



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

IMPLEMENTACE MODELU HLUBOKÉHO UČENÍ PRO SEGMENTACI OBRATLŮ V CT DATECH

IMPLEMENTATION OF A DEEP LEARNING MODEL FOR VERTEBRAL SEGMENTATION IN CT DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Lenka Blažková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Michal Nohel

BRNO 2023

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Lenka Blažková

ID: 230990

Ročník: 3

Akademický rok: 2022/23

NÁZEV TÉMATU:

Implementace modelu hlubokého učení pro segmentaci obratlů v CT datech

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s anatómií páteře, zpracováním objemových dat a s možnostmi využití aplikace strojového učení pro segmentaci obratlů z páteřních CT dat. 2) Zpracujte literární rešerši publikovaných metod strojového učení se zaměřením na dané téma. 3) Vyhledejte a získejte veřejně dostupné modely pro segmentaci obratlů a k nim relevantní databáze obsahující anotovaná CT data. 4) Vámi vybraný model implementujte v příslušném programovacím prostředí, navrhnete vhodný automatizovaný postup od načtení dat až po uložení výsledku na vytvořené databázi. 5) Otestujte a vyhodnoťte úspěšnost segmentace na databázi příslušné ke zvolenému modelu. 6) Předzpracujte klinická data od vedoucího a rozšířte implementaci modelu na tato data. Vyhodnoťte úspěšnost segmentace a diskutujte dosažené výsledky.

DOPORUČENÁ LITERATURA:

[1] SEKUBOYINA, Anjany, Malek E. HUSSEINI, Amirhossein BAYAT, et al. VerSe: A Vertebrae labelling and segmentation benchmark for multi-detector CT images. *Medical Image Analysis*. 2021, 73. ISSN 13618415. DOI: 10.1016/j.media.2021.102166

[2] ZHOU, Neng, Hairu WEN, Yi WANG, Yang LIU a Longfei ZHOU. Review of Deep Learning Models for Spine Segmentation. *Proceedings of the 2022 International Conference on Multimedia Retrieval*. New York, NY, USA: ACM, 2022, 2022-06-27, 498-507. ISBN 9781450392389. DOI: 10.1145/3512527.3531356

Termín zadání: 6.2.2023

Termín odevzdání: 29.5.2023

Vedoucí práce: Ing. Michal Nohel

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

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

Tato bakalářská práce se věnuje problematice segmentace obratlů v CT datech s využitím hlubokého učení. Nejprve je vytvořena teoretická rešerše zaměřená na anatomii a patologie páteře a obratlů, na CT systémy a na modely hlubokého učení pro segmentaci obratlů z 3D dat. Další část obsahuje podrobnější popis vybraného modelu pro segmentaci obratlů. V páté části je popsána samotná implementace vybraného modelu a navržená modifikace společně s výsledky na příslušné databázi. Nakonec je model s modifikací použit na klinická data poskytnutá vedoucím a popsána jeho úspěšnost na nich.

KLÍČOVÁ SLOVA

hluboké učení, konvoluční neuronové sítě, segmentace obratlů, segmentace, páteř, obratel, CT, výpočetní tomografie

ABSTRACT

This bachelor's thesis deals with the problem of vertebrae segmentation in CT data with the use of deep learning. Firstly, there is a theoretical review focused on the anatomy and the pathologies of the spine and the vertebrae, the CT systems, and the deep learning models for vertebrae segmentation in 3D data. The following section contains a more detailed description of the chosen model. The fifth section describes the implementation of the chosen model and the proposed modification, together with the results on the relevant database. In the end, the model with the modification is used on the clinical data provided by the supervisor and its evaluation is described.

KEYWORDS

deep learning, convolutional neural networks, vertebrae segmentation, segmentation, spine, vertebra, CT, computed tomography

BLAŽKOVÁ, Lenka. *Implementace modelu hlubokého učení pro segmentaci obratlů v CT datech*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022, 64 s. Bakalářská práce. Vedoucí práce: Ing. Michal Nohel

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Lenka Blažková
VUT ID autora: 230990
Typ práce: Bakalářská práce
Akademický rok: 2022/23
Téma závěrečné práce: Implementace modelu hlubokého učení pro segmentaci obratlů v CT datech

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucího závěrečné 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 autorka uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma 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 autorky*

* Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu mé bakalářské práce panu Ing. Michalovi Nohelovi za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Také děkuji mé rodině, která mě podporovala po celou dobu mého studia.

Obsah

Úvod	11
1 Anatomie páteře	12
1.1 Stavba obratle	13
1.2 Patologie páteře a těl obratlů	13
2 Výpočetní tomografie	15
2.1 CT obraz	15
2.2 Princip funkce CT	15
3 Modely hlubokého učení pro segmentaci obratlů	17
3.1 Konvoluční neuronová síť	17
3.2 Síť U-Net	19
3.3 Síť Backbone – ResNet a Res2Net	21
3.4 Algoritmy využívané pro segmentaci obratlů	25
3.5 Hodnocení segmentace obratlů	27
4 Vybraný model pro segmentaci obratlů	28
4.1 Předzpracování dat	28
4.2 Lokalizace páteře	28
4.3 Lokalizace a identifikace obratlů	30
4.4 Segmentace obratlů	31
4.5 Závěrečná úprava dat	32
4.6 Databáze CT dat	32
5 Výsledky modelu na příslušné databázi	34
5.1 Implementace vybraného modelu	34
5.2 Modifikace vybraného modelu	38
5.3 Publikované výsledky vybraného modelu	41
5.4 Diskuze výsledků vybraného modelu	42
6 Výsledky modelu na klinických datech	46
6.1 Popis klinických dat a jejich úprava pro implementaci modelu	46
6.2 Diskuze výsledků vybraného modelu	46
Závěr	50
Literatura	51

Seznam symbolů a zkratk	55
Seznam příloh	56
A Hodnocení úspěšnosti segmentace obratlů na databázi VerSe'20	57
B Obsah elektronické přílohy	64

Seznam obrázků

1.1	Struktura páteře	12
1.2	Hrudní obratel	13
2.1	Schéma CT systému	16
3.1	Konvoluční vrstva CNN	18
3.2	Max-pooling vrstva CNN	19
3.3	Architektura sítě U-Net	20
3.4	Architektura sítě ResNet a Res2Net	22
4.1	Blokové schéma vybraného modelu pro segmentaci obratlů	28
4.2	Znázornění předzpracování dat	29
4.3	Znázornění lokalizace páteře	29
4.4	Znázornění lokalizace a identifikace obratlů	30
4.5	Znázornění segmentace obratlů	31
4.6	Znázornění závěrečné úpravy dat	32
5.1	Krabicové grafy hodnot úspěšnosti modelu po implementaci	35
5.2	Příklady navíc vysegmentovaných obratlů	36
5.3	Příklady chybně vysegmentovaných obratlů	36
5.4	Příklady nevysegmentovaných částí páteře	37
5.5	Příklad chybného průběhu lokalizace a identifikace obratlů při segmentaci	37
5.6	Schéma modifikace modelu	39
5.7	Příklady správné segmentace páteře po modifikaci modelu	40
5.8	Krabicové grafy hodnot úspěšnosti modelu po implementaci a po modifikaci	41
6.1	Snímek „zdravého“ pacienta	47
6.2	Snímek pacienta č. 2	48
6.3	Snímek pacienta č. 9	48
6.4	Snímek pacienta č. 1	49
6.5	Snímek pacienta č. 5	49
6.6	Snímek pacienta č. 7	49

Seznam tabulek

3.1	Úspěšnost segmentace algoritmů ve VerSe'20	25
4.1	Struktura a vlastnosti databáze VerSe	32
5.1	Souhrnné výsledky hodnocení úspěšnosti segmentace obratlů	44
5.2	Výsledky hodnocení úspěšnosti segmentace obratlů pro části páteře	45
A.1	Hodnocení úspěšnosti segmentace na validačních datech VerSe'20	57
A.2	Hodnocení úspěšnosti segmentace na testovacích datech VerSe'20	60

Úvod

Páteř jako celek je hlavní součástí lidského pohybového systému, a tedy důležitou oporou lidského těla. Současně také zastává ochrannou funkci vůči míše, a proto má analýza struktury páteře významnou úlohu právě v medicíně. Automatická segmentace obratlů páteře by byla přínosným ulehčením práce lékařům, kteří by ji mohli využívat například při diagnostice různých onemocnění, plánování terapií či plánování a vedení operací. Jednotlivé struktury páteře jsou ale fyziologicky tvarově velmi proměnlivé i bez výskytu závažných patologií, a právě proto je automatizace segmentace složitým problémem.


Tato bakalářská práce se zabývá implementací modelu pro automatickou segmentaci obratlů páteře z 3D dat získaných pomocí výpočetní tomografie a to s využitím hlubokého učení, přesněji konvolučních neuronových sítí. Celá práce je rozdělena do několika částí.

První čtyři části se zabývají teoretickou literární rešerší, která je zaměřena na anatomii páteře a obratlů společně s některými jejich patologiemi, na výpočetní tomografii, pomocí které byla nasnímána analyzovaná data, na publikované metody hlubokého učení pro segmentaci obratlů z 3D dat a jejich hodnocení a nakonec na podrobný popis vybraného modelu segmentace, který je dále implementován, a jemu příslušné databáze.

Pátá část se zabývá již praktickou stránkou práce, tedy samotnou implementací vybraného modelu od C. Payera a kolektivu [28] využívající kombinaci konvolučních neuronových sítí U-Net a SpatialConfiguration-Net. Model je testován na jemu příslušné databázi a jeho úspěšnost je hodnocena několika metrikami. Současně je navržena také modifikace modelu pro zlepšení výsledků segmentace. V poslední šesté části práce je popsáno testování vybraného modelu na klinických datech poskytnutých vedoucím a jeho fungování na tato data.

1 Anatomie páteře

Páteř (*lat. columna vertebralis*) je částí základní osově kostry trupu člověka. Je k ní připojena lebka spolu s kloubními pletenci horních a dolních končetin. Jejím základním stavebním prvkem je jeden obratel (*lat. vertebra*). Jednotlivé obratle jsou k sobě navzájem pohyblivě a zároveň pevně spojeny pomocí vazů a meziobratlových plotének. Tato spojení zprostředkovávají hybnost páteře a její pružnost, která je zároveň podpořena sagitálním dvojesovitým zakřivením (krční lordóza, hrudní kyfóza, bederní lordóza a křížová kyfóza), viz Obr. 1.1 (vpravo). [1, 2]




Obr. 1.1: Struktura páteře: pohled zepředu (vlevo), zezadu (uprostřed) a z boku (vpravo), upraveno z [2]

Počet obratlů u člověka je obvykle 33 až 34, ale je i částečně variabilní. Obratle můžeme rozdělit do pěti skupin: krční obratle (C1–C7, *lat. vertebrae cervicales*), hrudní obratle (Th1–Th12, *lat. vertebrae thoracicae*), bederní obratle (L1–L5, *lat. vertebrae lumbales*), křížové obratle (S1–S5, *lat. vertebrae sacrales*) srostlé v kost křížovou (*lat. os sacrum*) a kostrční obratle (Co1–Co4/5, *lat. vertebrae coccygeae*) spojené v kost kostrční (*lat. os coccygis*), viz Obr. 1.1 (vlevo). První tři skupiny společně tvoří pohyblivou část páteře a můžeme je souhrnně nazývat obratli volnými nebo presakrálními. [1, 2]

1.1 Stavba obratle

Obratel se skládá ze tří hlavních částí: těla, oblouku a výběžků. Tělo obratle (*lat. corpus vertebrae*) je uloženo ventrálně a na jeho spodní a horní stranu naléhají meziobratlové ploténky, které oddělují jednotlivé obratle. K tělu obratle je připojen obratlový oblouk (*lat. arcus vertebrae*). Mezi tímto obloukem a tělem obratle je vytvořen otvor (*lat. foramen vertebrale*), který ohraničuje páteřní kanál (*lat. canalis vertebralis*). Z oblouku obratle vystupuje také několik obratlových výběžků (*lat. processus*). Popis jednotlivých částí hrudního obratle je vyobrazen na Obr. 1.2. [1, 2]



Obr. 1.2: Pohled na hrudní obratel shora (vlevo) a z boku (vpravo): 1 – *corpus vertebrae*, 2 – *fovea costalis superior*, 3 – *processus spinosus*, 4 – *arcus vertebrae*, 5 – *processus transversus*, 6 – *fovea costalis processus transversi*, 7 – *processus articularis superior*, 8 – *foramen vertebrale*, 9 – *fovea costalis inferior*, 10 – *processus articularis inferior*, upraveno z [1]

Přesná stavba obratlů je ale variabilní podle přesného postavení v páteři. Liší se ve velikosti těla, tvaru otvoru pro páteřní kanál či tvaru, velikosti a počtu obratlových výběžků atd. Úplnou výjimkou jsou první dva krční obratle: nosič (C1, *lat. atlas*), jehož tělo je nahrazeno druhým obratlovým obloukem, a čepovec (C2, *lat. axis*), který má tělo naopak vysoké. [1, 2]

1.2 Patologie páteře a těl obratlů

Různé patologie páteře mohou být nalezeny v odlišných tvarech páteře a také jejich vytočení. Mezi ně může být zařazena například skolióza, která vzniká nejčastěji kvůli nesouměrnému zatížení páteře a jeho následné kompenzaci, nadměrné zakřivení (hyperlordóza a hyperkyfóza), zakulacení nebo zploštění. [1]

Dalšími typy patologií mohou být různé fraktury či nádorová a nenádorová onemocnění. Mezi nenádorová onemocnění patří osteoporóza, která je nejčastějším onemocněním kostí. Je definována úbytkem kostní hmoty a porušením její architektury.

Nádorová onemocnění můžou být rozdělena na osteolytická a osteoblastická. Osteolytická ložiska se často vyskytují již při první diagnostice nádorového onemocnění. Postižené kosti jsou zdrojem silných bolestí a také patologických fraktur, způsobených v důsledku úbytku kostní tkáně. Osteogenní nádory naopak vznikají kvůli nekontrolovatelné proliferaci kostních buněk. Mohou být benigní, nebo dokonce i silně maligní. [3]

V počtu obratlů a jejich tvarech existují také určité patologie či variace. Nejvíce variantní je počet obratlů tvořící kost kostrční, naopak invariantní je počet obratlů krčních. V hrudní oblasti může docházet k připojení prvního bederního obratle L1 díky vyvinutému 13. páru žeber. Stejně tak se může poslední bederní obratel L5 připojit k prvnímu křížovému obratli S1 nebo naopak. Závažnou poruchou je také výskyt pouze jedné poloviny obratle, zapříčiňující skoliózu, nebo neuzavření obratlového oblouku, způsobující rozštěp páteře. [1]

2 Výpočetní tomografie

Rentgenová výpočetní tomografie (CT, *angl. Computed Tomography*) je dnes nejvíce rozšířenou zobrazovací metodou s výborným prostorovým rozlišením a vysokou rychlostí skenování, což jsou její hlavní výhody. Nevýhodou je naopak dávka absorbovaného rentgenového záření tělem pacienta. [4, 5]

2.1 CT obraz

Zobrazování pomocí CT systému využívá odlišného útlumu rentgenového záření v různých tkáních, který je následně pomocí matematické rekonstrukce, tzv. Radonovy transformace, převeden na 3D obraz neboli tomogram. Každá tkáň má svůj specifický lineární koeficient útlumu, který ovlivňuje intenzitu procházejícího a utlučeného záření v tkáních. Dá se odvodit ze vzorce

$$I = I_0 \cdot e^{-\mu x}, \quad (2.1)$$

kde I je výsledná intenzita prošlého záření, I_0 je původní intenzita dopadajícího záření, μ je lineární koeficient útlumu dané tkáně a x je tloušťka vrstvy tkáně, kterou záření prochází. [5]

Pro přehlednější zobrazení koeficientu útlumu byla zavedena tzv. Hounsfieldova jednotka HU neboli CT číslo, které můžeme určit pomocí vzorce


$$CT \text{ číslo} = HU = \frac{\mu_{tkáň} - \mu_{voda}}{\mu_{voda}} \cdot k, \quad (2.2)$$

kde $\mu_{tkáň}$ je lineární koeficient útlumu dané tkáně, μ_{voda} lineární koeficient útlumu vody a k je konstanta, standardně 1000. Díky této konstantě k je CT číslo pro vodu rovno 0, pro vzduch -1000 a pro kompaktní kost je uváděno jako přibližně +1000.

Současně se využívá tzv. radiologické okno, které zobrazuje hodnoty CT čísel pouze v určitém rozsahu pro lepší subjektivní zobrazení, protože CT obraz o dynamickém rozsahu cca 2000 stupňů šedi by nebyl přehledný. V praxi se využívají radiologická okna například kostní, plicní nebo pro hodnocení mozku a dalších měkkých tkání. [5, 6]

2.2 Princip funkce CT

CT systém se skládá z prstencového vyšetřovacího tunelu (gantry) v jehož středu je posuvný patientský stůl. V rámci gantry je uložen zdroj rentgenového záření (rentgenka), filtry, kolimační clony a detektor/detektory záření, viz Obr. 2.1. [6]



Obr. 2.1: Schematické zobrazení CT systému třetí generace

Soustava rentgenka-detektor pro snímání dat se postupem času vyvíjela a vzniklo několik generací CT systémů. Dnes je nejpoužívanější generace třetí využívající maticové detektory, které jsou ozařovány vějířovitým svazkem rentgenového záření. Díky dalším vylepšením původní třetí generace došlo například ke zkrácení skenovacího času a zvýšení prostorového rozlišení výsledného obrazu. [4, 5]

Důvodem je využívání tzv. *slip-ring* technologie, helikálního snímání a *multi-slice* systémů. *Slip-ring* technologie zajišťuje bezdrátové napájení otočného gantry. Helikální neboli spirální snímání je princip skenování, při kterém dochází ke kontinuální rotaci gantry současně s axiálním posuvem patientského stolu. *Multi-slice* neboli vícevrstvé systémy zajišťují snímání více řezů zároveň při jedné rotaci, čehož je docíleno ozařováním matice detektorů kuželovitým paprskem. Také je často využíváno spojování detektorů, například pro vyšší rychlost skenování s potřebou pouze nižšího rozlišení. [4, 5]

3 Modely hlubokého učení pro segmentaci obrátlů

Hluboké učení (*angl. Deep Learning*) je dnes široce využívané pro zpracování obrazových dat. Je podskupinou strojového učení, jenž je součástí umělé inteligence. Strojové učení (*angl. Machine Learning*) je založeno na principu, kdy jsou do určitého „programu“ vkládána vstupní data s požadovanými výsledky a jeho výstupem jsou určitá pravidla/váhy, s nimiž je možno daných výsledků docílit. [7]

Rozdílem mezi hlubokým učením a ostatními typy strojového učení, například mělkým učením (*angl. Shallow Learning*), je přístup ke zpracování dat. Data při hlubokém učením jsou učena v několika vrstvách a samotné učení je rozděleno tak, aby v každé následující vrstvě docházelo k zisku stále více reprezentativních informací. [7]

Modely hlubokého učení nejčastěji využívají neuronové sítě (NN, *angl. Neural Networks*), přesněji hluboké neuronové sítě s desítkami až stovkami vrstev, desítkami tisíc až miliony neuronů a stovkami tisíc až miliardami vah. Nicméně, jak by se mohlo předpokládat, nejsou řešením pro komplikovanější případy, ale jsou více efektivní a nedochází k jejich přeučení (*angl. overfitting*) nebo zisku nevyhovujících výsledků. Tyto sítě můžeme rozdělit na dva druhy: vícevrstvé dopředné NN a rekurzivní NN. Pro analýzu obrazů jsou využívány především vícevrstvé dopředné sítě, zejména konvoluční neuronové sítě, viz Kap. 3.1, které bývají různě modifikované. [4, 8]

3.1 Konvoluční neuronová síť

Konvoluční neuronové sítě (CNN, *angl. Convolutional Neural Networks*) jsou základní architekturou, ze které jsou odvozeny další modely sítí, z nichž některé jsou popsány v Kap. 3.2 a Kap. 3.3. Elementární struktura CNN je založena na několika různě po sobě jdoucích konvolučních a pooling vrstvách zakončených plně propojenou vrstvou. Tyto vrstvy jsou podrobněji popsány dále. [9, 8]

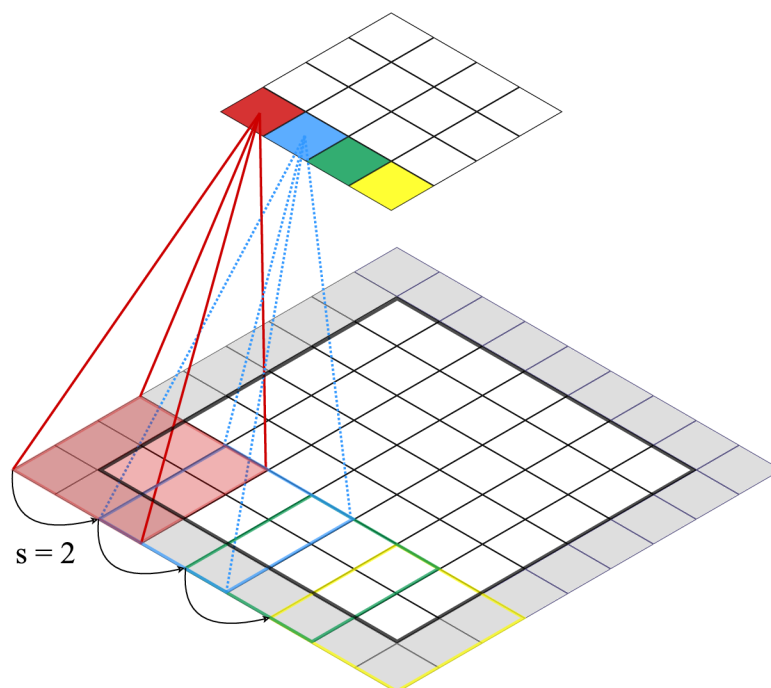
Konvoluční vrstvy

Důležitou částí CNN jsou konvoluční vrstvy. V jednotlivých vrstvách nejsou všechny neurony propojeny v rámci celé předcházející vrstvy, ale v první konvoluční vrstvě je každý neuron spojen pouze s pixely vstupních dat v jeho receptivním poli. Neurony v druhé a v dalších vrstvách jsou obdobně spojeny s neurony v jejich receptivních polích předcházející vrstvy, viz Obr. 3.1. Tato architektura dovoluže zaměřit se na tzv. *low-level* příznaky v první skryté vrstvě a postupně na další tzv. *high-level* komplexnější příznaky v následujících skrytých a zároveň hlubších vrstvách. [9, 8]

V každé konvoluční vrstvě je využívána sada filtrů (konvolučních masek/vah), které ze vstupního obrazu extrahují určité příznaky pro získání příznakových map. Z tohoto důvodu jsou výstupy každé takové vrstvy trojrozměrné, dvojrozměrný výstup z každého filtru v počtu podle množství užitých filtrů. [9, 8]

Volitelnými parametry konvoluční vrstvy je již zmíněný počet filtrů, a dále pak také tzv. *zero padding* a *stride*, viz Obr. 3.1. Při *zero paddingu* jde o doplňování nul po obvodu vstupního obrazu, tedy předcházející vrstvy, aby nedocházelo ke zmenšení výstupního obrazu. Hodnota *stride* popisuje velikost kroku, se kterým dochází k posuvu jednotlivých receptivních polí neuronů, a je využívána například pro snížení výpočetní náročnosti. [9, 8]

Každá z konvolučních vrstev je obvykle následována její aktivační funkcí pro sjednocení výstupů dílků neuronů. Nejčastěji používanou je funkce *ReLU* (*Rectified Linear Unit*) s předpisem $f(x) = \max(0, x)$. Její alternativou může být například: sigmoida, hyperbolický tangens nebo *Leaky ReLU*. [8, 9]

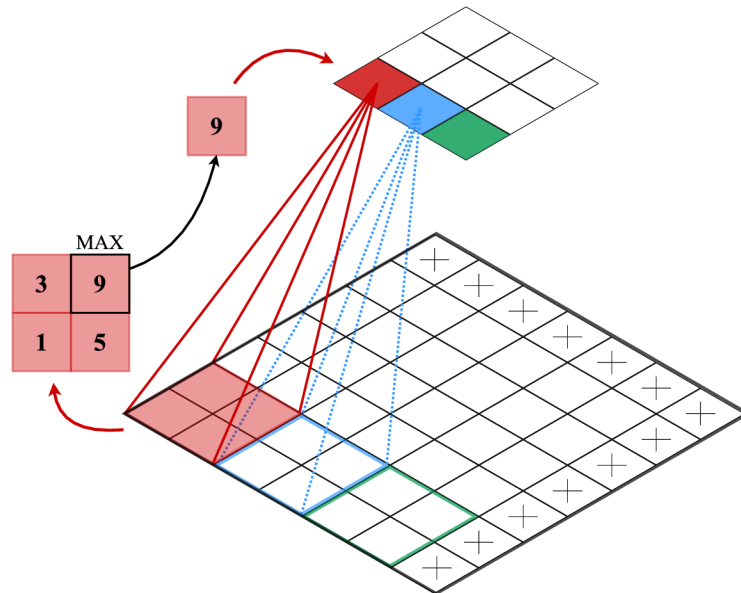


Obr. 3.1: Propojení 3×3 konvoluční vrstvy CNN s jedním filtrem (3×3), *zero paddingem* (šedá pole) a hodnotou *stride* ($s = 2$)

Pooling vrstvy

Dalšími důležitými vrstvami jsou tzv. *pooling* vrstvy, jejichž úkolem je podvzorkování vstupního obrazu, zmenšení jeho rozměrů. Důvodem je snížení výpočetní náročnosti, menší využití paměti, s čímž souvisí i redukce počtu parametrů, a tedy i zabránění *overfittingu*. [9, 8]

Stejně jako u konvolučních vrstev jsou tyto vrstvy propojeny s neurony předchozí vrstvy v rámci receptivních polí postupně posouvajících se o určitý krok, nicméně tyto vrstvy nekorrespondují žádnými vahami/filtry. Jejich funkcí je pouze podvzorkování vstupních dat s využitím nějaké funkce. Nejčastěji je využíván tzv. *max-pooling*, který z daného pole vybere maximální hodnotu, viz Obr. 3.2, nebo tzv. *average-pooling* neboli průměrovací *pooling*, který následně využívá průměr daného pole. [9, 8]



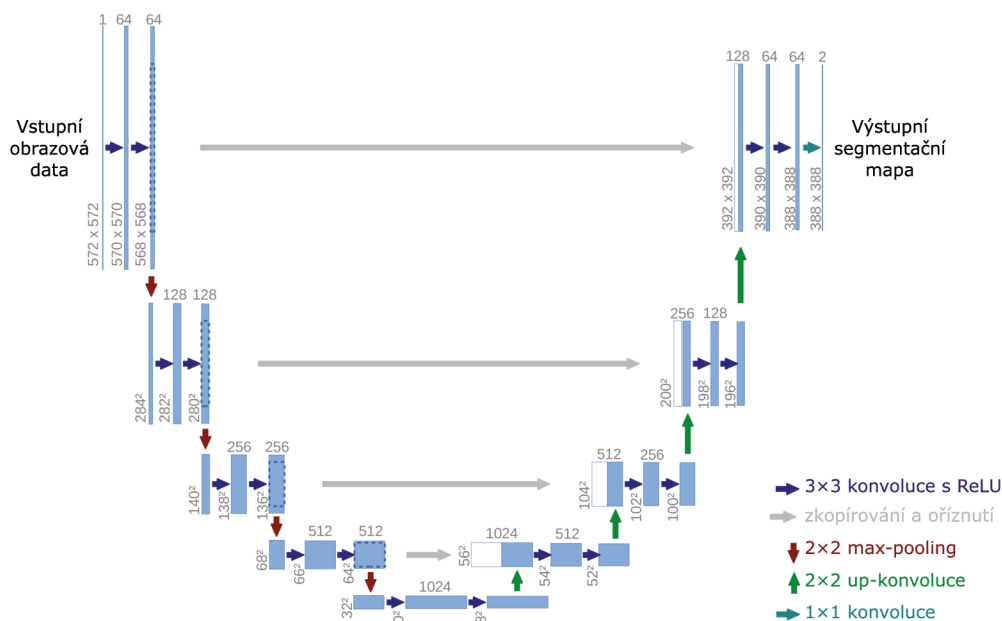
Obr. 3.2: Propojení 2×2 *max-pooling* vrstvy CNN (*krok* = 2)

Plně propojené vrstvy

CNN mohou obsahovat také plně propojené konvoluční vrstvy s vlastní aktivační funkcí. Tyto vrstvy se skládají z neuronů, kdy každý jeden neuron je propojen se všemi neurony předcházející vrstvy a jejichž výstupem je finální predikce, tedy výsledné zařazení do určité předem známé třídy. [9, 8]

3.2 Síť U-Net

Síť U-Net je modifikací klasické CNN a také je jednou z nejvyužívanějších metod pro segmentaci obrazů v medicíně, takže i obratlů. Zároveň je ale i nadále rozvíjena a doplňována, což zapříčiňuje vznik mnoha dalších segmentačních modelů. Její architektura je založena na symetričnosti. Skládá se ze dvou základních částí: enkodéru a dekodéru, které jsou spojeny do specifického tvaru připomínající písmeno „U“, viz Obr. 3.3. [10, 11]



Obr. 3.3: Architektura sítě U-Net, upraveno z [11]

Jednotlivé stupně enkodéru se skládají z několika opakujících se bloků, které jsou složeny z konvolučních vrstev, zpravidla s velikostí filtru 3×3 , následovaných aktivační funkcí $ReLU$ a 2×2 max -pooling vrstvou s krokem 2. Cílem této části sítě je extrakce příznaků ze vstupního obrazu. Dekodér využívá 2×2 up-konvoluci pro spojení aktuální mapy příznaků s mapou z enkodéru a další 3×3 konvoluční vrstvy s $ReLU$. Na konci dekodéru je závěrečná 1×1 konvoluce, ze které vystupuje finální segmentační mapa. [11, 7]

V následujících podkapitolách jsou podrobněji popsány některé modifikace architektury sítě U-Net, které se využívají právě pro segmentaci obratlů: Attention U-Net, ResUNet++, TransUNet a MiniSeg.

3.2.1 Attention U-Net

Sít Attention U-Net [12] je založena na propojení sítě U-Net spolu s pozornostním modulem (*angl. attention modul*), přesněji je využívána samoadaptabilní jemná pozornostní technika (*angl. soft-attention*) s využitím mřížky pro více specifické pozornostní koeficienty v jednotlivých lokalitách. Výsledkem je tedy zvýraznění důležitých oblastí a potlačení šumu a irelevantních oblastí během up-konvoluce v rámci dekodéru. Její hlavní výhodou je možnost dosáhnout výborných výsledků bez nutnosti využití dalších CNN pro určení významných oblastí a současně i s minimální výpočetní náročností. [12]

3.2.2 ResUNet++

ResUNet++ model [13] má typickou U-Net architekturu doplněnou o tři další části: SE jednotky (*angl. Squeeze and Excitation Units*), ASPP modul (*angl. Atrous Spatial Pyramidal Pooling Module*) a pozornostní jednotky (*angl. Attention Units*). SE jednotky a pozornostní jednotky jsou využívány pro zvýšení schopnosti modelu využít relevantní příznaky obrazu a potlačit ty nedůležité, hlavně tedy pozadí. Modul ASPP je používán jako propojení enkodéru a dekodéru, pro převzorkování a současně pro přesné zachování všech známých informací. [13]

3.2.3 TransUNet

Architektura sítě TransUNet [14] vychází ze spojení metod Transformer a U-Net. Jejím cílem je propojení dat z CNN s vysokým rozlišením a z globálního kontextu dat získaných pomocí sítě Transformer s využitím samopozornostního mechanismu (*angl. self-attention*). V enkodéru jsou nejprve získávány *low-level* příznaky. Na enkodér následně navazuje architektura Transformer, která naopak získává celkový kontext dat. V dekodéru dochází ke kaskádovitému nadvzorkování příznakových map a spojení s daty z enkodéru až na plné finální rozlišení. [14]

3.2.4 MiniSeg

Model sítě MiniSeg [15] je taktéž založen na architektuře sítě U-Net. Má vysokou účinnost, i přestože pracuje pouze s malým počtem parametrů, až o dva řády méně než klasické segmentační metody. Právě díky tomu je vhodný pro práci s omezeným počtem dat, aby nedocházelo k *overfittingu*. [15]

Enkodér se skládá se dvou větví, které jsou vícekrát vzájemně propojeny. Obsahuje konvoluční bloky, podvzorkovací bloky a modul AHSP (*angl. Attentive Hierarchical Spatial Pyramid*). Tento modul je prostorová pyramida složená z různých konvolučních vrstev, které jsou hierarchicky propojeny pro zvýšení rozlišení. Dekodér je složen z bloků, které jednoduše postupně nadvzorkovávají a spojují mapy příznaků z enkodéru, také s pomocí FFM (*angl. Feature Fusion Module*), který spojuje průběžné mapy příznaků. [15]

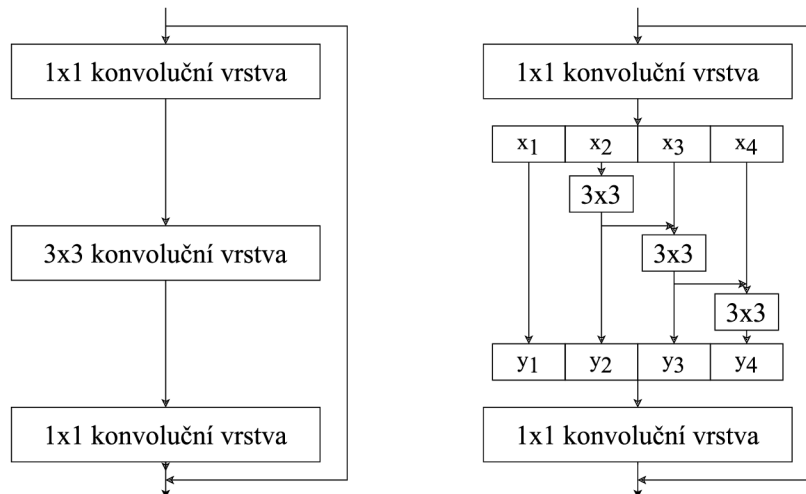
3.3 Sítě Backbone – ResNet a Res2Net

Sítě Backbone jsou využívány také při práci s medicínskými obrazy páteře a obratlů. Tato síť je pro segmentaci běžně využívána ve dvou podobách, ResNet a Res2Net, viz níže. Tyto dvě sítě jsou dále taktéž používány v dalších modifikovaných modelech,

kteře jsou komplexnější: PSPNet, DeepLabv++, DenseASPP, DANet, EMANet, InfNet a PSANet, které jsou popsány v následujících podkapitolách [10]

Resnet

Síť ResNet (*angl. Residual Network*) se postupně vyvíjela. Začínala s několika konvolučními vrstvami, později byla doplněna o tzv. *skip connection* neboli „zkratku“ mezi páry konvolučních vrstev až do nynější podoby. Dnes je tato síť složena z několika „*bottleneck*“ bloků, kdy každý tento blok je tvořen třemi konvolučními vrstvami (1×1 , 3×3 a 1×1) s jednou *skip connection* pro součet vstupních a výstupních hodnot bloku, viz Obr. 3.4 (vlevo). Toto propojení zaručuje lineární transformaci každé trénované NN, z čehož vyplývá, že výsledky se nezhoršují se zvyšujícím se počtem vrstev a dovolují tedy trénování hlubších NN. [16]



Obr. 3.4: Porovnání architektury „*bottleneck*“ bloku sítě ResNet (vlevo) a modulu Res2Net (vpravo)

Res2net

Res2Net se vyvinul z architektury sítě ResNet. Ve svém bloku neboli Res2Net modulu využívá *skip connection* a obdobnou počáteční a závěrečnou 1×1 konvoluci, mezi nimi je ale místo jednoho 3×3 filtru použita jejich skupina. Vstupní data jsou rozdělena do několika dílčích skupin, které jsou postupně filtrovány jednotlivými 3×3 filtry a výstupy jsou vždy hierarchicky propojeny s následujícími skupinami před jejich filtrací, viz Obr. 3.4 (vpravo). Tato síť je složitější a trénink časově náročnější, ale její výsledky se zlepšují s vyšším počtem dílčích skupin pro filtraci skupinou 3×3 filtrů. Celkově Res2Net dosahuje lepších výsledků než předcházející ResNet. [17]

3.3.1 PSPNet

PSPNet (*angl. Pyramid Scene Parsing Network*) [18] byl navržen pro rozpoznávání složitějšího kontextu obrazů na úrovni pixelů se stejnými výpočetními nároky. Oproti globálnímu průměrovacímu *poolingu* využívá tato síť tzv. pyramidový sdružovací modul (*angl. pyramid pooling module*), který získává a propojuje příznaky v různých pyramidových úrovních. První úroveň bývá o rozměru 1×1 , a dále se pak podregiony postupně zvětšují. Výstupy jednotlivých úrovní jsou mapy příznaků různých velikostí, jejichž hloubka je pomocí jednoduché konvoluce snížena. Poté následuje nadvzorkování map na původní velikost pro spojení všech map pomocí závěrečné konvoluce a získání finální mapy příznaků. [18]

3.3.2 DeepLabv3+

Architektura DeepLabv3+ [19] je rozšířením DeepLabv3 o jednoduchý a současně efektivní dekodér pro zachycení hran při segmentaci. Enkodér obsahuje ASPP modul, který se skládá z několika paralelních dilatovaných konvolučních vrstev s různými koeficienty a má modifikovatelné nastavení hustoty, právě pro zobrazení detailnějších informací při segmentaci. Dekodér poté postupně nadvzorkovává data s využitím příznaků z ASPP modulu a využívá další konvoluční vrstvy. [19]

3.3.3 DenseASPP

Tento model [20] je založen na „dense“ ASPP modulu, který využívá hustého propojení jeho jednotlivých dilatovaných konvolučních vrstev. V každé následující konvoluční vrstvě se postupně zvětšují koeficienty rozšíření a jejich vstupy jsou všechny mapy příznaků ze všech předcházejících vrstev, čímž vzniká dané propojení. DenseASPP model díky tomu poskytuje získání více příznaků bez ztráty potřebných informací, s větším receptivním polem a bez vyššího počtu parametrů. [20]

3.3.4 DANet

DANet (*angl. Dual Attention Network*) [21] dokáže zachytit více závislostí pomocí využívaného samopozornostního mechanismu, který je kombinací pozičního a kanálového pozornostního modulu. Poziční modul zabezpečuje stejný vliv podobných příznaků v různých vzdálenostech výsledné mapy příznaků. Kanálový modul používá samopozornostního mechanismus pro spojování příznaků mezi jednotlivými kanály. Oba výstupy jsou nakonec spojovány pro další vylepšení, což následně přispívá i k přesnější segmentaci. [21]

3.3.5 EMANet

Model sítě EMANet (*angl. Expectation-Maximization Attention Network*) [22] je založen na pozornostním mechanismu a současně je inspirován algoritmem očekávané hodnoty a maximalizace (EM, *angl. Expectation-Maximization algorithm*). Pro rekonstrukci nevyužívá pouze pixely jako báze, ale EM algoritmus vyhledává více kompaktní skupinu bází, snaží se určit jejich maximálně pravděpodobnostní odhad (*angl. maximum likelihood estimate*), čímž je současně snižována výpočetní náročnost modelu. [22]

Jeho základem je EMA jednotka (*angl. Expectation-Maximization Attention Unit*), která připomíná „bottleneck“ blok sítě ResNet, pouze místo 3×3 konvoluce využívá EM operace. Skládá se ze dvou částí „*Expectation*“ a „*Maximization*“, které pracují odděleně. „*Expectation*“ kroky slouží pro odhad očekávaných pozornostních map a „*Maximization*“ kroky aktualizují parametry pomocí maximalizace pravděpodobnosti dat. Po jejich konvergenci dochází k výpočtu výstupu jako váhované sumaci parametrů, kde jsou využité váhy vlastně normalizované výsledné pozornostní mapy. [22]

3.3.6 Inf-Net

Inf-Net [23] byl navržen pro správnější určování rozdílů mezi jednotlivými třídami. Jde o model využívající částečný paralelní dekodér (PPD, *angl. Parallel Partial Decoder*), reverzní pozornostní modul a pozornostní modul pro detekci hran. PPD je využíván pro získání hrubé globální mapy příznaků, pomocí sdružování *high-level* informací, a následují ho moduly k určení a vylepšení hran pro rozdělení do výsledných tříd. [23]

3.3.7 PSANet

PSANet (*angl. Point-wise Spatial Attention Network*) [24] využívá samoadaptivní pozornostní mapy pro zachycení komplexnějších závislostí. Tento model rozděluje vstupní data do dvou větví: sběrné a distribuční, které pracují s daty právě ve dvou perspektivách. Obě tyto větve shrnují celkové informace do globálních pozornostních map pro každou pozici mapy příznaků, které propojují všechny pozice se všemi. Současně nejsou ale filtry využitých konvolučních vrstev pro jednotlivé pozice stejné, aby kvůli adaptabilním vahám nedocházelo k zaznamenávání relativních pozic. Nakonec dochází k propojení obou cest, k redukcí rozměrů a spojení jednotlivých příznaků pro získání finálních příznakových map. [24]

3.4 Algoritmy využívané pro segmentaci obratlů

Následující algoritmy byly vytvořeny a zveřejněny v rámci výzvy VerSe („*Large Scale Vertebrae Segmentation Challenge*“) [25, 26, 27], která byla uspořádána ve spojení s mezinárodní konferencí MICCAI („*Medical Image Computing and Computer Assisted Intervention*“) v letech 2019 a 2020. Cílem této výzvy bylo vytvořit algoritmy pro značení a segmentaci obratlů z CT dat ze související databáze, která je podrobněji popsána v Kap. 4.6.

Jednotlivé algoritmy byly hodnoceny na veřejné validační databázi a doplňující skryté testovací databázi. Výsledky několika vybraných algoritmů jsou zobrazeny v Tab. 3.1 a v následujících podkapitolách podrobněji popsány spolu s jejich výsledky v rámci VerSe'20.

Tab. 3.1: Hodnocení úspěšnosti segmentace algoritmů ve VerSe'20 na veřejných validačních a skrytých testovacích datech pomocí průměrného Dice skóre, převzato a upraveno z [25]

Skupina autorů	Dice skóre [%] na veřejných datech	Dice skóre [%] na skrytých datech	Odkaz
Chen D. a kol.	91,72	91,23	viz 3.4.1
Payer C. a kol.	91,65	89,71	viz 3.4.2
Zhang A. a kol.	88,82	89,36	viz 3.4.3
Yeah T. a kol.	88,88	87,91	viz 3.4.4
Xiangshang Z. a kol.	83,58	85,07	viz 3.4.5
Hou F. a kol.	83,99	84,92	viz 3.4.6

3.4.1 Chen D. a kolektiv

Skupina D. Chena a kol. vytvořila algoritmus pro segmentaci a lokalizaci obratlů prostřednictvím hlubokého učení („*Vertebrae Segmentation and Localization via Deep Reasoning*“) [25], který využívá více fází přístupu k datům. Nejprve pracuje se sítí U-Net pro získání přibližného umístění páteře v datech. Poté další síť U-Net provádí binární segmentaci obratlů a CNN klasifikaci, jejich výsledky jsou nakonec propojeny do více-třídní segmentace pro výpočet jednotlivých centroidů. Průměrné Dice skóre tohoto algoritmu bylo určeno s hodnotou 91,72 % na veřejných datech a 91,23 % na skrytých datech. [25]

3.4.2 Payer C. a kolektiv

Algoritmus poskytnutý skupinou C. Payera a kol. do VerSe'20 byl inovací algoritmu z VerSe'19, tedy zlepšením lokalizace a segmentace obratlů s využitím sítí SpatialConfiguration-Net and U-Net („*Improving Coarse to Fine Vertebrae Localization and Segmentation with SpatialConfiguration-Net and U-Net*“) [25]. Tento algoritmus je složen ze tří částí: lokalizace páteře pomocí sítě U-Net, lokalizace a identifikace obratlů pomocí sítě SpatialConfiguration-Net a závěrečné binární segmentace pomocí druhé sítě U-Net. Průměrné Dice skóre tohoto algoritmu na veřejných datech bylo určeno jako 91,65 % a na skrytých datech 89,71 %. Tento algoritmus je podrobněji popsán v části 4. [25, 28]

3.4.3 Zhang A. a kolektiv

Skupina A. Zhanga a kol. vytvořila algoritmus pro lokalizaci a segmentaci obratlů („*A Segmentation-Based Framework for Vertebrae Localization and Segmentation*“) [25], který pracuje ve čtyřech krocích. Prvním krokem je lokalizace páteře s využitím sítě V-Net. Druhým krokem je jednotřídní lokalizace klíčových bodů pro hledání možných obratlů pomocí obdobné sítě. Třetím krokem je segmentace obratlů podle tří skupin (krční, hrudní a bederní obratle), taktéž s využitím sítě V-Net. Čtvrtým a posledním krokem je závěrečná úprava dat. Průměrné Dice skóre tohoto algoritmu bylo určeno jako 88,82 % a 89,36 % na veřejných a skrytých datech. [25]

3.4.4 Yeah T. a kolektiv

Tento dvoustupňový algoritmus s využitím hrubé a jemné identifikace a segmentace obratlů („*A Coarse-to-Fine Two-stage Framework for Vertebra Labeling and Segmentation*“) [25] využívá síť 3D U-Net s malým rozlišením pro určení přibližného umístění obratlů, které je vstupem druhé sítě 3D U-Net s vysokým rozlišením pro přesnější klasifikaci a segmentaci. Průměrné Dice skóre algoritmu od skupiny T. Yeaha a kol. bylo určeno pro veřejná data 88,88 % a 87,91 % pro ta skrytá. [25]

3.4.5 Xiangshang Z. a kolektiv

Skupina Z. Xiangshanga a kol. vytvořila algoritmus pro značení a segmentaci obratlů s využitím sítí Btrfly-Net a nnU-Net („*Vertebra Labelling and Segmentation using the Btrfly-net and the nnU-net*“) [25]. Tento algoritmus pracuje ve dvou samostatných částech. Jednou z nich je vylepšená síť Btrfly pro detekci hlavních bodů obratlů a druhou je síť nnU-Net zajišťující segmentaci jednotlivých obratlů. Pro tento algoritmus bylo průměrné Dice skóre určeno o hodnotě 83,58 % na veřejných datech a 85,07 % na skrytých datech. [25]

3.4.6 Hou F. a kolektiv

V tomto algoritmu od skupiny autorů F. Houa a kol. je využíván plně automatický přístup pro lokalizaci a segmentaci obratlů založený na kaskádovitých sítích U-Net („Fully Automatic Localization and Segmentation of Vertebrae Based on Cascaded U-Nets“) [25]. Nejprve je pomocí první variantní sítě U-Net lokalizována středová linie páteře, ze které je následně s využitím druhé sítě U-Net určena poloha jednotlivých obratlů. Pomocí další U-Net sítě jsou segmentovány jednotlivé obratle v jejich predikovaných oblastech. Na veřejných datech bylo průměrné Dice skóre určeno jako 83,99 % a na skrytých jako 84,92 %. [25]

3.5 Hodnocení segmentace obratlů

Pro hodnocení jednotlivých modelů, které se zabývají právě segmentací obratlů z CT nebo jiných 3D dat, je nejčastěji využíváno tzv. *Dice skóre (Dice)*. Pro jednoduché hodnocení binárních masek segmentace je využíváno Dice skóre podle vzorce

$$Dice(P, T) = \frac{2|P \cap T|}{|P| + |T|}, \quad (3.1)$$

kde P představuje predikované hodnoty umístění páteře s využitím modelu a T správné hodnoty určené lékařem (tzv. *ground truth*). Výsledné Dice skóre je bezrozměrné [-] a nabývá hodnot v rozmezí od 0 do 1 (nejlepší), často ale bývá také přepočítáváno na procenta [%].

Toto skóre může být využíváno i v upravených podobách, například pro zohlednění klasifikace obratlů současně se segmentací a to s využitím průměrného Dice skóre jednotlivých obratlů nebo jejich mediánu. Zde je uveden vzorec pro výpočet průměrného Dice skóre zahrnující i identifikaci obratlů:

$$Dice_N(P, T) = \frac{1}{N} \sum_{i=1}^N \frac{2|P_i \cap T_i|}{|P_i| + |T_i|}, \quad (3.2)$$


kde P představuje predikované hodnoty modelem, T správné hodnoty a i je využíváno pro indexaci N dílčích obratlů. [25]

Alternativou pro hodnocení segmentace by mohla být například *Hausdorffova vzdálenost (HD)*, která vyjadřuje největší vzdálenost povrchů dvou porovnávaných objektů, segmentačních masek. Nabývá hodnot od 0 mm (nejlepší) do nekonečna. Tato metrika může být určována pro segmentační masku jako celek, což by v případě obratlů a páteře nemělo velmi vysokou výpovědní hodnotu, nebo v lepší podobě jako například průměr nebo medián určené vzdálenosti pro jednotlivé obratle. [25]

4 Vybraný model pro segmentaci obratlů

Pro segmentaci obratlů s využitím hlubokého učení je implementován model, který byl součástí VerSe'20, spolu s ostatními modely zmíněnými v Kap. 3.4, a jehož kód pro implementaci a příslušná databáze snímků byly volně dostupné. Tento model byl navržen Christianem Payerem a jeho skupinou a má název „*Vertebrae localization and segmentation with SpatialConfiguration-Net and U-Net*“ [28, 25]. Byl zveřejněn již v roce 2019 v rámci VerSe'19 a následně znovu v roce 2020 s určitými změnami/vylepšeními, které jsou již zakomponovány v jeho následujícím popisu. Veškerý převzatý a upravený zdrojový kód tohoto modelu je dostupný také na <https://github.com/christianpayer/MedicalDataAugmentationTool-VerSe>.

Vybraný model je plně automatický a je tvořen třemi po sobě jdoucími CNN, současně s prvotním předzpracováním dat a jejich závěrečnou úpravou. Nejprve dochází k přibližné lokalizaci páteře v celém objemu CT dat, poté jsou lokalizovány a identifikovány středy jednotlivých obratlů a je provedena binární segmentace obratlů pro získání finální segmentační masky, viz Obr. 4.1. Implementovaný model byl trénován dvěma způsoby, pomocí trojnásobné křížové validace (*angl. k-fold cross-validation*) a s využitím celé trénovací databáze. [28]




Obr. 4.1: Blokové schéma vybraného modelu pro segmentaci obratlů

4.1 Předzpracování dat

Pro sjednocení orientace všech vstupních dat a jejich filtraci model nejprve využívá předzpracování vstupních dat, tzv. *preprocessing*, viz Obr. 4.2. Jednotlivá 3D data jsou přeorientována do tzv. RAI zobrazení, které vyobrazuje data v postavení „*Right–Anterior–Inferior*“, pohled na skenovanou páteř z pravé strany, zezadu a shora. Dále je provedena gaussovská filtrace s hodnotou $\sigma = 0,75$ pro potlačení náhodného šumu v obraze. Nakonec je ovlivněn dynamický rozsah CT snímků pomocí transformace kontrastu.

4.2 Lokalizace páteře


Nejprve je prováděna lokalizace páteře pro zmenšení oblasti zájmu v dalším zpracování, viz Obr. 4.3. Vstupní data jsou převzorkována na voxely o jednotné velikosti



Obr. 4.2: Znázornění předzpracování dat: (a) původní data, (b) upravená data

s hranou 8 mm, tedy na celkovou velikost $64 \times 64 \times 128$ voxelů ($512 \times 512 \times 1024$ mm), proto, aby bylo možné predikovat umístění páteře pro všechna různá CT data.

Je využíváno varianty sítě U-Net pro zmenšení oblasti zájmu vstupních CT dat pouze na páteř. Její obměnou je využití průměrovacího *poolingu* a lineárního nadzorkování. Architektura sítě je založena na pěti úrovních, v nichž je využíváno konvolucí s filtry o velikosti $3 \times 3 \times 3$ a 96 výstupy spolu se *zero paddingem* a aktivací funkcí *Leaky ReLU*. Výsledkem lokalizace páteře je tedy vytvoření gaussovské pravděpodobnostní heatmapy středové čáry páteře, která vede přibližně středy jednotlivých obratlů.




Obr. 4.3: Znázornění lokalizace páteře: (a) vstupní data, (b) převzorkovaná data, (c) výsledná pravděpodobnostní heatmapa pro lokalizaci páteře (bílá – vysoká pravděpodobnost umístění páteře, černá – malá pravděpodobnost umístění páteře)

4.3 Lokalizace a identifikace obratlů

Pro lokalizaci a identifikaci obratlů je využíváno SpatialConfiguration sítě (SC-Net) s cílem získat umístění všech obratlů v CT datech, viz Obr. 4.4. Vstupními daty sítě je převzorkovaný snímek s voxely o velikosti hrany 2 mm, tedy o rozměrech $96 \times 96 \times 128$ voxelů, a proto může být maximální rozměr vstupních dat $192 \times 192 \times 256$ mm. Snímky, které jsou větší než tyto rozměry, nemohou být segmentovány najednou, proto jsou rozděleny na části, které se částečně překrývají a na výstupu jsou opět propojeny.

Po převzorkování dat následuje již zmiňovaná síť SC-Net. První část sítě, která se zabývá umístěním jednotlivých středů obratlů a částečně se podobá síti U-Net, se skládá ze čtyř úrovní. Každá z úrovní enkodéru se skládá ze dvou konvolučních vrstev s *Leaky ReLU* a $3 \times 3 \times 3$ filtrem s 96 výstupy mezi jednotlivými podvzorkováními a každá z úrovní dekodéru také ze dvou konvolučních vrstev se stejnými parametry. Druhá část sítě pro prostorové uspořádání pracuje se čtvrtinovým prostorovým rozlišením než část první a využívá čtyř po sobě jdoucích konvolučních vrstev s filtry $7 \times 7 \times 7$.

Tyto dvě části jsou poté spojeny a vznikají z nich gaussovské pravděpodobnostní heatmapy jednotlivých obratlů, které jsou pro získání finální heatmapy propojeny pomocí prahování a určitých pravidel. Mezi tato pravidla patří: určení nejvýše a nejnižší položeného obratle a identifikace obratlů mezi nimi; současně s podmínkou, že po sobě jdoucí obratle musí být od sebe vzdáleny minimálně 12,5 mm a maximálně 50 mm.

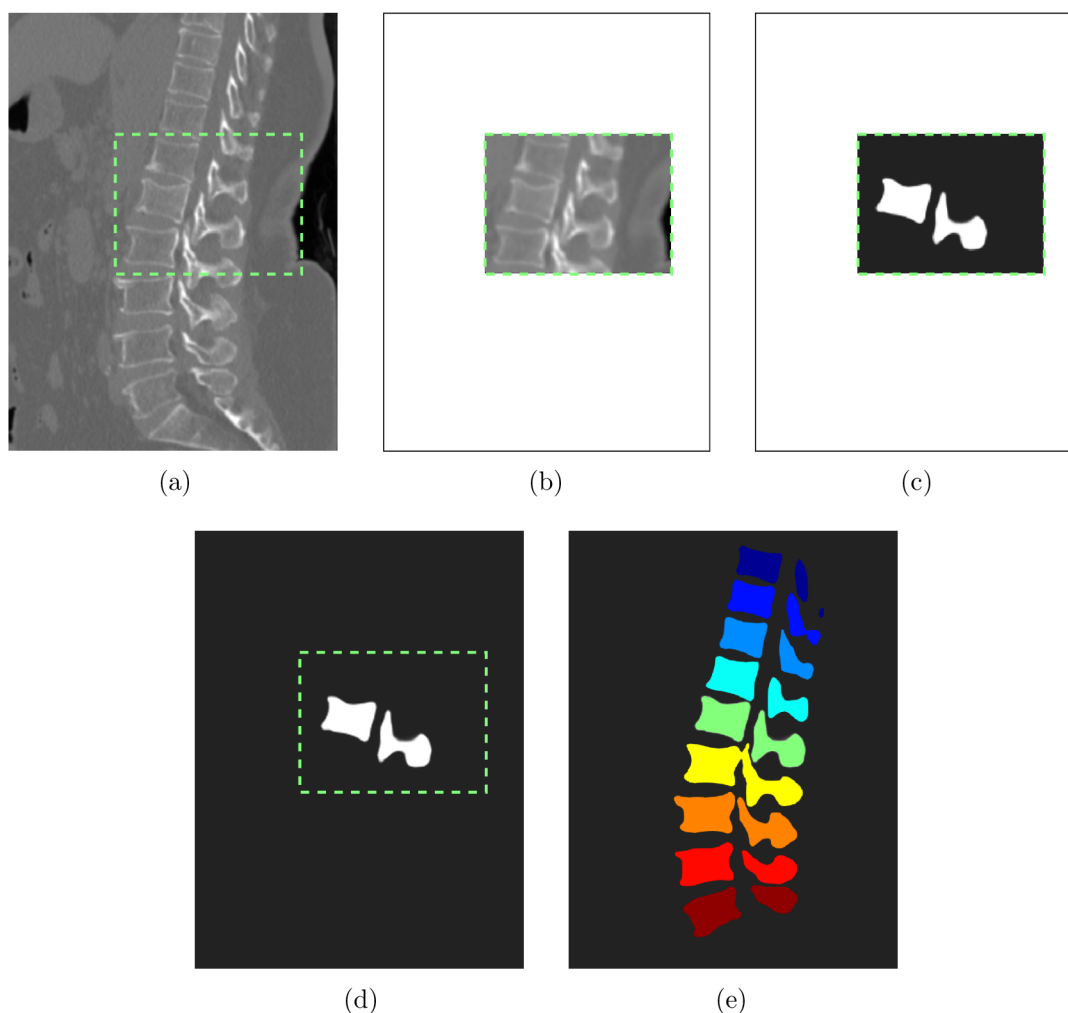


Obr. 4.4: Znárodnění lokalizace a identifikace obratlů: (a) vstupní data, (b) převzorkovaná data, (c) výsledná pravděpodobnostní heatmapa pro lokalizaci obratlů (bílá – vysoká pravděpodobnost umístění obratle, černá – malá pravděpodobnost umístění obratle)

4.4 Segmentace obratlů

Závěrečná binární segmentace obratlů je propojena s předcházející lokalizací obratlů, viz Kap. 4.3. K segmentaci dochází postupně pro jednotlivé obratle s využitím výstupu z předešlé sítě, viz Obr. 4.5. Nejprve dochází k oříznutí oblasti předpokládaného výskytu dílčího obratle ze vstupních dat, která je převzorkována na voxely o velikosti $1 \times 1 \times 1$ mm, vstupní data této sítě mají velikost $128 \times 128 \times 96$ voxelů ($128 \times 128 \times 96$ mm).


Pro samotnou segmentaci obratlů od jejich okolí je využívána síť U-Net se stejnou architekturou jako v Kap. 4.2. Výstupem této sítě je segmentační maska jednoho obratle, která je transformována a převzorkována do původní pozice ve vstupních CT datech sítě. Na závěr jsou segmentační masky jednotlivých obratlů spojeny do jedné finální segmentační masky.



Obr. 4.5: Znárodnění segmentace obratlů: (a) vstupní data, (b) převzorkovaná a oříznutá data pro jeden obratel, (c) segmentační maska jednoho obratle, (d) segmentační maska obratle převzorkovaná na původní pozici, (e) výsledná segmentační maska

4.5 Závěrečná úprava dat

Závěrečná úprava dat, tzv. *post-processing*, je složena z transformace a převzorkování vytvořené segmentační masky na zobrazení odpovídající původním vstupním CT datům, viz Obr. 4.6.



Obr. 4.6: Znázornění závěrečné úpravy dat: (a) výsledná segmentační maska na předzpracovaných datech, (b) výsledná segmentační maska na původních datech

4.6 Databáze CT dat

Databáze, na které byl popsán model natrénován, byla částečně zveřejněna v rámci již dříve zmíněného VerSe'20. Tato databáze je spolu s databází VerSe'19 součástí celkové databáze VerSe [27, 25, 26], která je souborem 374 snímků od 355 pacientů s průměrným věkem 59 let, viz Tab. 4.1. Databáze jsou rozděleny vždy do tří skupin přibližně stejné velikosti: trénovací data, veřejná validační data a skrytá testovací data. [25]

Tab. 4.1: Struktura a vlastnosti databáze VerSe, upraveno z [25]

VerSe	Počet pacientů	Počet snímků	Počet obratlů
2019	141	160	1725
2020	300	319	4141
celkem	355	374	4505

CT data obsažená v databázi jsou různě orientovaná a získána pomocí CT systémů od různých výrobců (*GE, Siemens, Philips a Toshiba*) a s rozdílnými akvizíčními parametry. Vyskytují se v ní snímky s různými oblastmi zájmu, od krční páteře až po bederní či celotělové, fyziologické i patologické snímky, ať už s mimořádným počtem obratlů, frakturami, implantáty či dalšími cizími materiály, jak je to běžné i v medicínské praxi. [25]

Databáze současně obsahuje i dva typy anotací, které byly získány s pomocí počítačových algoritmů a několika lidských expertů. Prvním typem jsou souřadnice umístění středů obratlů, které mají přidělené hodnoty (1–24, 25 a 28), které zastupují názvy jednotlivých obratlů C1–L5 a extra obratle L6 a T13. Druhým typem anotace je označení jednotlivých voxelů obrazů jako správný výstup segmentace (tzv. *ground truth*, referenční maska).

Všechna 3D data byla zobrazována pomocí volně dostupného softwaru *The Medical Imaging Interaction Toolkit (MITK)*¹ a jeho aplikace *MITK Workbench*, která je vhodným prostředím právě pro zobrazování 3D dat, jejich úpravu a ukládání.

¹[https://www.mtk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_\(MITK\)](https://www.mtk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_(MITK))

5 Výsledky modelu na příslušné databázi

V praktické části bakalářské práce byla provedena implementace a posléze i modifikace vybraného modelu od C. Payera a kol. [28] popsaného v předešlé části 4. Převzatý zdrojový kód tohoto modelu i s natrénovanými vahami CNN je dostupný na: <https://github.com/christianpayer/MedicalDataAugmentationTool-VerSe>. Model byl testován na validačních a testovacích datech příslušné databáze VerSe'20, viz Kap. 4.6, a každá z těchto skupin obsahovala 103 CT snímků od 100 pacientů.

5.1 Implementace vybraného modelu

Nejprve byla provedena implementace modelu pomocí softwaru *Docker*¹. Soubory *Docker image* pro jeho spuštění byly součástí veřejně dostupného modelu, a proto bylo jeho využití vhodné. Při tomto přístupu probíhá celá segmentace automaticky, výsledkem jsou ale pouze finální výstupní segmentační mapy ze vstupních CT dat bez mezikroků. Při této implementaci tedy nelze vyhodnotit, kde algoritmus selhává, nebo měnit určité parametry.

Právě proto, že tento druh implementace modelu by se dal považovat za tzv. „*black box*“, byl model implementován také přímo v programovacím prostředí *PyCharm*² v programovacím jazyce *Python*³, kde bylo v jednotlivých využívaných skriptech možno provést úpravy, například pro uložení mezikroků modelu a využívaných sítí.


Po provedení segmentace pomocí vybraného modelu byla vyhodnocena přesnost jednotlivých vytvořených segmentačních masek vůči poskytnutým anotacím. Hodnocení bylo provedeno výpočtem Dice skóre binárních segmentačních masek celé páteře a je pro jednotlivé snímky uvedeno v Tab. A.1 a Tab. A.2. Dice skóre masek všech CT snímků ze skupiny validačních dat bylo po implementaci modelu v průměru 0,9045 s odchylkou 0,0818. Pro testovací data byl průměr Dice skóre 0,8957 s odchylkou 0,0897. Souhrnné výsledky jsou i s dalšími statistickými hodnotami a metrikami přehledně vyobrazeny v tabulce finálních výsledků Tab. 5.1.

Po podrobnější analýze výsledků Dice skóre binárních masek pomocí krabíkových grafů, viz Obr. 5.1, a taktéž vytvořených segmentačních masek samotných bylo zjištěno, že po pouhé implementaci modelu se vyskytují v určitých segmentačních maskách jisté nepřesnosti, které stojí za nízkými hodnotami úspěšnosti segmentace. Po dalším přezkoumání bylo zjištěno, že za nízkým Dice skóre stojí tři hlavní důvody nepřesností.

¹<https://hub.docker.com/>

²<https://www.jetbrains.com/pycharm/>

³<https://www.python.org/>

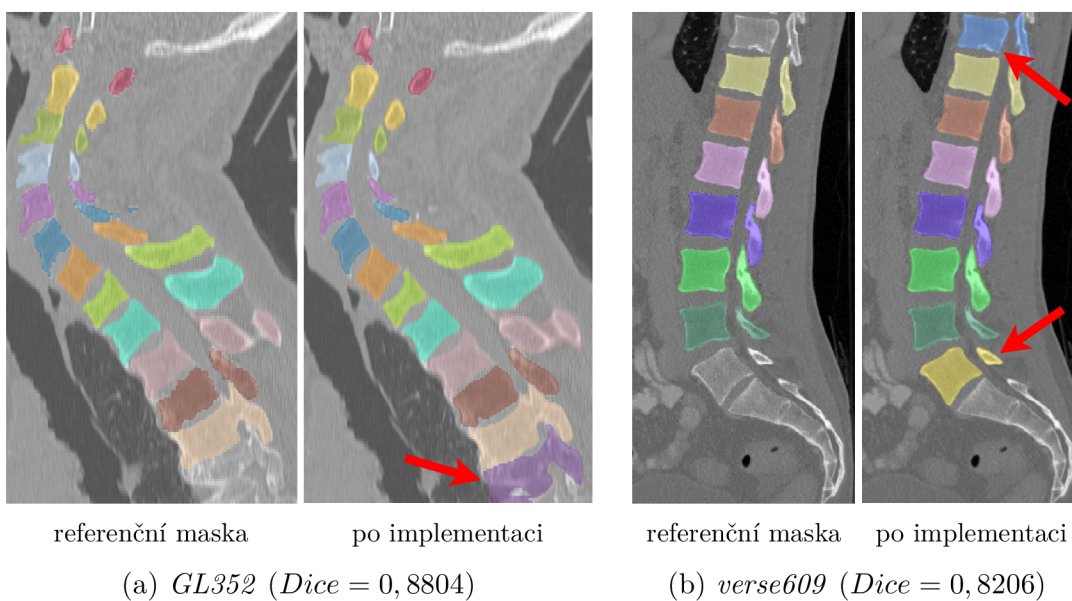


Obr. 5.1: Krabicové grafy hodnot Dice skóre binárních segmentačních masek po implementaci vybraného modelu na validačních a testovacích datech: průměr (zelený \times), medián (červená čára), mezikvartilový rozptyl (modrý obdélník), 1,5násobek mezikvartilového rozptylu (černé vousy) a odlehlé hodnoty (červené $+$)

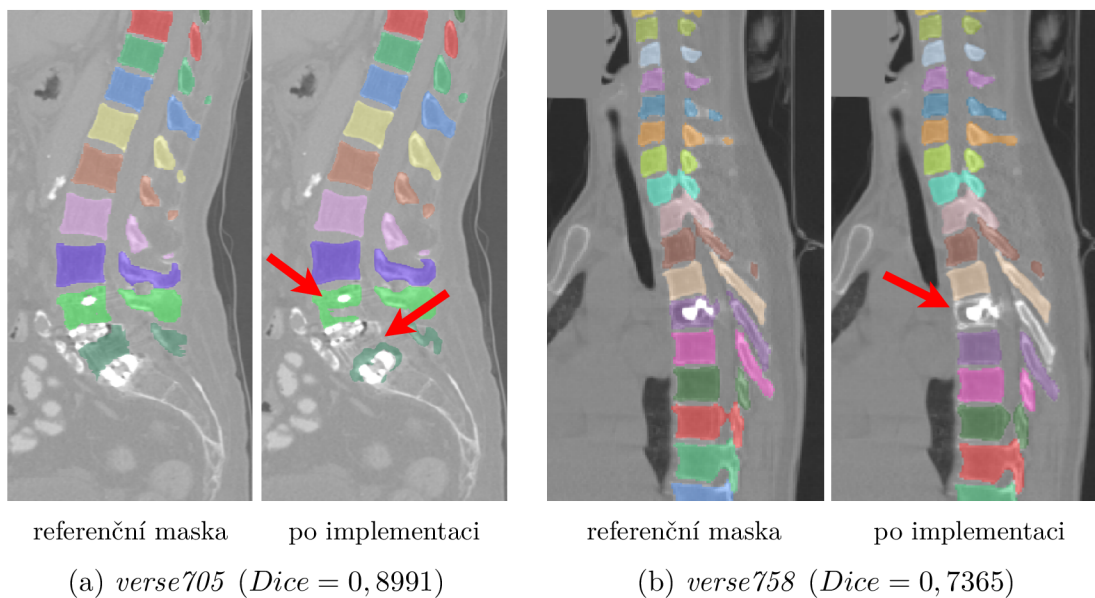
Prvním důvodem nízkého Dice skóre segmentační masky je vysegmentování více obratlů než je anotováno pro dané snímky. Tato nepřesnost by ale nemusela být považována za chybu, protože se vlastně jedná o nastavbu modelu, která při segmentaci obratlů dosahuje lepších výsledků než je původní anotace, referenční maska. Například na snímku *GL352* je vidět, že byl vysegmentován navíc obratel T6 oproti referenční masce, viz Obr. 5.2a. Stejně tak i na snímku *verse609* byly navíc detekovány obratle T11 a L6, viz Obr. 5.2b.

Druhým důvodem byla špatná, nedostatečná nebo žádná segmentace určitých obratlů kvůli vyskytujícím se patologiím. Například u snímku *verse705* byly špatně vysegmentovány obratle L4 a L5, viz Obr. 5.3a, což bylo způsobeno tím, že přilehlé meziobratlové ploténky těchto obratlů byly nahrazeny ploténkovými implantáty, se kterými si model při segmentaci nedokázal poradit, a proto zde segmentace selhala. U snímku *verse758* kvůli přítomné patologii nedošlo k segmentaci obratle T6 vůbec, viz Obr. 5.3b.

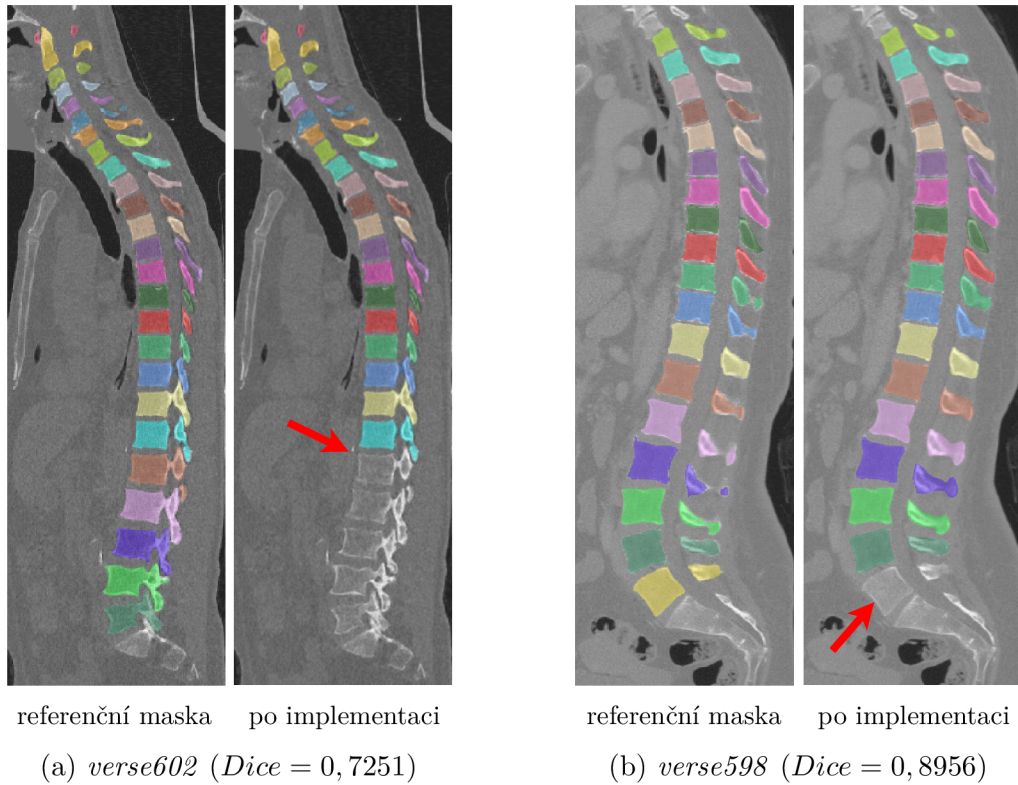
Třetím hlavním důvodem nízkého Dice skóre bylo vysegmentování jen části páteře, tedy pouze některých obratlů, které se vyskytlo například u snímků *verse602* a *verse598*, viz Obr. 5.4. Tyto nepřesnosti nebyly způsobeny chybou samotné segmentace, ale již při lokalizaci a identifikaci jednotlivých obratlů v druhé CNN (Kap. 4.3), což je ukázáno na snímku *verse759* na Obr. 5.5.




Obr. 5.2: Příklady navíc vysegmentovaných obratlů vůči referenční masce (zvýrazněny červenými šipkami)



Obr. 5.3: Příklady chybně vysegmentovaných obratlů vůči referenční masce (zvýrazněny červenými šipkami)



Obr. 5.4: Příklady nevysegmentovaných částí páteře vůči referenční masce (zvýrazněny červenými šipkami)



Obr. 5.5: Příklad chybného průběhu lokalizace a identifikace obratlů při segmentaci snímku *verse759* ($Dice = 0,6760$): (a) předzpracovaná data, (b) pravděpodobnostní heatmapa pro lokalizaci páteře, (c) necelistvá pravděpodobnostní heatmapa pro lokalizaci obratlů, (d) segmentační mapa pouze lokalizovaných obratlů

Na Obr. 5.5b je vidět, že byla páteř nejprve správně lokalizována, posléze byly ale nalezeny a identifikovány pouze obratle části páteře, viz Obr. 5.5c, a to bylo důvodem segmentace pouze obratlů C1–T11 zobrazených na Obr. 5.5d. Pro vylepšení těchto nepřesností bylo přistoupeno k vytvoření dodatečné modifikace modelu pro zlepšení segmentace v těchto případech, viz Kap. 5.2.

5.2 Modifikace vybraného modelu

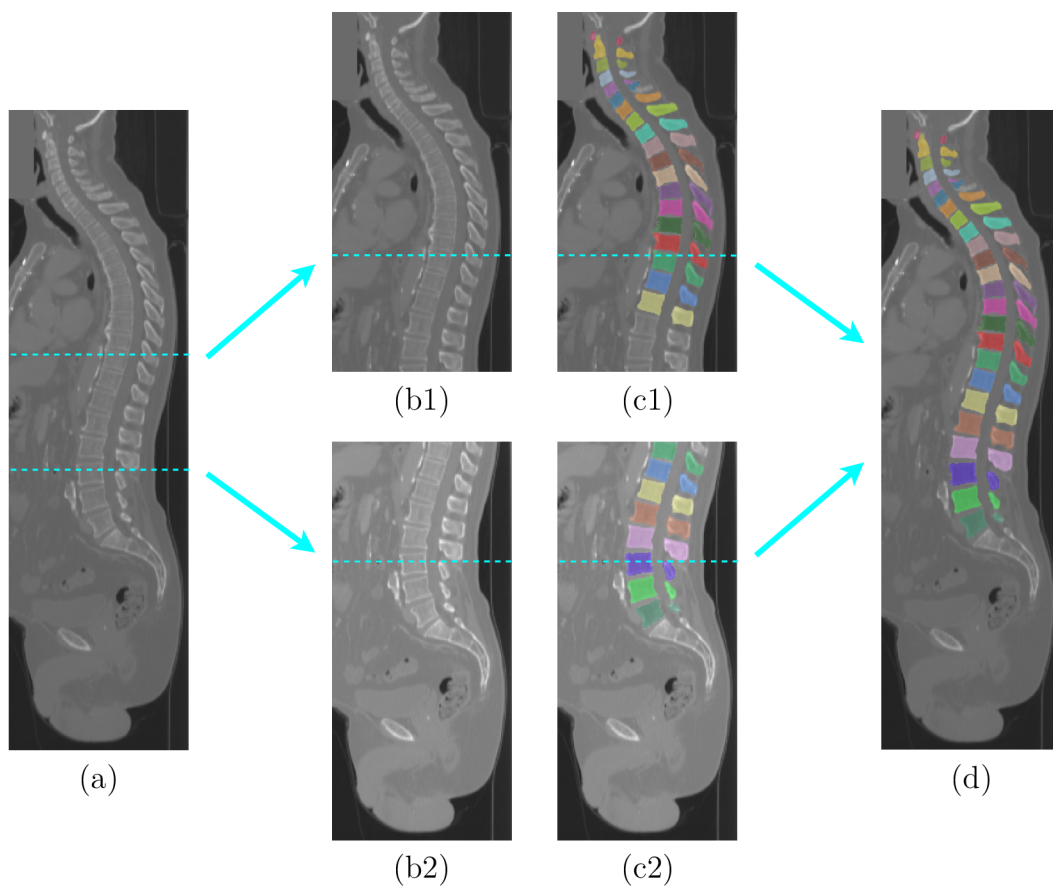
Po vyhodnocení úspěšnosti segmentace implementací modelu bylo zjištěno, že v určitých případech nízké Dice skóre není chybou segmentace, ale nesprávné lokalizace a identifikace obratlů na daném snímku. U těchto problémových snímků byla proto navržena modifikace algoritmu.

Nejprve byl daný CT objem rozdělen do dvou částí podél osy z snímku s překryvem 96 řezů. Tyto dva objemy byly poté samostatně segmentovány. Výstupem byly dvě samostatné segmentační masky, které byly nakonec propojeny v jednu finální masku, která již zahrnovala „všechny“ vysegmentované obratle. Tento postup je schématicky naznačen na Obr. 5.6 na snímku *verse759*, u kterého se po navržené modifikaci Dice skóre zlepšilo z původních 0,6760 na 0,9459.

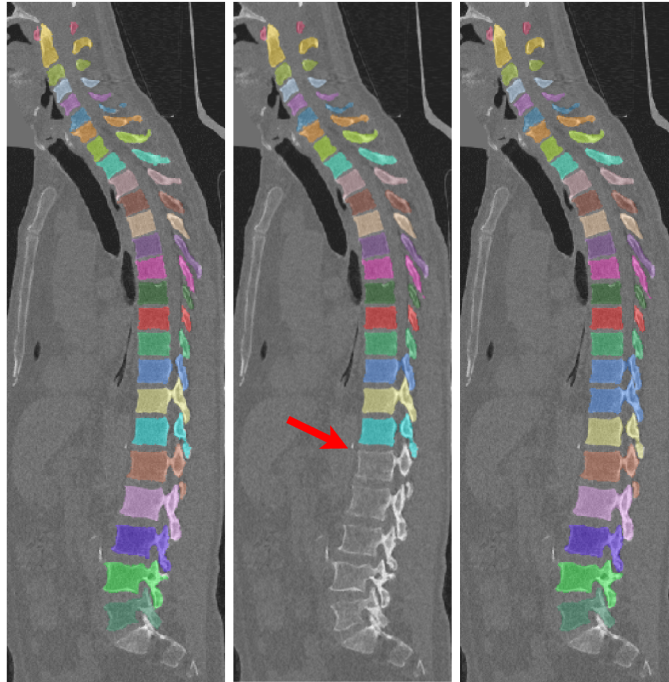
Na Obr. 5.7 jsou vyobrazeny výsledky původně necelistvé segmentace páteře po modifikaci modelu v porovnání s referenční maskou a maskou po pouhé implementaci modelu. Jsou zde zobrazeny snímky *verse602* a *verse598*, zmiňované již v předcházející kapitole na Obr. 5.4.

Na Obr. 5.7a snímku *verse602* je vidět, že po modifikaci došlo k zlepšení výsledné segmentační mapy a vysegmentování všech obratlů C1–L5. U tohoto snímku ale muselo dojít ještě k dodatečné upravě místa rozdělení původního snímku při modifikaci. Tento snímek je totiž celotělový a po jeho rozdělení na přibližné poloviny by segmentace proběhla znovu necelistvě. Výsledného Dice skóre tohoto snímku se zlepšilo z 0,7251 na 0,9563. Na Obr. 5.7b je zobrazená vysegmentovaná páteř snímku *verse598*, u které byly nejprve po implementaci vysegmentovány obratle T1–L5 a Dice skóre segmentační masky bylo 0,8956. Po modifikaci byl vysegmentován i obratel L6 a Dice skóre se zvýšilo na 0,9439.

Po této modifikaci bylo dosaženo zlepšení průměrného Dice skóre binárních masek pro validační data na 0,9308 s odchylkou 0,0343 a v rámci hodnocení segmentace dat z testovací části databáze došlo k zlepšení průměrného Dice skóre na 0,9299 a jeho směrodatné odchylky na 0,0309. Tyto výsledky i s dalšími statistickými hodnotami a metrikami jsou uvedeny v tabulce finálních výsledků Tab. 5.1 a výsledky pro jednotlivé snímky v Tab. A.1 a Tab. A.2. Vizualně je vidět vylepšení výsledků Dice skóre také na Obr. 5.8, kde v obou skupinách dat došlo k vymizení odlehlých hodnot a ke zvýšení průměrného Dice skóre.




Obr. 5.6: Schéma modifikace modelu na snímku *verse759*: (a) původní data, (b) data rozdělená na dvě části, (c) segmentační masky obou částí, (d) propojená finální segmentační maska



referenční maska po implementaci po modifikaci


(a) *verse602* ($Dice = 0,7251$; $Dice = 0,9563$)



referenční maska po implementaci po modifikaci

(b) *verse598* ($Dice = 0,8956$; $Dice = 0,9439$)

Obr. 5.7: Příklady výsledků správné segmentace před a po modifikaci vybraného modelu vůči referenční masce



Obr. 5.8: Krabicové grafy hodnot Dice skóre binárních segmentačních masek na validačních a testovacích datech po implementaci vybraného modelu a po jeho modifikaci: průměr (zelený ×), medián (červená čára), mezikvartilový rozptyl (modrý obdélník), 1,5násobek mezikvartilového rozptylu (černé vousy) a odlehle hodnoty (červené +)

5.3 Publikované výsledky vybraného modelu

Přesnost automatické segmentace a identifikace tohoto modelu byla publikována v [25] a byla hodnocena pomocí Dice skóre a Hausdorffovy vzdálenosti. Uváděné Dice skóre by mělo být podle [25] určeno podle vzorce 3.2, které současně s vyhodnocením segmentace zahrnuje také informace o identifikaci obratlů. Ve zveřejněném kódu pro hodnocení přihlášených modelů v rámci VerSe je ale uveden vzorec pro Dice skóre binární masky segmentace celé páteře podle vzorce 3.1. Kvůli tomu není úplně jasné, o jaký druh publikovaného Dice skóre se jedná. Pro validační data bylo publikováno tedy průměrné Dice skóre 0,9165 a jeho medián 0,9572. Pro data testovací byl publikován průměrný výsledek 0,8971 a medián 0,9565.

Publikované výsledky hodnocení segmentace pomocí průměrné Hausdorffovy vzdálenosti byly pro validační data v průměru 5,80 mm a medián 4,06 mm a pro testovací data byly 6,06 mm a 3,94 mm. V těchto výsledcích nejsou ale zahrnuty vzdálenosti pro případy obratlů, kdy nebyl daný obratel detekován modelem vůbec nebo naopak nebyl zahrnut v referenční masce, a proto tyto výsledky mohou být částečně zkresleny.

5.4 Diskuze výsledků vybraného modelu

Výsledné testování vybraného modelu a jeho modifikace bylo provedeno na dvou skupinách dat: validačních a testovacích. Pro segmentaci bylo využito zařízení s procesorem Intel Core i5-8600 3,60 GHz, s pamětí RAM o velikosti 32 GB, Windows 10 a grafickou kartou ASUS GeForce GTX 1070Ti s pamětí 8 GB GDDR5. GPU nebylo ale využíváno kvůli nekompatibilitě knihoven. Časová náročnost celého algoritmu pro segmentaci páteře s využitím všech kroků algoritmu se na CPU pohybovala pro jeden snímek celé páteře zhruba okolo 5–6 minut, ostatní snímky se časově pohybovaly v rozmezí zhruba od 4 do 10 minut.

Hodnocení samotné segmentace bylo prováděno pomocí Dice skóre (*Dice*) binárních segmentačních masek. Jak je vidět ve finální tabulce výsledků Tab. 5.1, po implementaci modelu bylo na validačních datech dosaženo výsledků průměrného Dice skóre 0,9045. Jenže po pouhé implementaci modelu se mezi výsledky vyskytovaly snímky s nízkými hodnotami Dice skóre, tyto nepřesnosti byly ale převážně odstraněny pomocí vytvořené modifikace modelu, čímž došlo k vylepšení Dice skóre jednotlivých snímků o 5–40 %, v průměru tedy na 0,9308. Stejný trend byl pozorován i na testovacích datech, u kterých se průměrné Dice skóre zvýšilo z původních 0,8957 po implementaci na 0,9299 po modifikaci modelu. Samotná segmentace pomocí vybraného modelu měla tedy velmi vysokou úspěšnost.

Dále bylo realizováno hodnocení segmentace spojené se správností identifikace a klasifikace obratlů páteře. V těchto výsledcích se ale projevují jisté nepřesnosti, protože klasifikace obratlů nebyla hlavním cílem práce. Jako metriky pro tento typ hodnocení byly využity průměrné Dice skóre ($Dice_N$) všech obratlů na snímku podle vzorce 3.2 a průměrná Hausdorfova vzdálenost (HD). Samostatné vyhodnocování klasifikace obratlů nebylo více rozváděno, i přestože byly dostupné anotace pozic centroidů obratlů na snímcích. Při určování středů obratlů, přesněji středů těl obratlů, by byly totiž získány souřadnice s významným zkreslením polohy kvůli obratlovému oblouku a obratlovým výběžkům.

Pro validační data bylo průměrné Dice skóre po implementaci modelu vypočteno jako 0,8425 se směrodatnou odchylkou 0,1713, kvůli nesprávné klasifikaci některých obratlů či dokonce i některých celých snímků. Po modifikaci se tato hodnota zvýšila na průměrné 0,8606 s odchylkou 0,1668. Nedošlo k markantnímu zlepšení tohoto skóre, protože samotná modifikace byla zaměřena hlavně na segmentaci „všech“ obratlů, ne jejich správnou klasifikaci. Taktéž tomu bylo i u dat testovacích, kdy se průměrné skóre zvýšilo z původních 0,8365 s odchylkou 0,2039 na 0,8531 s odchylkou 0,1975.

Výsledky hodnocení úspěšnosti pomocí průměrné Hausdorfovy vzdálenosti byly po implementaci modelu v průměru rovny 5,15 mm s odchylkou 5,31 mm na validač-

ních datech a 5,24 mm s odchylkou 6,47 mm na testovacích datech. Po modifikaci u této metriky nedošlo ke zlepšení. To je znovu způsobeno nezaměřováním se na klasifikaci obratlů, na kterou je tato metrika vázána, a také tím, že Hausdorffova vzdálenost byla počítána pouze u obratlů, které byly přítomny současně jak v anotaci, tak ve vytvořené segmentační masce, což způsobuje určité zkreslení.

Současně byla provedena analýza hodnocení úspěšností segmentace různých částí páteře, přesněji úspěšnost pro páteř krční (C1–C7), hrudní (T1–T12) a bederní (L1–L5). Před modifikací byla nejvyšší úspěšnost segmentace u obratlů krčních, poté následovaly obratle hrudní a nakonec bederní, což bylo způsobeno převážně necelistvou segmentací páteře u některých snímků způsobenou nesprávnou lokalizací všech obratlů. Po modifikaci se hodnoty průměrného Dice skóre totiž u všech částí páteře vyrovnaly na hodnoty okolo 0,85–0,88. Podrobnější výsledky této analýzy jsou uvedeny v Tab. 5.2.

Tab. 5.1: Souhrnné výsledky hodnocení úspěšnosti segmentace obratlů pomocí Dice skóre ($Dice$) binárních masek a průměrného Dice skóre ($Dice_N$) a průměrné Hausdorffovy vzdálenosti (HD) masek jednotlivých obratlů

(a) Hodnocení úspěšnosti modelu na validačních datech

Hodnocení segmentace	<i>po implementaci</i>			<i>po modifikaci</i>			<i>publikované</i>	
	$Dice$ [-]	$Dice_N$ [-]	HD [mm]	$Dice$ [-]	$Dice_N$ [-]	HD [mm]	$Dice_N$ [-]	HD [mm]
průměr	0,9045	0,8425	5,1484	0,9308	0,8606	5,4031	0,9165	5,80
směrodatná odchylka	0,0818	0,1713	5,3124	0,0343	0,1668	5,5275	–	–
medián	0,9363	0,8946	3,5713	0,9414	0,9035	3,7560	0,9572	4,06
maximum	0,9679	0,9657	40,9801	0,9678	0,9657	40,9802	–	–
minimum	0,5072	0,0001	2,0315	0,7675	0,0001	2,0786	–	–

(b) Hodnocení úspěšnosti modelu na testovacích datech

Hodnocení segmentace	<i>po implementaci</i>			<i>po modifikaci</i>			<i>publikované</i>	
	$Dice$ [-]	$Dice_N$ [-]	HD [mm]	$Dice$ [-]	$Dice_N$ [-]	HD [mm]	$Dice_N$ [-]	HD [mm]
průměr	0,8957	0,8265	5,2380	0,9299	0,8531	5,6081	0,8971	6,06
směrodatná odchylka	0,0897	0,2039	6,4661	0,0309	0,1975	7,0682	–	–
medián	0,9272	0,8909	3,5830	0,9391	0,9061	3,5830	0,9565	3,94
maximum	0,9724	0,9714	39,5603	0,9724	0,9736	39,5603	–	–
minimum	0,5327	0,0001	1,8734	0,8355	0,0001	1,8734	–	–

Tab. 5.2: Výsledky hodnocení úspěšnosti segmentace obratlů pomocí průměrného Dice skóre ($Dice_N$) pro obratle krční, hrudní a bederní páteře

(a) Hodnocení úspěšnosti modelu na validačních datech

Hodnocení segmentace	<i>po implementaci</i>			<i>po modifikaci</i>		
	$Dice_{C1-C7}$ [-]	$Dice_{Th1-T12}$ [-]	$Dice_{L1-L5}$ [-]	$Dice_{C1-C7}$ [-]	$Dice_{Th1-T12}$ [-]	$Dice_{L1-L5}$ [-]
průměr	0,8872	0,8677	0,7632	0,8816	0,8712	0,8501
směrodatná odchylka	0,0587	0,0446	0,0545	0,0576	0,0411	0,0402

(b) Hodnocení úspěšnosti modelu na testovacích datech

Hodnocení segmentace	<i>po implementaci</i>			<i>po modifikaci</i>		
	$Dice_{C1-C7}$ [-]	$Dice_{Th1-T12}$ [-]	$Dice_{L1-L5}$ [-]	$Dice_{C1-C7}$ [-]	$Dice_{Th1-T12}$ [-]	$Dice_{L1-L5}$ [-]
průměr	0,8624	0,8489	0,7559	0,8631	0,8640	0,8752
směrodatná odchylka	0,0285	0,0478	0,0689	0,0310	0,0362	0,0376

6 Výsledky modelu na klinických datech

Pro vyzkoušení vybraného modelu na klinických datech bylo vedoucím poskytnuto jedenáct anonymizovaných snímků pacientů. U deseti z nich se vyskytovaly mnohočetné myelomy a jeden pacient tímto onemocněním netrpěl.

6.1 Popis klinických dat a jejich úprava pro implementaci modelu

Využívaná klinická data byla získána se souhlasem etické komise pod registračním číslem žádosti NU23J-08-00027 a s informovaným souhlasem všech pacientů. U deseti pacientů s mnohočetnými myelomy bylo toto onemocnění taktéž diagnostikováno pomocí krevních testů, díky zvýšené hladině monoklonálního imunoglobulinu, a zvýšené hladiny plazmatických buněk v kostní dřeni.


Jednotlivé snímky byly získány pomocí CT systému *Philips Healthcare IQon spectral CT* [29] s následujícími parametry: napětí rentgenky 100 kV, proud rentgenky 10 mA, výkon rentgenky 120 kW, pokrytí detektoru 40 mm, maximální rozsah snímání 2100 mm, čas jedné rotace 0,27 s, snímání až 256 vrstev zároveň, průměr otvoru gantry 700 mm, rychlost konvenční rekonstrukce méně než 1 minuta a rychlost spektrální rekonstrukce 3–5 minut. Vytvořené snímky byly poskytnuty ve formátu DICOM s velikostí jednoho řezu 512×512 voxelů a jeho tloušťkou 0,9 mm.

Vybraný model využívá vstupní data ve formátu NIfTI, proto musela být před dalším zpracováním data transformována do tohoto formátu. Poté byla již klinická data zpracovávána navrženým automatizovaným postupem, který využíval vybraného modelu současně s navrženou modifikací. Modifikace byla využita v případě, kdy měl vstupní snímek více jak 650 řezů, což by odpovídalo velikosti snímku větší než 585 mm a bylo určeno po odvození přesnosti lokalizace a identifikace obratlů.

6.2 Diskuze výsledků vybraného modelu

Pro segmentaci páteře musela být využita vytvořená modifikace modelu s možností segmentace CT snímků po částech, protože se jednalo také o snímky celé páteře. Po provedené segmentaci všech snímků byla provedena analýza finálních segmentačních masek.

Nejprve byl model vyzkoušen na hrudním CT snímku „zdravého“ pacienta, u kterého proběhla segmentace správně, viz Obr. 6.1. Na vytvořených segmentačních maskách celotělových snímků pacientů s onemocněním se vyskytovaly čtyři hlavní anomálie, z nichž s některými si vybraný model poradit dokázal a s některými ne.




Obr. 6.1: Správná segmentace snímku „zdravého“ pacienta


Lokalizace obratlů proběhla u snímků úspěšně, pouze u pacienta č. 2 měl model problém s identifikací obratlů horní části páteře, kvůli jejímu nadměrnému zakřivení v hrudní oblasti v důsledku výskytu zkolabovaných obratlů, viz Obr. 6.2. Na tomto snímku je ale zároveň vidět, že si model dokázal správně poradit se segmentací těchto zborcených obratlů. Určité zhroucené obratle se vyskytovaly také například u pacienta č. 9 (Obr. 6.3).

Další anomálií na snímcích byl výskyt implantátu v oblasti obratlů Th12 až L2 u pacienta č. 1, viz Obr. 6.4. Na snímku je vidět, že i přes přítomnost kovového implantátu došlo k přesné segmentaci obratlů až na bílé nevysegmentované části těl obratlů v přímém kontaktu s implantátem.


Poslední zmiňovanou anomálií je výskyt samotných patologických lytických ložisek. U pacienta č. 2 (Obr. 6.2) a pacienta č. 5 (Obr. 6.5) v místě těchto ložisek segmentace selhala a nedošlo k jejich vysegmentování. Naopak u pacienta č. 7 (Obr. 6.6) došlo k jejich správnému vysegmentování, ložisko bylo tedy zahrnuto do segmentační masky obratle.




Obr. 6.2: Snímek pacienta č. 2: příklad nevysegmentování obratlů při nadměrném zakřivení páteře (označeno zelenou šipkou), správné segmentace zkolabovaných obratlů (označeno modrými šipkami) a selhání segmentace při výskytu lytických ložisek (označeno žlutou šipkou)




Obr. 6.3: Snímek pacienta č. 9: příklad správné segmentace zkolabovaných obratlů (označeno modrými šipkami)



Obr. 6.4: Snímek pacienta č. 1: příklad segmentace obratlů v okolí kovového implantátu (nevysegmentované části obratlů v okolí implantátu označeny červenými šipkami)



Obr. 6.5: Snímek pacienta č. 5: příklad selhání segmentace při výskytu lytických ložisek (označeno žlutou šipkou)



Obr. 6.6: Snímek pacienta č. 7: příklad správné segmentace při výskytu lytických ložisek (označeno žlutou šipkou)

Závěr

Tato bakalářská práce se zabývá problematikou segmentace obratlů z 3D CT dat s využitím hlubokého učení. Jejím cílem bylo zpracovat teoretickou literární rešerši, která je zaměřena na anatomii páteře a obratlů, výpočetní tomografii a publikované metody využívané pro segmentaci obratlů se zaměřením na hluboké učení. Celá tato rešerše je vyobrazena v prvních čtyřech částech práce.

V rámci rešerše a analýzy publikovaných metod byl také do třetí části práce zařazen přehled dostupných algoritmů zaměřených na problematiku bakalářské práce a přístupy k jejich možnému hodnocení. Jeden vybraný model od C. Payera a kol. [28] skládající se z pěti základních kroků a využívající kombinaci konvolučních sítí U-Net a SpatialConfiguration-Net byl spolu s jemu příslušnou databází popsán podrobněji ve čtvrté části.

Cílem praktické části práce bylo implementovat tento vybraný model hlubokého učení pro segmentaci obratlů v příslušném programovacím prostředí a zautomatizovat práci z CT daty od jejich načítání, přes jejich segmentaci až po jejich ukládání. Vybraný model byl poté testován na validačních a testovacích datech příslušné databáze.

Hodnocení úspěšnosti segmentace modelu bylo provedeno pomocí Dice skóre vytvořených binárních segmentačních masek. Průměrné Dice skóre bylo pro validační data vypočteno jako 0,9045 se směrodatnou odchylkou 0,0818 a mediánem 0,9363. Pro testovací data bylo toto skóre učeno v průměru jako 0,8957 se směrodatnou odchylkou 0,0897 a medián jako 0,9272.

Při další analýze výsledných segmentačních masek byly nalezeny určité nepřesnosti, a proto byla vytvořena modifikace vybraného modelu. Po této modifikaci se zvýšilo průměrné Dice skóre na 0,9308 s odchylkou 0,0343 a mediánem 0,9414 na validačních datech, a taktéž na testovacích datech se průměr Dice skóre zvýšil na 0,9299 se směrodatnou odchylkou 0,0309 a mediánem 0,9391.

Výsledky úspěšnosti segmentace byly také doplněny o vyhodnocení pomocí metrik zahrnující informace o správnosti klasifikace obratlů. Pro toto hodnocení bylo zvoleno průměrné Dice skóre jednotlivých obratlů segmentační masky páteře a také průměrná Hausdorffova vzdálenost těchto obratlů.

V poslední šesté části byl vybraný model společně s vytvořenou modifikací implementován na klinická data poskytnutá vedoucím. Bylo zjištěno, že vybraný model na tato data funguje velmi dobře. Dokáže si velmi dobře poradit se zkolabovanými obratli páteře a k drobným nepřesnostem dochází při výskytu kovových implantátů a lytických ložisek. Pouze při velkém zakřivení hrudní páteře nedochází k segmentaci krční páteře vůbec.

Literatura

- [1] GRIM, Miloš a Rastislav DRUGA. *Základy anatomie: 1. Obecná anatomie a pohybový systém*. Praha: Karolinum, 2001. ISBN 80-246-0307-1. 80-7262-112-2.
- [2] PAULSEN, Friedrich a Jens WASCHKE, ed. *Sobotta atlas of human anatomy: General anatomy and musculoskeletal system*. München: Elsevier, Urban and Fischer, 2011, 400 s. 15th ed. ISBN 978-0-7234-3639-3.
- [3] ZÁMEČNÍK, Josef, ed. *Patologie: Učebnice pro lékařské fakulty*. Svazek 2 a 3. Praha: LD Prager Publishing, 2019. ISBN 978-80-270-6457-1.
- [4] JAN, Jiri. *Medical Image Processing, Reconstruction and Analysis*. 2. Second. Milton: CRC Press, 2019. ISBN 113831028X. Dostupné z: <https://doi.org/10.1201/b22391>
- [5] MORNSTEIN, Vojtěch. *Lékařská fyzika a biofyzika*. Brno: Masarykova univerzita, 2018, 339 s. ISBN 978-80-210-8984-6.
- [6] VOMÁČKA, Jaroslav a kol. *Zobrazovací metody pro radiologické asistenty*. Druhé, doplněné vydání. Olomouc: Univerzita Palackého v Olomouci, 2015, 157 s. ISBN 978-80-244-4508-3.
- [7] CHOLLET, François. *Deep learning v jazyku Python: Knihovny Keras, Tensorflow*. Praha: Grada Publishing, 2019, 328 s. Knihovna programátora (Grada). ISBN 978-80-247-3100-1.
- [8] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep learning*. Cambridge: MIT Press, 2016. Adaptive computation and machine learning (MIT Press). ISBN 978-0-262-03561-3.
- [9] GÉRON, Aurélien. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. Second edition. Sebastopol: O'Reilly Media, 2019. ISBN 978-1-492-03264-9.
- [10] ZHOU, Neng, Hairu WEN, Yi WANG, Yang LIU a Longfei ZHOU. Review of Deep Learning Models for Spine Segmentation. *ICMR '22: Proceedings of the 2022 International Conference on Multimedia Retrieval* [online]. New York, NY, USA: ACM, 2022, 2022-06-27, 498-507 [cit. 2022-10-28]. ISBN 9781450392389. Dostupné z: <https://doi.org/10.1145/3512527.3531356>
- [11] RONNEBERGER, Olaf, Philipp FISCHER, Thomas BROX a , ed. U-Net: Convolutional Networks for Biomedical Image Segmentation. NAVAB, Nassir, Joachim HORNEGGER, William M. WELLS a Alejandro F. FRANGI. *Medical*

- Image Computing and Computer-Assisted Intervention — MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* [online]. Cham: Springer International Publishing, 2015, 2015-11-18, (9351), 234-241 [cit. 2022-10-28]. Lecture Notes in Computer Science. ISBN 978-3-319-24573-7. ISSN 978-3-319-24574-4. Dostupné z: https://doi.org/10.1007/978-3-319-24574-4_28
- [12] OKTAY, Ozan, Jo SCHLEMPER, Loic Le FOLGOC, et al. *Attention U-Net: Learning Where to Look for the Pancreas* [online]. 2018-04-11 [cit. 2022-10-28]. Dostupné z: <https://doi.org/10.48550/arXiv.1804.03999>
- [13] JHA, Debesh, Pia H. SMEDSRUD, Michael A. RIEGLER, Dag JOHANSEN, Thomas De LANGE, Pal HALVORSEN a Havard D. JOHANSEN. ResU-Net++: An Advanced Architecture for Medical Image Segmentation. *2019 IEEE International Symposium on Multimedia (ISM)* [online]. Los Alamitos, CA, USA: IEEE Computer Society, 2019, 2019-11-16 [cit. 2022-10-28]. ISBN 978-1-7281-5606-4. Dostupné z: <https://doi.org/10.1109/ISM46123.2019.00049>
- [14] CHEN, Jieneng, Yongyi LU, Qihang YU, et al. *Transunet: Transformers make strong encoders for medical image segmentation* [online]. 2021, 2021 [cit. 2022-11-14]. Dostupné z: <https://doi.org/10.48550/arxiv.2102.04306>
- [15] QIU, Yu, Yun LIU, Shijie LI a Jing XU. MiniSeg: An Extremely Minimum Network for Efficient COVID-19 Segmentation. *Proceedings of the AAAI Conference on Artificial Intelligence* [online]. 2021, 2021-05-18, **35**(6), 4846-4854 [cit. 2022-10-28]. ISSN 2374-3468. Dostupné z: <https://doi.org/10.1609/aaai.v35i6.16617>
- [16] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, 2015-12-10, 770-778 [cit. 2022-10-28]. ISBN 978-1-4673-8851-1. ISSN 1063-6919. Dostupné z: <https://doi.org/10.1109/CVPR.2016.90>
- [17] GAO, Shang-Hua, Ming-Ming CHENG, Kai ZHAO, Xin-Yu ZHANG, Ming-Hsuan YANG a Philip TORR. Res2Net: A New Multi-Scale Backbone Architecture. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. IEEE, 2021, 2019-04-02, **43**(2), 652-662 [cit. 2022-10-28]. ISSN 0162-8828. Dostupné z: <https://doi.org/10.1109/TPAMI.2019.2938758>

- [18] ZHAO, Hengshuang, Jianping SHI, Xiaojuan QI, Xiaogang WANG a Jiaya JIA. Pyramid Scene Parsing Network. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2017, 2017-04-27, 6230-6239 [cit. 2022-10-28]. ISBN 978-1-5386-0457-1. ISSN 1063-6919. Dostupné z: <https://doi.org/10.1109/CVPR.2017.660>
- [19] CHEN, Liang-Chieh, Yukun ZHU, George PAPANDREOU, Florian SCHROFF a Hartwig ADAM. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *Computer Vision — ECCV 2018* [online]. Cham: Springer International Publishing, 2018, 2018-10-06, 833-851 [cit. 2022-11-11]. Lecture Notes in Computer Science. ISBN 978-3-030-01233-5. Dostupné z: https://doi.org/10.1007/978-3-030-01234-2_49
- [20] YANG, Maoke, Kun YU, Chi ZHANG, Zhiwei LI a Kuiyuan YANG. DenseASPP for Semantic Segmentation in Street Scenes. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition* [online]. IEEE, 2018, 2018-06-01, 3684-3692 [cit. 2022-11-11]. ISBN 978-1-5386-6420-9. Dostupné z: <https://doi.org/10.1109/CVPR.2018.00388>
- [21] FU, Jun, Jing LIU, Haijie TIAN, Yong LI, Yongjun BAO, Zhiwei FANG a Hanqing LU. Dual Attention Network for Scene Segmentation. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2019, 2019-06, 3141-3149 [cit. 2022-11-11]. ISBN 978-1-7281-3293-8. Dostupné z: <https://doi.org/10.1109/CVPR.2019.00326>
- [22] LI, Xia, Zhisheng ZHONG, Jianlong WU, Yibo YANG, Zhouchen LIN a Hong LIU. Expectation-Maximization Attention Networks for Semantic Segmentation. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)* [online]. IEEE, 2019, 2019-10, 9166-9175 [cit. 2022-11-11]. ISBN 978-1-7281-4803-8. Dostupné z: <https://doi.org/10.1109/ICCV.2019.00926>
- [23] FAN, Deng-Ping, Tao ZHOU, Ge-Peng JI, Yi ZHOU, Geng CHEN, Huazhu FU, Jianbing SHEN a Ling SHAO. Inf-Net: Automatic COVID-19 Lung Infection Segmentation From CT Images. *IEEE Transactions on Medical Imaging* [online]. IEEE, 2020, 2020-05-22, **39**(8), 2626-2637 [cit. 2022-11-11]. ISSN 0278-0062. Dostupné z: <https://doi.org/10.1109/TMI.2020.2996645>
- [24] ZHAO, Hengshuang, Yi ZHANG, Shu LIU, Jianping SHI, Chen Change LOY, Dahua LIN a Jiaya JIA. PSANet: Point-wise Spatial Attention Network for Scene Parsing. *Computer Vision — ECCV 2018* [online]. Cham: Springer International Publishing, 2018, 2018-10-05, **11213**, 270-286 [cit. 2022-11-11].

Lecture Notes in Computer Science. ISBN 978-3-030-01239-7. Dostupné z: https://doi.org/10.1007/978-3-030-01240-3_17

- [25] SEKUBOYINA, Anjany, Malek E. HUSSEINI, Amirhossein BAYAT, et al. VerSe: A Vertebrae labelling and segmentation benchmark for multi-detector CT images. *Medical Image Analysis* [online]. Elsevier B.V., 2021, 2021-07-22, **73** [cit. 2022-11-25]. ISSN 13618415. Dostupné z: <https://doi.org/10.1016/j.media.2021.102166>
- [26] LÖFFLER, Maximilian T., Anjany SEKUBOYINA, Alina JACOB, et al. A Vertebral Segmentation Dataset with Fracture Grading. *Radiology: Artificial Intelligence* [online]. 2020, 2020-07-01, **2**(4) [cit. 2022-12-23]. ISSN 2638-6100. Dostupné z: <https://doi.org/10.1148/ryai.2020190138>
- [27] LIEBL, Hans, David SCHINZ, Anjany SEKUBOYINA, et al. A computed tomography vertebral segmentation dataset with anatomical variations and multi-vendor scanner data. *Scientific Data* [online]. 2021, 2021-10-28, **8**(1), 284 [cit. 2022-12-23]. ISSN 2052-4463. Dostupné z: <https://doi.org/10.1038/s41597-021-01060-0>
- [28] PAYER, Christian, Darko ŠTERN, Horst BISCHOF a Martin URSCHLER. Coarse to Fine Vertebrae Localization and Segmentation with SpatialConfiguration-Net and U-Net. *Proceedings of the 15th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2020)* [online]. SCITEPRESS - Science and Technology Publications, 2020, 2020-02-27, **5**, 124-133 [cit. 2022-11-25]. ISBN 978-989-758-402-2. Dostupné z: <https://doi.org/10.5220/0008975201240133>
- [29] IQon Spectral CT: The world's first and only detector-based spectral CT. *Philips: Professional Healthcare* [online]. Amsterdam, Nizozemsko: Koninklijke Philips N.V., 2022 [cit. 2022-12-29]. Dostupné z: <https://www.philips.cz/healthcare/product/HCN0CTN284/iqon-spectral-ct>

Seznam symbolů a zkratek

C1 nosič, *lat. atlas*

C2 čepovec, *lat. axis*

C3–C7 krční obratle

Th1–Th12 hrudní obratle

L1–L5 bederní obratle

Co1–Co4/5 kostrční obratle

CT výpočetní tomografie, z *angl. Computed Tomography*

NN neuronová síť, z *angl. Neural Network*

CNN konvoluční neuronová síť, z *angl. Convolutional Neural Network*

ReLU typ aktivační funkce, z *angl. Rectified Linear Unit*

ASPP z *angl. Atrous Spatial Pyramid Pooling*

AHSP z *angl. Attentive Hierarchy Spatial Pyramid*

FFM z *angl. Feature Fusion Module*

EM z *angl. Expectation-Maximization*

EMA z *angl. Expectation-Maximization Attention Unit*

PPD částečná paralelní rozšiřovací cesta, z *angl. Parallel Partial Decoder*

Seznam příloh

A	Hodnocení úspěšnosti segmentace obratlů na databázi VerSe'20	57
B	Obsah elektronické přílohy	64

A Hodnocení úspěšnosti segmentace obratlů na databázi VerSe'20

Tab. A.1: Hodnocení úspěšnosti segmentace obratlů na snímcích ze skupiny validačních dat databáze VerSe'20

Začátek tabulky						
snímek	<i>po implementaci</i>			<i>po modifikaci</i>		
	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>GL017</i>	0,9393	0,9361	3,2083	0,9393	0,9361	3,2083
<i>GL045</i>	0,9330	0,4619	14,7512	0,9330	0,4619	14,7512
<i>GL059</i>	0,9042	0,8916	6,1423	0,9042	0,8916	6,1423
<i>GL068</i>	0,9349	0,9288	3,3699	0,9349	0,9288	3,3699
<i>GL099</i>	0,9258	0,9193	2,9170	0,9258	0,9193	2,9170
<i>GL144</i>	0,9332	0,9280	3,1534	0,9332	0,9280	3,1534
<i>GL153</i>	0,8720	0,8372	4,3790	0,8720	0,8372	4,3790
<i>GL352</i>	0,8804	0,8454	4,9550	0,8804	0,8454	4,9550
<i>GL380</i>	0,9350	0,9271	4,2463	0,9350	0,9271	4,2463
<i>GL479</i>	0,9363	0,9297	3,5787	0,9363	0,9297	3,5787
<i>verse013</i>	0,9412	0,8942	4,8314	0,9412	0,8942	4,8314
<i>verse016</i>	0,9637	0,9594	4,1174	0,9637	0,9594	4,1174
<i>verse018</i>	0,9026	0,8468	4,1714	0,9026	0,8468	4,1714
<i>verse022</i>	0,7675	0,4671	15,8347	0,7675	0,4671	15,8347
<i>verse023</i>	0,9679	0,9657	5,1923	0,9679	0,9657	5,1923
<i>verse024</i>	0,9564	0,9529	4,3978	0,9564	0,9529	4,3978
<i>verse041</i>	0,8427	0,8391	4,6414	0,9505	0,9448	4,7949
<i>verse047</i>	0,9488	0,9439	4,8587	0,9488	0,9439	4,8587
<i>verse067</i>	0,9523	0,9494	4,9319	0,9523	0,9494	4,9319
<i>verse073</i>	0,8869	0,7933	4,3922	0,8869	0,7933	4,3922
<i>verse080</i>	0,9365	0,8770	6,5719	0,9365	0,8770	6,5719
<i>verse093</i>	0,9098	0,9055	9,8325	0,9098	0,9055	9,8325
<i>verse125</i>	0,9353	0,8833	3,3324	0,9353	0,8833	3,3324
<i>verse252</i>	0,9570	0,6085	13,0064	0,9570	0,6085	13,0064
<i>verse264</i>	0,9609	0,9586	3,2134	0,9609	0,9586	3,2134
<i>verse269</i>	0,9523	0,9095	2,9935	0,9523	0,9095	2,9935
<i>verse276</i>	0,9402	0,8946	4,5410	0,9402	0,8946	4,5410
<i>verse090</i>	0,9416	0,9339	4,8252	0,9416	0,9339	4,8252

Pokračování tabulky A.1						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse155</i>	0,9477	0,9043	3,4239	0,9477	0,9043	3,4239
<i>verse209</i>	0,9442	0,9395	2,7012	0,9442	0,9395	2,7012
<i>verse256</i>	0,9658	0,9622	3,8748	0,9658	0,9622	3,8748
<i>verse235</i>	0,9454	0,9425	2,8864	0,9454	0,9425	2,8864
<i>verse290</i>	0,8694	0,8632	3,3433	0,8694	0,8632	3,3433
<i>verse505</i>	0,9639	0,9626	2,7742	0,9639	0,9626	2,7742
<i>verse508</i>	0,9491	0,9045	2,0786	0,9491	0,9045	2,0786
<i>verse511</i>	0,8408	0,7849	3,5478	0,9427	0,8984	3,8968
<i>verse513</i>	0,9050	0,8884	5,8059	0,9050	0,8884	5,8059
<i>verse522</i>	0,9562	0,9553	3,7761	0,9562	0,9553	3,7761
<i>verse529</i>	0,8904	0,0003	32,2793	0,8904	0,0003	32,2793
<i>verse530</i>	0,9096	0,8410	3,2432	0,9096	0,8410	3,2432
<i>verse531</i>	0,7103	0,7254	3,0683	0,9583	0,6925	12,7049
<i>verse545</i>	0,8527	0,7499	3,3080	0,8527	0,7499	3,3080
<i>verse547</i>	0,5072	0,5492	9,4555	0,9393	0,6893	12,3891
<i>verse549</i>	0,7056	0,7339	2,2724	0,9484	0,9420	2,1492
<i>verse553</i>	0,9428	0,9011	3,3223	0,9428	0,9011	3,3223
<i>verse554</i>	0,7644	0,7143	2,3081	0,9231	0,8824	2,4582
<i>verse556</i>	0,8999	0,8748	2,9931	0,8999	0,8748	2,9931
<i>verse559</i>	0,9030	0,9012	2,9601	0,9030	0,9012	2,9601
<i>verse569</i>	0,9504	0,9474	2,7218	0,9504	0,9474	2,7218
<i>verse571</i>	0,9039	0,8959	3,5673	0,9039	0,8959	3,5673
<i>verse573</i>	0,6190	0,6512	2,0315	0,8923	0,9017	2,3037
<i>verse576</i>	0,9536	0,3032	19,2820	0,9536	0,3032	19,2820
<i>verse580</i>	0,9615	0,9613	2,6616	0,9615	0,9613	2,6616
<i>verse585</i>	0,6408	0,6841	2,3068	0,9605	0,9547	2,2304
<i>verse592</i>	0,8559	0,7713	3,5665	0,8559	0,7713	3,5665
<i>verse598</i>	0,8956	0,8857	2,7080	0,9439	0,9389	2,6753
<i>verse600</i>	0,9625	0,9619	3,6021	0,9625	0,9619	3,6021
<i>verse601</i>	0,8884	0,5708	11,5804	0,8884	0,5708	11,5804
<i>verse603</i>	0,8907	0,8469	5,0349	0,8907	0,8469	5,0349
<i>verse606</i>	0,8987	0,6417	8,7591	0,8835	0,6415	12,8209
<i>verse609</i>	0,8206	0,7213	2,2168	0,8206	0,7213	2,2168
<i>verse612</i>	0,9597	0,9592	3,8802	0,9597	0,9592	3,8802

Pokračování tabulky A.1						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse614</i>	0,9538	0,9537	2,1285	0,9538	0,9537	2,1285
<i>verse615</i>	0,9548	0,9527	3,3378	0,9548	0,9527	3,3378
<i>verse618</i>	0,7404	0,7349	2,7998	0,8798	0,8396	2,6988
<i>verse621</i>	0,9615	0,9618	4,4380	0,9615	0,9618	4,4380
<i>verse623</i>	0,8187	0,6465	7,8637	0,9545	0,6602	16,3571
<i>verse627</i>	0,8758	0,8546	2,7246	0,8758	0,8546	2,7246
<i>verse635</i>	0,9589	0,9588	2,8881	0,9589	0,9588	2,8881
<i>verse636</i>	0,9398	0,9334	2,3063	0,9398	0,9334	2,3063
<i>verse640</i>	0,9151	0,8871	2,9917	0,9151	0,8871	2,9917
<i>verse643</i>	0,9398	0,9372	3,4781	0,9398	0,9372	3,4781
<i>verse644</i>	0,8031	0,8177	3,4623	0,9485	0,9379	3,9425
<i>verse645</i>	0,8945	0,8732	2,8179	0,8945	0,8732	2,8179
<i>verse701</i>	0,9314	0,8576	3,7560	0,9314	0,8576	3,7560
<i>verse703</i>	0,9318	0,8556	2,9837	0,9318	0,8556	2,9837
<i>verse705</i>	0,8991	0,9035	5,3985	0,8991	0,9035	5,3985
<i>verse707</i>	0,9063	0,0001	40,9802	0,9063	0,0001	40,9802
<i>verse709</i>	0,9587	0,9559	5,2190	0,9587	0,9559	5,2190
<i>verse711</i>	0,9369	0,8589	4,4276	0,9369	0,8589	4,4276
<i>verse713</i>	0,9272	0,9217	4,5278	0,9272	0,9217	4,5278
<i>verse715</i>	0,9578	0,9567	4,3213	0,9578	0,9567	4,3213
<i>verse717</i>	0,9518	0,8964	3,7710	0,9518	0,8964	3,7710
<i>verse719</i>	0,9262	0,8396	4,6550	0,9262	0,8396	4,6550
<i>verse750</i>	0,9414	0,8995	4,4163	0,9414	0,8995	4,4163
<i>verse753</i>	0,9608	0,8536	2,9988	0,9608	0,8536	2,9988
<i>verse755</i>	0,9422	0,8926	5,8245	0,9422	0,8926	5,8245
<i>verse757</i>	0,9375	0,8851	3,3564	0,9375	0,8851	3,3564
<i>verse759</i>	0,6760	0,6923	6,2982	0,9459	0,9320	5,7974
<i>verse761</i>	0,9495	0,9038	3,5498	0,9495	0,9038	3,5498
<i>verse763</i>	0,9331	0,8658	3,2496	0,9331	0,8658	3,2496
<i>verse765</i>	0,9561	0,9518	4,3350	0,9561	0,9518	4,3350
<i>verse767</i>	0,8878	0,8618	4,5514	0,8878	0,8618	4,5514
<i>verse769</i>	0,9638	0,9620	5,3801	0,9638	0,9620	5,3801
<i>verse802</i>	0,9595	0,9575	3,3183	0,9595	0,9575	3,3183
<i>verse805</i>	0,9594	0,9589	2,8295	0,9594	0,9589	2,8295

Pokračování tabulky A.1						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse806</i>	0,9636	0,9634	7,1246	0,9636	0,9634	7,1246
<i>verse814</i>	0,9513	0,9473	3,5713	0,9513	0,9473	3,5713
<i>verse815</i>	0,9650	0,9646	3,0983	0,9650	0,9646	3,0983
<i>verse816</i>	0,9385	0,8674	3,0172	0,9385	0,8674	3,0172
<i>verse817</i>	0,9599	0,9588	2,8442	0,9599	0,9588	2,8442
<i>verse821</i>	0,9594	0,9568	6,5611	0,9594	0,9568	6,5611
<i>verse826</i>	0,8407	0,7840	2,9526	0,9416	0,8967	3,4907
Konec tabulky						

Tab. A.2: Hodnocení úspěšnosti segmentace obratlů na snímcích ze skupiny testovacích dat databáze VerSe'20

Začátek tabulky						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>GL108</i>	0,9391	0,9338	3,1097	0,9391	0,9338	3,1097
<i>GL146</i>	0,9211	0,9075	4,7408	0,9211	0,9075	4,7408
<i>GL195</i>	0,9328	0,9299	3,7032	0,9328	0,9299	3,7032
<i>GL216</i>	0,9225	0,9126	5,6312	0,9225	0,9126	5,6312
<i>GL217</i>	0,8746	0,8378	4,4652	0,8746	0,8378	4,4652
<i>GL279</i>	0,9349	0,1470	28,1476	0,9349	0,1470	28,1476
<i>GL348</i>	0,9316	0,9274	4,0890	0,9316	0,9274	4,0890
<i>GL419</i>	0,9043	0,8984	5,4409	0,9043	0,8984	5,4409
<i>GL428</i>	0,8706	0,6096	15,0046	0,8706	0,6096	15,0046
<i>GL492</i>	0,8721	0,8165	5,0950	0,8721	0,8165	5,0950
<i>verse020</i>	0,8965	0,1695	23,2313	0,9388	0,1576	24,8645
<i>verse029</i>	0,9602	0,9547	4,6611	0,9602	0,9547	4,6611
<i>verse050</i>	0,9652	0,9603	4,6163	0,9652	0,9603	4,6163
<i>verse054</i>	0,9242	0,8085	5,2791	0,9242	0,8085	5,2791
<i>verse055</i>	0,9438	0,8817	5,9104	0,9438	0,8817	5,9104
<i>verse066</i>	0,9058	0,8035	6,8219	0,9058	0,8035	6,8219
<i>verse070</i>	0,9252	0,8615	6,6461	0,9252	0,8615	6,6461
<i>verse083</i>	0,9342	0,8325	3,4262	0,9342	0,8325	3,4262
<i>verse085</i>	0,8599	0,8031	4,8528	0,8599	0,8031	4,8528

Pokračování tabulky A.2						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse089</i>	0,9724	0,9714	4,0262	0,9724	0,9714	4,0262
<i>verse092</i>	0,8060	0,7955	4,4916	0,9675	0,9655	5,5835
<i>verse101</i>	0,9612	0,9576	3,4666	0,9612	0,9576	3,4666
<i>verse108</i>	0,8236	0,8350	3,0037	0,9634	0,9568	3,0987
<i>verse119</i>	0,9533	0,9501	5,5223	0,9533	0,9501	5,5223
<i>verse130</i>	0,9337	0,8736	3,6019	0,9337	0,8736	3,6019
<i>verse131</i>	0,9637	0,9630	5,2245	0,9637	0,9630	5,2245
<i>verse138</i>	0,9681	0,9677	5,3814	0,9681	0,9677	5,3814
<i>verse143</i>	0,8915	0,7904	5,2723	0,8915	0,7904	5,2723
<i>verse149</i>	0,9154	0,0007	34,8453	0,9154	0,0007	34,8453
<i>verse154</i>	0,9351	0,8705	4,7024	0,9351	0,8705	4,7024
<i>verse217</i>	0,6559	0,4157	3,7457	0,8970	0,4177	32,7945
<i>verse236</i>	0,5436	0,5833	4,4857	0,9561	0,9439	4,9991
<i>verse260</i>	0,9528	0,9048	3,5820	0,9528	0,9048	3,5820
<i>verse271</i>	0,9655	0,9615	4,3475	0,9655	0,9615	4,3475
<i>verse241</i>	0,9467	0,9453	3,6631	0,9467	0,9453	3,6631
<i>verse273</i>	0,9656	0,9594	3,9925	0,9656	0,9594	3,9925
<i>verse247</i>	0,9536	0,9506	3,3195	0,9536	0,9506	3,3195
<i>verse279</i>	0,9531	0,9071	4,2817	0,9531	0,9071	4,2817
<i>verse277</i>	0,9103	0,9084	2,7645	0,9103	0,9084	2,7645
<i>verse278</i>	0,8678	0,8353	2,8867	0,8678	0,8353	2,8867
<i>verse502</i>	0,8822	0,8792	2,8020	0,8822	0,8792	2,8020
<i>verse509</i>	0,9539	0,9503	3,5830	0,9539	0,9503	3,5830
<i>verse512</i>	0,9010	0,8909	4,9805	0,9010	0,8909	4,9805
<i>verse517</i>	0,9536	0,9518	2,1882	0,9536	0,9518	2,1882
<i>verse524</i>	0,9114	0,8982	2,4367	0,9114	0,8982	2,4367
<i>verse526</i>	0,8946	0,8829	3,2826	0,8931	0,8867	3,3977
<i>verse540</i>	0,8640	0,8455	3,0277	0,9559	0,9522	3,0352
<i>verse546</i>	0,9121	0,8302	3,0145	0,9121	0,8302	3,0145
<i>verse550</i>	0,9396	0,9387	2,6846	0,9396	0,9387	2,6846
<i>verse551</i>	0,9592	0,9558	5,3861	0,9592	0,9558	5,3861
<i>verse552</i>	0,9503	0,9479	3,8679	0,9503	0,9479	3,8679
<i>verse555</i>	0,8887	0,8603	2,1575	0,8887	0,8603	2,1575
<i>verse558</i>	0,9502	0,9061	3,6772	0,9502	0,9061	3,6772

Pokračování tabulky A.2						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse560</i>	0,8518	0,8087	2,8387	0,9532	0,9095	3,2177
<i>verse563</i>	0,5327	0,5604	5,1154	0,8980	0,8949	4,4617
<i>verse570</i>	0,9583	0,9559	2,5944	0,9583	0,9559	2,5944
<i>verse572</i>	0,8547	0,8241	2,2903	0,8547	0,8241	2,2903
<i>verse578</i>	0,9606	0,9601	3,0910	0,9606	0,9601	3,0910
<i>verse582</i>	0,7175	0,6739	4,8603	0,9535	0,6431	12,3631
<i>verse587</i>	0,9521	0,9492	3,7091	0,9521	0,9492	3,7091
<i>verse590</i>	0,8923	0,8532	2,6334	0,8923	0,8532	2,6334
<i>verse591</i>	0,8670	0,0001	39,5603	0,8670	0,0001	39,5603
<i>verse597</i>	0,9187	0,8518	3,0214	0,9187	0,8518	3,0214
<i>verse599</i>	0,8073	0,7930	2,6290	0,8995	0,8922	2,5852
<i>verse602</i>	0,7251	0,7570	2,7989	0,9563	0,8592	5,7246
<i>verse604</i>	0,9289	0,8625	1,9972	0,9289	0,8625	1,9972
<i>verse607</i>	0,5493	0,5706	2,5009	0,9422	0,8796	2,7024
<i>verse613</i>	0,9394	0,8981	2,3301	0,9394	0,8981	2,3301
<i>verse616</i>	0,9495	0,9492	3,9960	0,9495	0,9492	3,9960
<i>verse617</i>	0,8618	0,8359	2,0214	0,8618	0,8359	2,0214
<i>verse620</i>	0,9506	0,9477	2,0797	0,9506	0,9477	2,0797
<i>verse626</i>	0,9541	0,9516	3,4971	0,9541	0,9516	3,4971
<i>verse647</i>	0,9393	0,9372	2,7886	0,9393	0,9372	2,7886
<i>verse648</i>	0,8923	0,8427	2,6567	0,8923	0,8427	2,6567
<i>verse649</i>	0,7241	0,7102	5,1615	0,9572	0,9506	3,5341
<i>verse650</i>	0,9110	0,8997	5,5743	0,9110	0,8997	5,5743
<i>verse651</i>	0,9282	0,9260	3,5352	0,9282	0,9260	3,5352
<i>verse700</i>	0,9393	0,8806	3,3699	0,9393	0,8806	3,3699
<i>verse702</i>	0,9272	0,8632	3,4089	0,9272	0,8632	3,4089
<i>verse704</i>	0,9481	0,9440	2,1144	0,9481	0,9440	2,1144
<i>verse706</i>	0,9055	0,8948	3,7621	0,9055	0,8948	3,7621
<i>verse708</i>	0,9541	0,9518	1,8734	0,9541	0,9518	1,8734
<i>verse710</i>	0,9524	0,9513	2,6229	0,9524	0,9513	2,6229
<i>verse712</i>	0,9580	0,9565	3,3716	0,9580	0,9565	3,3716
<i>verse714</i>	0,9378	0,9349	4,0736	0,9378	0,9349	4,0736
<i>verse716</i>	0,9026	0,8276	4,7735	0,9026	0,8276	4,7735
<i>verse718</i>	0,9122	0,8364	2,2280	0,9122	0,8364	2,2280

Pokračování tabulky A.2						
	<i>po implementaci</i>			<i>po modifikaci</i>		
snímek	<i>Dice</i> [-]	<i>Dice_N</i> [-]	<i>HD</i> [mm]	<i>Dice</i> [-]	<i>Dice</i> [-]	<i>HD</i> [mm]
<i>verse751</i>	0,9621	0,9610	4,0782	0,9621	0,9610	4,0782
<i>verse752</i>	0,8433	0,7847	2,2384	0,9412	0,8974	2,3381
<i>verse754</i>	0,8355	0,7446	3,5157	0,8355	0,7446	3,5157
<i>verse756</i>	0,9529	0,9498	2,2870	0,9529	0,9498	2,2870
<i>verse758</i>	0,7365	0,5046	10,3203	0,9340	0,7442	8,6467
<i>verse760</i>	0,9589	0,9572	3,8775	0,9589	0,9572	3,8775
<i>verse762</i>	0,9380	0,9360	3,2434	0,9380	0,9360	3,2434
<i>verse764</i>	0,8921	0,8583	3,0113	0,8921	0,8583	3,0113
<i>verse766</i>	0,7231	0,6985	6,1171	0,9483	0,9364	4,3794
<i>verse768</i>	0,9347	0,0003	34,8835	0,9347	0,0003	34,8835
<i>verse801</i>	0,9125	0,8319	2,4436	0,9125	0,8319	2,4436
<i>verse803</i>	0,8956	0,8993	2,8311	0,8956	0,8993	2,8311
<i>verse804</i>	0,9391	0,9376	2,6414	0,9391	0,9376	2,6414
<i>verse809</i>	0,6898	0,7097	2,9050	0,9579	0,9512	3,1479
<i>verse810</i>	0,9630	0,9627	2,8236	0,9630	0,9627	2,8236
<i>verse813</i>	0,9545	0,9540	2,8543	0,9545	0,9540	2,8543
Konec tabulky						

B Obsah elektronické přílohy

Elektronická příloha této práce obsahuje vybraný model pro segmentaci obratlů od C. Payera a kolektivu s určitými změnami a další vytvořené soubory. Všechny kódy pro segmentaci a její hodnocení jsou vytvořeny v programovacím jazyce *Python* 3.10 a byly spouštěny v programovacím prostředí *PyCharm* verze 2022.2.2.

V příloze nejsou obsaženy samotné natrénované modely z důvodu své velikosti, proto je nutné je před samotným spouštěním algoritmu stáhnout, odkaz na modely: <https://github.com/christianpayer/MedicalDataAugmentationTool-VerSe/tree/master/verse2020/docker/models>.

```
/.....kořenový adresář
├── docker.....soubory pro spuštění Docker Image
│   └── models.....natrénované modely
│       └── README_models.txt
├── interference.....soubory pro testování modelu
├── other.....soubory pro preprocessing
├── pickle.....soubory pro analýzu značení obratlů
├── training.....soubory pro trénování modelu
├── utils.....soubory pro postprocessing
├── verse2020_dataset.....složky s daty
│   ├── data.....vstupní data
│   │   └── README_data.txt
│   ├── tmp.....mezikroky jednotlivých sítí
│   ├── results_christian_payer.....výstupní data
│   └── setup.....soubory pro analýzu anotací a rozdělení dat
├── MAIN_script.py.....hlavní skript pro segmentaci
├── evaluation.py
├── evaluation_analysis.py
├── analysis_for_modification.py
├── modification_for_chosen_data.py.....skript pro modifikaci modelu
├── transform_data_dicom-nifti.py
├── clinical_data_MAIN_script.py.....skript pro segmentaci s modifikací
└── README.txt
```