



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

SEGMENTACE MOZKOVÝCH CÉV V OBJEMOVÝCH DATECH

SEGMENTATION OF CEREBRAL VESSELS IN VOLUMETRIC DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jan Sucháček

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček, Ph.D.

BRNO 2022

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Jan Sucháček

ID: 220955

Ročník: 3

Akademický rok: 2021/22

NÁZEV TÉMATU:

Segmentace mozkových cév v objemových datech

POKYNY PRO VYPRACOVÁNÍ:

1) Nastudujte anatomii cévního zásobení hlavy a možnosti jeho zobrazení. Zaměřte se na možnosti angiografického vyšetření a využití obrazové analýzy v diagnostickém procesu. 2) Vypracujte rešerši dostupných segmentačních technik a uveďte příklady již publikovaných řešení segmentace mozkových cév. 3) Seznamte se se strukturou, formátem a datovými typy dostupných objemových dat pro jejich načtení a následnou práci. Na základě provedené rešerše navrhnete segmentační přístup. 4) Implementujte navržený přístup ve zvoleném programovacím prostředí a proveďte prvotní vyhodnocení úspěšnosti. 5) Otestujte na dalších datech a navrhnete vhodnou metodiku hodnocení a proveďte detailnější vyhodnocení úspěšnosti navrženého přístupu. 6) Navrhnete a implementujte vhodné modifikace či odlišné přístupy a vhodně prezentujte a diskutujte dosažené výsledky.

DOPORUČENÁ LITERATURA:

[1] JAN, Jiří, 2005. Medical image processing, reconstruction and restoration: Concepts and methods. B.m.: CRC Press. ISBN 9781420030679.

[2] AJAM, Azimah et al., 2017. A Review on Segmentation and Modeling of Cerebral Vasculature for Surgical Planning. IEEE Access [online]. 5, 15222–15240. ISSN 21693536. doi:10.1109/ACCESS.2017.2718590

Termín zadání: 7.2.2022

Termín odevzdání: 27.5.2022

Vedoucí práce: Ing. Roman Jakubíček, Ph.D.

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 práce se zabývá návrhem, realizací a testováním algoritmu pro segmentaci mozkových cév v 3D CT obrazových datech se zaměřením na cévní mozkové příhody. Nejprve byla vytvořena 3D binární maska mozku, která byla následně využita k extrakci mozkové tkáně z původních objemových CT snímků. V takto extrahované mozkové tkáni byly zvýrazněny mozkové cévy pomocí tří pokročilých filtrů založených na výpočtu Hessovy matice a analýze vlastních čísel Hessovy matice. Výsledné parametrické obrazy zvýrazněných mozkových cév byly vstupem do šesti segmentačních metod, které byly v této práci implementovány a porovnány. Programové řešení této práce bylo implementováno v prostředí Matlab R2021b. Navržený algoritmus byl otestován na reálných patientských datech. V jednom z patientských CT skenů byly jako součást této práce označeny mozkové cévy a tento výsledný objem manuálně segmentovaných mozkových cév byl využit k objektivnímu zhodnocení dosažených výsledků segmentace. V teoretické části byla nastudována a popsána problematika anatomie, fyziologie a patologie cévního zásobení mozku. Dále byly popsány zobrazovací metody využívané pro zobrazení cévního zásobení mozku. Byla provedena rešerše dostupných segmentačních technik a již publikovaných konkrétních přístupů pro segmentaci cévního zásobení mozku. Také byly teoreticky popsány metody použité v této práci.

KLÍČOVÁ SLOVA

Angiografie mozku, Zvýraznění mozkových cév, Segmentace mozkových cév, Výpočetní tomografie.

ABSTRACT

This thesis deals with the design, implementation and testing of an algorithm for segmentation of cerebral vessels in 3D CT image data with a focus on stroke. First, a 3D binary mask of the brain was created and then used to extract brain tissue from the original volumetric CT images. In the extracted brain tissue, cerebral vessels were enhanced using three advanced filters based on Hessian matrix calculation and eigenvalue analysis of the Hessian matrix. The resulting parametric images of the enhanced cerebral vessels were input to six segmentation methods that were implemented and compared in this work. The program solution of this work was implemented in Matlab R2021b. The proposed algorithm was tested on real patient data. In one of the patient CT scans, cerebral vessels were labeled as part of this thesis and this resulting volume of manually segmented cerebral vessels was used to objectively evaluate the segmentation results obtained. In the theoretical part, the anatomy, physiology and pathology of the cerebral vascular supply were studied and described. Furthermore, the imaging methods used for imaging the cerebral vascular supply were described. A review of available segmentation techniques and specific approaches already published for segmentation of the cerebral vascular supply was performed. The methods used in this thesis were also theoretically described.

KEYWORDS

Brain angiography, Enhancement of cerebral vessels, Segmentation of cerebral vessels, Computed tomography.

SUCHÁČEK, Jan. *Segmentace mozkových cév v objemových datech*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022, 68 s. Bakalářská práce. Vedoucí práce: Ing. Roman Jakubíček, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Jan Sucháček
VUT ID autora: 220955
Typ práce: Bakalářská práce
Akademický rok: 2021/22
Téma závěrečné práce: Segmentace mozkových cév v objemových datech

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

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu bakalářské práce panu Ing. Romanovi Jakubíčkoví, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	12
1 Cévní zásobení mozku	14
1.1 Anatomie cévního zásobení mozku	14
1.1.1 Willisův tepenný okruh	15
1.2 Fyziologie cévního zásobení mozku	17
1.3 Patologie cévního zásobení mozku	17
1.3.1 Cévní mozková příhoda (CMP)	17
2 Možnosti zobrazení cévního zásobení	20
2.1 Rentgenová výpočetní angiografie – CTA	20
2.1.1 Princip CT systému	20
2.1.2 Princip CTA vyšetření	22
2.2 Perfuzní CT vyšetření - CTP	23
2.3 Digitální subtrakční angiografie - DSA	23
2.4 Angiografické skiaskopické metody	23
2.5 MR angiografie - MRA	24
3 Metody obrazové analýzy	25
3.1 Využití obrazové analýzy u CMP	25
3.2 Přehled segmentačních technik	26
3.3 Přehled publikovaných přístupů segmentace CZM	29
3.4 Použité metody	30
3.4.1 Morfologické operace	30
3.4.2 Metoda narůstání oblastí	32
3.4.3 Metody pro zvýraznění mozkových cév	33
3.4.4 Segmentační metody	36
4 Návrh a realizace segmentačního přístupu	40
4.1 Dostupný dataset	40
4.2 Tvorba trénovací a validační množiny	40
4.3 Algoritmus pro segmentaci mozkových cév	42
4.3.1 Předzpracování objemových CT dat	42
4.3.2 Tvorba 3D binární masky mozku pomocí metody vícenásobného narůstání oblastí	44
4.3.3 Zvýraznění mozkových cév a extrakce příznakových map	47
4.3.4 Segmentace mozkových cév	49

5	Výsledky a diskuze	53
5.1	Extrakce mozku a zvýraznění cév	53
5.2	Segmentace mozkových cév	55
5.2.1	Objektivní hodnocení výsledků segmentace	56
5.2.2	Analýza a filtrace malých objektů	58
5.2.3	Možné využití v diagnostickém procesu	60
	Závěr	62
	Literatura	63

Seznam obrázků

1.1	Tepenné zásobení mozku [5].	15
1.2	Willisův tepenný okruh [6].	16
1.3	Ischemická a hemoragická cévní mozková příhoda [13].	19
3.1	Schématické znázornění binární eroze.	31
3.2	Schématické znázornění binární dilatace.	32
3.3	Schéma jednoho neuronu.	38
3.4	Schéma nejjednodušší dopředné neuronové sítě.	38
4.1	Blokové schéma navrženého algoritmu.	42
4.2	Předzpracování objemových dat. Vlevo: Ukázka uspořádání řezů. Vpravo: Transformace řezu z transverzální do sagitální roviny.	43
4.3	Pozice třech počátečních semínek v sagitálním řezu.	45
4.4	2D binární masky mozku v sagitální rovině před vyplněním děr (vlevo) a po vyplnění děr (vpravo).	45
4.5	Ukázka binárních výstupů segmentace ze tří počátečních semínek a jejich následná fúze do výsledné 2D binární masky mozku jednoho řezu objemu.	46
4.6	Zleva: Transverzální, frontální a sagitální pohled na 3D binární masku mozku.	47
4.7	Frontální a sagitální pohled na extrahovaný objem mozkové tkáně. . .	47
4.8	Výstupy zvýraznění mozkových cév pomocí třech filtrů.	49
5.1	Výstupy extrakce objemu mozkové tkáně (sagitální pohled) a zvýraz- nění mozkových cév (sagitální a frontální pohled) pro všechny do- stupné CT data.	53
5.2	Původní 2D řez mozku, ve kterém je červenou konturou ohraničena oblast extrahovaného mozku.	54
5.3	2D řez mozkiem pátého CT skenu nasnímaného ve druhé kontrastní fázi a ukázka zvýraznění mozkových cév.	54
5.4	Výstupy segmentace mozkových cév (frontální, sagitální, transver- zální pohled) všemi segmentačními metodami pro dva vybrané CT skeny.	55
5.5	Sagitální a transverzální pohled na: a) Ground Truth b) výstup seg- mentace pomocí Adaptivního prahování c) bíle zobrazené TP pixely, šedě zobrazené FP a FN pixely, černě zobrazené pixely pozadí.	57
5.6	Sagitální a transverzální pohled na: a) Ground Truth b) výstup seg- mentace pomocí Globálního prahování c) bíle zobrazené TP pixely, šedě zobrazené FP a FN pixely, černě zobrazené TN pixely.	57

5.7	Výstupy segmentace mozkových cév pomocí Neuronové sítě pro první a třetí CT snímek naší databáze.	59
5.8	Filtrované výstupy segmentace mozkových cév pomocí Neuronové sítě pro první a třetí CT snímek naší databáze.	59
5.9	Ukázky využití segmentace mozkových cév v diagnostice patologií cévního zásobení mozku.	61

Úvod

V klinické praxi je diagnostika patologií cévního systému mozku, zejména cévní mozkové příhody, velmi častým případem. Vzhledem k charakteru a průběhu onemocnění cévního systému mozku je časná diagnostika a přesné určení příčiny vzniku patologie zásadní pro následný terapeutický postup. Nejvýznamnější a nejčastěji využívanou zobrazovací modalitou pro vyšetření mozkových cév je CT, neboli rentgenová výpočetní tomografie. Pro zobrazení mozkových cév pomocí CT systémů je do krevního řečiště pacienta aplikována kontrastní látka, která ve výsledném zrekonstruovaném objemu nasnímaných dat způsobí zvýraznění cévních struktur. Takto získaná obrazová data jsou poměrně dosti objemná a pro lékaře, který snímky vyhodnocuje, může být orientace v celém trojrozměrném objemu dat do značné míry komplikovaná a časově náročná. Z tohoto důvodu jsou vyvíjeny různé postupy digitálního zpracování obrazu, které mohou být využity k segmentaci původního objemu dat. Segmentační přístupy umožňují oddělení požadovaných struktur, v tomto případě cévního systému mozku, od okolních tkání. Práce s takto získaným objemem oblasti zájmu může lékařům a radiologům pomoci ke zvýšení efektivity, přesnosti a rychlosti diagnostického procesu.

Úkolem této práce je navržení algoritmu pro segmentaci mozkových cév z objemových dat se zaměřením na cévní mozkové příhody a jeho realizace v programovacím prostředí Matlab R2021b. V předložené práci je navržen a otestován přístup, který vede k sestavení trojrozměrné binární masky mozku, která je následně využita k extrakci mozkové tkáně z původního objemu tomografických snímků. V takto extrahovaném objemu mozku jsou zvýrazněny mozkové cévy pomocí třech pokročilých filtrů založených na výpočtu Hessovy matice a analýze vlastních čísel Hessovy matice. Získané parametrické obrazy zvýrazněných mozkových cév jsou následně využity pro segmentaci mozkových cév. Celý algoritmus je otestován na databázi pěti patientských CT skenů. Dosažené výsledky segmentace jsou popsány a diskutovány. V jednom patientském CT skenu byly manuálně označeny mozkové cévy. Výsledný anotovaný CT sken, tzv. „Ground truth“, byl využit pro objektivní zhodnocení výsledků segmentace, přičemž jako objektivní metrika byl zvolen Dice koeficient.

Teoretická část je rozdělena do tří kapitol. První kapitola je věnována medicínské oblasti, kdy byla nastudována problematika cévního zásobení mozku. Druhá kapitola je na pomezí medicínské a technické oblasti a jsou v ní popsány možnosti zobrazení cévního zásobení mozku, včetně jejich principů. Třetí kapitola je ryze technického charakteru. Jsou zde popsány metody zpracování obrazu se zaměřením na segmentační techniky. Také byla provedena rešerše již publikovaných řešení segmentace mozkových cév. V poslední části třetí kapitoly byly teoreticky popsány metody použité v jednotlivých krocích algoritmu. Ve čtvrté kapitole je popsán návrh a re-


alizace segmentačního přístupu. V kapitole páté jsou prezentovány a diskutovány výsledky.

1 Cévní zásobení mozku

Aby mohl mozek dobře plnit svoji funkci, musí být nepřetržitě a dostatečně zásoben okysličenou krví. Ta proudí do mozku a slouží jako zdroj nejen kyslíku, ale také všech důležitých živin, které mozek potřebuje. Mозek je na dostatečný přísun kyslíku velmi citlivý. Náhlé snížení průtoku krve mozkem vede ke snížení okysličení mozku a v důsledku toho nastává přibližně do 10 sekund stav bezvědomí [1]. Normální průměrný průtok krve mozkem je 750-900 ml krve za minutu [3]. Přívod okysličené krve do mozku zajišťuje systém tepenného zásobení, který je tvořen velkými tepnami, malými tepnami a tepénkami [3, 4].

1.1 Anatomie cévního zásobení mozku

Z aortálního oblouku vystupuje tzv. brachiocefalický kmen (který se dále dělí na pravou společnou karotidu (*a. carotis communis dextra*) a pravou podklíčkovou tepnu (*a. subclavia dextra*)), levá společná karotida (*a. carotis communis sinistra*) a levá podklíčková tepna (*a. subclavia sinistra*). Společné krční tepny (levá a pravá společná karotida) vedou směrem k hlavě a rozdvíhají se (bifurkují) na vnější (*a. carotis externa*) a vnitřní karotidu (*a. carotis interna*) v úrovni krčních obratlů C3-C4. Vnitřní karotidy (*aa. carotis internae*) zajišťují krevní zásobení předních částí mozkových hemisfér (*anterior circulation*). Karotické řečiště se podílí na krevním zásobení mozku asi z 80 % [4]. Z pravé a levé podklíčkové tepny vystupují pravá a levá vertebrální (páteřní) tepna (*a. vertebralis dextra et sinistra*). Obě tyto tepny vstupují do lebky přes otvor *foramen occipitale magnum* a v úrovni Varolova mostu (*pons Varoli*) se spojují v basilární tepnu (*a. basilaris*) a zajišťují krevní zásobení zadních částí mozku (týlní lalok, střední a zadní spánkový lalok), mozkového kmene, mozečku a míchy (*posterior circulation*). Basilární tepna vytváří větve, které vedou krev k Varolovu mostu (*aa. Pontines*), k mozečku (*a. cerebularis superior*) a které propojují tok krve přicházející vertebrálními tepnami s tokem krve přicházejícím do mozku z vnitřních karotid (viz. Willisův tepenný okruh) [3, 4].



Obr. 1.1: Tepenné zásobení mozku [5].

1.1.1 Willisův tepenný okruh

Přední cirkulace (*anterior circulation* 1.1 – vnitřní karotidy) a zadní cirkulace (*posterior circulation* 1.1 – basilární tepna) se spojují v cévní smyčce zvané Willisův tepenný okruh. Toto spojení je tvořeno levou a pravou tepnou *a. communicans posterior*. Ve Willisově okruhu se také spojují cévní zásobení pravé a levé mozkové hemisféry. Lze tedy říct, že ve Willisově okruhu se propojují nejdůležitější mozkové tepny, díky čemuž je zajištěn vícečetný přívod krve k mozkové tkáni pro případ, že by došlo například k ucpání (embolizaci) jedné z tepenných větví. Na druhou stranu je potřeba zmínit, že uvnitř Willisova okruhu dochází ke vzniku přibližně 60 % všech intrakraniálních aneurysmat [3, 4]. Z Willisova tepenného okruhu vystupují tři páry velkých mozkových tepen: *aa. cerebri anteriores*, *aa. cerebri mediae*, *aa. cerebri posteriores* [4].

Arteria cerebri anterior


A. cerebri anterior dextra se po odstupu z *a. carotis interna* propojuje s její párovou druhostrannou tepnou *a. cerebri anterior sinistra* přes *a. communicans anterior*. Takto propojené tepny tvoří velký oblouk, ze kterého odstupují další tepenné větve. Tento úsek tepenného systému zásobuje mediální plochy mozkových hemisfér nad *corpus calosum* [4].

Arteria cerebri media

Po odstupu z *a. carotis interna* ve Willisově okruhu prostupuje *a. cerebri media* mozkem až k povrchu hemisfér. Na zevním povrchu velkého mozku se větví všemi směry. Větve *a. cerebri media* vyživují největší část celé mozkové kůry, oblast celého parietálního laloku, dorzální části frontálního laloku a zevní kůru temporálních laloků [4].

Arteria cerebri posterior

Tato párová tepna vzniká bifurkací bazilární tepny (*a. basilaris*) a dochází na ní k soutoku s *a. communicans posterior*. Pravá i levá *a. cerebri posterior* prochází podél mozkového kmene a prostupuje dále mozkem, kde se dělí na větve. Tyto větve vyživují mediální část temporálních a okcipitálních laloků [4].



Obr. 1.2: Willisův tepenný okruh [6].

Koncové větve všech tří párů hlavních větví Willisova tepenného okruhu vytvářejí síť na povrchu hemisfér. Z povrchu hemisfér se zanořují do hlubších částí mozku, kde vyživují mozkovou kůru a bílou hmotu mozkovou [4].

Žilní systém mozku můžeme rozdělit na odtokové žíly mozkového kmene a mozkových hemisfér. Krev z mozkového kmene odtéká do *vena basalis*, která vzniká na spodní straně frontálního laloku a ústí do velké mozkové žíly (*vena magna cerebri*).

U mozkových hemisfér rozlišujeme povrchový a hloubkový žilní systém [4]. Povrchové žíly sbírají krev z mozkové kůry a ústí do nitrolebních žilních splavů. Hluboké mozkové žíly se spojují do velké mozkové žíly (*vena magna cerebri*), která ústí do *sinus rectus*. Odtud odtéká krev přes *sinus transversus* a *sinus sigmoideus* do vnitřní hrdelní žíly (*vena jugularis interna*) [1, 2].

1.2 Fyziologie cévního zásobení mozku

Krevní zásobení mozku je zprostředkováno tepenným a žilním cévním systémem. Vzhledem k tomu, že je mozek jednou z nejcitlivějších tkání na dostatečný přísun okysličené krve, je mozkový krevní oběh přísně regulován. Průtok krve mozkovou tkání představuje 12-15 % klidového minutového srdečního výdeje. Kromě toho, že krev proudící do mozku slouží k okysličení tkáně, je také zdrojem glukózy. Ta je nejen hlavním energetickým substrátem pro mozek, ale také prekurzorem některých neurotransmiterů. Vzhledem k tomu, že mozek nemá prakticky žádné zásoby glukózy, je její přísun krví nezbytný. Kromě zásobení mají mozkové tepny ještě jednu důležitou funkci - odvádějí intersticiální tekutinu. Dvoucestné zásobení mozku okysličenou krví zajišťují dvě vnitřní karotické tepny a dvě vertebrální tepny, o kterých je pojednáno v předešlé kapitole 1.1. Při snížení průtoku krve mozkem dochází během přibližně 10 sekund ke ztrátě vědomí a během 3-8 minut k nenávratnému a trvalému poškození mozku v důsledku odumírání mozkových neuronů. Při snížení či přerušení žilního odtoku dochází k hromadění odpadních produktů v mozkové tkáni, což také vede k degeneraci neuronů [1, 7, 8].

1.3 Patologie cévního zásobení mozku

1.3.1 Cévní mozková příhoda (CMP)

Cévní mozková příhoda neboli iktus je akutní život ohrožující stav, který vyžaduje brzkou neodkladnou lékařskou pomoc. Z hlediska mortality se jedná o druhou nejčastější neúrazovou příčinu úmrtí a nejčastější příčinou invalidity [9, 10].

Při cévní mozkové příhodě dochází k náhlému postižení mozkové funkce, které je způsobeno poruchou prokrvení mozkové tkáně, tedy v důsledku nedostatečného okysličení a přívodu živin. Příznaky cévní mozkové příhody často vznikají náhle a rychle se rozvíjejí, proto je velmi důležité tyto příznaky rozpoznat a ihned tento stav řešit odbornou lékařskou pomocí. Příznaky CMP mohou být různé v závislosti na lokalizaci ložiskového postižení mozku, avšak mezi nejčastější symptomy patří pokleslý koutek, neschopnost zvednout končetinu, porucha řeči [9, 10].

Pro určení stádia a typu cévní mozkové příhody se ze zobrazovacích modalit nejčastěji používají výpočetní tomografie (CT) a magnetická rezonance (MRI). Pro podrobnější vyšetření se dále využívá CT angiografie mozkových tepen nebo perfuzní CT mozku [9, 10].

Při léčbě cévní mozkové příhody bývá často využíváno digitální subtrakční angiografie (DSA), kdy pomocí miniinvazivního zákroku pod skiaskopickou kontrolou může být znovu zprůchodněna ucpaná céva nebo zastaveno krvácení z prasknuté cévy [9, 10].

Rozlišujeme 2 typy cévních mozkových příhod: ischemickou cévní mozkovou příhodu (iCMP) a hemoragickou cévní mozkovou příhodu (hCMP).


Ischemická cévní mozková příhoda (iCMP)

Jedná se o nejčastější typ CMP, tvoří celkem 87 % všech případů. Při ischemiích dochází ke snížení parciálního tlaku kyslíku v mozku zapříčiněného snížením perfúze mozku okysličenou krví. Příčinou vzniku iCMP je mozkový infarkt, který bývá způsoben trombózou nebo embolizací cévy, stlačením cévy, edémem mozku nebo nádorem. Při trombóze a embolizaci mozkových tepen dochází k uzávěru cévy a s tím spojenému nedostatečnému zásobení mozku okysličenou krví. Trombóza vzniká v důsledku aterosklerózy mozkových tepen. Naproti tomu embolie vzniká v důsledku utržení trombu, který po průchodu do cévního systému mozku ucpe některou z tepen. Rozsah postižení mozkové funkce je ovlivněný zejména místem okluze, rychlostí vzniku uzávěru cévy a možností zásobení kolaterálním oběhem. V případě lokální ischemie dochází k výpadku činnosti pouze příslušné oblasti mozku, kdežto úplné přerušování průtoku krve mozkem způsobuje ztrátu vědomí a později vede k nevratnému poškození mozku. Z hlediska terapie iCMP jsou nejčastějším řešením rekanalizační postupy (trombolýza a tromektomie) nebo karotický stenting [9, 10, 11].

Hemoragická cévní mozková příhoda (hCMP)

Jedná se o méně častý typ CMP, tvoří pouze 13 % všech případů. Při hemoragiích dochází k intrakraniálnímu krvácení, které se dále dělí na intracerebrální a extracerebrální krvácení. V případě extracerebrálních intrakraniálních (nitrolebečních) hemoragií dochází ke krvácení do prostoru mezi lebečními kostmi a mozkovými plenami. Při krvácení do extracerebrálních prostor se zvyšuje intrakraniální tlak a je utlačován mozek, což může vést ke zhoršení prokrvení mozku, útlaku dýchacího a kardiovaskulárního centra. Při intracerebrálních hemoragiích dochází ke krvácení do mozku. Tento patologický stav vzniká náhle, má rychlý průběh a způsobuje vážné poškození CNS až smrt. Hemoragické cévní mozkové příhody bývají nejčastěji způsobeny rupturou mozkové cévy, méně často krvácením arteriálních aneurysmat, kr-

vácením v důsledku traumat. K ruptuře neboli prasknutí mozkové cévy může dojít vlivem vysokého krevního tlaku nebo vlivem zúžení tepenné stěny [10, 12].



Obr. 1.3: Ischemická a hemoragická cévní mozková příhoda [13].

2 Možnosti zobrazení cévního zásobení

Vzhledem k významnému zdokonalení řady diagnostických zobrazovacích modalit během posledních pár let je v dnešní době možné zobrazení všech anatomických struktur lidského těla ve velmi vysoké kvalitě. Struktury, jako jsou cévy, můžeme zobrazovat například pomocí angiografických radiodiagnostických metod nebo pomocí magnetické rezonance [14].

Mezi nejpoužívanější zobrazovací systémy v lékařství patří skiografické a skiaskopické rentgenové přístroje, přístroje výpočetní tomografie (CT), magnetické rezonance (MRI), ultrazvukové přístroje a hybridní zobrazovací systémy nukleární medicíny – SPECT/CT a PET/MR, PET/CT [14].

Většina angiografických metod využívá aplikaci kontrastní látky do cévního systému těla pacienta a následně zobrazuje průtok a distribuci této látky ve vyšetřované oblasti cévního systému [14].

2.1 Rentgenová výpočetní angiografie – CTA

2.1.1 Princip CT systému

Systémy rentgenové výpočetní tomografie (CT) jsou moderní zobrazovací modalita využívající ionizujícího rentgenového záření pro zobrazení vnitřních struktur těla pacienta. Zdrojem rentgenového záření je skleněná vakuová trubice, zvaná rentgenka, ve které jsou naproti sobě umístěny 2 elektrody – kladná anoda a záporná katoda. Na katodu s wolframovým žhaveným vláknem je přivedeno nízké napětí a vysoký proud (10 V, 7-10 A), při průchodu proudu vláknem dochází k termoemisi elektronů z povrchu katody. Rotační anoda je napájena velmi vysokým napětím (40-120 kV), vlivem obrovského potenciálového rozdílu mezi anodou a katodou dochází k přitahování a velkému urychlení proudu elektronů letících z katody směrem k anodě. Rotační anoda je tak bombardována proudem rychle letících elektronů o vysoké energii. Místo dopadu elektronů se nazývá anodový terčík, často vyroben z materiálu wolframu, který díky svému vysokému atomovému číslu má lepší účinnost přeměny na RTG záření. Na užitečné RTG záření se přemění pouze 1 % energie elektronů, zbylých 99 % energie je přeměněno na odpadní teplo, což vede k vysokým nárokům na tepelné vlastnosti anody, odvod tepla a chlazení anody. Vzniklé RTG záření vychází ven z kovového obalu rentgenky výstupním okénkem, v němž dochází k filtraci a kolimaci záření. Naproti rentgenky je umístěn vícevrstvý polovodičový detektor ve tvaru půl prstence. Celý tento systém je uložen v rotační gantry [15, 16, 17].

Principem CT vyšetření je detekce utlumeného RTG záření, které se při průchodu tělem pacienta v závislosti na densitě jednotlivých tkání a struktur různě

tlumí. Takto utlumené svazky RTG záření prošlé tělem pacienta jsou detekovány pomocí pole mnohovrstvých detektorů při každém natočení gantry o určitý úhel – získáváme tak jednotlivé projekce scény. Během akvizice neboli snímkování dochází k nasnímání souboru projekcí pod různými úhly natočení (0-360°) gantry. Ze souboru projekcí pak pomocí rekonstrukčních algoritmů počítačový software sestaví výsledný tomografický snímek, který lze pomocí určitých výpočetních metod modifikovat do různých zobrazení. Dva nejčastější rekonstrukční algoritmy jsou filtrovaná zpětná projekce (FBP) a iterativní rekonstrukce (IR). Výsledný tomografický obraz je tedy soubor velmi tenkých (submilimetrových) tomografických řezů tělem pacienta, složených ze základních objemových elementů - voxelů [15, 16, 17].

CT čísla

Základní zobrazení výsledného tomografického obrazu je šedotónové. Jednotlivé typy tkání a orgánů se po zobrazení liší šedotónovým odstínem, který je dán útlumem RTG záření po průchodu danou strukturou scény. Útlum RTG záření je závislý na hodnotách lineárního součinitele útlumu μ jednotlivých voxelů¹ scény, kterými vějířovitý svazek RTG záření prochází.

Lineární součinitel útlumu je však značně ovlivnitelný energií použitého RTG záření, což má za následek to, že reprezentace CT obrazů v podobě hodnot lineárního součinitele útlumu není vhodná pro srovnání mezi systémy. Proto je ve výsledných CT datech míra absorpce RTG záření jednotlivými voxely scény vyjádřena pomocí CT čísel, která jsou zapsána v bezrozměrných Hounsfieldových jednotkách HU. CT čísla (HU) udávají míru absorpce RTG záření v daném voxelu scény vztahenou k absorpci vody:

$$CT = K \cdot \frac{\mu_A - \mu_v}{\mu_v} \quad (2.1)$$

V rovnici 2.1 parametr μ_A vyjadřuje lineární součinitel útlumu aktuálního voxelu, parametr μ_v vyjadřuje lineární součinitel útlumu vody. Konstanta K dosahuje u dnešních systémů hodnoty $K = 1000$.

Různé typy tkání lidského těla nabývají specifických hodnot CT čísel v závislosti na jejich schopnosti tlumit procházející RTG záření neboli v závislosti na jejich lineárním součiniteli útlumu. Kostí mívají hodnoty CT čísel 1000 HU, játra nabývají hodnot od 40 HU do 60 HU, ledviny 30 HU, svalová tkáň od 10 HU do 40 HU a tuková tkáň od -50 HU až -100 HU. Voda má vždy hodnotu CT čísla 0 HU, vzduch -1000 HU [15, 16, 17, 18, 19].

¹Voxel je elementární objem, který vzniká v důsledku diskretizace objemu scény

2.1.2 Princip CTA vyšetření

Cílem tohoto vyšetření je zobrazení cév pomocí CT přístroje. Vyšetření probíhá podobně jako běžné CT vyšetření, zásadní rozdíl je však v tom, že pro zobrazení cév je nutné vždy podat jodovou kontrastní látku do žíly. Nejčastěji se podává kontrastní látka do žíly v loketní jamce. Kontrastní látka prochází cévním systémem a ve výsledném zrekonstruovaném snímku zvýrazňuje cévy. Pro docílení dobré náplně cév bývá aplikována kontrastní látka automatickým injektorem, kde se přesně nastavuje rychlost průtoku a množství podané látky. Pro lepší hodnocení cév vyšetřující lékař zhotovuje z pořízených snímků další rekonstrukce v jiných rovinách, případně i trojrozměrné rekonstrukce cév. Používá se především pro zobrazení velkých tepen (aorty, ledvinné tepny, pánevní tepny, krkavice) a také pro zobrazení mozkových tepen. CT angiografie mozkových tepen může poměrně spolehlivě ukázat uzávěr některé z tepen při ischemické mozkové mrtvici [17, 20].

Zásadní kontraindikací CT angiografického vyšetření může být alergie na jodovou kontrastní látku, která může vyústit v silnou alergickou reakci pacienta (např. anafylaktický šok). V takovém případě se volí jiná metoda angiografického vyšetření – např. MRA. Další nevýhodou CT angiografického vyšetření je poměrně vysoká dávka ionizujícího záření [17, 20].

K hlavním indikacím CT angiografie patří cévní mozkové příhody, disekce aneurysmat aorty, intrakraniální aneurysmata a mozkové nádory. Výhodou CT angiografie je velmi krátká doba trvání celého vyšetření, což je v případě akutních uzávěrů cév důležitý faktor [17, 20].

Kontrastní látky

Jodová kontrastní látka se používá pro nástřík a následné zobrazení cév zejména kvůli jejímu vysokému útlumu procházejícího RTG záření. V důsledku vysokého atomového čísla má jód podstatně vyšší hodnotu lineárního součinitele útlumu rentgenového záření než všechny tkáně v lidském těle, včetně kostní tkáně. Tím pádem se cévy nastříknuté jodovou kontrastní látkou na angiografickém snímku jeví jako výrazně světlé struktury [17, 21].

2.2 Perfuzní CT vyšetření - CTP

Perfuzní CT je dynamické vyšetření určité oblasti lidského těla, často je zaměřené na jeden konkrétní orgán – například mozek. V podstatě se jedná o funkční vyšetření mozkové tkáně charakterizující stav mozkové perfuze pomocí několika parametrických map, získaných sériovou akvizicí dat při průchodu kontrastní látky mozkovou tkání. Po aplikaci jodové kontrastní látky do periferní žíly pacienta dochází k rychlému průtoku kontrastní látky mozkovými cévami, které obvykle trvá pouze několik sekund. Během tohoto krátkého časového úseku se provádí sériová akvizice dat mozkové tkáně s odstupem 1 sekunda po dobu 40-60 sekund, což je dostatečný časový interval postačující k zachycení prvního průchodu kontrastní látky celým mozkovým řečištěm [22].

Principem CTP vyšetření je tedy sériové snímání změny denzity mozkové tkáně při prvním průchodu (first-pass effect) intravenózně podané jodové kontrastní látky [22]. Význam perfuzního CT zobrazení spočívá v možnosti zobrazit pokles perfuze mozku již v okamžiku uzávěru tepny, což je důležité pro časnou léčbu této poruchy, která může vyústit až v akutní mozkovou ischémii neboli mozkovou mrtvici [22].

2.3 Digitální subtrakční angiografie - DSA

Digitální subtrakční angiografie je miniinvazivní metoda, která slouží k zobrazení cévního řečiště. Metoda využívá digitální zpracování skiaskopického obrazu a subtrakci (odečtení) obrazů před a po aplikaci kontrastní látky. Subtrakcí je získán tzv. rozdílový obraz, ve kterém jsou zvýrazněné struktury, kterými protéká kontrastní látka, tedy cévy a odstraněny všechny ostatní struktury, zejména skelet [14, 17].

DSA je zároveň také intervenční metoda, což znamená, že se provádí miniinvazivní zákrok přímo v cévním řečišti. Mezi nejčastější intervenční zákroky patří rozšíření zúžené cévy balónkovým katetrem, zavedení stentů do stenotických úseků, embolizace krvácivých stavů nebo uvolnění a znovu zprůchodnění cévy, která byla ucpana trombem [14, 17].

2.4 Angiografické skiaskopické metody

Skiaskopické rentgenové systémy jsou zobrazovací metody využívající rentgenového záření. Výstupem skiaskopických zobrazovacích systémů je sekvence snímků, můžeme tedy pozorovat dynamický vývoj obrazu v čase. V případě angiografického vyšetření jsou zobrazovanými objekty cévy. Jelikož cévy patří mezi měkké tkáně, mají nízkou denzitu a nejsou na obyčejném rentgenovém snímku viditelné. Z tohoto důvodu je důležitá aplikace jodové kontrastní látky do cévního řečiště. Kontrastní látka

prochází cévním systémem a umožňuje zvýraznění cév v důsledku jejího vysokého lineárního součinitele útlumu rentgenového záření. U skiaskopických zobrazovacích systémů pozorujeme dynamický průtok kontrastní látky cévním řečištěm a lze tak rozpoznat například počáteční stádia aterosklerózy nebo cévní aneurysmata [23].

2.5 MR angiografie - MRA

Jedná se o neinvazivní metodu vyšetření cévního systému, která využívá moderní zobrazovací modalitu – magnetickou rezonanci (MR). Tato metoda na rozdíl od klasické angiografie nevyužívá pro zobrazení cév rentgenové záření, což je její zásadní výhodou, protože se tak eliminuje riziko ozáření pacienta ionizujícím zářením [24, 25].

Nativní MR angiografie nabízí zobrazení cévního řečiště bez podání jakékoliv kontrastní látky. Pomocí speciální techniky (TOF – time of flight) lze odlišit pohybující se částice v tkáni (pohybující se krevní částice v cévách), a tím zobrazit neinvazivně tepny a žíly bez použití kontrastní látky. V současnosti je nativní MRA vyhrazena prakticky výhradně k vyšetření intrakraniální tepenné i žilní cirkulace. Naproti tomu kontrastní MRA s aplikací paramagnetické kontrastní látky do periferní žíly prakticky zcela vytlačila nativní MRA ze všech extrakraniálních aplikací. V současnosti je kontrastní MRA velmi vhodnou miniinvazivní metodou pro detekci patologických stavů hrudní a břišní aorty a jejich větví [24, 25, 26].

Výhodou oproti CT systémům je absence ionizujícího záření a zanedbatelná nefrotoxicita a alergenicita používané paramagnetické kontrastní látky (chelátu gadolinia). Dnešní MR systémy dosahují velmi dobré rozlišovací schopnosti a jsou vhodnější pro zobrazení měkkých tkání [24, 25].

Mezi nevýhody je nutno zařadit vyšší cenu vyšetření, nižší dostupnost, vyšší nároky na spolupráci vyšetřovaného (vyšetření cév trupu v apnoe o délce 12-20 sekund) a nemožnost vyšetřit osoby absolutně kontraindikované k MR vyšetření, především osoby s kardiostimulátorem, implantovaným defibrilátorem nebo s aneurysmatickými cévními svorkami (klipy), které nejsou z ryze nemagnetického materiálu. Mezi kontraindikace MR vyšetření patří také podstatně delší vyšetřovací doba (20-50 minut) v porovnání s CT vyšetřením (20-60 sekund), což je velmi důležitý parametr při vyšetření akutních stavů [17].

MRA se používá pro vyšetření možných problémů jako stenóza (zúžení průtoku krve), blokáda nebo aneurysma (zeslabení cévní stěny a riziko prasknutí). Často se používá na zobrazení cév krku nebo mozku [17].

3 Metody obrazové analýzy

3.1 Využití obrazové analýzy u CMP

Systémy výpočetní tomografie během snímkování vyšetřované oblasti těla pacienta nasnímají soubor projekcí pod různými úhly natočení gantry. Z takto nasnímaných dat je pomocí rekonstrukčních algoritmů dopočítán výsledný tomografický obraz. V dnešních CT systémech se nejčastěji využívá iterativní rekonstrukce. Obraz vznikající na monitoru již během snímkování, dokončen je však až po skončení celého vyšetření. Výsledný CT snímek je v základním zobrazení šedotónový. Následně lze obraz různě modifikovat podle potřeby a indikace vyšetření, tyto úpravy provádí radiolog pomocí počítačových rekonstrukcí a zpracování obrazů. Tyto úpravy obrazu se souhrnně nazývají post-processing [27, 28].

Během počítačového zpracování obrazu dochází také k redukci artefaktů, které často vznikají na rozhraní dvou prostředí o různé absorpci rentgenového záření, například hvězdicový artefakt kolem kovových implantátů. Odstraněním artefaktů je získán kvalitnější tomografický snímek [27, 28].

Moderní CT systémy v dnešní době umožňují automatické zobrazení 3D modelů kostních nebo cévních struktur, přičemž je vyžadována pouze minimální interakce softwaru s radiologem. Takto rekonstruované 3D modely cév a kostí velmi přesně ilustrují reálné tkáně v těle pacienta, což je užitečné pro diagnózu různých onemocnění [27].

Mezi nástroje využívané pro transformaci zobrazování snímků patří multiplanární rekonstrukce, projekce maximální/minimální intenzity, zobrazení stínovaných povrchů, vykreslování objemů a segmentace orgánů. Dnešní nejmodernější vizualizační nástroje jsou schopny například extrakce os cév s analýzou průměru cév, plochy lézí a stupně stenózy [27].

Dalším pokročilým nástrojem dnešních CT systémů je analýza perfuze u pacientů s cévní mozkovou příhodou. Radiolog má možnost využít snímkovou analýzu, která vyhodnocuje obrazy z dynamické CT angiografie. Tento proces vyhodnocuje změny jasové intenzity snímku v průběhu času a poskytuje spolehlivé informace o typu a rozsahu poruchy mozkové perfuze prostřednictvím kvalitativních a kvantitativních informací týkajících se různých parametrů perfuze. Takové parametry perfuze bývají spojeny právě s náhlou cévní mozkovou příhodou [28].

Další metody pro pokročilou analýzu cév využívají trojrozměrných měřicích nástrojů pro přesné vyhodnocení stavu cév z CT angiografických dat. Pokročilé post-processingové metody jsou využívány k manipulaci s radiografickými snímky za účelem získání dalších kvantitativních nebo kvalitativních informací. Tyto procesy dávají radiologovi mnohem širší možnosti pro kvalitní interpretaci obrazových dat a pro

co nepřesnější určení diagnózy. Jednou z takových metod je již zmiňovaná segmentace specifických tkání z nasnímaných dat, která je v klinické praxi hojně využívána [27].

3.2 Přehled segmentačních technik

Segmentace obrazu je jedním ze základních kroků analýzy obrazu. Jedná se v podstatě o rozdělení původního obrazu na nepřekrývající se oblasti, které reprezentují různé objekty reálné scény, například měkké tkáně, kosti, cévy. Výstupem segmentace je obraz o stejných rozměrech jako originál, ve kterém jsou separovány specifické oblasti. Jestliže je cílem segmentace oddělit od sebe určitý objekt a pozadí, pak výstupní obraz je binární. K segmentaci lze využít nejružnější lokální parametry jasové funkce, nebo lze využít samotnou hodnotu jasu [29, 30].

Segmentace podle homogenity oblastí

Prahování je z hlediska principu a implementace nejjednodušší segmentační metoda. Základním problémem při prahování je stanovení hodnoty prahů, kterými vymezíme jedinečný interval hodnot parametru segmentace. Nejčastějším parametrem segmentace bývá jasová hodnota pixelu. Pro stanovení hodnot prahů může být využít histogram, nebo kvantitativní metody výpočtu optimálního prahu. Modifikací obvyčejného prahování je adaptivní prahování. U metody adaptivního prahování není hodnota prahu pevně nastavena pro každý pixel celého obrazu, ale vyhodnocuje se lokálně v určitém okně. Další metodou, která je založená na nastavení prahových hodnot, je metoda dvojitého prahování. U této metody se nastavují hodnoty dvou prahů. Těmito prahy je oboustranně vymezen interval hodnot. Pixelům obrazu spadajícím svými hodnotami do intervalu mezi danými prahy je přiřazena hodnota 1, všem ostatním pixelům hodnota 0, tím je získán binární obraz [29, 30].

Metoda dělení a slučování oblastí je taktéž založena na segmentaci podle homogenity hodnot intenzity pixelů. Oblasti, které jsou z hlediska daného parametru (intenzity) nehomogenní, se rekurzivně dělí na menší. Takové dělení probíhá dokud není v rámci dílčích suboblastí dosaženo homogenity. V dalších krocích jsou pak podobné sousední homogenní oblasti, vzniklé dělením, spojovány [29].

Metoda narůstání oblastí (z angl. region growing) je další ze segmentačních technik, jejichž hlavním parametrem je hodnota intenzity pixelu. Prvním krokem je volba iniciačních bodů narůstání, tzv. semínek. Následně se kontrolují okolní pixely iniciačních bodů a podle zvoleného kritéria se rozhodne, zda budou nebo nebudou patřit tyto okolní pixely do vznikajícího segmentu. Pokud byl pixel přidán do vznikajícího

segmentu, stává se novým výchozím bodem, kolem kterého se hodnotí okolní pixely [29, 30].

Hranově orientované segmentace

Prvním krokem hranově orientovaných segmentačních technik často bývá detekce hran. To je přístup, který slouží k detekci pixelů, ve kterých dochází ke skokovým změnám jasových hodnot. Právě v místech, kde dochází k prudkým změnám jasu se často nachází hranice mezi jednotlivými oblastmi. Důležitým krokem při detekci hran je nastavení prahové hodnoty, pomocí které bývá rozhodováno, jestli daný jasový skok bude považován za hranu, či nikoliv [30].

Houghova transformace patří mezi hranově orientované segmentační techniky. Tato segmentační metoda se používá zejména pro částečnou segmentaci obrazu, kdy jsou v obraze hledány objekty známých tvarů, které lze popsat matematickou rovnicí (například přímkou či kružnicí) [29, 30].

Metoda aktivních kontur používá hranově orientovanou segmentaci a její princip spočívá v postupném tvarování kontur až k hraně objektu v obraze. Model aktivní kontury je řízená křivka, která nejprve přibližně ohraničuje objekt v obraze a následně se deformuje vlivem tzv. vnitřních, obrazových a vnějších sil. Vnitřní síly kontrolují hladkost průběhu, obrazové síly směřují tvarování kontury směrem ke hraně objektu a vnější síly jsou výsledkem počátečního umístění kontury [46].

„Level-sets“ metody segmentace využívají obdobný přístup jako metoda aktivních kontur. Křivka je reprezentována tzv. nulovou hladinou („zero level set“), což je řez v rovině x,y nějakou vícedimenzionální funkcí. Tato funkce se nazývá „level set function“ a každému bodu roviny x,y přiřazuje jeho výšku nad nulovou hladinou. Povrch funkce se postupně adaptuje vzhledem k zadaným metrikám křivosti a obrazovým gradientům. Základní rozdíl „level-set“ metody proti klasickým aktivním konturám je ten, že tvar křivky neměníme přímo, ale prostřednictvím „level-set“ funkce [46].

Metoda rozvodí (z angl. watershed) je na pomezí mezi hranově a regionově orientovanými segmentacemi. Tato metoda se nepoužívá na původní jasový obraz, ale na parametrický obraz. Parametrický obraz je odvozený z původního jasového obrazu nejčastěji pomocí lokálních diferenčních operátorů, tedy takových, které aproximují první derivace diferencemi. Tato metoda je založena na zvedání pomyslné vodní hladiny a postupnému zaplavování terénu (obrazu) vodou. Vodní hladina se zvedá z lokálních minim terénu a vytváří tzv. povodí. V momentě, kdy by mělo dojít ke slití vody ze dvou povodí, je mezi ně vložena hráz, která toto spojení přerušuje. Zvedání hladiny je ukončen dosažením maximální úrovně terénu, kdy už hladina nemá kam dál stoupat. Takto byl celý povrch zaplaven a zůstaly pouze vzniklé hráze.

Výsledkem je několik povodí oddělených hrázemi, což znázorňuje rozdělení oblastí původního obrazu [29, 30, 38].

Metody založené na strojovém učení

V posledních letech došlo k významnému pokroku v dosahování přesnějších výsledků segmentace právě díky využití metod strojového učení. Strojové učení je jedním z odvětví umělé inteligence, kdy základní myšlenkou je navrhnout algoritmus, který umožní počítači se co nejlépe naučit řešit daný problém. Výsledkem navrženého algoritmu strojového učení je matematická funkce $y = f(x)$, která vypočítá ze vstupní informace uložené ve vektoru x požadovaný výstup y . Dva nejčastěji řešené problémy pomocí algoritmů strojového učení jsou klasifikace a regrese. V případě klasifikačních problémů je objekt reprezentovaný vstupním vektorem příznaků x zařazen do jedné z diskrétních klasifikačních tříd. Pokud je však výstup množinou jedné nebo více spojitých hodnot, jedná se o regresní problém [39].

Mezi principy, které segmentační metody založené na strojovém učení využívají, patří například hluboké konvoluční neuronové sítě (CNN), podpůrné vektory (SVM), lineární regrese, Markovovo náhodné pole.

Metoda podpůrných vektorů (SVM, z angl. Support Vector Machines) je často využívanou metodou pro lineární klasifikaci. Tato metoda je založená na rozdělení objektů v příznakovém prostoru nadrovinou (přímkou). Předpokladem dělicí nadroviny je, že se snaží maximalizovat vzdálenost mezi nadrovinou a nejbližšími objekty. Optimálního výsledku je dosaženo v případě, že je zvolena co největší šířka tzv. diskriminační hyperroviny, která dané klasifikační třídy odděluje. Objekty, které jsou nejbližší dělicí nadrovině se nazývají podpůrné vektory [39].

Specifickým typem neuronových sítí jsou konvoluční neuronové sítě (CNN, z angl. Convolutional Neural Networks). Konvoluční neuronové sítě patří do skupiny algoritmů hlubokého učení a byly vytvořeny zejména pro zpracování dat ve formě matic, příkladem mohou být 2D obrazy se třemi barevnými kanály. Tyto sítě využívají v alespoň jedné ze svých vrstev matematickou operaci konvoluce, proto se daná vrstva a celá síť nazývá „konvoluční“. V porovnání s ostatními metodami strojového učení dosahují konvoluční neuronové sítě při praktickém použití velmi vysoké úspěšnosti. Tento typ neuronových se řadí do skupiny tzv. učení s učitelem, kdy je pro natrénování sítě nutné znát požadované výstupy klasifikace trénovacích objektů [40].

Mezi nevýhody a značné omezení používání metod založených na strojovém učení patří zejména potřeba velkého množství trénovacích dat, která musí být, v případě učení s učitelem, ručně označena lidským expertem [45].

3.3 Přehled publikovaných přístupů segmentace CZM

Tato kapitola je věnována několika aktuálně publikovaným řešením segmentace mozkových cév. Jsou zde stručně popsány přístupy a metody, které byly autory při segmentaci využity.

Článek [47] pojednává o návrhu automatického algoritmu pro efektivní segmentaci trojrozměrných CT angiografických snímků mozkových cév. Popisovaná metoda je odolná vůči šumu o vysoké intenzitě a dokáže přesně segmentovat cévy s vysokým rozsahem hodnot jasu i cévy s nízkým kontrastem. Principem této metody je vyhodnotit, do jaké míry je sledovaný parametr v okolí (o určité velikosti a tvaru) centrálního pixelu podobný aktuálnímu (centrálnímu) pixelu. U této metody je okolí pixelu vybíráno jako lineární projekce (přímka procházející centrálním pixelem), což oproti například čtvercovému okolí podstatně zrychluje výpočet. V takto definovaném okolí pixelu je následně počítána charakteristická funkce, která je tvořena kombinací elementárních funkcí. Mezi tyto elementární funkce patří: minimum (min), maximum (max), průměr (avr) a střední rozsah (mdr). Charakteristická funkce může vypadat takto: $s=(mdr+avr+max)/3$. Hodnoty charakteristické funkce okolí porovnáваме s hodnotou aktuálně zpracovávaného pixelu. Postupně se mění směr projekce na základě předem definované hodnoty úhlu posunu. Hodnota pixelu v nově vznikajícím transformovaném obrazu je rovna počtu projekcí, pro které má charakteristická funkce nižší hodnotu než je hodnota aktuálního pixelu. Pro výslednou segmentaci obrazu musíme použít na transformovaný obraz metodu prahování. Podle nastavené prahové hodnoty zůstanou zachovalé pouze ty pixely, které byly vysegmentované ve více směrech lineárních projekcí, než byla nastavená prahová hodnota [47].

V publikaci [48] je popsána metoda pro automatickou segmentaci mozkových tepen a žil ze 4D CT angiografických snímků s využitím plně konvoluční neuronové sítě. Pro segmentaci mozkových tepen a žil byla tedy navržena 3D Dense-U-Net, která představuje vylepšení standardní architektury 3D-U-Net, neboť se snížil počet parametrů sítě a zvýšila se rychlost predikce. Architektura sítě je rozdělena na levou (sestupnou) část sítě a pravou (vzestupnou) část sítě. V sestupné části sítě probíhá kódování vstupních dat pomocí řady bloků, které obsahují 3D konvoluční filtry. Ve vzestupné části sítě dochází k dekódování dat. Síť byla natrénována k segmentaci tepen a žil jako problém klasifikace do tří tříd: pozadí, tepna a žíla. Vzorky byly rovnoměrně vybrány z trénovací množiny tvořené 40 různými pacienty, přičemž každý pacient byl reprezentován jedním snímkem 4D CT angiografie. K trénování sítě byla použita ztrátová funkce vzájemné entropie (z angl. cross-entropy loss function) spolu s algoritmem adaptivního odhadu momentu (známým jako ADAM) [48].

Autoři studie [49] vyvinuli nový algoritmus pro automatickou prahovou segmen-

taci mozkových cév ze snímků magnetické rezonance (TOF MRA¹). Prvním krokem této metody je rozdělení MRA snímku mozku pomocí Otsuovy metody na dvě oblasti - popředí a pozadí. Oblast popředí odpovídá bílé a šedé kůře mozkové, oblasti očí a mozkovým cévám. Oblast pozadí zahrnuje mozkomíšní mok a kosti. Prahová hodnota se v oblasti popředí volí pro rozlišení cév od mozkové tkáně kombinací vhodných statistických modelů a lokálních informací o voxelu. S využitím teorie extrémních hodnot lze detekovat odlehle abnormálně vysoké nebo nízké hodnoty, které se vyskytují v okrajových oblastech určitých pravděpodobnostních rozložení. Na snímcích MRA vykazují mozkové cévy vyšší hodnotu signálu (intenzity) než okolní mozková tkáň, která má střední hodnotu signálu (intenzity). Homogenní mozkovou tkáň s výjimkou mozkových cév lze reprezentovat normálním rozdělením. Rozložení intenzity mozkových cév, které se nachází v okrajových oblastech histogramu, nelze dobře popsat normálním rozdělením. Proto bylo použito specifické rozdělení extrémních hodnot, konkrétně Gumbelovo rozdělení. Pro extrakci mozkových cév ze snímků MRA určíme práh porovnáním funkce hustoty pravděpodobnosti (PDF²) obou statistických rozdělení (normální a Gumbelovo). Hodnoty funkce hustoty pravděpodobnosti jsou vypočítány pro každý voxel v oblasti popředí. Voxel, jehož PDF Gumbelova rozložení bylo větší nebo rovno, než dvojnásobek PDF normálního rozložení, byl považován za potenciální oblast mozkové cévy. Z takových potenciálních voxelů bylo vybráno minimum, které odpovídá prahové hodnotě. Pixely, jejichž hodnota byla vyšší, než prahová hodnota, byly klasifikovány jako mozková céva [49].

3.4 Použité metody

3.4.1 Morfologické operace

Morfologické operátory je možné využít pro analýzu tvarů objektů v binárních obrazech, k určení počtu objektů a k úpravám hranových reprezentací objektů binárních obrazů. Základními a nejjednoduššími morfologickými operátory jsou eroze a dilatace. Jejich kombinací můžou být odvozeny složitější morfologické operace, jako například morfologické otevření a uzavření [29, 30].

Morfologické uzavření


Morfologické uzavření je definováno kombinací základní morfologické operace dilatace, která je následována erozí. Základním parametrem morfologických operátorů je strukturní element, který bývá definován jako maska specifického tvaru o rozměrech

¹Time-of-flight Magnetic resonance angiography


²Probability density function

mnohonásobně menších, než je zpracováváný obraz. Strukturální element (čtvercový, obdelníkový, kruhový, ...) je tvořen aktivními prvky, které jsou reprezentovány jedničkami. Referenční prvek (z angl. origin) strukturálního elementu je středový neboli centrální prvek [29, 30].

Binární erozi lze popsat jako operátor, který prochází vstupní obraz a v každém pixelu se ptá na otázku, jestli jsou pod všemi aktivními prvky strukturálního elementu jedničky. V případě, že je tato podmínka splněna, ve výstupním obraze se na pozici referenčního prvku strukturálního elementu objeví jednička, v opačném případě nula. Binární dilatace funguje na podobném principu, v každém pixelu obrazu je však kladena otázka, zda pod strukturálním elementem je v obraze alespoň jedna jednička. Jestliže je tato podmínka splněna, ve výstupní obraze se na pozici referenčního prvku strukturálního elementu objeví jednička. Schématické znázornění principu binární eroze 3.1 a dilatace 3.2 je na obrázcích níže [29, 30].



Obr. 3.1: Schématické znázornění binární eroze. (a) vstupní binární obraz, tečkami jsou znázorněny jedničky binárního obrazu, zeleně je ohraničena aktivní poloha strukturálního elementu, červeně je ohraničena neaktivní poloha strukturálního elementu. (b) Strukturální element s vyznačeným centrálním referenčním prvkem. (c) Výstupní obraz binární eroze, prvek v červeném rámečku byl odstraněn, prvek v zeleném rámečku byl zachován [29]



Obr. 3.2: Schématické znázornění binární dilatace. (a) vstupní binární obraz, tečkami jsou znázorněny jedničky binárního obrazu, zeleně je ohraničena aktivní poloha strukturního elementu, červeně je ohraničena neaktivní poloha strukturního elementu. (b) Strukturní element s vyznačeným centrálním referenčním prvkem. (c) Výstupní obraz binární dilatace, prvek v červeném rámečku nebyl nijak ovlivněn, prvek v zeleném rámečku byl dilatací přidán [29]

Z výše uvedeného lze říct, že ve výstupu binární eroze jsou objekty zmenšené nebo odstraněné, naopak ve výstupu binární dilatace jsou vyplněna prázdná místa a objekty jsou zvětšeny a propojeny. Při morfologickém uzavření je pro obě tyto operace použit stejný strukturní element. Zřetězením dilatace a eroze dojde k vyhlazení a mírnému rozšíření povrchu (hranice) segmentovaného objektu [29, 30].

3.4.2 Metoda narůstání oblastí

Metoda narůstání oblastí (z angl. Region Growing) je jedním z přístupů regionově orientované segmentace založené na homogenitě oblastí. Algoritmus segmentace je tvořen z následujících základních kroků: volba počátečních (iniciačních) bodů narůstání, kontrola okolních pixelů, rozhodnutí o přidání pixelu do narůstající oblasti a ukončení algoritmu [29, 30].

Počáteční (iniciační) body neboli tzv. semínka (z angl. seeds) mohou být do obrazu vložena automaticky na základě předchozí analýzy, nebo mohou být vybrána jako náhodné pixel obrazu, nebo je může interaktivně zadávat sám uživatel. Po umístění semínka do obrazového prostoru jsou procházeny a kontrolovány jeho okolní pixely. Okolní pixely iniciačního semínka jsou vybrány nejčastěji z tzv. čtyřokolí nebo osmiokolí. V případě čtyřokolí jsou vybrány 4 pixely z horizontálního a vertikálního směru, nebo 4 pixely v diagonálním směru. Následně se na základě zvoleného kritéria

rozhoduje, zda budou či nebudou vybrané okolní pixely přidány do narůstajícího segmentu. Kritéria pro přidání pixelu do narůstajícího segmentu mohou být statická nebo dynamická. V případě statického kritéria je porovnáván parametr, nejčastěji jasová hodnota, semínka s parametrem aktuálně zpracovávaného pixelu podle vzorce:

$$|p_s - p_j| \leq T \quad (3.1)$$

V rovnici 3.1 odpovídá p_s jas semínka, p_j jas aktuálně zpracovávaného pixelu a T je prahová hodnota. Jestliže aktuálně zpracovávaný pixel vyhovuje této podmínce, pak je přidán do narůstajícího segmentu a v další iteraci se stává novým centrálním bodem, kolem něhož jsou znovu kontrolovány okolní pixely [29, 30].

V této práci bylo využito dynamické kritérium. V případě dynamického kritéria je porovnáván jas aktuálně zpracovávaného pixelu p_j se střední hodnotou jasu všech pixelů zařazených do narůstající segmentované oblasti p_a :

$$|p_a - p_j| \leq T \quad (3.2)$$

Dynamické kritérium je vhodné využít v případě, kdy sledovaný parametr není homogenní, ale pomalu se vyvíjí. Narůstání segmentované oblasti je ukončeno v případě, že už žádné další pixely obrazu nespĺňují dané podmínky. K nesplnění podmínek může dojít v případě, že v okolí nově vzniklého centrálního pixelu se vyskytuje obrazová hrana, tedy dojde k výraznému skoku jasových hodnot [29, 30].

3.4.3 Metody pro zvýraznění mozkových cév

Proces zvýraznění mozkových cév vede v šedotónových angiografických snímcích ke zřetelnému zvýšení kontrastu cévních struktur vůči okolní mozkové tkáni. Metody pro zvýraznění mozkových cév převedou původní vstupní obraz, ve kterém jsou jednotlivé voxely reprezentovány hodnotami CT čísel, na výstupní parametrický obraz, jehož voxely jsou reprezentovány hodnotami daného parametru. Výsledné parametrické obrazy zvýrazněných mozkových cév bývají často využity jako vstupní data pro segmentaci mozkových cév. Častým přístupem pro zvýraznění mozkových cév v angiografických snímcích je využití filtrů zvýrazňujících cévy (z angl. vessel enhancement filters), například filtrů založených na Hessianu (z angl. Hessian-based filters) [31, 32].

Filtry založené na Hessianu

Jedná se o pokročilé filtry založené na výpočtu Hessovy matice a analýze vlastních čísel Hessovy matice. Vzhledem ke kontrastu a geometrickým vlastnostem cév se obecně předpokládá, že pozorováním lokálních zakřivení v obraze prostřednictvím

analýzy Hessovy matice může vést k určení polohy a orientace předpokládaných cévních struktur [31, 32].

Předpokladem těchto filtrů je, že cévy jsou světlé tubulární struktury na tmavším pozadí. Na základě těchto faktů, filtry pro zvýraznění cévních struktur počítají Hessovu matici šedotónového obrazu. Hessova matice je vypočtena jako derivace druhého řádu hodnot intenzity šedotónového obrazu, což charakterizuje zakřivení obrazových struktur. Hessova matice H funkce $f(x_1, x_2, x_3)$ je definována v každém bodě jako:

$$H(f) = \begin{bmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \frac{\partial^2 f}{\partial x_1 \partial x_3} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} & \frac{\partial^2 f}{\partial x_2 \partial x_3} \\ \frac{\partial^2 f}{\partial x_3 \partial x_1} & \frac{\partial^2 f}{\partial x_3 \partial x_2} & \frac{\partial^2 f}{\partial x_3 \partial x_3} \end{bmatrix} \quad (3.3)$$

Funkce f musí být spojitá a alespoň dvakrát diferencovatelná, zatímco původní obraz I je digitální, tedy nespojitý a nediferencovatelný. Pro vyřešení tohoto problému se obvykle definuje funkce f z původního obrazu I s využitím aplikace Gaussova jádra (kernelu) se směrodatnou odchylkou σ . Konvolucí obrazu I s Gaussovým jádrem se také vytvoří vícerozměrný model založený na paradigmatu lineárního měřítkového prostoru, kde měřítko zájmových cév závisí na parametru σ [31, 32].

Nechť e_1 , e_2 a e_3 jsou tři vlastní vektory Hessovy matice $H(f)$ přiřazené vlastním číslům λ_1 , λ_2 a λ_3 , přičemž $|\lambda_1| \leq |\lambda_2| \leq |\lambda_3|$. Lokálně lze cévu považovat za světlou tubulární strukturu na tmavém pozadí. Z hlediska vlastní analýzy je to vyjádřeno následujícími vlastnostmi:

$$\begin{aligned} |\lambda_1| &\approx 0 \\ \lambda_2 &\approx \lambda_3 \ll 0 \end{aligned}$$

Hessiánovy filtry dopočítávají parametrické obrazy zvýrazněných podlouhlých zaoblených struktur pomocí specifické zvýrazňovací funkce založené na analýze vlastních čísel Hessovy matice [31, 32].

Frangiho zvýrazňovací funkce

Tato zvýrazňovací funkce je pro dopočítání parametrického obrazu zvýrazněných cév nejvyužívanější. Z vlastních čísel Hessovy matice jsou odvozeny tři parametry:

$$R_b = \frac{|\lambda_1|}{\sqrt{|\lambda_2\lambda_3|}}$$

$$R_a = \frac{|\lambda_2|}{|\lambda_3|}$$

$$S = \sqrt{\lambda_1^2 + \lambda_2^2 + \lambda_3^2}$$

Parametr R_b je určen k rozlišení skvrn (z angl. blobs), R_a k rozlišení plošných a liniových struktur, S k měření normy Hesiánu, aby bylo potlačeno zvýraznění struktur s nízkým kontrastem. Tyto parametry jsou následně využity k výpočtu výsledné zvýrazňovací funkce:

$$F = (1 - \exp(-\frac{R_a^2}{2\alpha^2}))\exp(-\frac{R_b^2}{2\beta^2})(1 - \exp(-\frac{S^2}{2c^2})) \quad (3.4)$$

Pokud $\lambda_2, \lambda_3 \leq 0$, pak $F = 0$. Tato funkce je řízena třemi nastavitelnými parametry: α, β, c [31, 32, 33].

Nedokonalostí původní Frangiho zvýrazňovací funkce je, že dochází k útlumu zvýraznění cév v jejich ohybech a také, že zvýraznění je nejsilnější ve středu cévy a poté směrem k periférii postupně klesá. Výsledné zvýraznění cév je tedy značně ovlivněno morfologií cév a distribucí kontrastní látky v cévách. Hodnoty voxelů výsledného parametrického obrazu můžou být interpretovány jako podobnost vlastních čísel Hessovy matice každému voxelu původního 3D obrazu.

Jermanova zvýrazňovací funkce

Tato zvýrazňovací funkce je vylepšením původní Frangiho zvýrazňovací funkce a odstraňuje její výše zmíněné nedostatky. Pozměněním způsobu výpočtu parametrického obrazu z vlastních čísel Hessovy matice bylo dosaženo homogenního zvýraznění cév v celém jejich průřezu. Hodnoty voxelů výsledného parametrického obrazu nabývají hodnot od 0 do 1, v ideálním případě je 0 pro nevaskulární a 1 pro vaskulární struktury.

3.4.4 Segmentační metody

Prahování obrazu

Princip prahování lze popsat pomocí transformační funkce 3.5, pomocí níž jsou jednotlivé pixely vstupního obrazu $I(x, y)$ binárně klasifikovány:

$$Y(x, y) = \begin{cases} 1 & \text{pro } I(x, y) \geq T \\ 0 & \text{pro } I(x, y) < T \end{cases} \quad (3.5)$$

kde $Y(x, y)$ jsou pixely výstupního obrazu, $I(x, y)$ jsou pixely vstupního obrazu, T je stanovený práh.

Základním problémem celé metody je stanovení prahové hodnoty T daného parametru, nejčastěji jasové hodnoty pixelu. Podle způsobu nastavení prahové hodnoty rozlišujeme různé metody prahování [29, 30].

V případě expertního prahování je pro všechny pixely obrazu (tedy globálně) nastavena jedna konstantní prahová hodnota, která byla stanovena buďto na základě optimalizačního přístupu (experimentálně), nebo pomocí analýzy histogramu, nebo s využitím znalostí o zpracovávaném obrazu [29, 30].

Metoda adaptivního prahování je sofistikovanější přístup, kdy každému pixel obrazu je zvlášť stanovena prahová hodnota. Pro každý pixel je definováno jeho okolí. Z okolních pixelů je vypočítána lokální střední hodnota jasové intenzity a tato hodnota je nastavena jako práh T pro aktuálně zpracovávaný pixel [34].

Metoda globálního prahování pracuje, podobně jako expertní prahování, s jedinou globální prahovou hodnotou. Ta je však objektivně vypočítána nejčastěji pomocí Otsuovy metody, která je založená na výpočtu rozptylu a hledá optimální hodnotu prahu, při níž je rozptyl pixelů uvnitř třídy popředí a uvnitř třídy pozadí co nejmenší. Základním principem je iterace přes všechny možné hodnoty prahu a výpočet vnitrotřídního rozptylu pixelů pozadí a popředí, přičemž výsledný práh je ten, u kterého je vnitrotřídní rozptyl nejmenší [35].

K-means klasifikace

Metoda k-means je jednou z nejčastěji používaných nehierarchických metod shlukové analýzy dat. Tato metoda rozdělí vstupní data do předem stanoveného počtu (k) shluků na základě podobnosti analyzovaných objektů. Každý objekt je reprezentován specifickými příznaky. Každý shluk je reprezentován centroidem (středem, z angl. mean). Algoritmus k-means rozdělí objekty do shluků na základě minimalizace vzdálenosti mezi objektem a centroidem shluku, do kterého patří. Poté následuje přepočítání pozice centroidu shluku pomocí výpočtu střední hodnoty příznaků objektů patřících do daného shluku. Proces klasifikace objektů a přepočítání pozic centroidů

se iterativně opakuje. Vzdálenost mezi objektem a centroidem je nejčastěji hodnocena výpočtem Euklidovské vzdálenosti. K-means je optimalizační metoda a vývoj algoritmu shlukování je sledován pomocí kritériální funkce (3.6), která hodnotí, zda došlo další iterací ke zmenšení vzdálenosti objektů ve shluku k centroidu shluku. V ideálním případě by měla kritériální funkce exponenciálně klesat, což by znamenalo, že vzdálenost objektů od centroidu se minimalizuje - centroid se posouvá přesněji do středu shluku [36].

$$E = \sum_{k=1}^K \sum_{\bar{x}_n \in c_k} d(\bar{x}_n, \bar{V}_k) \quad (3.6)$$

kde $X = \{\bar{x}_1, \dots, \bar{x}_N\}$ je množina objektů, c_1, c_2, \dots, c_K jsou nepřekrývající se shluky, \bar{V}_k je centroid shluku c_k , $d(\bar{x}_n, \bar{V}_k)$ je vzdálenost objektu \bar{x}_n od centroidu \bar{V}_k , $n = 1, 2, \dots, N$ je počet objektů, $k = 1, 2, \dots, K$ je počet shluků.


Neuronová síť

Umělá neuronová síť je zjednodušený matematický model fungování mozku. Základním stavebním prvkem neuronové sítě je neuron neboli perceptron. Neurony jsou nejjednodušší prvky, jejichž úkolem je transformace vstupních příznaků x na co nejideálnější požadované výstupy y : $\{x_1, \dots, x_N\} \rightarrow \{y_1, \dots, y_M\}$, kdy N je počet příznaků a M je počet výstupních elementů. Každý neuron je definovaný vektorem vah $w = [w_1, \dots, w_n]$, prahem (z angl. bias) w_0 a aktivační funkcí f . Transformaci vstupního vektoru $x = [x_1, \dots, x_N]$ na výstupní hodnotu y perceptron počítá podle vztahu:

$$y = f\left(\sum_{i=0}^N w_i x_i\right) \quad (3.7)$$


přičemž bylo zavedeno $x_0 = 1$ a $w_0 = -\theta$. Člen $\sum_{i=0}^N w_i x_i$ je aktivace a a funkce $f(a)$ je aktivační funkce. Existují různé typy aktivačních funkcí, jako například skoková, lineární, sigmoidální. Typ aktivační funkce je volen podle požadovaného výstupu [37].

Pro názornost je neuron schématicky zakreslen na obrázku níže 3.3:



Obr. 3.3: Schéma jednoho neuronu.

Umělé neuronové sítě jsou tvořeny velkým množstvím propojených neuronů. Jednotlivé neurony jsou uspořádány do vrstev, přičemž počet a typ vrstev je volitelný podle typu a složitosti řešené úlohy. Neuronové sítě se dělí podle architektury na dopředné a rekurentní (zpětnovazebné). Architektura dopředných sítí lze obecně zjednodušeně popsat jako jednu vstupní vrstvu neuronů, skryté vrstvy a jednu výstupní vrstvu. Schéma nejjednodušší neuronové sítě tvořené vstupní vrstvou, jednou skrytou vrstvou a výstupní vrstvou je na obrázku níže 3.4:



Obr. 3.4: Schéma nejjednodušší dopředné neuronové sítě.

Základním problémem po navržení architektury sítě je její natrénování. Natrénování (učení) neuronové sítě vede k optimálnímu nastavení parametrů (vah w a prahu θ) jednotlivých neuronů. Z hlediska učení (trénování) jsou neuronové sítě děleny do 2 kategorií: s učitelem (většina UNS) a bez učitele (shlukování). V případě neuronových sítí s učitelem je potřeba, aby pro vstupní vektor x byl známý požadovaný

výstupní vektor d . Cílem procesu učení s učitelem je iterativní optimalizace parametrů každého neuronu, což se projeví minimalizací kriteriální funkce. Kriteriální funkce slouží ke sledování průběhu učení sítě a je dopočítávána porovnáním výstupů odhadnutých neuronovou sítí y s požadovanými výstupy d . Pro úpravu parametrů jednotlivých neuronů je často využíván algoritmus zpětného šíření chyby (z angl. back propagation) nebo metoda gradientního sestupu (z angl. gradient descent) [37, 39].

Náhodné lesy

Metoda náhodných lesů (z angl. Random Forests) je klasifikační metoda strojového učení. Náhodný les je tvořen velkým množstvím rozhodovacích stromů (z angl. Decision Tree) [41].

Rozhodovací strom je tvořen z uzlů a koncových listů. V každém uzlu je definována podmínka (práh), podle které se data na základě hodnot příznaku dělí do větví. V případě, že data splňují podmínku uzlu, jsou přiřazena do levého větve. Data, která nesplňují podmínku, jsou zařazena do pravé větve. Postupným tříděním jsou data rozdělena do tzv. listů (terminálních uzlů), které ideálně obsahují pouze objekty stejné klasifikační kategorie. Cílem trénování rozhodovacího stromu je optimalizace vah uzlů tak, aby byla minimalizována klasifikační chyba. Velkým nedostatkem rozhodovacích stromů je jejich nízká generalizační schopnost, kdy se složitější stromy až příliš naučí na trénovací data a pak špatně reagují na testovací data. Proto byla navržena metoda náhodných lesů, které jsou tvořeny množstvím jednoduchých rozhodovacích stromů pracujících v náhodně zvoleném podprostoru příznakového prostoru [41].

V prvním kroku algoritmu náhodného lesa je vytvořen tzv. bootstrapped dataset, kdy je ze vstupních dat pomocí náhodného výběru určitého počtu objektů vytvořeno n trénovacích datasetů, ve kterých se objekty mohou opakovat. Dále jsou pro každý z n trénovacích datasetů vybrány náhodné příznaky, na kterých jsou natrénovány rozhodovací stromy. Takto je získán náhodný les tvořený n rozhodovacími stromy. Testovací objekt, který je takovým lesem klasifikován, projde každým z natrénovaných stromů a výstupy všech stromů jsou zaznamenány. Ze zaznamenaných výsledků každého stromu je většinově rozhodnuto o výsledné klasifikaci objektu. Náhodné procesy v algoritmu náhodných lesů vedou k lepším generalizačním schopnostem modelu [41].

4 Návrh a realizace segmentačního přístupu

4.1 Dostupný dataset

Pro praktické řešení této bakalářské práce byl k dispozici dataset pěti anonymizovaných patientských 3D CT skenů. Všechna dostupná obrazová data byla uložena ve formátu DICOM¹. Jedná se o standardizovaný formát, který slouží k zobrazování, distribuci a ukládání medicínských obrazových dat nasnímaných zobrazovacími modalitami, jako jsou CT, MRI nebo ultrazvuk. Každý DICOM soubor obsahuje kromě obrazových dat také hlavičku s metadaty, ve kterých je zahrnuta informace o samotném snímku, o vyšetřovaném pacientovi a také o parametrech snímkování [50]. Poskytnutá databáze 3D CT skenů byla variabilní. Obsahovala objemová data, která byla nasníмана v různých nemocničních pracovištích, různými CT systémy, při různých proudcích procházejících rentgenkou (od 328 mA do 442 mA), při různých anodových napětí (od 80 kV do 120 kV) a ve dvou odlišných kontrastních fázích (první a druhá). Vyšetřovaní pacienti byli různých věkových kategorií. Šířka jednotlivých řezů byla 0,90 mm. Velikost voxelu byla $0.4883 \times 0.4883 \times 0.9000$ mm. Každý snímek z 3D objemu (CT řez) je reprezentován rekonstrukční maticí o rozměrech 512×512 pixelů.

4.2 Tvorba trénovací a validační množiny

V této práci bylo pro segmentaci mozkových cév použito celkem šest segmentačních metod. První tři segmentační metody byly založené na prahování obrazu. Zbývající tři metody byly klasifikační metody strojového učení. První z metod založených na strojovém učení byla metoda k-means. Další dvě metody strojového učení jsou náhodný les a neuronová síť - v obou případech se jedná, z hlediska učení klasifikátoru, o přístupy učení s učitelem. Proto bylo nutné alespoň v jednom patientském CT skenu ručně označit mozkové cévy. Objem ručně segmentovaných mozkových cév, nazýván také Ground Truth, byl použit jako požadovaný výstup (učitel), ke kterému se naučený klasifikátor má co nejpřesněji přiblížit. Pro natrénování náhodného lesa a neuronové sítě tedy bylo nejprve potřeba vytvořit trénovací a validační množinu dat.

¹Digital Imaging and Communications in Medicine

Trénovací a validační množina pro neuronovou síť

Pro natrénování a validaci neuronové sítě byly vytvořeny množiny dat, ve kterých jsou rovnoměrně zastoupeny pixely cév a pixely pozadí v poměru 1 ku 1. V prvním kroku byla vytvořena matice pixelů cév, ve které byly uloženy všechny pixely s hodnotou 1 (cévy) v Ground Truth a k nim odpovídající pixely všech třech parametrických obrazů. Podobným způsobem byla vytvořena matice pixelů pozadí, do které byly uloženy náhodné nulové pixely (pozadí) z Ground Truth a k nim odpovídající pixely parametrických obrazů. Obě matice měly počet řádků odpovídající počtu cévových pixelů v Ground Truth a čtyři sloupce, kdy v 1. až 3. sloupci byly hodnoty pixelů v parametrických obrazech, ve 4. sloupci binární hodnota pixelu (0/1) v Ground Truth. Matice byly následně rozděleny v poměru 80 % pixelů pro trénování a 20 % pixelů pro validaci. Části obou matic určené pro trénování byly sloučeny do společné matice, taktéž bylo učiněno s částmi matic pro validaci. V trénovací i validační matici byly pixely cév a pozadí náhodně promíchány. Poté byly obě tyto matice rozděleny na matici X a vektor Y . V matici X byly uloženy objekty (pixely) se třemi příznaky (hodnoty v parametrických obrazech), které byly určeny pro trénování/validaci. Ve vektoru Y byly uloženy požadované výstupy klasifikace každého z objektů trénovací/validační množiny, tedy hodnoty pixelů z Ground Truth.


Trénovací a validační množina pro náhodný les

Pro natrénování a validaci náhodného lesa bylo nutné vytvořit větší množiny dat, než v případě neuronové sítě. Zastoupení pixelů cév a pozadí již nemohlo být v poměru 1 ku 1, ale pixelů pozadí bylo potřeba násobně víc. Stejným způsobem jako u neuronové sítě byla vytvořena matice pixelů cév, ve které je počet řádků roven počtu pixelů s hodnotou 1 v Ground Truth, v 1. až 3. sloupci jsou hodnoty pixelu v parametrických obrazech a ve 4. sloupci je hodnota pixelu v Ground Truth (hodnota 1). Při tvorbě matice pixelů pozadí bylo nutné si uvědomit, že při ručním značení mozkových cév (Ground Truth) mohly být některé cévy vynechány (falešně označeny jako pozadí). Pixely falešně vynechaných cév nabývají v Ground Truth hodnotu 0, avšak v parametrických obrazech budou mít hodnotu nenulovou. A právě takové pixely budou klasifikátor mást, protože hodnotami v parametrických obrazech můžou odpovídat cévě, ale podle učitele (hodnoty z Ground truth) mají být klasifikovány do pozadí. Proto do matice pixelů pozadí bylo náhodně vybráno 850 000 pixelů z oblasti mozku, které v Ground Truth mají hodnotu 0. K těmto pixelům byly následně přiřazeny hodnoty z parametrických obrazů. Dále bylo do matice pixelů pozadí přidáno ještě 150 000 nulových pixelů z prvního řezu objemu Ground Truth, u kterých je jisté, že v parametrických obrazech nabývají čistě nulové hodnoty. Výsledná matice pixelů pozadí má 1 000 000 řádků (pixelů) a 4 sloupce (hodnoty z

parametrických obrazů a Ground Truth). Obě matice byly, stejně jako u neuronové sítě, rozděleny v poměru 80 % pixelů pro trénování a 20 % pixelů pro validaci. Části matic určené pro trénování byly sloučeny do společné matice, stejný postup byl zopakován s částmi matic pro validaci. V trénovací i validační matici byly pixely cév a pozadí náhodně promíchány. Trénovací a validační matice byly rozděleny na matici X a vektor Y . V matici X byly uloženy objekty (pixely) se třemi příznaky (hodnoty v parametrických obrazech), které byly určené pro trénování/validaci. Ve vektoru Y byly uloženy požadované výstupy klasifikace každého z objektů trénovací/validační množiny, tedy hodnoty pixelů z Ground Truth.

4.3 Algoritmus pro segmentaci mozkových cév

Programové řešení bakalářské práce bylo implementováno v programovacím prostředí Matlab R2021b. Na obrázku níže 4.1 je uvedeno blokové schéma algoritmu pro segmentaci mozkových cév. Algoritmus se skládá z pěti na sebe navazujících bloků, které budou následně detailněji popsány.




Obr. 4.1: Blokové schéma navrženého algoritmu.

4.3.1 Předzpracování objemových CT dat

Vzhledem k tomu, že v každém 3D CT skenu byly jednotlivé řezy seřazeny podle jejich názvu, nebyly po načtení celého objemu dat uspořádány tak, jak ve skutečnosti byly nasnímány. Z toho důvodu bylo nutné nejprve řezy seřadit, aby jejich pořadí skutečně odpovídalo průběhu akvizice. K uspořádání řezů byla využita informace o pořadí řezu během snímkování, která je uložena v hlavičce každého DICOM souboru. Následně bylo potřeba z celého objemu vybrat pouze oblast, se kterou bude algoritmus dále pracovat. V této práci je oblastí zájmu mozek, proto byl pro každý CT snímek manuálně určen první a poslední řez objemu, kterými byla ohraničena

oblast snímků obsahujících mozkovou tkáň. V této fázi byly využity řezy v transverzální rovině. Pro následnou segmentaci mozku je ale vhodnější pracovat s řezy v sagitální rovině, proto byl objem dat obsahujících mozkovou tkáň do této roviny transformován 4.2.



Obr. 4.2: Předzpracování objemových dat. Vlevo: Ukázka uspořádání řezů. Vpravo: Transformace řezu z transverzální do sagitální roviny.

Pro transformaci trojrozměrné obrazové matice do sagitální roviny byla použita funkce *permute*, jejímiž vstupními parametry byl 3D obraz v transverzální rovině a požadovaná přeuspořádaná dimenzionalita 3D objemu. Objemová data v sagitální rovině byla znovu omezena pouze na řezy, které zobrazovaly mozek. Na takto předzpracovaná data byla aplikována segmentační metoda, jejímž cílem bylo vytvořit 3D binární masku mozku.

4.3.2 Tvorba 3D binární masky mozku pomocí metody vícenásobného narůstání oblastí

Pro segmentaci mozkové tkáně byl použit již naprogramovaný algoritmus narůstání oblastí, který je volně dostupný na MathWorks [51]. Tento algoritmus byl ale původně implementován na jinou segmentační úlohu, na jiná obrazová data, s jinak nastavenými parametry a pouze s jedním počátečním semínkem. Proto bylo nutné některé části kódu pozměnit, doplnit a modifikovat tak, aby algoritmus správně fungoval na naše data.


Nastavení souřadnic počátečních semínek a narůstání segmentované oblasti

V objemu v sagitální rovině, který byl získán ořezáním celého CT skenu pouze na oblast obsahující mozek, byla vyindexována pozice prostředního sagitálního řezu. Od tohoto řezu začínala segmentace a pokračovala ve dvou směrech - směrem k prvnímu řezu a směrem k poslednímu řezu objemu v sagitální rovině. V první iteraci byly souřadnice x, y všech tří počátečních semínek nastaveny napevno do středu obrazové matice prostředního řezu.

Následně je procházeno čtyřokolí (pixely vpravo, vlevo, nahoře, dole) aktuálního (centrálního) pixelu. V první iteraci je centrálním pixelem počáteční semínko. Pokud jsou splněny nastavené podmínky, jsou pixely čtyřokolí přidány do okolí narůstajícího segmentu. Nastavené podmínky jsou takové, že daný pixel se nachází uvnitř obrazové matice a zároveň doposud nebyl přidán do okolí narůstajícího segmentu. V takto vznikajícím okolí je hledán pixel, který má hodnotu intenzity co nejbližší střední hodnotě intenzity vysegmentovaných pixelů. Tento pixel je přidán do narůstajícího segmentu a stává se novým centrálním pixelem. Ostatní pixely zůstávají pouze v okolí narůstajícího segmentu. Následuje přepočítání průměrné intenzity vysegmentované oblasti. Pokud byla splněna podmínka, že rozdíl intenzit centrálního pixelu a střední hodnoty intenzity segmentovaných pixelů není vyšší než maximální přípustná hodnota, pak algoritmus pokračuje a je znovu procházeno čtyřokolí centrálního pixelu. Pokud byly splněny podmínky, jsou přidávány další pixely do okolí rostoucího segmentu, v němž je hledán nový centrální pixel. Maximální hodnota přípustného rozdílu intenzity nového centrálního pixelu a průměrné intenzity vysegmentované oblasti byla nastavena optimalizačním přístupem na 30 HU. Narůstání segmentované oblasti z jednoho semínka tedy probíhá až do porušení této podmínky. Pak lze říct, že narůstající segment se zastavil o lebeční kost. Po ukončení narůstání jsou do výsledného segmentu brány pouze centrální pixely. Tímto způsobem je získán z každého semínka výsledek segmentace jednoho řezu - binární obraz.

Při segmentaci dalších řezů se automaticky přepočítávají souřadnice počátečních semínek. První semínko je umístěno do těžiště vysegmentované oblasti z předcho-

zího řezu. Druhé semínko je vůči prvnímu semínku posunuto dolů o jednu čtvrtinu výšky vysegmentované oblasti z předchozího řezu a doleva o jednu čtvrtinu šířky vysegmentované oblasti z předchozího řezu. Třetí semínko je vůči prvnímu semínku posunuto nahoru o jednu čtvrtinu výšky vysegmentované oblasti z předchozího řezu a doprava o jednu čtvrtinu šířky vysegmentované oblasti z předchozího řezu, viz. obrázek níže 4.3.




Obr. 4.3: Pozice třech počátečních semínek v sagitálním řezu.

Postprocessingové úpravy výsledných 2D segmentovaných oblastí

Každý ze tří binárních obrazů (získaných ze tří semínek) byl upraven pomocí morfologického operátoru *imfill*, kterým dojde k vyplnění děr ve vysegmentované oblasti (Obr. 4.4). Poté tyto tři binární obrazy byly zfúzovány. Fúze obrazů je prováděna jako logický součet (disjunkce) tří obrazových matic. Tak byla získána 2D binární maska mozku, která je uložena jako jeden řez předdefinovaného objemu.



Obr. 4.4: 2D binární masky mozku v sagitální rovině před vyplněním děr (vlevo) a po vyplnění děr (vpravo).



Obr. 4.5: Ukázka binárních výstupů segmentace ze tří počátečních semínek a jejich následná fúze do výsledné 2D binární masky mozku jednoho řezu objemu.

Tři různá počáteční semínka byla použita proto, že některé ze semínek může být umístěno do pixelu s vyšší hodnotou intenzity, než má mozková tkáň - například céva, kalcifikace. Tím pádem narůstání segmentované oblasti skončí v této struktuře (Obr. 4.5 1. semínko). Avšak další semínka, která byla umístěna do jiných pixelů obrazu budou v narůstání pokračovat, dokud se nezastaví o lebku (Obr. 4.5 2. a 3. semínko). Následným zfúzováním těchto takto vzniklých segmentů bylo dosaženo požadovaného výsledku.

Postprocessingové úpravy vysegmentovaného 3D objemu


V další krocích již algoritmus pracuje s 3D objemem, který vznikl ukládáním 2D binárních výstupů segmentace mozku každého z řezů objemu do předdefinované prázdné trojrozměrné matice. Tato matice je stejných rozměrů jako ořezaný objem CT snímku. Na výsledný segmentovaný 3D objem byl použit morfologický operátor *imclose*, pomocí kterého dojde k morfologickému uzavření 3D objektu (viz. kapitola 3.4.1). Zvolený strukturní element („*strel*“) pro morfologické uzavření 3D binární masky mozku byl diskového tvaru o poloměru 5. Takto upravený objem je tzv. 3D binární maska mozku (Obr. 4.6).



Obr. 4.6: Zleva: Transverzální, frontální a sagitální pohled na 3D binární masku mozku.

Extrakce objemu mozkové tkáně

K extrakci mozkové tkáně z ořezaného objemu CT snímku byla využita výsledná 3D binární maska mozku. Extrakce mozku byla provedena tak, že všechny voxely ořezaného objemu CT skenu ležící mimo masku mozku (reprezentovanou hodnotami 1) byly nastaveny na hodnotu 0, tedy jako pozadí. Tak byly odstraněny okolní tkáně, lebka, patientský stůl a zůstal zachován pouze objem mozkové tkáně s voxely reprezentovanými původními hodnotami CT čísel vyjádřených v Hounsfieldových jednotkách.



Obr. 4.7: Frontální a sagitální pohled na extrahovaný objem mozkové tkáně.

4.3.3 Zvýraznění mozkových cév a extrakce příznakových map

V tomto kroku algoritmu byly z objemu extrahované mozkové tkáně dopočítány tři parametrické příznakové mapy zvýrazněných mozkových cév. Pro výpočet příznakových map byly využity 3 pokročilé filtry založené na výpočtu Hessovy matice a analýze vlastních čísel Hessovy matice. Princip filtrů založených na Hessianu je podrobněji popsán v kapitole 3.4.3. Výstupem těchto filtrů je parametrický trojrozměrný obraz zvýrazněných mozkových cév, ve kterém je jasně zřetelný kontrast

světle zvýrazněných mozkových cév vůči tmavému pozadí. Proto bývají parametrické obrazy zvýrazněných mozkových cév často využívány pro diagnostiku patologií cévního zásobení mozku, ovšem velký význam mají také pro segmentaci mozkových cév. V procesu segmentace mozkových cév bývají parametrické obrazy využity jako vstupní obraz (příznakový prostor) mnoha různých segmentačních metod.

Filtry založené na Hessianu zvýrazňují zakřivené struktury kontrastní vůči pozadí. Aplikací těchto filtrů na původní objem extrahované mozkové tkáně byl zvýrazněn pouze povrch mozku a žádné mozkové cévy. To bylo způsobeno velkým kontrastem mozkové tkáně vůči nulovému pozadí. Proto bylo nutné upravit pozadí extrahovaného mozku, aby bylo dosaženo plynulého přechodu mezi mozkovou tkání a pozadím. Do pozadí byly uměle nastaveny hodnoty, které byly vypočtené jako průměrná hodnota všech CT čísel reprezentujících voxely extrahované mozkové tkáně. Takto upravený objem byl pak vstupním obrazem každého z použitých filtrů:

Hessian based Frangi Vesselness filtr

Tento filtr pro výpočet parametrického obrazu zvýraznění mozkových cév využívá Frangiho zvýrazňovací funkci, která je podrobněji popsána v kapitole 3.4.3. Jedná se o již implementovaný filtr, který je volně stažitelný na MathWorks [42].

Pro tento filtr byly v této práci nastaveny následující parametry: rozsah hodnot σ : pacient 1,3,4 = [1:2], pacient 2,5 = [1:4]; Velikost kroku mezi hodnotami σ : pacient 1-5 = 1; Frangiho zvýrazňovací konstanta α : pacient 1-5 = 1; Frangiho zvýrazňovací konstanta β : pacient 1-4 = 0.5 a pacient 5 = 0.1; Práh mezi vlastními čísly pro šum a cévní struktury c : pacient 1,2 = 45 a pacient 3,4,5 = 35;

Fibermetric

U tohoto filtru je taktéž využívána Frangiho zvýrazňovací funkce. Filtr je přímo implementován jako funkce v Matlabu, která je volána příkazem *fibermetric*. Ve výsledném parametrickém obrazu zvýrazněných mozkových cév bylo dosaženo maximální odezvy filtru v celé tloušťce zvýrazněné struktury, která velikostí odpovídá detekované trubkové struktuře v původním obraze.

Jediný využitý nastavitelný parametr tohoto filtru byl parametr *StructureSensitivity* s hodnotami pro pacienta 1-5 = 30 s výjimkou pro pacienta 2 = 50. Pomocí tohoto parametru byl experimentálně nastaven práh (citlivost) pro odlišení tubulárních struktur od pozadí.

Jeran Enhancement filtr

Poslední z použitých filtrů založených na Hessianu dopočítává parametrický obraz zvýrazněných mozkových cév pomocí Jermanovy zvýrazňovací funkce. Způsob výpo-

čtu parametrického obrazu touto funkcí je oproti Frangiho funkci modifikován, což vedlo k homogennímu zvýraznění cévních struktur napříč celým jejich průřezem. Tento filtr byl již implementován a je volně stažitelný na MathWorks [43].

V této práci byly pro tento filtr nastaveny následující parametry: Škála, na které je zvýraznění cév počítáno (*sigmas*): pacient 1,4 = [1:2], pacient 2,3,5 = 1; Rozlišení rozestupu pixelů vstupního obrazu (*spacing*): pacient 1-5 = [1;1;1]; Parametr řídicí uniformitu odezvy filtru (τ): pacient 1-5 = 0.8.



Obr. 4.8: Výstupy zvýraznění mozkových cév pomocí třech filtrů, vlevo: Jerman Enhancement filtr, uprostřed: Hessian based Frangi Vesselness filtr, vpravo: Fibermetric filtr.

Každý z použitých filtrů fungoval lépe na určitý typ cév. Na obrázku výše (Obr. 4.8) lze pozorovat, že například ve výstupu Hessian based Frangi Vesselness filtru došlo k útlumu zvýraznění cév v jejich ohybech. Obecně lze říct, že použité filtry založené na Hessianu lépe zvýrazňují velké mozkové cévy oproti menším periferním cévám.

4.3.4 Segmentace mozkových cév

Cílem posledního bloku algoritmu byla segmentace mozkových cév z parametrických obrazů zvýrazněných mozkových cév, které byly získány v předchozím kroku algoritmu. Na parametrické obrazy bylo použito celkem 6 segmentačních metod, jejichž úkolem bylo binárně klasifikovat každý voxel objemu do jedné ze dvou skupin: jako cévu (1) nebo jako pozadí (0). Klasifikace voxelů parametrických obrazů byla provedena na základě jejich hodnot daného parametru.

V této kapitole budou popsány použité segmentační přístupy pouze z hlediska implementace a nastavených parametrů. Z hlediska principu a fungování jsou jednotlivé metody podrobněji teoreticky popsány v kapitole 3.4.4.

Metody prahování obrazu

Pro segmentaci obrazu byly využity celkem tři prahovací metody. Jednotlivé prahovací metody byly postupně použity na každou ze tří parametrických map a následně byly tyto tři výstupy segmentace maximově zfúzovány. Tak byl získán výsledný segmentovaný objem, na základě kterého mohly být jednotlivé prahovací metody mezi sebou porovnány.

První metodou bylo expertní prahování, což je nejjednodušší z použitých metod. V případě této metody byly manuálně nastaveny takové prahové hodnoty každé z parametrických map, pro které bylo dosaženo subjektivně nejlepšího výsledku segmentace.

Další použitou metodou bylo automatické globální prahování parametrického prostoru. Práh pro každou ze tří parametrických map byl automaticky vypočítán pomocí Otsuovy metody. K naprahování obrazu bylo využito funkce *imbinarize*, které byl zadán parametr *'global'*, pomocí něhož je nastaveno dopočítání globálního prahu právě Otsuovou metodou.

Poslední z prahovacích segmentačních metod je adaptivní prahování. Tato metoda dopočítává zvláště pro každý voxel prahovou hodnotu z jeho předdefinovaného okolí. V této práci bylo pro výpočet lokálního adaptivního prahu využito funkce *adaptthresh*, které byl nastaven parametr *sensitivity = 0.5* (citlivost pro prahování více pixelů jako popředí) a okolí aktuálního voxelu pro výpočet střední hodnoty intenzity (*mean*) bylo nastaveno na $5 \times 5 \times 5$ voxelů.

K-means klasifikace

Segmentace mozkových cév z 3D parametrických obrazů pomocí metody k-means probíhala ve 2D rovině řez po řezu. Z každého 2D řezu třech parametrických objemů byla vytvořena příznaková matice X o rozměru $m \times n$, kdy m je celkový počet pixelů 2D řezu a n je počet příznaků (parametrických obrazů). Řádky matice X reprezentují jednotlivé objekty (pixely 2D řezu), přičemž každý z objektů má 3 příznaky zapsané ve sloupcích matice X . Tři příznaky každého objektu jsou hodnoty daného pixelu ve třech parametrických mapách. Takto vytvořená příznaková matice byla následně podrobena klasifikaci pomocí metody k-means.

V této práci k-means klasifikuje objekty trojrozměrného příznakového prostoru do dvou klasifikačních tříd (shluků). Byla využita funkce *kmeans*, kdy počáteční pozice prvního centroidu byly nastaveny do bodu $[0 \ 0 \ 0]$, druhý centroid byl umístěn do bodu $[0.01 \ 0.01 \ 0.01]$. Maximální počet iterací byl optimalizačním přístupem nastaven na hodnotu 5. Po klasifikaci všech pixelů příznakové matice X do jedné z klasifikačních tříd byly všechny pixely převedeny do 2D roviny, přičemž původní souřadnice jednotlivých pixelů zůstaly zachovány. Výsledný 2D binární obraz byl

následně uložen jako jeden řez předdefinovaného objemu. Následně jsou iterativně procházeny a klasifikovány všechny 2D řezy parametrických objemů, binární výstupy jsou vždy převedeny do 2D obrazové matice původních rozměrů, která je uložena jako řez vznikajícího segmentovaného objemu.

Klasifikace pixelů každého 2D řezu parametrických objemů byla v této práci zvolena proto, že v případě, kdy bylo snahou klasifikovat celé 3D parametrické objemy najednou, byla příznaková matice X tvořena všemi pixely 3D objemů a nabývala obrovských rozměrů. Počet objektů (řádků) v příznakové matici X byl v řádu desítek milionů (kolem 70 mil.), přičemž každý objekt měl 3 příznaky. Klasifikace tak obrovského příznakového prostoru pak byla velmi výpočetně náročná.

Náhodné lesy

Další z použitých metod pro segmentaci mozkových cév je metoda náhodných lesů (z angl. Random Forests). Sestavení trénovací a validační množiny je podrobněji popsáno v kapitole 4.2. Pro natrénování náhodného lesa byla využita funkce *Tree-Bagger*, která vrátí soubor (les) natrénovaných n náhodných rozhodovacích stromů. Vstupními parametry této funkce je zvolený počet rozhodovacích stromů $n = 150$, matice trénovacích objektů X a vektor požadovaných výstupů klasifikace každého objektu Y . Následně je natrénovaný náhodný les otestován na validační množině dat, kdy porovnáním predikovaných a požadovaných výstupů klasifikace pixelů byla vypočtena přesnost 99.61 % natrénovaného náhodného lesa.

Následně je natrénovaný náhodný les použit pro segmentaci 3D parametrických obrazů. Segmentace probíhá, stejně jako v případě k-means, ve 2D rovině řez po řezu. Stejným způsobem je vytvořena příznaková matice X , která je klasifikována natrénovaným náhodným lesem. Výstupem je binární vektor klasifikovaných pixelů, které jsou převedeny se zachováním původních souřadnic do 2D obrazu. Výsledný 2D binární obraz je uložen jako řez předdefinovaného objemu. Dále jsou iterativně procházeny všechny 2D řezy parametrických objemů a celý postup klasifikace pixelů se opakuje.

Neuronová síť

Posledním přístupem pro segmentaci mozkových cév z parametrických obrazů je klasifikace pixelů pomocí neuronové sítě. V této práci byla navržena následující architektura umělé neuronové sítě: vstupní vrstva (3 vstupní neurony), plně propojená vrstva sloužící k normalizaci vstupů (15 neuronů), plně propojená vrstva se sigmoidální aktivační funkcí (2 neurony) a výstupní klasifikační vrstva.

Pro trénování neuronové sítě byly nastaveny následující parametry: Optimalizační funkce *sgdm* (stochastický gradientní sestup s hybností), počet epoch = 10, velikost skupiny trénovacích dat = 100, krok učení = 0.1, snižování kroku učení v každé 10. epoše o 1 %.

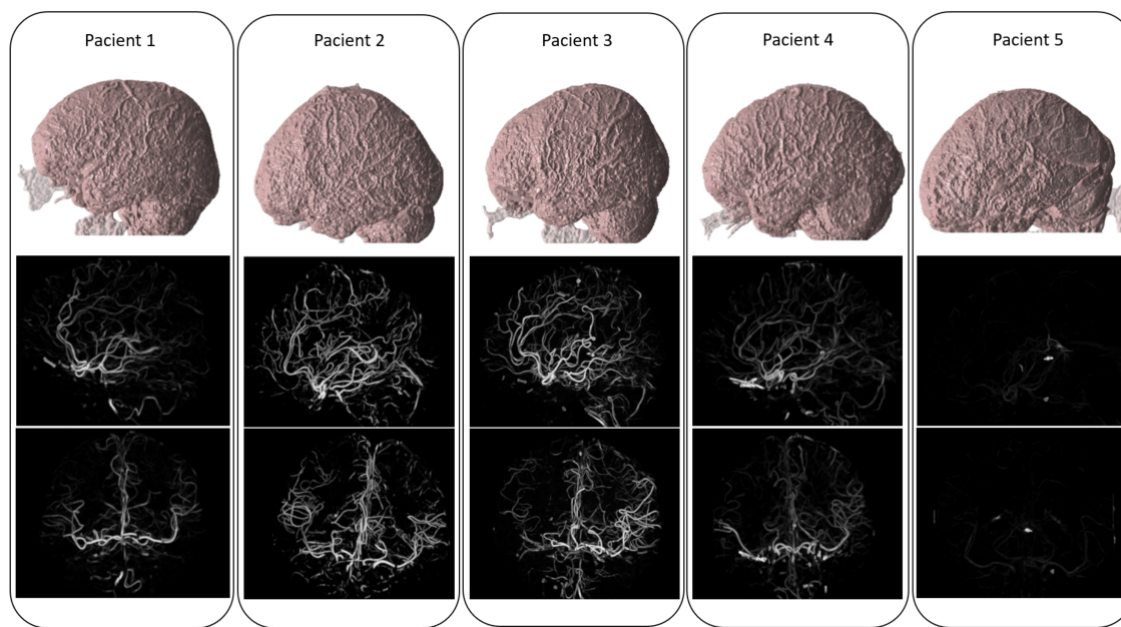
K natrénování neuronové sítě byla využita funkce *trainNetwork*, jejímiž vstupními parametry byla tabulka trénovacích dat, navržená architektura sítě a parametry trénování sítě. Tabulka trénovacích dat byla vytvořena z matice trénovacích objektů X a vektoru požadovaných výstupů klasifikace objektů Y . Trénovací množiny X a Y jsou blíže popsány v kapitole 4.2. Natrénovaná neuronová síť byla otestována na validační množině a porovnáním predikovaných a požadovaných výstupů klasifikace pixelů byla vypočtena přesnost 98.63 % natrénované neuronové sítě pro binární klasifikaci.

Princip použití natrénované neuronové sítě pro segmentaci 3D parametrických obrazů je totožný jako v případě segmentace pomocí náhodného lesa a k-means. Jediný rozdíl je v tom, že příznaková matice X musí být nejprve převedena do formátu tabulky, na kterou je následně použita natrénovaná neuronová síť.

5 Výsledky a diskuze


5.1 Extrakce mozku a zvýraznění cév

V krocích navrženého algoritmu, které jsou popsány v kapitolách 4.3.2 a 4.3.3 bylo dosaženo následujících výsledků.




Obr. 5.1: Výstupy extrakce objemu mozkové tkáně (sagitální pohled) a zvýraznění mozkových cév (sagitální a frontální pohled) pro všechny dostupné CT data.

Na obrázku výše (Obr. 5.1) jsou v prvním řádku uvedeny výstupy extrakce mozkové tkáně pro všechny dostupné patientské CT snímky. Extrahované objemy mozkové tkáně jsou zobrazeny v sagitální rovině. U některých ze zobrazených výsledků je patrné, že při tvorbě binární masky mozku pomocí metody narůstání oblastí byly do výsledné segmentované oblasti přidány i pixely, které nepatří do oblasti mozku. To je způsobeno anatomíí lebky, kdy lebka není v některých místech uzavřena - například v oblasti vstupu zrakového nervu do lebky. V důsledku toho se v místě těchto otvorů lebky narůstající segmentovaná oblast nemá o co zastavit, a proto narůstání oblasti pokračuje i mimo lebeční dutinu (Obr. 5.2). Tato nedokonalost výsledného extrahovaného objemu mozkové tkáně však neovlivňuje negativně další kroky algoritmu.



Obr. 5.2: Původní 2D řez mozku, ve kterém je červenou konturou ohraničena oblast extrahovaného mozku. V modrém rámečku je detailněji zobrazeno místo průniku narůstající oblasti mimo lebeční dutinu.

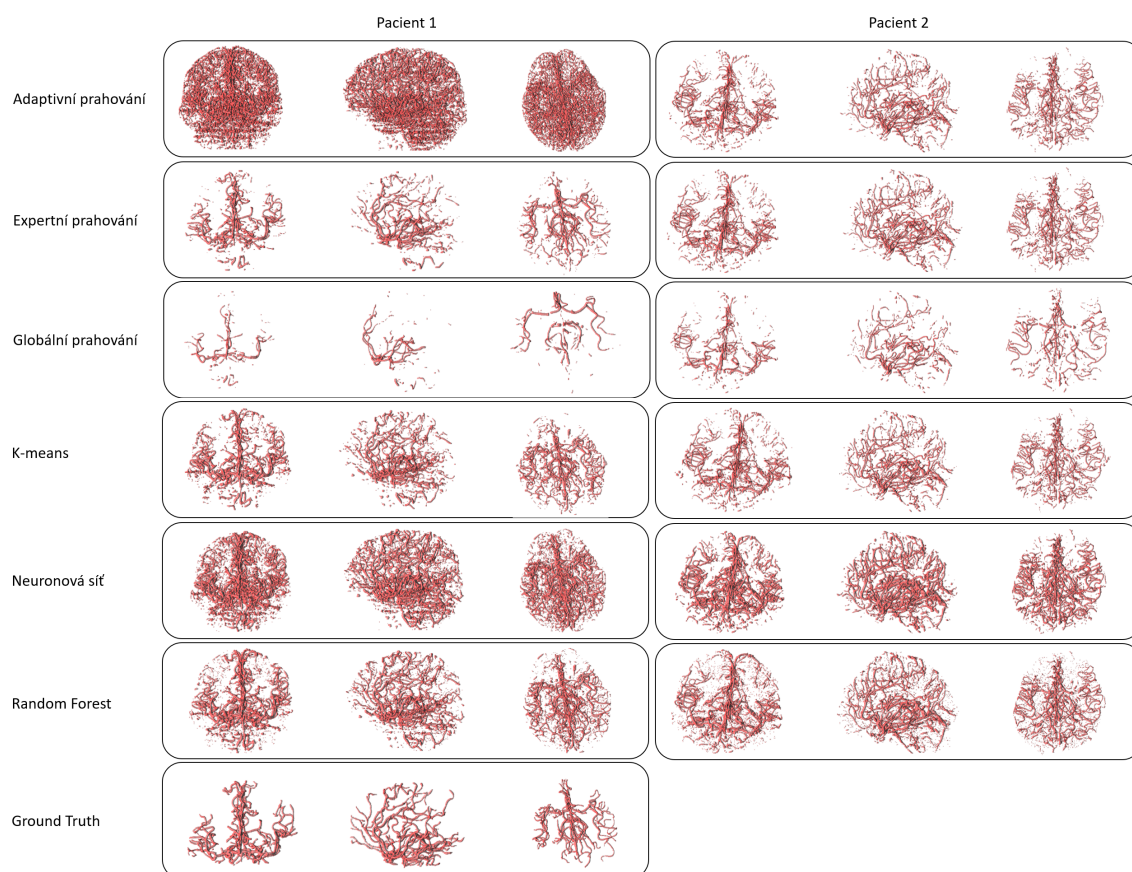
Ve druhém a třetím řádku obrázku (Obr. 5.1) jsou v sagitálním a frontálním pohledu zobrazeny výsledky zvýraznění mozkových cév. Pro prezentaci výsledků zvýraznění mozkových cév byly použity objemy zfužovaných třech parametrických obrazů. Fúze třech parametrických obrazů byla provedena jejich součtem. Zvýrazněním mozkových cév bylo dosaženo výrazného kontrastu světle zobrazených mozkových cév vůči tmavému pozadí. V případě pátého CT snímku (Obr. 5.1 Pacient 5) byly zvýrazněny pouze hlavní mozkové cévy, jejich kontrast vůči pozadí však není tak zřetelný jako u ostatních CT snímků (Obr. 5.3). To bylo zapříčiněno tím, že pátý CT sken byl nasnímán až v druhé kontrastní fázi, kdy část kontrastní látky byla krví odplavena z cévního systému mozku.



Obr. 5.3: Vlevo: 2D řez mozkiem pátého CT skenu nasnímaného ve druhé kontrastní fázi - nízký kontrast cév. Vpravo: 2D řez objemu zvýrazněných mozkových cév. Pro názornost obrázku bylo nutné zvýšit kontrast zvýrazněných cév vůči pozadí.

5.2 Segmentace mozkových cév

Pro segmentaci mozkových cév bylo využito celkem 6 segmentačních metod, které byly popsány v kapitole 4.3.4. Není nutné v této práci prezentovat výsledky segmentace dosažené všemi šesti metodami na všech pěti dostupných CT snímcích, proto budou v této kapitole ukázány zejména vybrané reprezentativní nebo zajímavé výstupy.



Obr. 5.4: Výstupy segmentace mozkových cév (frontální, sagitální, transverzální pohled) všemi segmentačními metodami pro dva vybrané CT skeny.

Na obrázku (Obr. 5.4) jsou ukázány segmentace mozkových cév pro dva vybrané CT skeny všemi segmentačními metodami. Výstupy jsou zobrazeny ve třech základních anatomických rovinách: frontální, sagitální a transverzální. V levé polovině obrázku (Pacient 1) jsou výstupy segmentace pro CT snímek, ve kterém byly ručně označeny mozkové cévy - Ground Truth v posledním řádku. V pravé polovině obrázku (Pacient 2) jsou ukázány segmentované mozkové cévy, které byly vybrány jako reprezentativní výstupy segmentace.

5.2.1 Objektivní hodnocení výsledků segmentace

Pro objektivní zhodnocení dosažených výsledků segmentace byl zvolen výpočet metriky zvané Dice koeficient (DSC, z angl. Dice similarity coefficient), která se pohybuje v rozmezí 0 % až 100 % a je vypočítána podle vztahu:

$$DSC = \frac{2|V_{GT} \cap V_S|}{|V_{GT}| + |V_S|} \cdot 100 \quad (5.1)$$

kdy V_{GT} je objem Ground Truth, V_S je výsledný segmentovaný objem [44]. Jak již vyplývá ze vztahu 5.1, pro objektivní hodnocení segmentace je nezbytné mít k dispozici objem ručně označených mozkových cév, tzv. Ground Truth. V této práci byly ručně označeny mozkové cévy v jednom patientském CT skenu (Obr. 5.4 Patient 1), pro který byly výsledky segmentace mozkových cév objektivně zhodnoceny. Pro ruční segmentaci mozkových cév byla využita volně stažitelná aplikace MITK Workbench (The Medical Imaging Interaction Toolkit).

Pro objektivní zhodnocení výsledků každé ze segmentačních metod byl podle vztahu 5.1 vypočítán Dice koeficient. Výsledné hodnoty jsou uvedeny v tabulce 5.2.1.


Tab. 5.1: Tabulka hodnot Dice koeficientu pro každou ze segmentačních metod.

Segmentační metoda	Dice koeficient %
Adaptivní prahování	34.08
Expertní prahování	77.06
Globální prahování	31.42
K-means	70.47
Neuronová síť	47.76
Náhodný les	74.12

Dice koeficient lze interpretovat jako míru podobnosti segmentovaného objemu s referenčním objemem Ground Truth. Nejnižších hodnot DSC bylo dosaženo Adaptivním prahováním (34.08 %) a Globálním prahováním (31.42 %). Naopak nejlepších výsledků segmentace bylo dosaženo metodou Náhodného lesa (74.12 %) a Expertním prahováním (77.06 %).


V případě Adaptivního prahování je nízká hodnota Dice koeficientu zapříčiněná velkým množstvím falešně pozitivních pixelů (FP, z angl. false positive). V porovnání s Ground Truth (Obr. 5.5) bylo celkem 155 301 pixelů falešně klasifikováno jako céva (FP) a 18 461 pixelů bylo falešně klasifikováno jako pozadí (FN, z angl. false negative). Správně klasifikovaných (TP, z angl. true positive) jako céva bylo

44 925 pixelů. Z uvedeného vyplývá, že metoda adaptivního prahování má tendenci klasifikovat pixely spíše jako cévy.



Obr. 5.5: Sagitální a transverzální pohled na: a) Ground Truth b) výstup segmentace pomocí Adaptivního prahování c) bíle zobrazené TP pixely, šedě zobrazené FP a FN pixely, černě zobrazené pixely pozadí.

Opačným případem je Globální prahování, kdy nízká hodnota Dice koeficientu je způsobena velkým množstvím falešně negativních (FN) pixelů. Ve srovnání s Ground Truth (Obr. 5.6) bylo správně klasifikováno jako céva (TP) pouze 12 066 pixelů. Naopak 51 320 pixelů bylo falešně klasifikováno jako pozadí (FN). Falešných cévových pixelů (FP) bylo 1341. Lze tedy říct, že metoda globálního prahování má tendenci pixely klasifikovat spíše jako pozadí.



Obr. 5.6: Sagitální a transverzální pohled na: a) Ground Truth b) výstup segmentace pomocí Globálního prahování c) bíle zobrazené TP pixely, šedě zobrazené FP a FN pixely, černě zobrazené TN pixely.


Tab. 5.2: Tabulka počtu pixelů správně klasifikovaných jako céva (TP), falešně klasifikovaných jako céva (FP) a falešně klasifikovaných jako pozadí (FN) pro každou ze segmentačních metod.

Segmentační metoda	TP	FP	FN
Adaptivní prahování	44925	155301	18461
Expertní prahování	45129	8618	18257
Globální prahování	12066	1341	51320
K-means	55085	37867	8301
Neuronová síť	61476	128445	1910
Náhodný les	61826	41626	1560

V tabulce 5.2.1 jsou uvedeny počty pixelů, které byly klasifikovány danou segmentační metodou správně jako céva (TP), falešně jako céva (FP) a falešně jako pozadí (FN). Tyto hodnoty byly dopočítány porovnáním výstupu segmentace danou metodou a referenčního objemu expertně označených mozkových cév (Ground Truth). Celkový počet cévových pixelů v Ground Truth byl 63 386. Nejvíce se k tomuto počtu cévových pixelů blíží výstup segmentace metodou Náhodného lesa. I přesto, že Náhodný les klasifikoval značné množství pixelů falešně pozitivně, dosáhl druhé nejvyšší hodnoty Dice koeficientu (74.12 %). Objektivně nejlepších výsledků segmentace mozkových cév bylo dosaženo metodou Expertního prahování - hodnota Dice koeficientu byla 77.06 %. Cílem této metody bylo nastavit takové prahové hodnoty pro každý z parametrických obrazů, pro které budou výstupy segmentace subjektivně (pro experta) nejlepší možné. Tak bylo dosaženo nízkého počtu falešně pozitivních (FP) pixelů ve výsledném segmentovaném objemu.

5.2.2 Analýza a filtrace malých objektů

Jestliže ve výsledném objemu segmentovaných mozkových cév je velké množství pixelů klasifikováno falešně pozitivně, pak má výstup segmentace z hlediska subjektivního i objektivního hodnocení nízkou kvalitu. Dobrým příkladem jsou výstupy segmentace mozkových cév metodou Neuronové sítě, kdy pro první a třetí patientský CT snímek bylo dosaženo následujících výsledků:




Obr. 5.7: Výstupy segmentace mozkových cév pomocí Neuronové sítě pro první a třetí CT snímek naší databáze.

Výstup segmentace Neuronovou sítí pro první CT snímek (Pacient 1) dosahuje hodnoty Dice koeficientu 47.74 % (Tab. 5.2.1). Subjektivním zhodnocením obou výstupů segmentace (Pacient 1, Pacient 3) lze říci, že v obou případech výsledný objem působí dosti zašuměle. Z toho důvodu byla ve výsledném segmentovaném objemu provedena analýza všech objektů klasifikovaných jako céva - byly nalezeny a spočítány všechny spojené komponenty a také byla získána informace o velikosti každého z těchto objektů - tedy kolika pixely je tvořen. Ve výstupu segmentace prvního CT snímku (Pacient 1) bylo nalezeno celkem 2695 objektů, ve výstupu segmentace třetího CT snímku (Pacient 3) bylo nalezeno 9303 objektů.

Základním problémem filtrace bylo stanovení prahové velikosti objektů, podle které budou objekty zachovány jako cévy, nebo odfiltrovány do pozadí. Vzhledem k tomu, že ve výsledném objemu segmentace nejsou cévy spojitě, nebylo ideální volbou vybrat pouze objekt o maximální velikosti. Cílem bylo zachovat zejména hlavní mozkové cévy, větší spojitě cévy a odfiltrovat všechny malé objekty. Proto byla manuálně optimalizačním přístupem nastavena prahová hodnota velikosti objektů na 300 pixelů, pro kterou byly filtrované objemy subjektivně i objektivně (pro první CT sken) nejlepší.

Výsledné objemy segmentovaných mozkových cév po odfiltrování objektů menších než 300 pixelů jsou ukázány na obrázku 5.8:



Obr. 5.8: Filtrované výstupy segmentace mozkových cév pomocí Neuronové sítě pro první a třetí CT snímek naší databáze.

Ve filtrovaném objemu segmentovaných mozkových cév pro první CT snímek (Pacient 1) zůstalo celkem 56 objektů, filtrací objemu segmentovaných mozkových cév pro třetí CT snímek (Pacient 3) zůstalo zachováno celkem 63 objektů.

Objektivní hodnocení filtrovaného objemu segmentovaných mozkových cév pro první CT snímek (Pacient 1) je uvedeno ve druhém řádku tabulky 5.3:


Tab. 5.3: Tabulka srovnání objektivního hodnocení výsledného objemu segmentace prvního CT snímku před a po filtraci.

	Dice koeficient %	TP	FP	FN
Výsledný objem segmentace prvního CT snímku	47.76	61476	128445	1910
Filtrovaný objem segmentace prvního CT snímku	57.85	60612	85534	2774

Porovnáním hodnot Dice koeficientu pro výsledný objem segmentovaných mozkových cév z prvního CT snímku před a po filtraci lze říci, že odfiltrováním objektů menších než 300 pixelů bylo dosaženo zvýšení hodnoty Dice koeficientu o 10.09 %. Filtrací bylo odstraněno celkem 42 911 falešně pozitivních pixelů (FP) a pouze 816 pixelů původně správně klasifikovaných jako céva (TP) bylo odfiltrováno do pozadí (FN). Z hlediska subjektivního porovnání výsledných objemů před a po filtraci lze jednoznačně říci, že filtrovaný objem segmentovaných mozkových cév se jeví jako čistější a kvalitnější výsledek segmentace.

5.2.3 Možné využití v diagnostickém procesu

Jak již bylo zmíněno v úvodních kapitolách této práce, patologie cévního systému mozku jsou časté a velmi vážné život ohrožující stavy. Vzhledem k četnosti těchto onemocnění, jejich rychlému průběhu a závažnosti následků, je kladen velký důraz na celkové zlepšení diagnostického procesu. Ke zefektivnění diagnostického procesu může vést i to, že radiologovi je poskytnut pohled pouze na oblast jeho zájmu, v tomto případě na mozkové cévy. V objemu segmentovaných mozkových cév je pro radiologa mnohem jednodušší se zorientovat, trasovat jednotlivé větve cévního systému a hodnotit stav mozkových cév.



Obr. 5.9: Ukázky využití segmentace mozkových cév v diagnostice patologií cévního zásobení mozku pacienta s ischemickou oblastí. V modrých rámečcích je ohraničená oblast cévního systému mozku, kde pravděpodobně došlo k ucpání některé z hlavních cév - ischemické cévní mozkové příhodě.

Na obrázku (Obr. 5.9) jsou ukázány výstupy segmentace mozkových cév pro dva patientské CT snímky. U obou výstupů (Pacient 3, Pacient 4) je patrné, že v levé větvi cévního systému mozku je méně cév, než v pravé větvi. To je pravděpodobně způsobeno ucpáním některé z hlavních mozkových cév levé hemisféry. Ucpání hlavní mozkové cévy (například trombem) lze ve výsledném objemu segmentace pozorovat jako nefyziologické ukončení celé cévní větve. Oblast cévního systému mozku, ve které pravděpodobně došlo k ucpání cévy, je v obrázku (Obr. 5.9) ohraničena modrým rámečkem.

Z výsledného objemu segmentovaných mozkových cév tedy může radiolog s vyšší přesností a rychlostí určit příčinu vzniku dané patologie cévního zásobení mozku. Ve výše uvedených případech (Obr. 5.9 Pacient 3 a Pacient 4) by se pravděpodobně jednalo o ischemickou cévní mozkovou příhodu.

Závěr

V této práci byla nastudována anatomie, fyziologie a patologie cévního zásobení mozku. Byly popsány zobrazovací modalita využívané pro angiografické vyšetření a také metody obrazové analýzy se zaměřením na segmentační techniky. Byla provedena rešerše publikovaných zajímavých přístupů pro segmentaci cévního zásobení mozku a byly teoreticky popsány metody použité v této práci. Hlavním cílem práce byl návrh, realizace a testování algoritmu pro segmentaci mozkových cév v 3D CT obrazových datech se zaměřením na cévní mozkové příhody. Byl navržen algoritmus, který se skládá z pěti na sebe navazujících bloků. Po načtení a předzpracování objemových dat byla vytvořena 3D binární maska mozku, která byla následně využita k extrakci mozkové tkáně z původních CT snímků. Na extrahovaný objem mozku byly použity tři pokročilé filtry založené na výpočtu Hessianovy matice a analýze vlastních čísel Hessianovy matice, jejichž výstupem jsou 3D parametrické obrazy zvýrazněných mozkových cév. Výsledné parametrické obrazy zvýrazněných mozkových cév byly využity jako vstupy do šesti implementovaných segmentačních metod. První tři použité segmentační metody jsou založené na prahování obrazu a jedná se o adaptivní, globální a expertní prahování. Zbývající tři segmentační metody patří do skupiny klasifikačních metod strojového učení. Byla implementována metoda k-means, neuronová síť a náhodný les.

Navržený algoritmus byl otestován na databázi pěti anonymizovaných patientských CT skenů. Výsledky segmentace mozkových cév všemi použitými metodami byly objektivně zhodnoceny výpočtem Dice koeficientu. Pro výpočet Dice koeficientu je nutné mít k dispozici objem manuálně označených mozkových cév, proto byly jako součást této práce manuálně segmentovány mozkové cévy v jednom patientském CT snímku. Pro objektivní srovnání jednotlivých segmentačních metod byly také ve výsledných objemech segmentace spočítány všechny pixely správně klasifikované jako céva (TP), falešně klasifikované jako céva (FP) a falešně klasifikované jako pozadí (FN). Objektivně nejlepších výsledků segmentace mozkových cév bylo dosaženo metodou expertního prahování (Dice = 77.06 %) a metodou náhodného lesa (Dice = 74.12 %).

Výsledky jednotlivých kroků algoritmu, tedy extrakce mozku, zvýraznění mozkových cév a segmentace mozkových cév, jsou prezentovány a diskutovány v poslední kapitole této práce. V závěru práce je také diskutováno možné využití navrženého algoritmu v diagnostice patologií cévního systému mozku.

Literatura

- [1] ČIHÁK, Radomír. *Anatomie*. Třetí, upravené a doplněné vydání. Praha: Grada, 2016. ISBN 978-80-247-5636-3.
- [2] NAŇKA, Ondřej a Miloslava ELIŠKOVÁ. *Přehled anatomie*. Třetí, doplněné a přepracované vydání. Praha: Galén, [2015]. ISBN 978-80-7492-206-0.
- [3] SHAH, Rahul S. a Deva S. JEYARETNA. Cerebral vascular anatomy and physiology. *Surgery (Oxford)* [online]. 2021, **39**(8), 463-469 [cit. 2021-11-12]. ISSN 02639319. DOI: 10.1016/j.mpsur.2021.06.006
- [4] KALVACH, Pavel. *Mozkové ischemie a hemoragie*. 3., přeprac. a dopl. vyd. Praha: Grada, 2010. ISBN 978-80-247-2765-3.
- [5] Cévní zásobení mozku. *123Sonography* [online]. [cit. 2021-11-13]. Dostupné z: <https://123sonography.com/carotid-ultrasound-anatomy>
- [6] Diffusion Tensor Imaging of the Human Brain. *ResearchGate* [online]. [cit. 2021-11-13]. Dostupné z: https://www.researchgate.net/publication/291346848_Diffusion_Tensor_Imaging_of_the_Human_Brain?channel=doi&linkId=56a155e808ae27f7de266645&showFulltext=true
- [7] TAMEEM, Alifia a Hari KROVVIDI. Cerebral physiology. *Continuing Education in Anaesthesia Critical Care & Pain* [online]. 2013, **13**(4), 113-118 [cit. 2021-12-30]. ISSN 17431816. DOI: 10.1093/bjaceaccp/mkt001
- [8] AGARWAL, Nivedita a Roxana Octavia CARARE. Cerebral Vessels: An Overview of Anatomy, Physiology, and Role in the Drainage of Fluids and Solutes. *Frontiers in Neurology* [online]. 2021, **11** [cit. 2021-12-30]. ISSN 1664-2295. DOI: 10.3389/fneur.2020.611485
- [9] Ischemic stroke. *Radiopaedia.org* [online]. 2011, 2005-12-01 [cit. 2021-11-11]. DOI: 10.53347/rID-13437
- [10] ABRAMOVA, Valeriia, Albert CLÈRIGUES, Ana QUILES, Deysi Garcia FIGUEREDO, Yolanda SILVA, Salvador PEDRAZA, Arnau OLIVER a Xavier LLAD-. Hemorrhagic stroke lesion segmentation using a 3D U-Net with squeeze-and-excitation blocks. *Computerized Medical Imaging and Graphics* [online]. 2021, **90** [cit. 2021-11-11]. ISSN 08956111. DOI: 10.1016/j.compmedimag.2021.101908
- [11] SILBERNAGL, Stefan a Florian LANG. *Atlas patofyziologie*. 2. české vyd. Praha: Grada, 2012. ISBN 978-80-247-3555-9.

- [12] POVÝŠIL, Ctibor a Ivo ŠTEINER. *Speciální patologie*. 2., dopl. a přeprac. vyd. Praha: Galén, c2007. ISBN 978-80-7262-494-2.
- [13] Understanding Key Differences between Ischemic and Haemorrhagic Strokes. *World stroke day: A Blog on Stroke & Neurology Related Issues* [online]. 1.12.2019 [cit. 2021-12-16]. Dostupné z: <https://www.wsdcon.com/blog/what-is-the-difference-between-ischemic-and-haemorrhagic-strokes/>
- [14] LAVIÑA, Bàrbara. Brain Vascular Imaging Techniques. *International Journal of Molecular Sciences* [online]. 2017, **18**(1), full article [cit. 2021-11-11]. ISSN 1422-0067. DOI: 10.3390/ijms18010070
- [15] BUSHBERG, Jerrold T., J. Anthony SEIBERT, Edwin M. LEIDHOLDT a John M. BOONE. *The essential physics of medical imaging*. 3rd ed. Philadelphia: Wolters Kluwer, 2011. ISBN 978-0781780575
- [16] HSIEH, Jiang. *Computed Tomography: Principles, Design, Artifacts, and Recent Advances*. Third Edition. Bellingham: SPIE Press, 2015. ISBN 9781628418255
- [17] MALÍKOVÁ, Hana. *Základy radiologie a zobrazovacích metod*. 01.03.2019. Praha: Univerzita Karlova, nakladatelství Karolinum, 2019. ISBN 978-80-246-4036-5
- [18] DRASTICH, Aleš. *Tomografické zobrazovací systémy*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a informatiky, Ústav biomedicínského inženýrství, 2004. ISBN 80-214-2788-4.
- [19] KALENDER, Willi A. *Computed Tomography: Fundamentals, System Technology, Image Quality, Applications*. 3. Auflage. Erlangen: Publicis, 2011. ISBN 978-3-89578-317-3.
- [20] PROKOP, Mathias. Multislice CT angiography. *European Journal of Radiology* [online]. 2000, **36**(2), 86-96 [cit. 2021-11-11]. DOI: doi.org/10.1016/S0720-048X(00)00271-0
- [21] BOTTINOR, Wendy, Pritam POLKAMPALLY a Ion JOVIN. Adverse Reactions to Iodinated Contrast Media. *International Journal of Angiology* [online]. 2013, **22**(03), 149-154 [cit. 2021-11-11]. ISSN 1061-1711. DOI: 10.1055/s-0033-1348885
- [22] V. Rohan, P. Ševčík, J. Polívka, Z. Ambler, B. Kreuzberg a J. Ferda. Klinický pohled na výpočetní tomografii u akutní ischemie mozku. *Česká a slovenská*

- neurologie a neurochirurgie* [online]. 2007, (6), 643-652 [cit. 2021-11-11]. Dostupné z: <https://www.csmn.eu/casopisy/ceska-slovenska-neurologie/2007-6-1/klinicky-pohled-na-vypocetni-tomografii-u-akutni-ischemie-mozku-52510>
- [23] AUFRICHTIG, R. a D.L. WILSON. X-ray fluoroscopy spatio-temporal filtering with object detection. *IEEE Transactions on Medical Imaging* [online]. 1995, **14**(4), 733-746 [cit. 2021-11-11]. ISSN 02780062. DOI: 10.1109/42.476114
- [24] HARTUNG, Michael P, Thomas M GRIST a Christopher J FRANÇOIS. Magnetic resonance angiography: current status and future directions. *Journal of Cardiovascular Magnetic Resonance* [online]. 2011, **13**(1) [cit. 2021-11-11]. ISSN 1532-429X. DOI: 10.1186/1532-429X-13-19
- [25] STUBER, Matthias a Robert G. WEISS. Coronary magnetic resonance angiography. *Journal of Magnetic Resonance Imaging* [online]. 2007, **26**(i2), 219-234 [cit. 2021-11-11]. ISSN 10531807. DOI: 10.1002/jmri.20949
- [26] WHEATON, Andrew J. a Mitsue MIYAZAKI. Non-contrast enhanced MR angiography: Physical principles. *Journal of Magnetic Resonance Imaging* [online]. 2012, **36**(2), 286-304 [cit. 2021-11-11]. ISSN 10531807. DOI: 10.1002/jmri.23641
- [27] MEZRICH, Reuben, Krishna JULURU a Paul NAGY. Should Post-Processing Be Performed by the Radiologist? *Journal of Digital Imaging* [online]. 2011, **24**(3), 378-381 [cit. 2021-11-11]. ISSN 0897-1889. DOI: 10.1007/s10278-011-9370-5
- [28] FLOHR, Thomas a Bernd OHNESORGE. Image Visualization and Post-processing Techniques. *Multi-slice and Dual-source CT in Cardiac Imaging* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, , 151-177 [cit. 2021-11-11]. ISBN 978-3-540-25523-9. DOI: 10.1007/978-3-540-49546-8_6
- [29] WALEK, Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů: Počítačová cvičení* [online]. Druhé, aktualizované. Vysoké učení technické v Brně: Vydáno pouze elektronickou formou, 2015 [cit. 2021-12-04]. ISBN 978-80-214-4792-9.
- [30] JAN, Jiří. *Medical image processing reconstruction and analysis: concepts and methods*. Second edition. CRC Press, 2019. ISBN 9781-138-31028-5.
- [31] LAMY, Jonas, Odyssee MERVEILLE, Bertrand KERAUTRET, Nicolas PASSAT a Antoine VACAVANT. Vesselness filters: A survey with benchmarks applied to liver imaging. *HAL: Science Ouverte* [online]. Milan, Italy,

- 2020, 3528-3535 [cit. 2022-05-12]. Dostupné z: <https://hal.archives-ouvertes.fr/hal-02544493v2>
- [32] JERMAN, Tim, Franjo PERNUŠ, Boštjan LIKAR a Žiga ŠPICLIN. Enhancement of Vascular Structures in 3D and 2D Angiographic Images. *IEEE Transactions on Medical Imaging* [online]. 2016, **35**(9), 2107-2118 [cit. 2022-05-12]. DOI: 10.1109/TMI.2016.2550102
- [33] JIN, Jiaoying, Linjun YANG, Xuming ZHANG a Mingyue DING. Vascular Tree Segmentation in Medical Images Using Hessian-Based Multiscale Filtering and Level Set Method. *Computational and Mathematical Methods in Medicine* [online]. 2013, **2013**, 1-9 [cit. 2022-05-12]. ISSN 1748-670X. DOI: 10.1155/2013/502013
- [34] BRADLEY, Derek a Gerhard ROTH. Adaptive Thresholding using the Integral Image. *Journal of Graphics Tools* [online]. 2011, **12**(2), 13-21 [cit. 2022-05-13]. ISSN 1086-7651. DOI: 10.1080/2151237X.2007.10129236
- [35] OTSU, Nobuyuki. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics* [online]. 1979, **9**(1), 62-66 [cit. 2022-05-13]. ISSN 0018-9472. DOI: 10.1109/TSMC.1979.4310076
- [36] H. CHARLES, Romesburg. *Cluster Analysis for Researchers*. Morrisville: Lulu Press, 2004. ISBN 9781411606173.
- [37] JAIN, A.K., Jianchang MAO a K.M. MOHIUDDIN. Artificial neural networks: a tutorial. *Computer* [online]. 1996, **29**(3), 31-44 [cit. 2022-05-14]. ISSN 00189162. DOI: 10.1109/2.485891
- [38] HARIS, K., S.N. EFSTRATIADIS, N. MAGLAVERAS a A.K. KATSAGGELOS. Hybrid image segmentation using watersheds and fast region merging. *IEEE Transactions on Image Processing* [online]. 1998, **7**(12), 1684-1699 [cit. 2021-12-30]. ISSN 10577149. DOI: 10.1109/83.730380
- [39] BISHOP, Christopher M. *Pattern recognition and machine learning*. [New York]: Springer, c2006. Information science and statistics. ISBN 978-0387-31073-2.
- [40] SUMIT, Saha. A Comprehensive Guide to Convolutional Neural Networks: the ELI5 way. *Towards Data Science* [online]. 2018 [cit. 2022-05-11]. Dostupné z: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

- [41] TIN KAM HO. Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition* [online]. IEEE Comput. Soc. Press, 1995, 278-282 [cit. 2022-05-14]. ISBN 0-8186-7128-9. DOI: 10.1109/ICDAR.1995.598994
- [42] Dirk-Jan Kroon (2022). Hessian based Frangi Vesselness filter (<https://www.mathworks.com/matlabcentral/fileexchange/24409-hessian-based-frangi-vesselness-filter>), MATLAB Central File Exchange. Retrieved May 17, 2022.
- [43] Tim Jerman (2022). Jerman Enhancement Filter (<https://github.com/timjerman/JermanEnhancementFilter>), GitHub. Retrieved May 18, 2022.
- [44] DICE, Lee R. Measures of the Amount of Ecologic Association Between Species. *Ecology* [online]. 1945, **26**(3), 297-302 [cit. 2022-05-23]. ISSN 00129658. DOI: 10.2307/1932409
- [45] SEO, Hyunseok, Varun VASUDEVAN, Charles HUANG a Hongyi REN. Machine learning techniques for biomedical image segmentation: An overview of technical aspects and introduction to state-of-art applications. *Medical Physics: The International Journal of Medical Physics Research and Practice* [online]. 2020, 17.5.2020, **47**(5) [cit. 2021-12-04]. ISSN 2473-4209. DOI: <https://doi.org/10.1002/mp.13649>
- [46] ŠPANĚL, Michal a Vítězslav BERAN. *Obrazové segmentační techniky: Přehled existujících metod* [online]. In: . 12.10.2005 [cit. 2021-12-09]. Dostupné z: <http://www.fit.vutbr.cz/~spanel/segmentace/>
- [47] BABIN, D., E. VANSTEENKISTE, A. PIZURICA a W. PHILIPS. Segmentation of brain blood vessels using projections in 3-D CT angiography images. *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. IEEE, 2011, 2011, , 8475-8478 [cit. 2021-12-28]. ISBN 978-1-4577-1589-1. DOI: 10.1109/IEMBS.2011.6092091
- [48] MEIJS, Midas, Sjoert A. H. PEGGE, Maria H. E. VOS, et al. Cerebral Artery and Vein Segmentation in Four-dimensional CT Angiography Using Convolutional Neural Networks. *Radiology: Artificial Intelligence* [online]. 2020, 29.7.2020, **2**(4) [cit. 2021-12-28]. ISSN 2638-6100. DOI: 10.1148/ryai.2020190178

- [49] WANG, Rui, Chao LI, Jie WANG, Xiaoer WEI, Yuehua LI, Yuemin ZHU a Su ZHANG. Threshold segmentation algorithm for automatic extraction of cerebral vessels from brain magnetic resonance angiography images. *Journal of Neuroscience Methods* [online]. 2015, **241**, 30-36 [cit. 2021-12-28]. ISSN 01650270. DOI: 10.1016/j.jneumeth.2014.12.003
- [50] MILDENBERGER, Peter, Marco EICHELBERG a Eric MARTIN. Introduction to the DICOM standard. *European Radiology* [online]. 2002, **12**(4), 920-927 [cit. 2021-12-29]. ISSN 0938-7994. DOI: 10.1007/s003300101100
- [51] KROON, Dirk-Jan. Region Growing. *MathWorks* [online]. 6.3.2008 [cit. 2021-12-30]. Dostupné z: <https://se.mathworks.com/matlabcentral/fileexchange/19084-region-growing>