



FAKULTA APLIKOVANÝCH VĚD
ZÁPADOČESKÉ UNIVERZITY
V PLZNI

KATEDRA
KYBERNETIKY

Bakalářská práce

Segmentace cévních struktur
v jaterním parenchymu

Jana Romová

ZÁPADOČESKÁ UNIVERZITA V PLZNI

Fakulta aplikovaných věd
Akademický rok: 2022/2023

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Jana ROMOVÁ**
Osobní číslo: **A19B0376P**
Studijní program: **B0714A150005 Kybernetika a řídicí technika**
Specializace: **Umělá inteligence a automatizace**
Téma práce: **Segmentace cévních struktur v jaterním parenchymu**
Zadávající katedra: **Katedra kybernetiky**

Zásady pro vypracování

1. Seznamte se s metodami počítačového vidění pro segmentaci v obraze. Zaměřte se na metody vhodné pro segmentaci cévních struktur.
2. Navrhněte metodu pro segmentaci cévních struktur v jaterním parenchymu.
3. Pomocí experimentu ověřte funkčnost navržené metody a funkčnost vhodným způsobem vyhodnoťte.



Rozsah bakalářské práce: **30-40 stránek A4**

Rozsah grafických prací:

Forma zpracování bakalářské práce: **tištěná**

Seznam doporučené literatury:

- Čihák, R. (2002). Anatomie 2. Praha: Grada Publishing.
- Nekula, J., Heřman, M., Vomáčka, J., & Köcher, M. (2005). Radiologie. Univerzita Palackého .
- Sonka, M., Hlavac, V., & Boyle, R. (2014). Image Processing, Analysis, and Machine Vision Second Edition. Thomson-Engineering.
- Tetteh, G., Efremov, V., Forkert, N. D., Schneider, M., Kirschke, J., Weber, B., Zimmer, C., Piraud, M., & Menze, B. H. (2020). DeepVesselNet: Vessel Segmentation, Centerline Prediction, and Bifurcation Detection in 3-D Angiographic Volumes. *Frontiers in Neuroscience*, 14(December), 1–17. <https://doi.org/10.3389/fnins.2020.592352>
- Oliveira, D. A., Feitosa, R. Q., & Correia, M. M. (2011). Segmentation of liver, its vessels and lesions from CT images for surgical planning. *BioMedical Engineering OnLine*, 10(1), 30. <https://doi.org/10.1186/1475-925X-10-30>

Vedoucí bakalářské práce:

Ing. Miroslav Jiřík, Ph.D.

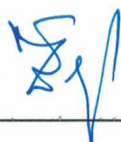
Výzkumný program 1

Datum zadání bakalářské práce:

17. října 2022

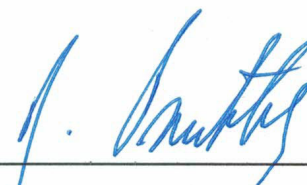
Termín odevzdání bakalářské práce:

22. května 2023



Doc. Ing. Miloš Železný, Ph.D.

děkan



Prof. Ing. Josef Psutka, CSc.

vedoucí katedry

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci samostatně a výhradně s použitím citovaných pramenů, literatury a dalších odborných zdrojů. Tato práce nebyla využita k získání jiného nebo stejného akademického titulu.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona v platném znění, zejména skutečnost, že Západočeská univerzita v Plzni má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona.

Plzeň dne 10. srpna 2023

.....

Jana Romová

V textu jsou použity názvy produktů, technologií, služeb, aplikací, společností apod., které mohou být ochrannými známkami nebo registrovanými ochrannými známkami příslušných vlastníků.

Abstrakt

Bakalářská práce se zaměřuje na využití architektury neuronových sítí U-Net v oblasti medicínského zobrazování pro segmentaci cév v játrech. Medicínské zobrazování, jako je např. CT nebo MRI, poskytuje klíčové informace o anatomických strukturách lidského těla, avšak ruční segmentace cév je náročný a subjektivní úkol. Neuronové sítě se ukázaly jako efektivní nástroj pro automatizaci tohoto procesu.

Práce představuje různé architektury neuronových sítí U-Net a specifické výzvy spojené se segmentací cév, včetně variabilního tvaru cévních struktur a náročnosti na paměť. Výsledky experimentů ukazují, že navržené modely dosahují poměrně dobré kvality pro úlohy segmentace cév a cévních centrálních linií.

Abstract

The bachelor's thesis focuses on the utilization of the U-Net neural network architecture in the field of medical imaging for vessel segmentation in the liver. Medical imaging, such as CT or MRI, provides crucial information about anatomical structures within the human body. However, manual vessel segmentation is a demanding and subjective task. Neural networks have proven to be an effective tool for automating this process.

The thesis presents various U-Net neural network architectures and specific challenges associated with vessel segmentation, including variable vessel shapes and memory requirements. Experimental results demonstrate that the proposed models achieve relatively good quality for vessel segmentation tasks and vascular centerline extraction.

Klíčová slova

segmentace • cévy • játra • CT • Deepvesselnet • neuronové sítě • U-Net

Poděkování

Na tomto místě bych ráda poděkovala zejména Ing. Miroslavu Jiříkovi, Ph.D., který mne problematikou segmentace pomocí neuronových sítí v oblasti medicíny vede již třetím rokem, a to v rámci různých projektů a nyní i bakalářské práce. Dále bych chtěla poděkovat výzkumnému týmu pana prof. Lišky, který poskytl mikro-CT snímky jater prasat domácích, které byly pořízeny v rámci výzkumné činnosti na Lékařské fakultě univerzity Karlovy v Plzni. Poděkování také zaslouží projekt Deepvesselnet, jež poskytl kvalitní trénovací data.

Obsah

1	Úvod	3
2	Zobrazovací a segmentační metody	4
2.1	Zobrazovací metody v medicíně	4
2.1.1	Ultrazvuk	4
2.1.2	Rentgen	6
2.1.3	Výpočetní tomografie	7
2.1.4	Výpočetní mikrotomografie	9
2.1.5	Magnetická rezonance	10
2.2	Metody segmentace obrazu	11
2.2.1	Prahování	11
2.2.2	Růst oblastí	13
2.2.3	Detekce hran	13
3	Neuronové sítě	16
3.1	Struktura	16
3.1.1	Model neuronu	16
3.1.2	Propojení sítě	17
3.2	Proces učení	21
3.2.1	Učení	21
3.2.2	Data	21
3.3	Vyhodnocení	22
3.3.1	Metriky přesnosti	22
3.3.2	Metriky ztráty	26
4	Experiment	28
4.1	Data	28
4.1.1	Trénovací, validační a testovací dataset	28
4.1.2	Snímky jaterních cév	30
4.2	Neuronové sítě	31
4.2.1	U-Net	33

4.2.2	Učení a vyhodnocení na datasetu Deepvesselnet	33
4.3	Aplikace na snímcích jaterních cév prasat	36
4.4	Shrnutí a návrh možných vylepšení	39
5	Závěr	43
	Bibliografie	44
	Seznam obrázků	47
	Seznam tabulek	48

Interpretace medicínských obrazů je velmi častá úloha. Segmentace obrazů je v medicíně důležitá zejména pro jemné struktury, u kterých potřebujeme vědět co nej-přesněji jejich umístění a strukturu. Zejména máme na mysli cévy v různých organických strukturách. Segmentace může být prováděna člověkem, je však velmi nákladná na čas a expertní znalosti. Odborník musí mít medicínské znalosti a zkušenosti z praxe, aby byl schopen odhadnout 3D povahu dat z jednotlivých řezů celkového obrazu, které se zobrazují na monitoru. Výsledná data mohou být zkusena osobním názorem odborníka, proto se u složitých obrazů vyžaduje názor více expertů, což zvyšuje časovou nákladnost úlohy. Náročnost na čas také může pozdržet léčbu, proto je snaha o urychlení, nebo nahrazení této metody její zautomatizovanou alternativou.

Automatická segmentace cév je náročný, pro většinu medicínských aplikací stále nevyřešený problém, zejména kvůli velké různorodosti spojené s různými modalitami obrazů, kódovacími parametry přístrojů a organickou variabilitou zkoumaných objektů. I pokud úlohu omezíme na jeden druh a tkáň, ve které cévy hledáme, vznikají výrazné odchylky pro každého jedince. Pro účel segmentace v medicíně se v dnešní době nejčastěji používají hluboké neuronové sítě, zejména pak architektura U-Net, která je schopna zpracovat 2D a 3D data a vytvořit obraz segmentovaných struktur ve stejném rozměru. Je ovšem nutné si uvědomit, že pokud takto získaná data chceme použít k diagnostice pacienta či naplánování chirurgického zákroku, je vždy třeba data zkontrolovat expertem a použít je pouze jako nápomocný prostředek k finálnímu rozhodnutí.

Zobrazovací a segmentační metody

2

Medicínské zobrazovací metody jsou procesy zobrazování vnitřní tkáně zejména pro klinickou analýzu, plánování lékařských zásahů, stejně tak jako pro vizuální reprezentaci funkce některých orgánů nebo tkání. Proces zobrazování v medicíně také vytváří databázi obecné anatomie a fyziologie. Díky těmto poznatkům je možné identifikovat abnormality a zavčas navrhnout metodu péče o pacienta.

Proces segmentace medicínských dat je důležitou součástí diagnostiky nejruznějších onemocnění a analýzy struktur v živých organismech.

2.1 Zobrazovací metody v medicíně

Ačkoli zobrazování a modelování již odebraných orgánů a tkání může být provedeno z lékařských důvodů, jsou takové postupy obvykle považovány za součást patologie spíše než za medicínské zobrazování. Měřicí a záznamové techniky, které nejsou primárně navrženy pro tvorbu obrazů, jako například elektroencefalografie (EEG), magneticko-rezonanční angiografie (MRA), magnetoencefalografie (MEG), elektrokardiografie (EKG), rentgen atd., představují technologie, které produkují data vhodná k reprezentaci parametrů živé tkáně jako graf závislosti na čase nebo 3D/2D mapy obsahující informace o místech měření. Tyto technologie lze považovat za metody medicínského zobrazování.

2.1.1 Ultrazvuk

Ultrazvuková diagnostika, známá také jako ultrazvukové zobrazování nebo sonografie, je neinvazivní diagnostická metoda, která využívá vysokofrekvenční zvukové vlny k vytváření obrazů vnitřních tkání, orgánů a cév v těle. Ultrazvukový přístroj vysílá zvukové vlny do těla a zachycuje návratné odrazy těchto vln od tkání. Na základě těchto odrazů se vytváří obrazový průřez zkoumané oblasti.

Hlavní výhodou ultrazvukové diagnostiky je neinvazivnost. Ultrazvuk je jedna z nejméně invazivních zobrazovacích metod, neboť nepoužívá žádné ionizující zá-

ření. To znamená, že nepředstavuje žádné riziko ozáření pro pacienta. Ultrazvuk je vhodný pro opakované použití, a proto je oblíbeným nástrojem při sledování průběhu léčby, nebo pomůckou pro vyšetření těhotných žen. Další jeho výhodou je zobrazování v reálném čase. Ultrazvukový snímač může poskytovat real-time obrazy, což umožňuje lékařům sledovat pohyb orgánů, například srdečních chlopní, a dynamické procesy, jako je proudění krve. Ultrazvukové zařízení je obvykle cenově dostupné ve srovnání s jinými zobrazovacími metodami a je relativně snadno transportovatelné, což umožňuje provádění vyšetření v různých klinických prostředích a podmínkách. Ultrazvuk má využití v různých oborech medicíny, včetně gynekologie, porodnictví, kardiologie, gastroenterologie, urologie a dalších.

Nevýhodou ultrazvuku je omezený kontrast tkání. I když ultrazvuk poskytuje cenné informace o tkáních a orgánech, jeho schopnost zobrazovat různé tkáně zřetelně může být omezená ve srovnání s jinými metodami, jako je např. MRI nebo CT. [VVH]

2.1.1.1 Dopplerova sonografie

Speciální varianta ultrazvukové diagnostiky je tzv. Dopplerova ultrasonografie, která se zaměřuje na zobrazení rychlosti a směru průtoku krve v cévách a tepnách. Tato technika je pojmenována po německém fyzikovi Christianu Dopplerovi, který popsal Dopplerův efekt, což je změna frekvence zvuku nebo světla pozorovaná při pohybu zdroje zvuku nebo světla vzhledem k pozorovateli.

Základní princip Dopplerovy sonografie spočívá v tom, že ultrazvukové vlny jsou vysílány do průtoku krve v cévách a tepnách. Když se červené krvinky pohybují směrem k ultrazvukové sondě, frekvence odražených vln se zvyšuje (tzv. pozitivní Dopplerův posun). Naopak, když se krvinky pohybují směrem od sondy, frekvence se snižuje (tzv. negativní Dopplerův posun). Z těchto změn frekvence lze získat informace o rychlosti průtoku krve, směru a charakteristikách cévního systému.

Dopplerova ultrasonografie se využívá pro mnoho různých vyšetření, jako např. hodnocení cirkulace, diagnostiku cévních onemocnění, sledování průtoku krve, těhotenské sonografie a pozorování srdce. [Bc]

2.1.1.2 Využití pro segmentaci cév

Ultrazvuk obvykle poskytuje velmi zašuměný videozáznam. U většiny ultrazvuků je také nutné, aby se s nimi ručně manipulovalo během vyšetření. Záznamy se od sebe mohou velmi lišit, a nemají vysokou kvalitu. Z těchto důvodů se data z ultrazvuku nedají doporučit pro segmentaci cév. Velkým přínosem ale zůstává možnost získat časový záznam toku krve v cévách.

2.1.2 Rentgen

Rentgenové záření je forma elektromagnetického záření o vlnových délkách 10 nm až 1 pm. Využívá se především při lékařských vyšetřeních, geologii, průmyslu, optice, nebo chemii. Jedná se o formu ionizujícího záření a jako takové může být nebezpečné živým organismům. Pro člověka nastává riziko pouze při opakovaném snímání. Dlouhodobé a nadměrné vystavení rentgenovému záření může zvýšit riziko poškození buněk a následně vést ke vzniku nádorů, proto se lékaři snaží minimalizovat expozici pacientů a personálu rentgenovému záření pomocí moderních technik a protokolů.

Rentgenové záření má krátkou vlnovou délku a vysokou energii, což mu umožňuje pronikat materiály, včetně lidského těla. Tato schopnost průchodu materiály umožňuje rentgenovým paprskům vytvářet obrazy vnitřní struktury objektů, což má široké využití v lékařství. Nejčastěji bývá využito pro zobrazení detailů kostí a zubů, popřípadě za pomoci vhodných technik i ke zkoumání měkké tkáně (denzitografie, subtrakční skiografie, mamografie, angiografie, vyšetření plic).

Celkově vzato, rentgenové záření je důležitým nástrojem v lékařství a průmyslu pro zobrazování vnitřní struktury objektů, ale vyžaduje opatření k minimalizaci rizik spojených s jeho použitím. [Jan+16] [Nek+05]


2.1.2.1 Angiografie

Pojem angiografie je obor zkoumání cév a oběhové soustavy. V dnešní medicíně se pojmem angiografie myslí vyšetření koronárních tepen v okolí srdce pod rentgenem, či jiným snímacím zařízením(2.1). Ke kvalitnímu zobrazení koronárních tepen a dalších cévních struktur je při vyšetření nezbytné intravenózní zavedení kontrastní látky přímo do dané cévy a správné načasování snímání, aby bylo možno získat optimální zobrazení cíleného místa a časového průběhu šíření kontrastní látky. Díky tomu je možné získat informace o toku krve a případných blokacích, které by bylo třeba odstranit. Pro některá vyšetření je také nutné, aby pacient zadržel dech, vůbec nedýchal, či měl zpomalený tlukot srdce. I když je tedy vyšetření pacienta rentgenem vcelku neškodné, samotná angiografie je poměrně náročná vyšetřovací metoda.

Důležitou součástí vyšetření srdce a koronárních tepen je tzv. *post-processing*, tedy zpracování dat a diskuze získaných snímků odborníky. Pro hodnocení objemů a funkce srdečních komor jsou využívány specializované programy. [Asc08] [Čih97]

2.1.2.2 Využití pro segmentaci cév

Rentgenové snímky nejsou vhodné pro zobrazení měkké tkáně, ale spíše pro vyšetření kostí. Pro vyšetření cévní soustavy se rentgen používá např. při angiografii, což



Obrázek 2.1: Barevná rekonstrukce CT angiografie embolií (Obr. 1), vpravo: CT angiografie embolií při pohledu směrem od hlavy k patám (Obr. 2) [Asc08]

je vyšetření největších cév v lidském těle, a to s využitím kontrastní látky. Z toho důvodu nelze rentgenové snímky pro segmentaci cév doporučit.

2.1.3 Výpočetní tomografie

Počítačová tomografie (Computed Tomography, CT) je diagnostická metoda z oblasti medicíny, která umožňuje vytvářet detailní obrazy vnitřních struktur těla. CT skenuje tělo pomocí rentgenového záření a vytváří tenké průřezy (řezy) tkáně nebo orgánů, které jsou následně spojeny do 2D nebo 3D obrazů.

Základní princip CT spočívá v tom, že zkoumaný objekt leží na pohyblivém lůžku, zatímco kolem něj v kruhové trajektorii obíhá zařízení schopné pořizovat rentgenové snímky. Rentgenové záření prochází objektem, kde různé tkáně pohlcují toto záření v různé míře (kosti nejvíce, dutiny nejméně) a dopadá na detektor. Zkoumaný objekt je prozářen z nejrůznějších úhlů v jedné rovině, čímž získáme několik snímků jednoho řezu. Tyto snímky je potom díky výkonnému počítači, možno složit a vytvořit jeden plošný řez. Vzniklé řezy se dají složit za sebe pro vytvoření 3D obrazu.

Záznamy pořízené tomografem (2.2) je možno zobrazit medicínskými programy z různých úhlů, či v jiných barevných intenzitách. Díky tomu je možné zobrazení jen tkání se stejnou mírou pohlcování záření. Pokud mají různé tkáně podobnou hodnotu prahové hustoty (stejnou míru pohlcování záření), může být nemožné je jednoduše oddělit úpravou parametrů volumetrického zobrazení. Řešením je segmentace, nebo v některých případech použití kontrastní látky. Během celého procesu snímání může také vzniknout šum na datech (např. u obézních pacientů vzniká šum pohlcováním záření v podkožních tukových vrstvách). [Asc08]



Obrázek 2.2: CT tomograf [Ven]

CT má několik výhod, jako např. rychlost a detailní zobrazování. Výpočetní tomografie je rychlé vyšetření, které poskytuje detailní obrazy středně velkých struktur (např. kostí, orgánů, cév). Jednou z hlavních výhod je také vysoký kontrast tkání. Oproti rentgenu je CT schopna zobrazovat různé druhy tkání s vysokým kontrastem, což umožňuje rozlišit různé struktury. Z tohoto důvodu se také používá při nutnosti rychlého vyšetření a diagnostiky např. na traumatologii.

CT má také některá rizika a omezení, neboť používá ionizující rentgenové záření. Vystavení častým vyšetřením pomocí CT může mít potenciálně negativní vliv na zdraví. Další nevýhodou jsou omezení pro některé pacienty. Těhotné ženy a děti, by měly být skenovány pouze v případech, kdy je to absolutně nezbytné. I když CT je schopna zobrazovat různé tkáně, kontrast mezi nimi může být omezený ve srovnání s jinými metodami, jako je např. MRI. Přesto je CT významným nástrojem v diagnostice různých onemocnění a poruch, a má široké spektrum aplikací v různých oborech medicíny, včetně traumatologie, onkologie, kardiologie a dalších. [Nek+05]

Volumetrické zobrazení: je technika používaná k vytvoření 3D souboru z 2D dat, které snímá tomografický skener. Tyto projekce jsou obvykle získávány pravidelně, např. jeden řez každý milimetr, a mají obvykle pravidelný počet obrazových pixelů v pravidelném vzoru. To je příklad pravidelného objemového mřížování, kde každý objemový prvek nebo voxel je reprezentován jedinou hodnotou získanou vzorkováním jeho okolí. Velkou výhodou medicínských dat, je

jejich neměnnost v rámci jednoho souboru. Všechny řezy mají konstantní rozměr, barevné spektrum i stejné podmínky za kterých byly řezy pořízeny. [Asc08]

2.1.3.1 Využití pro segmentaci cév

Přesnost zobrazování výpočetní tomografie se pohybuje v rámci jednotek milimetrů (3-5 mm). Tato přesnost stačí pro použití ve většině segmentačních úloh. Pro vyšetření jemných biologických struktur, jako např. vlásčnice, je nutno využít přesnější zobrazovací metody např. mikro-CT, MRA. [CFO11]

2.1.4 Výpočetní mikrotomografie

V radiografii se používá rentgenová mikrotomografie (Mikro-CT) k vytváření průřezů fyzického objektu pomocí rentgenového záření. Tyto průřezy lze použít k vytvoření virtuálního modelu (3D modelu) bez poškození původního objektu. Rentgenová mikrotomografie je podobná tomografii a výpočetní tomografii (CT). Předpona "mikro" se používá proto, že velikosti pixelů v průřezích jsou v rozmezí mikrometrů, zatímco u běžného CT se pohybují v jednotkách milimetrů.

Mikro-CT má aplikace jak v medicínském zobrazování, tak v průmyslové výpočetní tomografii. Obecně existují dva typy uspořádání skenerů. V prvním uspořádání je rentgenový zdroj a detektor během snímání obvykle v klidu, zatímco zkoumaný objekt rotuje. Druhé uspořádání, které je více užíváno u klinické výpočetní tomografie, je založeno na opačném systému, kde objekt je v klidu, zatímco kolem něj rotují rentgenová trubice s detektorem. Tyto skenery se obvykle používají pro malá zvířata, biomedicínské vzorky, potraviny, mikrofosilie a další studie, pro které je požadován drobný detail. [Asc08][Jiř+18]

2.1.4.1 Využití pro segmentaci cév

Mikro-CT snímky se dají velmi dobře použít pro segmentaci cévních struktur v těle a některých orgánech. Větší cévy je snadné určit i v játrech která, jsou velmi hustě prokrvená, a tedy špatně přehledná. Není ovšem vždy možné rozlišit malé cévy a vlásčnice, kde je malý rozdíl v pohlcení mezi cévou a okolní tkání. Pro účely výzkumu se dá použít metoda, kde se zkoumaný orgán vyjme a do cév se vstříkne hmota na bázi pryskyřice. Po zatvrdnutí této hmoty se orgán vloží do roztoku, který odstraní původní tkáň tak, aby zbyl pouze odlitek cév. Tímto postupem lze získat fyzický 3D model cévního stromu. Pro snadnější zkoumání se odlitek vloží do mikro-CT a naskenuje do počítače, kde je možno vidět přehledně i dovnitř modelu. Tento postup ale nelze použít u živých subjektů.[Jiř+18][Jiř+16][Čih02]

2.1.5 Magnetická rezonance

Magnetická rezonance (Magnetic Resonance Imaging, MRI) je sofistikovaná diagnostická metoda v oblasti medicíny, která umožňuje neinvazivní vizualizaci vnitřních tkání a orgánů lidského těla. MRI využívá silná magnetická pole a rádiové vlny k vytváření detailních obrazů struktur tkání. Základní princip MRI spočívá v tom, že jádra vodíku v těle reagují na aplikované magnetické pole a rádiové pulzy. Tato jádra se začnou chovat jako malé magnety a emitují rádiové signály, které jsou následně zachyceny a analyzovány skenerem MRI. Z těchto dat se poté vytváří obrazový průřez těla, který zobrazuje různé tkáně a struktury na základě jejich charakteristických magnetických vlastností. MRI má několik výhod oproti jiným metodám zobrazování, jako je např. CT (počítačová tomografie). Mezi ně patří:

- **Neinvazivnost:** Vyšetření MRI nepoužívá ionizujícího záření, což znamená, že nepředstavuje riziko pro pacienta.
- **Vysoký kontrast tkání:** MRI má schopnost zobrazovat různé typy tkání vysokým kontrastem, což umožňuje lékařům rozlišovat mezi různými strukturami.
- **Všestrannost:** Díky vysokému kontrastu zobrazení se dá MRI použít pro široké spektrum medicínských vyšetření.
- **Dynamické zobrazování:** MRI může zachytit pohyb v těle, což je užitečné například pro zobrazení srdeční činnosti nebo proudění krve.

MRI má však také některá omezení a kontraindikace. Některé kovové implantáty nebo zařízení, jako např. kardiostimulátory, mohou ovlivnit průběh MRI. Pro některé skupiny pacientů je lépe vyšetření pomocí MRI vynechat (např. pro těhotné ženy v prvním trimestru může MRI představovat riziko pro plod). Celkově je MRI důležitým nástrojem v diagnostice a sledování různých onemocnění a stavů. Používá se v různých specializacích medicíny, včetně neurologie, ortopedie, kardiologie a onkologie, a má klíčový význam pro poskytování komplexní péče pacientům.[Lim+08][Asc08]

2.1.5.1 Magneticko-rezonanční angiografie

Magneticko-rezonanční angiografie (MRA) je skupina technik založených na magnetické rezonanční tomografii (MRI), které slouží k zobrazování krevních cév. Magneticko-rezonanční angiografie se používá k vytváření obrazů tepen (a méně často žil), aby byly hodnoceny na případné zúžení (abnormální zužování), uzávěry (bloky cév sraženinou), aneurysma (nadměrné rozšíření cévy až k prasknutí), nebo jiné

nepravidelnosti. MRA je často používána k vyšetření tepen v krku, v mozku, hrudní a břišní aorty, renálních tepen nebo tepen dolních končetin. [Asc08] [Lim+08]

2.1.5.2 Využití pro segmentaci cév

Magnetická rezonance je velmi přesná a poskytuje kvalitní data. Vyšetření je ale nákladné, proto se v dnešní době pro zobrazení cév používá jen v případech, kde je nutné velké rozlišení snímků (např. vyšetření cév mozku).

2.2 Metody segmentace obrazu

V oblasti zpracování a analýzy obrazu existuje řada segmentačních metod, které umožňují rozdělení obrazu na jednotlivé části nebo objekty. V dnešní době mají velký význam také metody založené na neuronových sítích. Vlastnosti neuronových sítí jsou popsány v samostatné kapitole (3).

2.2.1 Prahování

Jednou z nejzákladnějších a nejrozšířenějších metod je metoda prahování (thresholding). Tato metoda se vyznačuje svou jednoduchostí a efektivitou, což ji činí vhodnou pro aplikace v různých oborech.


Metoda prahování je proces rozdělení obrazu na dvě části (popředí, pozadí) na základě určitého prahu intenzity pixelů. Tento práh je hodnota intenzity, která odděluje pixely příslušející k popředí (hledané objekty) od těch, které přísluší k pozadí (okolí). Pokud je hodnota intenzity pixelu větší než práh, pixel je přiřazen k do třídy popředí, v opačném případě je zařazen do třídy pozadí. Metodu prahování lze matematicky vyjádřit následovně:

$$f(c) = \begin{cases} A, & \text{pokud } c > \text{ než práh} \\ B, & \text{pokud } c \leq \text{ než práh} \end{cases}$$

kde:

- c je intenzita aktuálního pixelu,
- $f(c)$ je výsledná intenzita pixelu,
- práh je prahovací hodnota,
- A je hodnota intenzity kterou budou v segmentovaném obraze vykresleny pixely popředí, obvykle je nastavena na 1,
- B je hodnota intenzity kterou budou v segmentovaném obraze vykresleny pixely pozadí, obvykle je nastavena na 0.

Hodnota prahu může být zvolena empiricky nebo na základě analýzy obrazu. Histogram obrazu zobrazuje rozložení intenzit pixelů v obraze. Analýzou výkyvů v těchto datech se dá usnadnit proces hledání prahu. Ukázka segmentace pomocí prahování je ukázána na obr. (2.3).



Obrázek 2.3: Ukázka segmentace pomocí metody prahování: a) Původní obrázek, b) Segmentace prahováním s optimální hodnotou prahu, c) Segmentace prahováním s příliš vysokou hodnotou prahu, d) Segmentace prahováním s příliš nízkou hodnotou prahu [SHB06]

Metoda prahování má několik výhod, včetně jednoduchosti implementace a rychlosti výpočtu. Je vhodná pro segmentaci objektů s výrazným kontrastem v intenzitě pixelů. Nicméně metoda může selhat v případech, kdy kontrast mezi objekty a pozadím není dostatečný nebo když není obraz rovnoměrně osvětlen a dochází k zobrazení objektu v různých intenzitách. Metoda prahování se často využívá v oblastech, jako je lékařské zobrazování pro segmentaci kostí, automatické rozpoznávání textu v dokumentech, nebo analýzu snímků mikroskopie. [SHB06]

2.2.2 Růst oblastí

Metoda růstu oblastí (Region Growing) je jednou z pokročilých metod segmentace, která se zaměřuje na identifikaci oblastí v obraze na základě podobnosti intenzity pixelů. Tato metoda využívá algoritmický přístup k segmentaci obrazu, který spočívá v postupném přidávání sousedních pixelů do již segmentovaných oblastí na základě určitého kritéria podobnosti (jas, pravděpodobnostní funkce). Metoda předpokládá, že sousední pixely s podobnými hodnotami intenzity by měly tvořit spojitou oblast, kterou lze považovat za objekt.

Prvním krokem je výběr počátečního pixelu či pixelů, které bude sloužit jako základní body růstu. Pixely mohou být rozmístěny náhodně nebo na základě určitých kritérií např. v dané vzdálenosti od sebe. Algoritmus následně porovnává hodnotu intenzity každého počátečního pixelu s hodnotami intenzity jeho sousedních pixelů. Pokud hodnoty intenzity sousedních pixelů splňují stanovené kritérium podobnosti (např. rozdíl intenzit je menší než určitá prahová hodnota), jsou tyto pixely přidány do regionu. Pro každý nově přidávaný pixel jsou opakovány kroky porovnání s okolními pixely a přidání do regionu. Tímto způsobem se region postupně rozšiřuje a objevují se nové segmentované oblasti. Oblast pokračuje v růstu, dokud nejsou splněny zastavovací podmínky např. dosažení maximálního počtu pixelů v regionu nebo nedosažitelnost nových pixelů, které by splňovaly podmínku podobnosti.

Výhodou metody růstu oblastí je schopnost identifikovat regiony s nepravidelnými tvary a různými intenzitami. Je zároveň odolná proti šumu v obraze. Potíže mohou nastat v případě, že regiony s podobnými intenzitami nejsou odděleny hranou či jiným přerušením. Metoda růstu oblastí je využívána např. v průmyslu pro kontrolu kvality a identifikaci vad na povrchích. V medicíně se používá pro segmentaci orgánů, analýzu mikroskopických snímků pro identifikaci buněk a jejich částí atd. [SHB06]


2.2.3 Detekce hran

Metoda detekce hran (Contour based segmentation) se zaměřuje na identifikaci hran a hraničních kontur objektů v obraze. Na těchto místech dochází k výrazným změnám intenzity pixelů, což může indikovat přítomnost objektů nebo struktur v obraze.

Pro obraz je nejprve nutné spočítat gradient jasové funkce. S rostoucí změnou jasu v obraze, bude růst i hodnota gradientu, čímž dojde k zvýraznění hran na obraze. Pro zlehčení výpočtu se obvykle detekují hrany pouze ve čtyřech směrech. Dobrou možností je také místo gradientu použít konvoluci s vhodně zvolenou maskou např. $(-1, 1)$, $(1, 0, -1)$.

Na obraz se zvýrazněnými hranami se následně použije metoda prahování. Práh je volen tak, aby prahovával segmentovalo pouze hrany, a vyčistil se tak zbytek obrazu.

Segmentované hrany mohou být spojeny nebo aproximovány funkcí pro získání konečného obrazu kontur. Proces detekce hran je zobrazen na obrázku (2.4)



Obrázek 2.4: Ukázka segmentace pomocí metody detekce hran: a) Původní obrázek, b) Obraz po provedení konvoluce, c) Obraz po provedení prahování [SHB06]

Různé metody detekce obrysů nabízejí různé přístupy k zachycení hran a hraničních kontur. Existuje několik metod vhodných pro detekci obrysů:

- **Sobelův operátor:** používá konvoluci se specifickou maskou:

$$\begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix},$$

kteřá umožňuje lepší detekci horizontálních a vertikálních hran.

- **Prewittové operátor:** Podobně jako u Sobelova operátoru se soustředí na detekci horizontálních a vertikálních hran, využívá ale jinou masku pro konvoluci.

$$\begin{pmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{pmatrix}$$

Masku lze také rozšířit:

$$\begin{pmatrix} -2 & -2 & -2 & -2 & -2 \\ -1 & -1 & -1 & -1 & -1 \\ 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 \\ 2 & 2 & 2 & 2 & 2 \end{pmatrix}.$$

Platí, že s rostoucí dimenzí konvoluční masky se zvyšuje odolnost metody vůči šumu.

- **Robertsův křížový operátor:** Jedná se o jednoduchý operátor pro detekci šikmých hran, využívající dvě konvoluce s maskami:

$$\begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix} \text{ a } \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}.$$

Detekce obrysů je citlivá na šum v obraze, a proto se u dat vyžaduje předzpracování filtrací. Správný výběr operátoru a hodnoty prahu může významně ovlivnit kvalitu detekce. Metoda může také vyžadovat dodatečné úpravy pro správné zachycení objektů s různými tvary a velikostmi. Jedná se o segmentační metodu velmi náročnou na kvalitu dat.

Detekce obrysů je klíčovou technikou pro analýzu struktury obrazu a identifikaci objektů. Tato technika je nezbytná pro mnoho aplikací, které vyžadují identifikaci objektů na základě jejich tvarů a struktur v obraze, např. strojové vidění, medicínské zobrazování, segmentace obrazu atd. [Bib+17][SHB06]

Neuronové sítě

3

Neuronové sítě (NNs - neural networks) jsou zajímavou alternativou, vedle klasických segmentačních metod, jako např. thresholding, borderline segmentation nebo boundary tracking. Pro úlohy segmentace v medicíně mají neuronové sítě obecně lepší výsledky, a jsou účinnější v segmentaci u různých jedinců, díky jejich schopnosti zobecňování hledaných příznaků.

Neuronové sítě jsou oblast umělé inteligence zabývající se řešením úloh pomocí architektur připomínající biologické struktury, zejména nervovou soustavu. Jejich aplikace zahrnují např. kompresi, segmentaci, rozpoznávání či analýzu obrazu (např. CT a rentgenové snímky) a analýzu akustických stop (např. záznam řeči) či elektrických signálů (např. záznamy EKG a EEG). V medicínských oborech se neuronové sítě používají jako pomocný nástroj pro diagnostiku onemocnění či k prohlubování znalostí o fungování systémů živých organismů, mají však spoustu dalších aplikací v oborech geologie, mechaniky, meteorologie atd.[SHB06] [Mou+20]

3.1 Struktura

Struktura neuronové sítě se liší v závislosti na úloze, kterou chceme vzniklým modelem řešit. Všechny neuronové sítě se ovšem skládají z neuronů a jejich propojení.

3.1.1 Model neuronu


Umělá neuronová síť se skládá z neuronů propojených navzájem vazbami, kterými si předávají signály a transformují je tzv. aktivačními přenosovými funkcemi. Každý neuron může mít libovolné množství vstupů, ale pouze jeden výstup. Ačkoli je mnoho modelů neuronů, jeden z nejpoužívanějších je model (3.1), popsáný rovnicí:

$$Y = f \left(\sum_{i=1}^N (w_i x_i) - \Theta \right),$$

kde:

- x_i jsou vstupy neuronu,

- w_i jsou synaptické váhy (udává důležitost informace daných vstupů),
- Θ je práh,
- f je aktivační přenosová funkce,
- y je výstup neuronu.




Obrázek 3.1: Model neuronu

Pro řešení složitějších úloh je nutný nelineární systém. Aktivační přenosové funkce zavádí do neuronové sítě nelinearitu a umožňují řešení komplexních úloh s menším počtem neuronů. S větším počtem neuronů je síť schopná vytvořit komplexnější aproximační funkce. Jedny z nejpoužívanějších přenosových funkcí v neuronových sítích jsou funkce sigmoida a ReLU (rectified linear unit). (3.2)

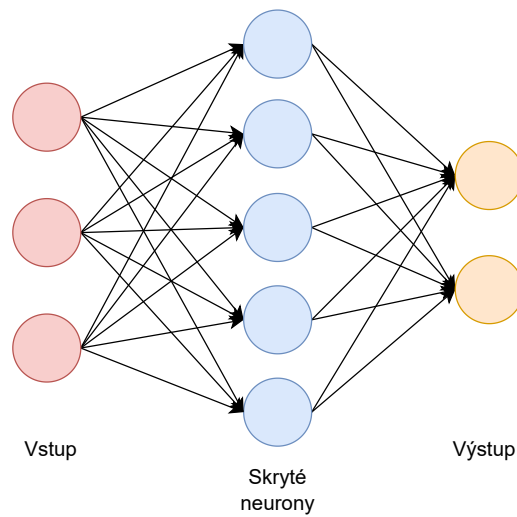
ReLU je nejčastěji definovaná jako $f(x) = \max(0, x) = \frac{x+|x|}{2}$ s prahem Θ v nule, není tedy omezená shora. Sigmoida je definovaná jako $f(x) = \frac{1}{1+e^{-\lambda(x-\Theta)}}$ a je omezená shora i zdola, nabývá hodnot od 0 do 1. Obě tyto funkce jsou vhodné pro transformování výstupu neuronu pro další užití v síti. [Kři21]

3.1.2 Propojení sítě

Neurony jsou obvykle organizovány do více vrstev, zejména při hlubokém učení. Název hluboké neuronové sítě vychází ze skutečnosti, že se jedná o hierarchické architektury s velkou hloubkou, tedy velkým množstvím neuronových vrstev, ve kterých probíhá transformace dat. Přesněji řečeno jde o počet transformací dat cestou ze vstupu (vstupní vrstva) na výstup (výstupní vrstva). Mezi nimi se může nacházet libovolný počet skrytých vrstev. (3.3) Využívají se také jednovrstvé a bezvrstvé neuronové sítě, neboť už s jednou vrstvou je síť schopna aproximovat libovolnou vektorovou funkci. Přidáváním dalších vrstev se nezlepšuje aproximační schopnost sítě, ale množství extrahovatelných vlastností ze vstupních dat. Větší počet vrstev tedy zefektivňuje proces učení.



Obrázek 3.2: Aktivační funkce



Obrázek 3.3: Struktura neuronové sítě

Mezi dvěma vrstvami je možné více vzorů spojení. Mohou být tzv. "plně propojeny", přičemž každý neuron v jedné vrstvě se spojí s každým neuronem v další vrstvě, nebo mohou být "sdružené", kdy se skupina neuronů v jedné vrstvě spojí s jedním neuronem v následující vrstvě a sníží tak počet neuronů v ní. Neurony s pouze takovými spojeními tvoří řízený acyklický graf a jsou známé jako dopředné sítě. Alternativně jsou sítě, které umožňují spojení mezi neurony ve stejných nebo předchozích vrstvách, známé jako sítě rekurentní.

Aktivační funkce (3.2) mezi vrstvami hlubokých neuronových sítí se mohou lišit od vrstvy k vrstvě. Obvykle se uvnitř sítě používá aktivační funkce ReLU a na poslední výstupní vrstvě se používá aktivační funkce sigmoida, která výstup převede do intervalu od 0 do 1 pro snadnou interpretaci výsledků.

Protože jsou algoritmy zpracování 2D obrazu často používány k analýze 3D obrazu, může docházet ke ztrátě cenných informací. Zároveň postupné zpracování 3D dat vrstvu po vrstvě je zdlouhavý a náročný proces. Proto je v mnoha případech obtížné pracovat s prostorovými daty. Pro různé typy úloh se tedy hodí různé architektury propojení neuronových vrstev. Architektura U-Net představuje řešení tohoto problému. [GP17]

3.1.2.1 2D U-NET

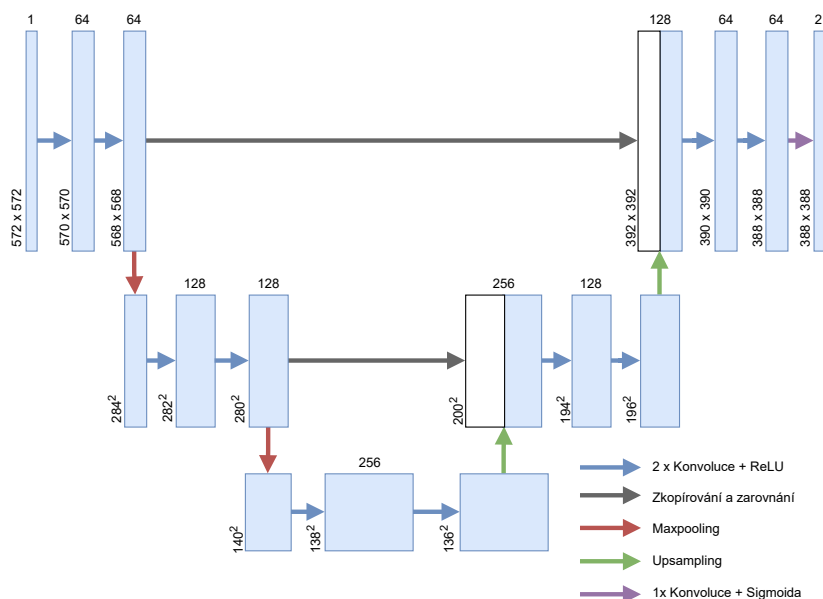
U-Net je plně konvoluční neuronová síť používaná pro segmentaci biomedicínských dat (2D i 3D) s širokým spektrem aplikovatelnosti. Jeho U-struktura splňuje požadavky na segmentaci v medicíně, kombinací kontextových informací, rychlostí tréninku a malými nároky na množství trénovacích dat.

Tradiční dvourozměrná architektura sítě U-Net je znázorněna na obr. (3.4). Architektura U-Net upravuje a rozšiřuje tradiční architekturu konvoluční sítě, čímž umožňuje pracovat s velmi malým trénovacím datasetem a produkovat přesnější výstupní segmentaci. U-Net doplňuje tuto obecnou strukturu, která se skládá z redukčních vrstev ("redukční část") o střed ("bottleneck") a expanzní část.

V redukční části se v každé vrstvě provádí dvě 2x2 konvoluce, následované aktivační funkcí ReLU a operací "maxpooling". Je vhodné využít operace šumu pro zajištění správného natrénování sítě (např. "dropout").

Střed ("bottleneck") je jedna vrstva obvykle přesně uprostřed redukční a expanzní části, kde se neprovádí operace "maxpooling" ani "upsampling", ale pouze dvě konvoluce s aktivační funkcí.

V expanzní části se v každé vrstvě provádí operace "upsampling" pro zpětné zvětšení výstupu. Během tohoto procesu se vytváří velké množství příznakových kanálů s využitím dat z redukční části i předešlé neuronové vrstvy, což umožňuje síti zahrnovat kontextová data do vrstev s vyšším rozlišením. Následují dvě konvoluce 2x2 a aktivační funkce ReLU. Expanzní část je přibližně symetrická k cestě redukční a



Obrázek 3.4: Příklad architektury U-Net

vytváří tvar písmene U. Díky této architektuře je výstupní velikost segmentovaného obrazu srovnatelná s velikostí vstupních dat.

Jako poslední vrstva se může přidat jedna konvoluce s aktivační funkcí sigmoida (transformuje výstup na interval od 0 do 1) pro snadnější interpretaci výsledků [Yin+20].

3.1.2.2 3D U-NET

Sejně jako u standardního 2D U-Netu je u 3D verze redukční a expanzní část se středem. V každé vrstvě se opět provádí dvě konvoluce (tentokrát jsou ovšem 3×3×3), následované aktivační funkcí ReLU a operací *maxpooling* případně *upsampling*. Počet vrstev v obou částech bývá stejný. V expanzní části může být stejně jako u 2D U-Netu přidána navíc jedna vrstva obsahující aktivační funkci sigmoida pro transformaci výstupu. Vylepšená struktura U-Net identifikuje 3D data na úrovni pixelu, což usnadňuje úlohu segmentace trojrozměrného obrazu na sémantické úrovni.

U-Net je tedy schopen provádět operace nad libovolným rozměrem dat a je vhodný pro strategii překrývání dlaždic. Díky této vlastnosti je schopen zpracovat i velká medicínská data, jsou-li rozdělena do menších kusů a skládat je s minimální ztrátou dat. Tato architektura tedy umožňuje použití rychlých poloautomatických a zcela automatických metod pro segmentaci 3D dat s vysokou přesností [Yin+20].

3.2 Proces učení

Cílem učení sítě je nastavit parametry dané sítě tak, aby její výsledky byli co nej-
přesnější. Učení neuronové sítě má dvě fáze: adaptivní (sít se učí a její výsledky
nejsou spolehlivé) a aktivní (sít dodává požadované výsledky i na nových datech).
Pro získání funkční neuronové sítě je důležité zvolit správný způsob učení, ale též
disponovat dostatečným množstvím kvalitních a relevantních dat.

3.2.1 Učení

Učení neuronové sítě může probíhat dvěma způsoby, a to s učitelem a bez učitele.
Při učení s učitelem poskytujeme neuronové síti dva vektory jako trénovací data.
První je vektor příznaků (vstupní data) a druhý je vektor požadovaných ohodnocení
(chtěná výstupní data). Tyto systémy lze chápat jako funkce, které ze vstupních dat
vypočítávají výstupní data a principem zpětné vazby upravují své parametry, dokud
nedosáhnou požadované přesnosti.

Neuronová síť nejprve vezme první vektor a na základě svého aktuálního nastave-
ní předpoví výsledek, ten poté porovná s druhým vektorem (chtěný výstup) a určí
chybu. Podle typu neuronové sítě se pak spočte korekce a upraví se váhy (či práh)
na neuronech. Proces se poté opakuje od začátku, dokud síť nedosáhne stanovené
minimální chyby. Takováto síť je adaptována a schopna vypočítat výstupní vektor i
pro vstup, který nebyl v trénovacích datech.

Při učení bez učitele má síť k dispozici pouze první vektor a chybí informace
o požadovaném výstupu. Síť si tedy učení řídí sama podle své architektury a výsledná
informace není známa. Toto učení se obvykle používá pro třídění vzorků do skupin
a u kompetitivních sítí. Tento postup není vhodný pro segmentaci, a proto se dále
budeme zabývat pouze sítěmi, které se učí s učitelem.

Někdy může docházet k chybnému procesu učení, který se nazývá přeučení. Síť
je příliš přizpůsobena množině trénovacích dat a není schopna získat požadované
výsledky u dat, která v této množině původně nebyla. Přeučení je obvykle způso-
beno malým rozsahem trénovací množiny, nebo nadměrnou komplexitou sítě (např.
nadměrné množství skrytých neuronů, či hledaných parametrů). Řešením problému
je obvykle zavedení šumu, zvětšení trénovací množiny, nebo omezení parametrů
v síti.[Kři21] [GP17]

3.2.2 Data

Pro správné naučení inteligentního systému je obvykle potřeba dostatečné množství
kvalitních trénovacích dat. Data určená pro učení neuronové sítě s učitelem se sklá-
dají ze vstupních vektorů a k nim odpovídajících výstupních vektorů (požadovaný

výstup). Proto při vytváření neuronové sítě pro segmentaci cév potřebujeme větší množství odborníkem segmentovaných dat.

Data se rozdělují na trénovací, validační a testovací množinu (dataset). Je důležité, aby data v trénovací a testovací množině byla nezávislá. Trénovací dataset se používá k učení sítě. Algoritmus hledá vztah mezi vstupem a výstupem regresní analýzou. Poté se na validačních datech kontroluje, zda síť nevykazuje chyby porovnáním úspěšností vyhodnocení dat z trénovací a validační množiny. Pokud je úspěšnost srovnatelná pro oba datasety, síť je natrénovaná správně. Pokud by úspěšnost pro trénovací dataset byla výrazně vyšší, došlo k přeučení sítě a je třeba upravit trénovací parametry. Na závěr se určí kvalita natrénované sítě na testovacím datasetu, tedy na neznámých nových datech.

3.3 Vyhodnocení

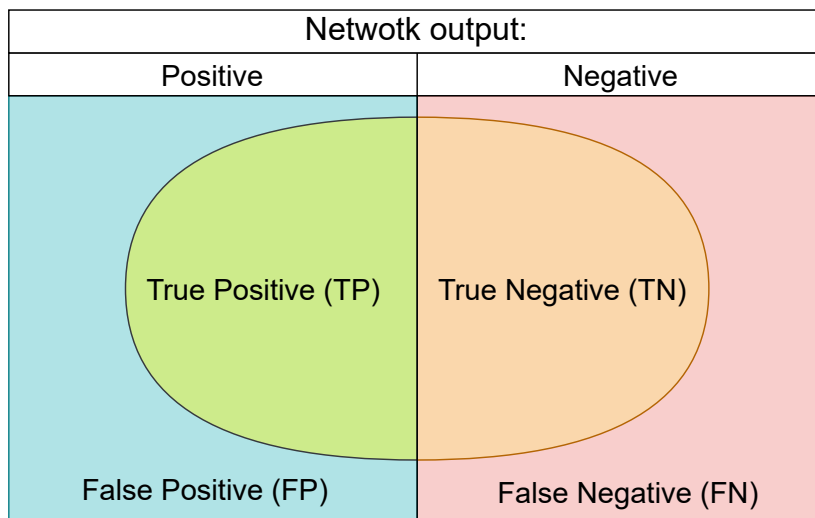
Pro vyhodnocení úspěšnosti průběhu učení neuronové sítě se obvykle používají dva ukazatele, ztrátová a zisková funkce. Tyto metriky slouží k vyhodnocení přesnosti a určení spolehlivosti modelu. Síť pro každý pixel v obraze rozhoduje, zda se jedná o třídu či okolí, pro pixel tedy může nastat jedna ze čtyř situací:

- je správně určen jako třída - patří do množiny TP (true positive),
- je správně určen jako okolí - patří do množiny TN (true negative),
- je chybně určen jako třída - patří do množiny FP (false positive),
- je chybně určen jako okolí - patří do množiny FN (false negative).

Vzniklé množiny jsou nutné k vypočtení metrik, schéma zařazení pixelů do těchto množin je zobrazeno na obr. (3.5). Některé metriky jsou také definovány pomocí množin A (množina pixelů dané třídy podle předlohy) a B (množina pixelů zařazených do třídy neuronovou sítí). Použití dané metrické metody závisí na povaze dat a zadané úloze. V této kapitole se budeme zabývat metrikami vhodnými pro segmentaci obrazu. [GP17]

3.3.1 Metriky přesnosti

Funkce přesnosti udává přehled o výkonnosti klasifikačního modelu. Jde o množství správně předpovězených výstupů, obvykle udávaný v procentech. Funkce přesnosti se používá k průběžnému hodnocení kvality modelu i během trénování a je snadněji interpretovatelná než ztrátová funkce.



Obrázek 3.5: Schéma možných případů klasifikace

3.3.1.1 Pixelová přesnost a recall

Jedná se o jednu z nejjednodušších metrik na pochoopení, je ovšem málokdy vhodná k použití. Míra úspěšnosti je procento pixelů obrazu, které byli správně zařazeny do klasifikační třídy. Přesnost určení jedné třídy P se dá určit podle vzorce:

$$P = \frac{TP}{TP + FP},$$

kde TP je celkové množství správně zařazených pixelů do dané třídy a $TP+FP$ je celkové množství pixelů zařazených do dané třídy neuronovou sítí. Jelikož můžeme klasifikovat do více tříd, používá se také průměrná pixelová přesnost mP . Pro k tříd, lze pak tuto metriku spočítat následovně:

$$mP = \frac{1}{k} \sum_{i=1}^N P_i.$$

Problém nastává v případě, kdy je objem klasifikačních tříd nevyvážený, tedy objem pixelů v některých třídách výrazně převyšuje množství pixelů v ostatních. Metrika dává dobré výsledky pouze, pokud jsou správně zařazeny pixely dominantních tříd a minoritní třídy nebere příliš v úvahu.

Vzeme-li např. v úvahu úlohu segmentace cév, objem cév ve snímku jater se pohybuje okolo 3%. Síť má tendenci určovat cévy jako okolí, protože náhodný pixel

je s větší pravděpodobností okolí nežli céva. U této úlohy ovšem potřebujeme spíše upřednostnit malou skupinu na úrok větší, proto se pixelová metrika nedoporučuje.

Jestliže pixelová přesnost ukazuje přesnost modelu, recall ukazuje množství dat, které je síť schopná správně zařadit. Metriku recall (R) lze spočítat jako podíl správně přiřazených pixelů do dané třídy, ku celkovému množství pixelů patřících do dané třídy.

$$R = \frac{TP}{TP + FN}$$

Tato metrika není vhodná pro aplikaci samostatně, ale používá se v kombinaci s pixelovou přesností pro lepší výsledky učení. [LSD15]

3.3.1.2 Krychlový koeficient

Protože samostatné použití metriky pixelová přesnost ani recall nestačí, zavádí se nová metrika, která předešlé metriky spojuje. Nejjednodušší je zavést metriku jako průměr dvou kritérií, ta ale dává špatné výsledky pro extrémní hodnoty (pro jednu z metrik rovnou 1 a druhou 0 dostáváme hodnotu 0,5). Od nové metriky požadujeme tyto vlastnosti:

- spojitost,
- tranzitivitu (pokud $a_1 \geq a_2$ a $a_2 \geq a_3$, pak $a_1 \geq a_3$),
- srovnatelné zohlednění obou složek,
- vzájemnou nezávislost složek,
- je-li jedno kritérium konstantní a vidíme změnu výsledku metriky pro dvě různé hodnoty druhého kritéria, nelze tuto změnu zvrátit změnou konstantní hodnoty.

Pomocná metrika E splňující tyto podmínky je definována jako:

$$E = 1 - \left(\frac{\alpha}{P} + \frac{1 - \alpha}{R} \right)^{-1},$$

kde α je hodnota mezi 0 a 1, P je pixelová přesnost a R je recall. Dále definujeme metriku F_β :

$$F_\beta = 1 - E = \frac{PR}{\alpha R + P - \alpha P}$$

kde platí, že parametr $\alpha = \frac{1}{1+\beta^2}$. Pro hodnotu $\beta = 1$ ($\alpha = \frac{1}{2}$) získáváme harmonický průměr F_1 :

$$F_1 = \left(\frac{0,5}{P} + \frac{0,5}{R} \right)^{-1} = \frac{2PR}{P + R}.$$

Po převedení do klasifikačních množin získáváme:

$$F1 = \frac{2TP}{2TP + FP + FN}$$

Z definice je vidět, že tato metrika nezohledňuje skutečná negativa (TN) přímo. V praxi se více užívá označení krychlový koeficient (D) definované pro dvě množiny A (třída podle trénovací množiny) a B (třída předpovězená sítí):

$$D = \frac{2|A \cap B|}{|A| + |B|}$$

Zde je zobrazena souvislost mezi metrikou F1 a krychlovou metrikou:

$$|A| = TP + FN,$$

$$|B| = TP + FP,$$

$$|A \cap B| = TP.$$

[SF07][LSD15]

3.3.1.3 Jaccard index


Jaccardův index, nebo také průnik nad sjednocením (IoU) (Intersection over Union) je obvykle definován pomocí dvou množin A (chtěný výsledek) a B (předpovězený výsledek).

$$IoU = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|}$$

Pro lepší pochopení lze také zapsat:

$$IoU = \frac{TP}{TP + FP + FN}$$

Jedná se o jednu z nejpoužívanějších metrik v úlohách segmentace, jelikož se soustředí na minimalizování rozdílu mezi průnikem a sjednocením (3.6).[GP17]



Obrázek 3.6: Schéma Jaccardova indexu

3.3.2 Metriky ztráty

Ztrátová funkce, známá také jako nákladová funkce, bere v úvahu pravděpodobnosti nebo nejistotu předpovědi na základě toho, jak moc se předpověď liší od skutečné hodnoty. Tento přístup poskytuje podrobnější pohled na to, jak dobře model funguje. Na rozdíl od přesnosti se ztrátová funkce neudává v procentech, ale jde o součet chyb pro všechny vzorky v trénovacích nebo validačních datasetech. Ztráta se často používá v tréninkovém procesu k nalezení "nejlepších" hodnot parametrů pro model (např. váhy v neuronové síti). Na rozdíl od funkce přesnosti lze ztrátovou funkci použít v klasifikačních i regresních problémech.

Během tréninkového procesu je cílem minimalizovat hodnotu ztrátové funkce a maximalizovat hodnotu přesnosti. Většinu času se hodnota přesnosti zvyšuje s poklesem ztráty, ale není tomu tak vždy. Přesnost a ztráta mají různé definice a měří různé věci. Často se zdají být nepřímo úměrné, ale mezi těmito dvěma metrikami neexistuje žádný matematický vztah.

3.3.2.1 Průměrná kvadratická chyba

Průměrná kvadratická chyba (*Mean Squared Error - MSE*) je často používanou ztrátovou funkcí pro regresní úlohy. Mean Squared Error spočítá čtverec rozdílu mezi predikcí modelu (B) a skutečnou hodnotou (A), pro každou dvojici (vstup, chtěný výsledek) v trénovacích datech. Poté se spočítá průměr těchto čtverců pro všechny data v trénovacím datasetu. Metriku spočteme podle vzorce:

$$MSE = \frac{1}{N} \sum_{i=1}^N (B_i - A_i)^2,$$

kde N je počet dvojic (vstup, chtěný výstup) v trénovacím datasetu, A jsou skutečné hodnoty (ground truth) a B jsou predikované hodnoty modelu. Výsledné hodnoty jsou vždy nezáporné, neboť jsou druhými mocninami rozdílů.

Při trénování modelu je cílem minimalizovat hodnotu ztráty, což znamená, že model se snaží co nejlépe aproximovat skutečné hodnoty v trénovacích datech. Model postupně upravuje parametry modelu tak, aby se minimalizovala ztráta. Je důležité zmínit, že MSE má tendenci zvýhodňovat velké odlehlé hodnoty, což může být problém, pokud jsou v datech výkyvy. V takových případech se používají jiné ztrátové funkce, které jsou robustnější vůči extrémním hodnotám. Celkově vzato, MSE je jednoduchá a efektivní metrika pro měření rozdílů mezi predikcemi modelu a skutečnými hodnotami v regresních úlohách.[GP17]

3.3.2.2 Entropie

Categorical Cross-Entropy Loss: je ztrátová funkce používaná především pro klasifikační úlohy s více než dvěma třídami. Používá se, když model predikuje pravděpodobnost příslušnosti vstupních dat do různých tříd a porovnává tyto pravděpodobnosti se skutečným zařazením do zvolené třídy. Cross-Entropy Loss (H) lze obecně vyjádřit následovně:

$$H = - \sum_{i=1}^N A_i \log(B_i),$$

kde: N je počet zkoumaných prvků. A_i vyjadřuje pravděpodobnost, že zkoumaný prvek i náleží k dané třídě (nabývá hodnot 0 nebo 1). A B_i je pravděpodobnost příslušnosti prvku i do dané třídy určená neuronovou sítí (nabývá hodnot od 0 do 1). Metoda Cross-Entropy Loss vyžaduje, aby model predikoval pravděpodobnosti pro všechny klasifikační třídy. [BKR05] [LSD15]

Binary Cross-Entropy Loss: nazývaná také Log Loss nebo Binary Logarithmic Loss, je speciální případ předešlé metody. Používá se pro binární klasifikační úlohy, kde je snaha přiřadit vstupní data do jedné ze dvou možných tříd (popředí, pozadí). Tato ztrátová funkce se často používá v kombinaci s logistickou sigmoidovou aktivační funkcí pro poslední vrstvu neuronové sítě. Výstup sigmoidové funkce (B_i) odpovídá pravděpodobnosti, že prvek i patří do třídy popředí. Vzhledem k počtu tříd je tato informace dostačující k vypočtení ztrátové funkce. Hodnota Binary Cross-Entropy Loss (H_B) pro jeden prvek i lze vyjádřit následovně:

$$H_{B_i} = \begin{cases} -\log(B_i), & \text{pokud prvek } i \text{ náleží do popředí} \\ -\log(1 - B_i), & \text{pokud prvek } i \text{ náleží do pozadí} \end{cases}$$

Výsledná hodnota Binary Cross-Entropy Loss je rovna průměru ztrát pro všech N prvků množiny.

$$H_B = \frac{1}{N} \sum_{i=1}^N H_{B_i}$$

Tato ztrátová funkce je citlivá na vyvážení tříd. Pokud jsou třídy v trénovacích datech nevyvážené, můžou vzniknout nepřesnosti. V takových případech je vhodné použít váženou verzi této funkce: Weighted Binary Cross-Entropy Loss (H_{Bw}), kde hodnoty a a b označují váhy jednotlivých tříd. [BKR05] [LSD15]

$$H_{Bw_i} = \begin{cases} -a \log(B_i), & \text{pokud prvek } i \text{ náleží do popředí} \\ -b \log(1 - B_i), & \text{pokud prvek } i \text{ náleží do pozadí} \end{cases}$$

Experiment

4


Cílem práce bylo nalézt a vyzkoušet metodu vhodnou pro segmentaci cév v jaterním parenchymu. Nejčastěji užívanou metodou pro segmentaci cév v medicíně je v dnešní době užití hlubokých konvolučních neuronových sítí (CNNs). V této práci představuji použití architektury U-Net natrénované na 3D datech poskytnutých projektem Deepvesselnet a následnou aplikaci sítě na reálných medicínských datech zprostředkovaných Lékařskou fakultou univerzity Karlovy v Plzni a Medicínským centrem univerzity Karlovy v Plzni.

4.1 Data

Rozhodla jsem se pro trojrozměrná data, kvůli minimalizování ztráty 3D informace v medicínských datech. Trojrozměrná povaha dat ovšem vytváří několik problémů. Jedním z hlavních je velikost datasetů na disku. Podle rozměru vstupních dat může jediný soubor pro 3D segmentaci zabírat stejné množství paměti jako desítky až stovky souborů pro segmentaci ve 2D rozměru. Dalším problémem je delší čas, který síť potřebuje na zpracování trojrozměrné matice. Architektura U-Net potřebuje k natrénování malé množství souborů a pracuje relativně rychle, čímž problémy 3D dat kompenzuje. Z důvodu obrovské velikosti medicínských dat a velké náročnosti na výpočetní paměť i čas, jsem využívala službu <https://metavo.metacentrum.cz/>, která poskytuje úložný prostor a výpočetní čas na strojích podle zvolených parametrů.

4.1.1 Trénovací, validační a testovací dataset

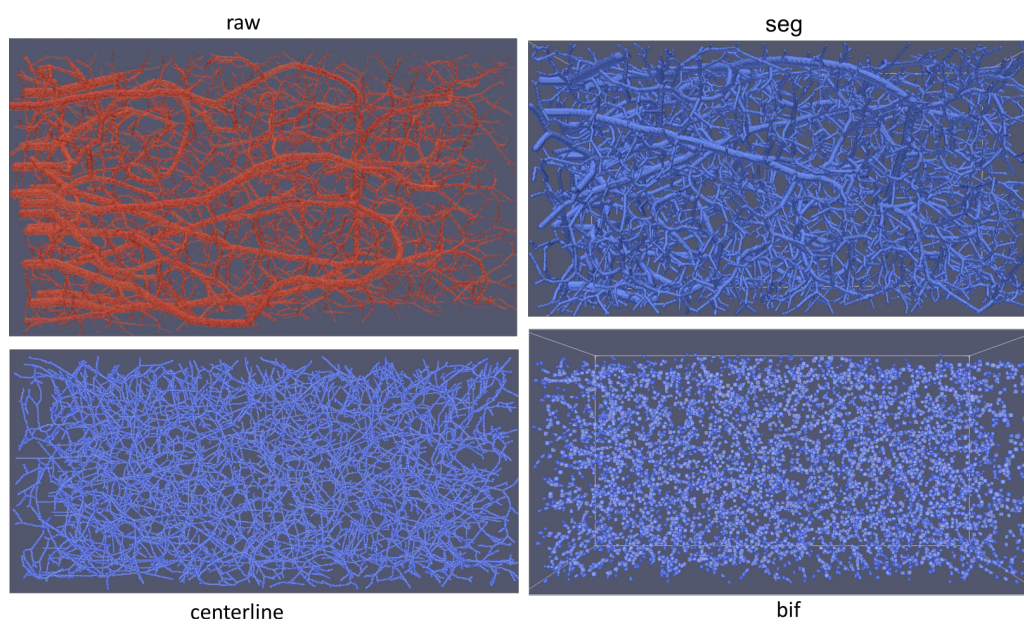
Pro vytvoření a natrénování sítě jsem použila data zprostředkovaná projektem Deepvesselnet. [Tet+20] Deepvesselnet je projekt soustředící se na použití hlubokých neuronových sítí v medicíně a rozšíření jejich aplikovatelnosti na různé medicínské úlohy segmentace, zejména segmentaci cévních struktur v různých tkáních. Široké veřejnosti poskytuje kvalitní data vhodná pro různé segmentační úlohy, spolu se



Obrázek 4.1: Ukázka vybraných datasetů Deepvesselnet

třemi architekturami hlubokých neuronových sítí: U-Net, V-Net a FC-Net, které se v dnešní době používají v oblasti segmentace medicínských dat.

Datasets poskytnuté projektem Deepvesselnet obsahují nezpracované MRA snímky cév lidského mozku (adresář *raw*), a k nim odpovídající segmentovaná data celých cévních struktur (adresář *seg*), centrálních linií cév (adresář *centerline*) a míst kde se cévy rozvětvují tzv. *bifurkace* (adresář *bif*). Vedle těchto datasetů obsahuje ještě pomocné adresáře *points* a *radius*. Jelikož v práci testuji tři metody segmentace: detekci celých cév, segmentaci centrálních linií cév a detekci bifurkací, využívám pro práci pouze adresáře *raw*, *seg*, *bif* a *centerline*. Tyto datasety jsou velmi kvalitní a rozsáhlé, jde o více než 130 souborů formátu ".nii" o rozměrech 325x304x600 pixelů. Ukázka průřezů vybranými adresáři datasetu Deepvesselnet je zobrazena na



Obrázek 4.2: Ukázka vybraných adredářů projektu Deepvesselnet ve 3D

obr. (4.1). Na obr. (4.2) jsou pak zobrazeny náhledy těchto souborů ve 3D vygenerované programem *ParaView*. Pro větší přehlednost jsem data rozdělila do tří datasetů: *dataset_train.h5*, *dataset_validation.h5* a *dataset_test.h5*. Pro snadnější zpracování je za běhu programu dále dělím do menších matic o rozměrech $50 \times 50 \times 50$.

4.1.2 Snímky jaterních cév

Reálná data byla poskytnuta Lékařskou fakultou univerzity Karlovy v Plzni. Jedná se o Mikro-CT snímky jater prasat domácích (*Sus Domesticus*), plemena Přestické černostrakaté prase (4.3). Data z Mikro-CT tomografu byla velmi objemná ($1207 \times 1207 \times 200 \times 200$) a podmínky snímání se pro každý soubor liší. Z toho důvodu bylo nutné data předem upravit pro potřeby neuronové sítě. Jelikož poskytnutá data byla uložena ve formátu *".mhd"*, bylo možné zjistit doplňující informace o podmínkách při kterých se daný snímek pořizoval např. barevnou intenzitu, rozlišení, orientaci objektu pod tomografem, měřítko, nastavení parametrů tomografu atd. Tyto informace jsou důležité pro přípravu dat před samotnou segmentací.

Jelikož se podmínky pro každý snímek lišili, prováděla jsem přípravu dat pro každý soubor zvlášť. Obvykle bylo nutné upravit barevné spektrum snímku a zmenšit jeho rozlišení. Při velkém snížení rozlišení jsem ovšem ztrácela příliš mnoho informací, proto bylo nutné některé snímky rozdělit na menší části a provádět segmentaci postupně.

Prasata jsou často využívána pro medicínské účely, neboť jejich fyziologie je

velmi podobná té lidské. Proto průběh nemocí a klinických testů je srovnatelný s jejich průběhem u člověka. Plemeno Přestické černostrakaté prase má navíc malé množství podkožního tuku, díky čemuž dochází k minimálnímu zkreslení medicínských snímků. Z předchozích důvodů je toto plemeno velmi častým testovacím subjektem v oblasti medicíny.




Obrázek 4.3: Přestické černostrakaté prase, (*Sus scrofa f. domestica*) [Pok13]

Metoda získání Micro-CT snímků prasečích jater : Pro účely výzkumu nemají někdy CT snímky dostatečné rozlišení (CT snímá v rozsahu jednotek milimetrů), proto se pořizují mikro-CT snímky daných oblastí. Snímky jater se pořizují postmortum specifickou metodou (zobrazeno na obr. (4.4)). Mrtvé prase se otevře a do cévy vedoucí do jater se vstříkne pryskyřice. Po zatuhnutí hmoty se orgán vyjme z prasete a vloží do roztoku, který odstraní okolní živočišnou tkáň. Vznikne tak 3D odlitek jaterní cévní struktury z pryskyřice. Získaný 3D model cévního stromu se pro snadnější zkoumání nařeže na menší části a vloží do tomografu. Nasnímanou část je pak možno zobrazit vrstvu po vrstvě ve specializovaném medicínském programu. Ukázka odlitku pod elektronovým mikroskopem je zobrazena na obr. (4.5). [Jiř+18][Jiř+16]


Pro tuto bakalářskou práci jsem použila mikro-CT snímky jater prasat domácích pořízené výše popsanou metodou.

4.2 Neuronové sítě

Při použití hlubokých konvolučních neuronových sítí v medicíně je jednou z nejčastěji používaných architektur struktura U-Net. Její hlavní výhoda spočívá v tom,



Obrázek 4.4: Postup vytvoření snímků prasečích jater mikro-CT tomografem [Jiř+16]



Obrázek 4.5: Odlitek prasečích jater pod elektronovým mikroskopem [Mou+20]

že výstupem mohou být různě rozměrné matice. Má tedy schopnost segmentovat dvourozměrná i trojrozměrná data. U-Net dává na výstupu matice segmentovaných dat ve stejných rozměrech, která měla data poskytnutá na vstupu. Díky této skutečnosti je snadné interpretovat výstupní segmentační mapy. Model vytvořený sítí U-Net také poskytuje velmi přehledně informaci, jak moc si je jist zařazením každého pixelu. Pro vytváření jednotlivých architektur jsem využívala knihovnu *Keras*, která obsahuje mnoho metod pro snadnější práci s neuronovými sítěmi.

4.2.1 U-Net

Pro řešení 3D segmentace jsem vytvořila dvě architektury sítě U-Net. Obě se učí na datech o rozměrech (*počet_souborů; rozměr; rozměr; rozměr; počet_kanáů*), s využitím ziskové funkce *krychlový koeficient* a ztrátovou funkcí *weighted binary cross-entropy loss*. Počet kanálů je u všech datasetů 1 a rozměry vstupních dat jsem zvolila ($50 \times 50 \times 50$). Váhy metrik jsem nastavila podle funkce *class_weight.compute_class_weight()* implementované v rámci knihovny *Keras*. Jelikož cévy zabírají kolem 3% z celkového objemu dat, vycházejí váhy přibližně ($0.5, 30$) pro adresář *seg*, ($0.5, 130$) pro adresář *centerline* a ($0.5, 127$) pro adresář *bif*. *UNET1* je vytvořen z pěti vrstev s šestou výstupní vrstvou obsahující *sigmoidu* a *UNET2* je rozšířen z pěti vrstev na devět s desátou výstupní vrstvou opět obsahující *sigmoidu* jako aktivační funkci. Sigmoida na výstupní vrstvě zajišťuje, že výstupní data obsahují hodnoty na intervalu od 0 do 1, je tedy snadnější je interpretovat a přehledně vykreslit. Vnitřní struktura jednotlivých vrstev je vytvořena podle popisu v sekci (3.1.2.2). [GP17]

4.2.2 Učení a vyhodnocení na datasetu Deepvesselnet

Pro své potřeby jsem vytvořila několik modelů obou architektur sítě U-Net a nechala jsem je trénovat na různých objemech dat nejdéle po dobu okolo jednoho týdne. Trénovací data zabírají velké množství paměti, z toho důvodu jsem vytvořila metodu "*img_generator()*" podle předlohy v dokumentaci knihovny *Keras*, která poskytuje obrázky souboru postupně, dokud neprojde celý dataset.

Po zvolené době jsem natrénované modely uložila pro budoucí použití. U sítí vytvořených pomocí knihovny *Keras*, lze obvykle uložit celý model jako jediný soubor (*model.dat*), ale pro mé potřeby bylo nutné vytvořit vlastní váhové a ztrátové funkce. To mi znemožnilo ukládat modely standartní metodou. Z tohoto důvodu jsem pro každý model vytvořila dva soubory: záznam průběhu trénování (*history_model.json*) a natrénované váhy modelu (*weights_model.h5*).

Všechny modely jsou pojmenovány podle jednotného formátu. První tři písmena názvu značí adresář, ze kterého se brala trénovací data: *cen* (*centerline*), *seg* (*seg*), *bif* (*bif*), a tedy i segmentační úlohu. Následuje číslo (1 nebo 2) udávající architekturu U-Netu a podtržítka, za kterým je množství dat v trénovací množině. Např. název

modelu: *cen1_200* znamená, že model je natrénován pro segmentaci centrálních linií cév, pomocí adresáře *centerline* architekturou *UNET1* na trénovací množině o rozsahu 200 souborů.

Uložené modely jsem otestovala metodou "*evaluate()*" knihovny *Keras* pomocí datasetu *dataset_test.h5*. V následujících tabulkách (4.1, 4.2) jsou zobrazeny finální výsledky učení jednotlivých modelů na trénovacím a validačním datasetu, spolu s výsledky testování už naučeného modelu na testovací množině. Na obrázcích (4.6)

UNET1									
Model	Train			Validation			Test		
	Loss	Dice	Accur	Loss	Dice	Accur	Loss	Dice	Accur
seg1_10	0.02	75 %	98 %	0.69	69 %	99 %	1.89	37 %	99 %
seg1_50	0.00	93 %	99 %	0.85	85 %	99 %	0.11	54 %	97 %
seg1_100	0.00	97 %	99 %	0.85	88 %	99 %	9.45	55 %	99 %
seg1_200	0.00	99 %	99 %	0.88	81 %	99 %	7.39	82 %	99 %
seg1_300	0.00	98 %	99 %	0.91	90 %	99 %	0.01	93 %	99 %
bif1_10	n	2 %	0 %	n	1 %	0 %	n	3 %	0 %
bif1_50	n	n %	99 %	n	n %	99 %	n	n %	99 %
bif1_100	n	n %	99 %	n	n %	99 %	n	n %	99 %
bif1_200	n	n %	99 %	n	n %	99 %	n	n %	99 %
cen1_10	0.01	59 %	99 %	0.05	51 %	99 %	99.55	0 %	99 %
cen1_50	0.00	94 %	99 %	0.76	66 %	99 %	77.05	0 %	99 %
cen1_100	5.43	99 %	99 %	0.18	83 %	99 %	0.00	98 %	100 %
cen1_200	0.06	99 %	99 %	0.34	85 %	99 %	0.25	97 %	99 %
cen1_300	0.00	90 %	99 %	0.26	78 %	99 %	0.04	74 %	99 %

Tabulka 4.1: Přehled modelů s architekturou UNET1 (Loss - weighted binary cross-entropy loss, Dice - krychlový koeficient, Accur - pixelová přesnost)

a (4.7) je ukázka segmentací cév a středových linií cév nejméně úspěšnými modely pro obě architektury U-Net. [GP17]

Z výsledků je patrné, že architektura U-Net se nehodí pro segmentaci bifurkací. Hodnota *n* značí počítačem nevyčíslitelnou hodnotu, což je velmi negativní výsledek. U-Net se dá ale velmi dobře použít pro segmentaci středových linií cév a segmentaci celých cévních stromů. Z výsledných hodnot je také patrné, jak je důležité použít správnou metrickou funkci. Metrika *přesnost* (*Accur*) dává velmi dobré výsledky i přes to, že model evidentně nefunguje podle metrik *weighted binary cross-entropy loss* (*Loss*) a *krychlový koeficient* (*Dice*). To je způsobeno nevyvážeností tříd v datech. Segmentovaná data v souboru adresáře *bif* zabírají kolem 1% celkového obrazu.


Architektura *UNET2* má sice podle tabulky horší výsledky, je ale lepší v nalézání celkové povahy struktury cév. Protože má architektura *UNET2* více vrstev, potřebuje

UNET2									
	Train			Validation			Test		
Model	Loss	Dice	Accur	Loss	Dice	Accur	Loss	Dice	Accur
seg2_10	0.00	78 %	99 %	0.07	77 %	99 %	0.27	32 %	99 %
seg2_50	0.01	85 %	99 %	0.07	82 %	99 %	22.11	74 %	99 %
seg2_100	0.00	97 %	99 %	0.32	82 %	99 %	167.71	85 %	98 %
seg2_200	0.00	99 %	99 %	0.76	86 %	99 %	7.39	73 %	99 %
seg2_300	0.00	88 %	99 %	0.03	88 %	99 %	0.2	82 %	99 %
bif2_10	n	2 %	0 %	n	1 %	0 %	n	3 %	0 %
bif2_50	n	n %	99 %	n	n %	99 %	n	n %	99 %
cen2_10	0.00	75 %	99 %	0.21	61 %	99 %	0.21	12 %	94 %
cen2_50	0.00	97 %	99 %	0.13	67 %	99 %	3.17	56 %	99 %
cen2_100	6.59	99 %	99 %	0.22	66 %	99 %	6.44	59 %	100 %

Tabulka 4.2: Přehled modelů s architekturou UNET2 (Loss - weighted binary cross-entropy loss, Dice - krychlový koeficient, Accur - pixelová přesnost)


delší čas na zpracování jednoho souboru. To výrazně prodlužuje dobu, kterou model potřebuje na jednu epochu učení. Zároveň je u obou architektur potřeba poměrně velkého množství dat, aby nedocházelo k přetrénování modelu. Tento fenomén je vidět na rozdílných výsledcích pro metriku *Dice* u trénovacího a testovacího datasetu. Je patrné že neuronová síť s větší hloubkou *UNET2* má lepší schopnost nacházet obecné příznaky pro segmentaci cév. U modelů s malým počtem dat v trénovací množině má architektura *UNET1* převážně horší výsledky než *UNET2*. S rostoucím počtem souborů, se tento rozdíl snižuje. U modelů s velkou trénovací množinou se lépe jeví architektura *UNET1*, to může být ovšem způsobeno krátkou dobou učení. Modely jsou s rostoucí velikostí trénovací množiny schopny segmentovat vstup obecněji a nedochází k jejich specializaci na data poskytnutá pro proces učení.

Na obrázku (4.8) je vidět vývoj všech metrik po epochách pro model *seg1_50*. Je zřejmé, že metrika *Dice* je nejdůležitějším ukazatelem vývoje modelu při trénování, protože ostatní metriky se poměrně rychle ustálí i přes to, že segmentace nedosahuje požadované kvality. Na obrázku (4.9) je zobrazeno porovnání průběhu metriky *Dice* pro různé modely architektury *UNET1* během počátku trénování. Jelikož model provádí tím více operací natrénování v jedné epoše, čím je větší trénovací množina, nabízí se závěr, že čím je větší trénovací množina dat, tím méně epoch model potřebuje ke kvalitnímu natrénování. Doba trvání jedné epochy bude odpovídat velikosti trénovací množiny.


Obrázek 4.6: Ukázka segmentace cév na datech adresáře *seg* projektu Deepvesselnet

4.3 Aplikace na snímcích jaterních cév prasat


V předešlé kapitole byly představeny natrénované a otestované modely pro úlohy segmentace cév a segmentace jejich středových linií, které dosáhly na testovací množině úspěšnosti 93 % (*seg1_300*) a 98 % (*cen1_100*) dle metriky *Dice*. Nyní je třeba otestovat, zda lze natrénované modely použít pro segmentaci dat, která byla poskytnuta jiným zdrojem. Mikro-CT snímky jater prasat jsou příliš velké a pořízené za různých podmínek. Z toho důvodu je třeba nejprve každý individuálně upravit. Při úpravě rozměrů snížením rozlišení docházelo k příliš velké ztrátě informací, proto bylo nutné soubor rozdělit do menších částí. Segmentace se prováděla po částech na maticích o rozměru (50x50x50). Pro každou úlohu segmentace prasečích jater jsem vybrala dva nejlépe natrénované modely každé architektury následovně:



Obrázek 4.7: Ukázka segmentace centrálních linií cév na datech adresáře *centerline* projektu Deepvesselnet




Obrázek 4.8: Ukázka časového vývoje metrik během trénování modelu *seg1_50*




Obrázek 4.9: Porovnání průběhů krychlové metriky pro různé modely architektury UNET1

- UNET1: segmentace cév → seg1_200, seg1_300 → obr.(4.10),
- UNET1: segmentace středových linií → cen1_100, cen1_200 → obr.(4.11),
- UNET2: segmentace cév → seg2_50, seg2_100 → obr.(4.12),
- UNET2: segmentace středových linií → cen2_50, cen2_100 → obr.(4.13).



Obrázek 4.10: Segmentace cév na snímcích prasečích jater pomocí architektury UNET1

Z obrázků je vidět, že segmentace na snímcích jaterních cév prasat není srovnatelná se segmentací na datasetech od projektu Deepvesselnet. Výsledek ale poskytuje




Obrázek 4.11: Segmentace středových linií cév na snímcích prasečích jater pomocí architektury UNET1

přibližnou představu o poloze cév i cévních středových linií. Zkreslení výsledků může být způsobeno jak nedostatečným natrénováním sítě, tak skutečností, že trénovací data obsahují pouze snímky cév lidského mozku, zatímco segmentovaná data pocházejí z prasete a zobrazují játra. Pro lepší výsledky by bylo nutné modely dotrénovat na segmentovaných snímcích jaterních cév prasat.

4.4 Shrnutí a návrh možných vylepšení

Architektura U-Net je schopná segmentace cév a centrálních linií po relativně krátké době učení na poměrně malém datasetu ve 3D rozměru, nehodí se ale vůbec k segmentaci bifurkací neboli míst, kde se cévy rozvětvují. Velkou výhodou je schopnost neuronové sítě hledat si vlastní obecné příznaky, díky čemuž ji je možné použít na segmentaci velmi specifických oblastí pouze s poskytnutím obecných dat. Na obrázku (4.14) je vidět, že segmentace jaterních cév provedená neuronovou sítí *seg2_50* odpovídá segmentaci, kterou by provedl člověk intuitivně i přes to, že se neuronové sítě učily na snímcích lidských cévních struktur v různých oblastech lidského těla.

Ukazuje se, že výsledky modelů jsou tím lepší, čím déle se nechají trénovat, pokud ovšem mají dostatečně rozsáhlé datasety pro trénování. Z výše uvedených tabulek se zdá, že architektura s menším počtem vrstev má lepší výsledky pro




Obrázek 4.12: Segmentace cév na snímcích prasečích jater pomocí architektury UNET2


větší množství dat (*UNET1*) v trénovací množině, ačkoli teoreticky by to mělo být naopak. To může být způsobeno potřebou delší doby pro kvalitní natrénování hlubší architektury *UNET2*. V ukázce segmentovaných obrazů jater prasat (4.10,4.12,4.11,4.13) má *UNET2* srovnatelné výsledky s architekturou *UNET1*. Z tabulek (4.1) a (4.2) je patrné, že hlubší architektura (*UNET2*) je schopna najít obecné příznaky pro segmentaci požadované struktury i na menším množství dat v porovnání s méně hlubokou architekturou *UNET1* (modely *seg1_50* vs. *seg2_50*, *seg1_100* vs. *seg2_100*, *cen1_10* vs. *cen2_10* a *cen1_50* vs. *cen2_50*).

Ukázka programů: V adresáři GitHub (<https://github.com/romova/UNet-Segmentace-cev.git>) jsou zveřejněny ukázky dvou skriptů *jupyter notebook*. Soubor *U-Net.ipynb* slouží k vytvoření nového modelu, zatímco soubor *Vyhodnoceni.ipynb* je vhodný pro načtení již natrénovaného modelu a jeho použití pro segmentaci na vlastních datech. Adresář dále obsahuje odkazy na dva archivy ke stažení, soubor *data.zip*, který obsahuje trénovací datasety, a soubor *modely.zip*, který obsahuje již natrénované modely diskutované dříve.

Za zmínku také stojí, že tato bakalářská práce byla vytvořena pomocí šablony představené v diplomové práci Ing. Kamila Ekšteina, Ph.D. [Ekš22]



Obrázek 4.13: Segmentace středových linií cév na snímcích prasečích jater pomocí architektury UNET2



Obrázek 4.14: Zpětně složený obraz po provedení segmentace cév modelem seg2_50 na menších částech Mikro-CT snímku prasečích jater (vlevo: segmentace, vpravo: původní snímek)

Pro větší přehlednost výsledků je možné vytvořit metodu prahování. Takto upravená data by dávala jasné výsledky (ano, ne) ohledně lokalit cév, připravili bychom se ovšem o informaci, jak moc si je neuronová síť jistá svou předpovědí. Dalšími metodami vylepšení segmentační schopnosti neuronové sítě jsou např. tyto metody:

- **Vícevrstvý U-Net:** Pokud se architektury *UNET1* a *UNET2* zdají nedostatečné pro zachycení složitých vzorů a struktur v obraze, můžeme zvážit vytvoření nové architektury U-Net. Výsledná architektura by mohla zahrnovat více vrstev nebo další bloky pro zvýšení kapacity a schopnosti modelu.
- **Předzpracování dat:** V této úloze jsem díky kvalitním datasetům projektu Deepvesselnet neprováděla žádné úpravy. Metody jako kontrastování, normalizace nebo odstranění šumu, by mohly pomoci zvýšit kvalitu vstupních dat a tím i segmentačních výsledků.
- **Transfer Learning:** Využití předtrénovaných modelů na obecných obrazech a jejich následným přizpůsobením pro segmentaci cév v játrech může urychlit trénink a zlepšit výkon modelu.
- **Ensemble Learning:** Kombinování více modelů, např. architektury U-Net s jinými strukturami projektu Deepvesselnet, může vést k větší stabilitě a přesnosti segmentace. Projekt Deepvesselnet tuto metodu výslovně doporučuje.
- **Větší datové sady a delší doba učení:** Rozšíření a diversifikace trénovacích datových sad může pomoci modelu lépe se přizpůsobit různorodým situacím. V této práci doba trénování nepřesáhla jeden týden. Delší doba trénování bude vést k lepšímu nastavení váhových funkcí.

Každá z těchto možností může přinést další vylepšení segmentačního procesu a přispět k přesnějším a spolehlivějším výsledkům. [Tet+]

Segmentace cév v játrech má klíčový význam v diagnostice a plánování chirurgických zákroků na játrech. Kvalitní a přesná segmentace umožňuje lékařům lépe porozumět anatomii pacienta a získat důležité informace pro rozhodnutí o vhodném léčebném postupu. Výsledky této bakalářské práce naznačují důležitost tohoto procesu a ukazují, že segmentace cév je nezbytným krokem směrem k vylepšení léčby pacientů trpících onemocněním jater.

V rámci této práce jsem uskutečnila důkladné zkoumání využití architektury neuronových sítí U-Net v kontextu segmentace jaterních cév v medicínském zobrazování. Vysvětlila jsem základní pojmy z oboru neuronových sítí, proces jejich inicializace, trénování, vyhodnocení a testování. Krok za krokem jsem demonstrovala vytvoření hluboké neuronové sítě 3D U-Net a její použití při segmentaci CT snímků prsat domácích. Diskutovala jsem důležitost zachování 3D povahy segmentovaných dat, včetně nevýhod, které to přináší v porovnání se segmentací na 2D datech. Analýza a experimenty ukázaly, že U-Net je vhodnou volbou pro tuto úlohu. Jeho schopnost zachytit jak globální, tak lokální kontext 3D obrazu umožňuje přesné a přesvědčivé výsledky v oblasti segmentace cév v játrech a cévních centrálních linií. Bylo dosaženo 93% úspěšnosti při testování modelu určeného pro segmentaci cév a 98% úspěšnosti při testování modelu specializovaného na segmentaci středových linií cév. Z těchto výsledků je patrné, že s technologickým pokrokem ve výpočetní technice bude využívání neuronových sítí v medicíně stále častější.

Vzhledem k tomu, že medicínské zobrazování a léčebné postupy se neustále vyvíjejí, je tato práce pouze prvním krokem směrem k dalším vylepšením a inovacím v oblasti segmentace cév v játrech. Věřím, že zjištění a doporučení v této práci poskytnou základ pro další výzkum a rozvoj této problematiky, což může mít významný dopad na zlepšení zdravotní péče a diagnostiky.

Bibliografie

- [Asc08] ASCHERMANN, Michael. Využití CT angiografie a magnetické rezonance v kardiologii. 2008.
- [Bc] BC MAGDALÉNA ŠVECOVÁ, Fakulta ZDRAVOTNICKÝCH VĚD Ústav radiologických metod. *UNIVERZITA PALACKÉHO V OLOMOUCI Charakteristiky aterosklerotických plátů v karotickém povodí detekované ultrazvukovou sonografií a riziko cévní mozkové příhody Diplomová práce Olomouc 2021.*
- [Bib+17] BIBI, Irfana; LIU, Fang; RAZI, Amir; CUI, Yuanhao. Image segmentation by hybrid active contour model using harmonic mean. In: Institute of Electrical a Electronics Engineers Inc., 2017, s. 363–367. ISBN 9781538630136. Dostupné z doi: 10.1109/ICISCE.2017.83.
- [BKR05] BOER, Pieter-Tjerk De; KROESE, Dirk P.; RUBINSTEIN, Reuven Y. *A Tutorial on the Cross-Entropy Method.* 2005. Dostupné také z: <http://www.cemethod.org/>.
- [CFO11] CORREIA, Mauro M.; FEITOSA, Raul Q.; OLIVEIRA, Dário AB. Segmentation of liver, its vessels and lesions from CT images for surgical planning. 2011. Dostupné také z: <https://doi.org/10.1186/1475-925X-10-30>.
- [Čih97] ČIHÁK, Radomír. *Anatomie 3.* 1997.
- [Čih02] ČIHÁK, Radomír. *Anatomie 2.* Praha: Grada Publishing, 2002.
- [Ekš22] EKŠTEIN, Kamil. *Diplomová práce FASThesis-návod k použití šablony závěrečné práce na FAV ZČU.* 2022.
- [GP17] GULLI, Antonio; PAL, Sujit. *Deep learning with Keras.* Packt Publishing Ltd, 2017.
- [Jan+16] JANG, Jinhee et al. Radiation doses of various CT protocols: A multi-center longitudinal observation study. *Journal of Korean Medical Science.* 2016, roč. 31, S24–S31. ISSN 15986357. Dostupné z doi: 10.3346/jkms.2016.31.S1.S24.

- [Jiř+16] JIŘÍK, Miroslav et al. Stereological quantification of microvessels using semiautomated evaluation of X-ray microtomography of hepatic vascular corrosion casts. *International Journal of Computer Assisted Radiology and Surgery*. 2016, roč. 11, s. 1803–1819. ISSN 18616429. Dostupné z DOI: 10.1007/s11548-016-1378-3.
- [Jiř+18] JIŘÍK, Miroslav et al. Generating standardized image data for testing and calibrating quantification of volumes, surfaces, lengths, and object counts in fibrous and porous materials using X-ray microtomography. *Microscopy Research and Technique*. 2018, roč. 81, s. 551–568. ISSN 10970029. Dostupné z DOI: 10.1002/jemt.23011.
- [Kři21] KŘIVAN, Miloš. Umělé neuronové sítě. 2021.
- [Lim+08] LIM, Ruth P. et al. 3D time-resolved MR angiography (MRA) of the carotid arteries with time-resolved imaging with stochastic trajectories: Comparison with 3D contrast-enhanced bolus-chase MRA and 3D time-of-flight MRA. *American Journal of Neuroradiology*. 2008, roč. 29. ISSN 01956108. Dostupné z DOI: 10.3174/ajnr.A1252.
- [LSD15] LONG, Jonathan; SHELHAMER, Evan; DARRELL, Trevor. Fully convolutional networks for semantic segmentation. In: IEEE Computer Society, 2015, sv. 07-12-June-2015, s. 431–440. ISBN 9781467369640. ISSN 10636919. Dostupné z DOI: 10.1109/CVPR.2015.7298965.
- [Mou+20] MOULISOVÁ, Vladimíra et al. Novel morphological multi-scale evaluation system for quality assessment of decellularized liver scaffolds. *Journal of Tissue Engineering*. 2020, roč. 11. ISSN 20417314. Dostupné z DOI: 10.1177/2041731420921121.
- [Nek+05] NEKULA; HEŘMAN; VOMÁČKA; KÖCHER. Radiologie. 2005.
- [Pok13] POKORNÝ, Zbyněk. *Chov Zvířat.cz*. 2013.
- [SF07] SASAKI, Yutaka; FELLOW, Research. *The truth of the F-measure*. 2007.
- [SHB06] SONKA; HLAVAC; BOYLE. *Image Processing, Analysis, and Machine Vision*. 2006.
- [Tet+20] TETTEH, Giles et al. DeepVesselNet: Vessel Segmentation, Centerline Prediction, and Bifurcation Detection in 3-D Angiographic Volumes. *Frontiers in Neuroscience*. 2020, roč. 14. ISSN 1662453X. Dostupné z DOI: 10.3389/fnins.2020.592352.
- [Tet+] TETTEH, Giles et al. *DeepVesselNet: Vessel Segmentation, Centerline Prediction, and Bifurcation Detection in 3-D Angiographic Volumes*.

- [VVH] VAVRIKOVA, Marketa; VALEK, Vlastimil; HUSTY, Jakub. *Využití ultrazvuku v diagnostice onemocnění střev*. Dostupné také z: <https://www.researchgate.net/publication/266469957>.
- [Ven] VENDIŠ, Tomáš. [B.r.]. Dostupné také z: <http://radiologieplzen.eu>.
- [Yin+20] YIN, Pengshuai; YUAN, Rui; CHENG, Yiming; WU, Qingyao. Deep Guidance Network for Biomedical Image Segmentation. *IEEE Access*. 2020, roč. 8, s. 116106–116116. ISSN 21693536. Dostupné z DOI: 10.1109/ACCESS.2020.3002835.

Seznam obrázků

2.1	Ukázka CT angiografie	7
2.2	CT tomograf	8
2.3	Segmentace metodou prahování	12
2.4	Segmentace metodou detekce hran	14
3.1	Model neuronu	17
3.2	Aktivační funkce	18
3.3	Struktura neuronové sítě	18
3.4	Příklad architektury U-Net	20
3.5	Schéma možných případů klasifikace	23
3.6	Schéma Jaccardova indexu	25
4.1	Ukázka vybraných datasetů Deepvesselnet	29
4.2	Ukázka vybraných adredářů projektu Deepvesselnet ve 3D	30
4.3	Přeštické černostrakaté prase	31
4.4	Postup vytvoření mikro-CT snímků	32
4.5	Odlitek jater pod elektronovým mikroskopem	32
4.6	Ukázka segmentace cév na trénovacím datasetu	36
4.7	Ukázka segmentace centrálních linií cév na trénovacím datasetu	37
4.8	Průběh trénování modelu	37
4.9	Porovnání průběhů krychlové metriky pro různé modely architektury UNET1	38
4.10	Segmentace jaterních cév architekturou UNET1	38
4.11	Segmentace středových linií jaterních cév architekturou UNET1	39
4.12	Segmentace jaterních cév architekturou UNET2	40
4.13	Segmentace středových linií jaterních cév architekturou UNET2	41
4.14	Segmentace snímku prasečích jaterních cév	41

Seznam tabulek

4.1	Přehled modelů s architekturou UNET1	34
4.2	Přehled modelů s architekturou UNET2	35

