti všech tří metod podobné, byla vypočítána také časová náročnost. Z výpočtu vyplynulo, že síť AlexNet je oproti dvěma zbývajícím metodám méně časově náročná, a proto byla určena jako nejvhodnější z provedených metod.

Pro trénování a testování byla použita data pouze pacientů s malými patologi-

emi. V praxi jsou ovšem CT snímky prováděny především pacientům s výraznými patologiemi, proto je otázkou, jak by se výsledek změnil. Pro využití v praxi by bylo tedy nutné rozšířit dataset nejen na větší množství CT snímků, ale také by bylo nutné přidat patologické pacienty. Také by bylo potřeba rozšířit úlohu z klasifikace obratlů jejich typů krční, hrudní a bederní na konkrétní pojmenování od C_1 do L_5 .

LITERATURA

AKPAYAK, I., IGHO, E., SALAAM, A., A SHUAIBU, S., 2017. Multidetector computed tomography scan for renal cell carcinoma: A review. *Journal of Medicine in the Tropics*. **19**(2), 81–85. DOI: 10.4103/jomt.jomt_7_17.

ŠALPLACHTA, J., 2017. *Analýza 3D CT obrazových dat se zaměřením na detekci a klasifikaci specifických struktur tkáně*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. 93 s. Vedoucí diplomové práce prof. Ing. Jiří Jan, CSc.

CAI, Y., LANDIS, M., LAIDLEY, D. T., KORNECKI, A., LUM, A., A LI, S., 2016. Multi-modal vertebrae recognition using transformed deep convolution network. *Computerized Medical Imaging and Graphics*. **51**, 11–19. ISSN 0895-6111.

CHEN, H., SHEN, C., QIN, J., NI, D., SHI, L., CHENG, J. C., A HENG, P.-A., 2015. Automatic localization and identification of vertebrae in spine ct via a joint learning model with deep neural networks. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. **9349**, 515–522. online ISBN 978-3-319-24553-9.

GLOCKER, B., FEULNER, J., CRIMINISI, A., HAYNOR, D. R., A KONUKOGLU, E., 2012. Automatic localization and identification of vertebrae in arbitrary field-of-view ct scans. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. **7512**, 590–598. online ISBN 978-3-642-33454-2.

HANZLOVÁ, J., A HEMZA, J., 2009. *Základy anatomie pohybového ústrojí*. Masarykova univerzita. 94 s. ISBN 978-80-210-4937-6.

HE, K., ZHANG, X., REN, S., A SUN, J., 2016. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*. **9**. DOI: 10.1109/CVPR.2016.90.

HOLIBKOVÁ, A., A LAICHMAN, S., 2010. *Přehled anatomie člověka*. Univerzita Palackého v Olomouci. 140 s. ISBN 978-80-244-2615-0.

HOLČÍK, J., 2012. *Analýza a klasifikace dat*. Brno: Akademické nakladatelství CERM. 112 s. ISBN 978-80-7204-793-2.

HONZÍK, P., 2006. *Strojové učení*. Elektronická skripta VUT Brno. 85 s.

KLINDER, T., OSTERMANN, J., EHM, M., FRANZ, A., KNESER, R., A LORENZ, C., 2009. Automated model-based vertebra detection, identification, and segmentation in ct images. *Medical image analysis*. **13**, 471–82. ISSN 1361-8415.

KRIZHEVSKY, A., SUTSKEVER, I., A HINTON, G. E., 2012. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25*. **6 s.**, 84–90. DOI: 10.1145/3065386. Dostupné z: <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>

LECUN, Y., BENGIO, Y., A HINTON, G., 2015. Deep learning. *Nature*. **521**, 436–44. DOI 10.1038/nature14539.

LIAO, H., MESFIN, A., A LUO, J., 2018. Joint vertebrae identification and localization in spinal ct images by combining short-and long-range contextual information. *IEEE transactions on medical imaging*. **37**, 1266–1275. ISSN 0278-0062.

LUŇÁČEK, L., 2007-2012. *Fotografický interaktivní atlas člověka*. Citováno dne 28.11.2018. Dostupné z: <http://www.atlasloveka.upol.cz/cs/cs02/cs0201/cs020104.html>

MA, J., A LU, L., 2013. Hierarchical segmentation and identification of thoracic vertebra using learning-based edge detection and coarse-to-fine deformable model. *Computer Vision and Image Understanding*. **117(9)**, 1072 – 1083. ISSN 1077-3142.

ŠÍMA, J., A NERUDA, R., 1996. *Teoretické otázky neuronových sítí*: Matfyzpress. 390 s. ISBN 80-85863-18-9.

MAJOR, D., HLADVKA, J., SCHULZE, F., A BÜHLER, K., 2013. Automated landmarking and labeling of fully and partially scanned spinal columns in ct images. *Medical image analysis*. **17**, 1151–1163. DOI 10.1016/j.media.2013.07.005.

MATERNA, J., 2016. *Konvergence algoritmu k-means*. Citováno dne 30.12.2018. Dostupné z: <http://www.mlgyuru.com/cs/konvergence-algoritmu-k-means/>

MÍRKA, H., 2009. *Skenovací parametry*. Citováno dne 24.3.2019. Dostupné z: <https://drive.google.com/file/d/0BwIPmvTQ8YLqZ1FIWXZoNmg2UG8/view>

NOVOSADOVÁ, M., 2014. *Segmentace 3D obrazových dat s využitím pokročilých texturních a tvarových příznaků*: Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. 90 s. Vedoucí diplomové práce prof. Ing. Jiří Jan, CSc.

ŠRÁMEK, J., A KOLEKTIV, 2015. *Chirurgická léčba degenerativního postižení bederní páteře*: Grada. 162 s. IBSN 9788024790015.

RUDER, S., 2016. An overview of gradient descent optimisation algorithms. *arXiv preprint arXiv:1609.04747*. **14 s.**

SEIDL, Z., A LAICHMAN, S., 2012. *Radiologie pro studium i praxi*: Grada. 368 s. ISBN 978-80-247-4108-6.

SIMONYAN, K., A ZISSERMAN, A., 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. **14 s.**

STANFORD, 2019. *Convolutional Neural Networks (CNNs / ConvNets)*: CS231n: Convolutional Neural Networks for Visual Recognition. Citováno dne 20.5.2019. Dostupné z: <http://cs231n.github.io/convolutional-networks/case>

SZEGEDY, C., LIU, W., JIA, Y., SERMANET, P., REED, S., ANGUELOV, D., ERHAN, D., VANHOUCHE, V., A RABINOVICH, A., 2015. Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. **9 s.** DOI: 10.1109/CVPR.2015.7298594.

THEODORIDIS, S., KOUTROUMBAS, K., A KOL., 2009. *Pattern recognition*: Academic Press. 984 s. ISBN 978-1-59749-272-0.

VOJÁČEK, A., 2006. *Samoučící se neuronová síť - SOM, Kohonenovy mapy*. Citováno dne 30.12.2018. Dostupné z: https://www.kiv.zcu.cz/studies/predmety/uir/NS/Samouc_NN2.pdf

YANG, D., XIONG, T., XU, D., HUANG, Q., LIU, D., ZHOU, S. K., XU, Z., PARK, J., CHEN, M., TRAN, T. D., A KOL., 2017a. Automatic vertebra labeling in large-scale 3d ct using deep image-to-image network with message passing and sparsity regularization. *International Conference on Information Processing in Medical Imaging*. **10265**, 633–644. online ISBN 978-3-319-59050-9.

YANG, D., XIONG, T., XU, D., ZHOU, S. K., XU, Z., CHEN, M., PARK, J., GRBIC, S., TRAN, T. D., CHIN, S. P., A KOL., 2017b. Deep image-to-image recurrent network with shape basis learning for automatic vertebrae labeling in large-scale 3d ct volumes. *International Conference on Medical Image Computing and Computer-Assisted Intervention*. **10435**, 498–506. online ISBN 978-3-319-66179-7.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

CT	výpočetní tomografie, <i>angl. Computed Tomography</i>
C_1	nosič, <i>lat. atlas</i>
C_2	čepovec, <i>lat. axis</i>
C_{3-7}	krční obratle, <i>lat. vertebrae cervicales</i>
Th_{1-12}	hrudní obratle, <i>lat. vertebrae thoracicae</i>
L_{1-5}	bederní obratle, <i>lat. vertebrae lumbales</i>
S_{1-5}	křížové obratle, <i>lat. vertebrae sacrales</i>
Co_{1-5}	kostrční obratle, <i>lat. vertebrae coccygeae</i>
RTG	rentgenovo
HU	Hountsfieldova jednotka
EBT	tomograf s elektronovým svazkem, <i>angl. electron beam tomography</i>
SVM	metoda podpůrných vektorů, <i>angl. Support Vector Machines</i>
CNN	konvoluční neuronová síť, <i>angl. Convolution Neural Network</i>
SGD	stochastický gradientní sestup, <i>angl. Stochastic Gradient Descent</i>
PCA	analýza hlavních komponent, <i>angl. Principal Component Analysis</i>
PBT	<i>angl. Probabilistic Boosting Tree</i>
TDCN	<i>angl. Transformed Deep Convolution Network</i>
MRI	magnetická resonance, <i>angl. Magnetic Resonance Imaging</i>
LSTM	<i>angl. Long Short-Term Memory</i>
MRI	plně konvoluční neuronová síť, <i>angl. Fully Convolution Neural Network</i>
RNN	rekurentní neuronová síť, <i>angl. Recurrent Neural Network</i>
J-CNN	<i>angl. Joint Convolutional Neural Network</i>
RNN	rekurentní neuronová síť, <i>angl. Recurrent Neural Network</i>
RGB	barevný model červená zelená modrá, <i>angl. Red Green Blue</i> , v této práci značí obraz složený ze tří vrstev
SGDM	stochastický gradientní sestup s momentem, <i>angl. Stochastic Gradient Descent with Momentum</i>

SEZNAM PŘÍLOH

A AlexNet	53
B VGG16	55

A ALEXNET

	hodnoty	lřez	3řezy	okolo	lřez augmentace funkci	3řezy augmentace funkci	okolo augmentace funkci	lřez augmentace v ose z	3řezy augmentace v ose z	okolo augmentace v ose z
maxEpochs miniBatchSize InitialLearnRate L2Regularization	13 30 2e-5 10e-4	98,8%	98,6%	97,8%	96,6%	98,6%	99,3%	99,0%	98,6%	99,0%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	16 28 3e-5 10e-4	98,6%	98,3%	98,8%	98,3%	97,3%	98,3%	99,5%	99,3%	99,0%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	12 28 3e-5 10e-4	99,0%	98,6%	99,3%	98,6%	96,9%	96,9%	99,5%	99,5%	99,0%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	13 40 3e-5 10e-4	99,0%	98,6%	98,1%	98,8%	96,1%	96,4%	99,3%	99,0%	99,3%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	22 28 3e-5 10e-4	99,0%	98,8%	99,0%	98,1%	98,6%	98,6%	99,5%	99,3%	99,3%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	16 28 5e-5 10e-4	99,0%	99,3%	99,3%	99,3%	96,6%	97,3%	99,5%	99,5%	99,3%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	22 28 5e-5 10e-4	98,6%	98,3%	99,3%	99,5%	98,0%	98,3%	99,5%	99,3%	99,3%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	13 28 5e-5 10e-4	99,3%	98,1%	99,0%	97,3%	96,9%	98,3%	99,3%	99,3%	99,5%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	16 20 3e-5 10e-4	99,0%	99,3%	99,3%	98,6%	96,6%	97,8%	99,3%	98,6%	99,3%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	16 28 3e-5 10e-3	98,3%	99,0%	98,8%	97,3%	97,8%	99,0%	99,0%	99,3%	98,6%
maxEpochs miniBatchSize InitialLearnRate L2Regularization	16 28 3e-5 10e-5	98,8%	99,3%	98,6%	98,1%	96,6%	98,1%	99,5%	99,5%	99,5%

B VGG16

	hodnoty	lřez	3řezy	okolo	lřez augmentace funkcí	3řezy augmentace funkcí	okolo augmentace funkcí	lřez augmentace v ose z	3řezy augmentace v ose z	okolo augmentace v ose z
maxEpochs	12									
miniBatchSize	28	98,3%	97,3%	98,6%	97,3%	97,1%	99,3%	98,6%	97,8%	99,5%
InitialLearnRate	3e-5									
L2Regularization	10e-4									
maxEpochs	5									
miniBatchSize	30	98,1%	94,9%	97,3%	95,7%	94,9%	98,8%	98,8%	97,1%	99,3%
InitialLearnRate	2e-5									
L2Regularization	10e-4									
maxEpochs	7									
miniBatchSize	30	97,6%	96,4%	97,8%	95,9%	95,4%	99,0%	99,0%	97,3%	98,6%
InitialLearnRate	2e-5									
L2Regularization	10e-4									
maxEpochs	9									
miniBatchSize	30	99,3%	98,1%	98,6%	98,1%	96,4%	99,0%	98,6%	97,3%	99,0%
InitialLearnRate	2e-5									
L2Regularization	10e-4									
maxEpochs	7									
miniBatchSize	30	97,1%	95,7%	98,6%	97,1%	95,4%	99,0%	99,3%	97,1%	99,0%
InitialLearnRate	2e-5									
L2Regularization	10e-4									
maxEpochs	9									
miniBatchSize	35	99,0%	96,1%	97,6%	98,3%	95,2%	98,3%	99,0%	97,3%	99,5%
InitialLearnRate	3e-5									
L2Regularization	10e-3									
maxEpochs	7									
miniBatchSize	30	98,3%	95,2%	98,8%	96,4%	92,5%	98,3%	99,0%	96,6%	99,0%
InitialLearnRate	4e-5									
L2Regularization	10e-5									
maxEpochs	7									
miniBatchSize	25	98,1%	97,6%	98,8%	96,4%	96,6%	97,6%	98,3%	97,3%	99,8%
InitialLearnRate	3e-5									
L2Regularization	10e-4									
maxEpochs	9									
miniBatchSize	30	98,8%	96,1%	99,0%	97,8%	96,4%	99,3%	98,6%	98,1%	99,3%
InitialLearnRate	3e-5									
L2Regularization	10e-3									
maxEpochs	9									
miniBatchSize	25	97,3%	96,4%	98,6%	97,6%	94,7%	98,6%	99,0%	96,4%	99,5%
InitialLearnRate	3e-5									
L2Regularization	10e-4									