

**Vysoká škola báňská – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství**

**Detekce a modelování zájmových objektů z MR mozkových
dat**

**Detection and Modeling Objects of Interest from MR Brain
Images**

2018

Tereza Muchová

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání bakalářské práce

Student: **Tereza Muchová**
Studijní program: B2649 Elektrotechnika
Studijní obor: 3901R039 Biomedicínský technik
Téma: **Detekce a modelování zájmových objektů z MR mozkových dat**
Detection and Modeling Objects of Interest from MR Brain Images
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování klinických aspektů mozku.
2. Nastudování zobrazovacích metod, které se využívají ke klinickému zobrazování mozkové tkáně.
3. Nastudování obecných principů pro segmentaci obrazových dat.
4. Rešerše metod a komerčních SW, které se využívají k detekci patologických oblastí mozku z MR dat.
5. Analýza a definování zájmových patologických oblastí z MR mozkových obrazových dat.
6. Design a implementace předzpracování MR dat.
7. Návrh automatizované procedury pro segmentaci MR obrazových dat.
8. Návrh modelu patologických oblastí z MR dat.
9. Testování a verifikace navržených algoritmů na reálných obrazových datech.
10. Zhodnocení výsledků.

Seznam doporučené odborné literatury:

- [1] CRUM, William R. Magnetic Resonance Brain Image Processing and Arithmetic with FSL. *Magnetic Resonance Neuroimaging, part of the Methods in Molecular Biology*. 2011, vol. 711, 109-126. Print ISBN 978-1-61737-991-8/ISSN 1064-3745. doi: 10.1007/978-1-61737-992-5_5.
- [2] LANDINI, Luigi, Vincenzo POSITANO a Maria Filomena SANTARELLI. *3D Medical Image Processing. Image Processing in Radiology* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, s. 67. Online ISBN 978-3-540-49830-8.
- [3] BIRKFELLNER, Wolfgang. *Applied medical image processing: a basic course*. Second edition. Boca Raton: CRC Press, Taylor & Francis Group, 2014. ISBN 978-1-4665-5557-0.
- [4] BATCHELOR, Bruce G. (Ed.) *Machine vision handbook*. London: Springer, c2012. Springer reference. ISBN 978-1-84996-168-4.

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

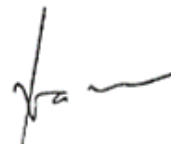
Vedoucí bakalářské práce: **Ing. Jan Kubíček**

Datum zadání: 01.09.2017

Datum odevzdání: 30.04.2018



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení studenta

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

V Ostravě dne: *19. dubna 2018*

Muchová
.....
podpis studenta

Poděkování

Ráda bych poděkovala svému vedoucímu bakalářské práce, panu Ing. Janu Kubíčkoví, za odborné vedení, cenné rady a konzultace průběžných i konečných výsledků při vytváření této bakalářské práce.

Abstrakt

Cílem této bakalářské práce je návrh automatizovaného algoritmu pro segmentaci a modelování patologických oblastí z MR mozkových obrazových dat. Pro účely segmentace jsou použity dvě metody, a to konkrétně Otsu multiregionální segmentace a metoda aktivních kontur, které jsou realizovány v prostředí MATLAB. Následně jsou tyto metody porovnány s cílem vyhodnocení efektivity segmentace MR obrazů. Dále je zhodnocena efektivita použití metod předzpracování obrazu pro zlepšení výsledků segmentace a následně provedena extrakce patologických oblastí. Kromě prezentování vývoje algoritmu provádějící segmentaci patologických oblastí a jejich filtrace od pozadí jsou v této práci popsány také obecné principy segmentace obrazových dat, SW a metody využívající se k detekci patologických oblastí mozku. Navrhované algoritmy byly testovány na datasetu 21 snímků z MR.

Klíčová slova

Mozek; patologické oblasti mozku; magnetická rezonance; detekce; segmentace; zpracování obrazu; aktivní kontury; Otsu metoda; MATLAB.

Abstract

The aim of this bachelor thesis is the design of an automated algorithm for segmentation and modeling of pathological areas of MR brain imaging data. Two methods are used for segmentation purposes, namely Otsu multiregional segmentation and active contouring method implemented in MATLAB. Subsequently, these methods are compared to the purpose of evaluating the efficiency of segmentation of MR images. Furthermore, the effectiveness of using image pre-processing to improve segmentation results and subsequently extracting pathological areas is evaluated. This work describes general principles of segmentation of image data, SW and methods used to detect pathological regions of the brain. The proposed algorithms were tested on a dataset of 21 MR frames.

Key words

Brain; pathological areas of the brain; magnetic resonance; detection; segmentation; image processing; active contours; Otsu method; MATLAB.

Obsah

Seznam použitých zkratk	- 9 -
Seznam ilustrací	- 10 -
Seznam tabulek	- 12 -
Úvod	- 13 -
1 Anatomie mozku	- 14 -
1.1 Anatomické struktury	- 14 -
1.2 Tkáňové struktury	- 15 -
2 Patologie mozku	- 16 -
2.1 Multiformní glioblastom	- 16 -
2.2 Meningiomy	- 16 -
2.3 Glioblastom	- 17 -
2.4 Infekční a zánětlivá onemocnění	- 17 -
2.4.1 Mozkový absces	- 17 -
2.4.2 Jiná infekční a zánětlivá onemocnění	- 17 -
3 Zobrazovací metody	- 18 -
3.1 Magnetická rezonance	- 18 -
3.2 Další metody	- 18 -
4 Obecné principy segmentace obrazu	- 20 -
4.1 Prahování	- 20 -
4.2 Narůstání oblastí	- 20 -
4.3 Štěpení a spojování oblastí	- 21 -
4.4 Detektory hran	- 21 -
4.4.1 Laplaceův operátor	- 21 -
4.4.2 Cannyho hranový detektor	- 21 -
5 Rešerše komerčních SW pro diagnostiku mozku	- 22 -
5.1 3D Slicer	- 22 -
5.2 Analyze	- 22 -
5.3 FreeSurfer	- 23 -
5.4 FSL	- 23 -
5.5 SPM	- 24 -

6	Rešerše metod k detekci patologických oblastí mozku	- 25 -
6.1	Watershed transformace	- 25 -
6.2	Region growing	- 26 -
6.3	K-means algoritmus	- 26 -
6.4	BIANCA – Algoritmus klasifikace abnormality intenzity mozku	- 27 -
6.5	Fuzzy C-Means	- 28 -
7	Modelování zájmových objektů z MR mozku	- 29 -
7.1	Charakteristika obrazových dat použitých k analýze	- 29 -
7.2	Předzpracování MR obrazu	- 30 -
7.2.1	Ostření obrazu	- 31 -
7.2.2	Jasové transformace	- 31 -
7.2.3	Vymezení oblasti zájmu ROI	- 32 -
7.3	Regionální segmentace MR obrazových dat	- 33 -
7.3.1	Regionální segmentace obrazu	- 33 -
7.3.2	Princip Otsu metody	- 33 -
7.3.3	Implementace algoritmu v prostředí MATLAB	- 34 -
7.3.4	Testování algoritmu na reálných datech	- 34 -
7.3.5	Zhodnocení	- 37 -
7.4	Metoda aktivních kontur	- 37 -
7.4.1	Vnitřní energie	- 38 -
7.4.2	Energie obrazu	- 38 -
7.4.3	Implementace metody aktivních kontur v prostředí MATLAB	- 39 -
7.4.4	Testování algoritmu na reálných datech	- 40 -
8	Evaluace a testování segmentačního modelu	- 44 -
8.1	Korelace	- 44 -
8.2	Testování segmentačního modelu	- 44 -
	Závěr	- 48 -
	Použitá literatura	- 49 -
	Seznam příloh	I

Seznam použitých zkratek

3D	Trojrozměrný
4D	Čtyřrozměrný
CNS	Centrální nervová soustava
CSF	Cerebrospinal fluid (cerebrospinální tekutina)
CT	Computed Tomography (výpočetní tomografie)
DICOM	Digital Imaging and Communications in Medicine (datový standard pro přenos biomedicínských obrazových dat)
EEG	Elektroencefalografie
fMRI	Funkční magnetická rezonance
FLAIR	Sekvence MR s potlačením likvoru
GM	Grey Matter (šedá hmota)
KL	Kontrastní látka
k-NN	Algoritmus k-nejbližších sousedů
MR	Magnetic Resonance (magnetická rezonance)
MRI	Magnetic Resonance Imaging (zobrazování magnetickou rezonancí)
PET	Positron Emission Tomography (pozitronová emisní tomografie)
PNG	Portable Network Graphics (přenosná síťová grafika)
SPECT	Single-Photon Emission Computed Tomography (jednofotonová emisní výpočetní tomografie)
STIR	Sekvence MR s potlačením tuku
T1	Podélná relace
T2	Příčná relace
TPM	Talairachův anatomický atlas
WM	White Matter (bílá hmota)

Seznam ilustrací

Obrázek 1: Frontální řez mozkiem	- 15 -
Obrázek 2: Nativní snímek z MR mozku	- 15 -
Obrázek 3: Multiformní glioblastom na T2 obrazu MR.....	- 16 -
Obrázek 4: Meningeom na T1 obraze MR	- 16 -
Obrázek 5: Glioblastom.....	- 17 -
Obrázek 6: Absces mozku na snímku MR	- 17 -
Obrázek 7: Snímek z CT mozku	- 18 -
Obrázek 8: Snímek ze sonografie mozku	- 19 -
Obrázek 9: Snímek z fMRI mozku.....	- 19 -
Obrázek 10: Vymezení oblasti zájmu obrazu o velikosti 3x3 pixely	- 20 -
Obrázek 11: Ukázka 3D Slicer	- 22 -
Obrázek 12: Tři stupně z kortikální analýzy FreeSurfer	- 23 -
Obrázek 13: Snímek obrazovky FSLView.....	- 24 -
Obrázek 14: Metoda rozvodí s ukázkou povodí, hráze a lokálních minim	- 25 -
Obrázek 15: Watersheed transformace.....	- 26 -
Obrázek 16: Segmentace region growing.....	- 26 -
Obrázek 17: K-means algoritmus.....	- 27 -
Obrázek 18: k-NN algoritmus	- 28 -
Obrázek 19: Multiformní glioblastom.....	- 29 -
Obrázek 20: Gliom nízkého stupně malignity.....	- 30 -
Obrázek 21: Gliom nízkého a vysokého stupně malignity.....	- 30 -
Obrázek 22: Glioblastom.....	- 30 -
Obrázek 23: Blokové schéma kroků předzpracování obrazu	- 30 -
Obrázek 24: Původní snímek (vlevo), snímek po aplikaci „unsharp“ (vpravo)	- 31 -
Obrázek 25: Snímek před (vlevo) a po jasové transformaci (vpravo).....	- 32 -
Obrázek 26: Původní snímek se zaznačenou lézí.....	- 32 -
Obrázek 27: Extrahovaný ROI.....	- 32 -
Obrázek 28: Vlevo ilustrativní snímek, vpravo jeho histogram.....	- 33 -
Obrázek 29: Vývojový diagram kroků algoritmu	- 34 -
Obrázek 30: Implementace algoritmu s nastavenou prahovací úrovní 4.....	- 35 -
Obrázek 31: Předzpracovaný snímek s nastavenou prahovou hodnotou 4.....	- 36 -
Obrázek 32: Implementace algoritmu s nastavenou prahovací úrovní 6.....	- 36 -
Obrázek 33: Testování metody na nativních a předzpracovaných snímcích.....	- 36 -
Obrázek 34: Testování metody na nativních a předzpracovaných snímcích.....	- 37 -
Obrázek 35: Vývojový diagram kroků algoritmu	- 39 -
Obrázek 36: Vývoj kontury od inicializační po konečnou	- 40 -
Obrázek 37: Vlevo energetická mapa, vpravo binární model objektu	- 40 -
Obrázek 38: Testování algoritmu na nativních snímcích	- 41 -
Obrázek 39: Testování algoritmu na předzpracovaných snímcích.....	- 42 -

Obrázek 40: Testování algoritmu na ROI	- 43 -
Obrázek 41: Vlevo binární model snímku, vpravo zlatý standard	- 44 -

Seznam tabulek

Tabulka 1: Výsledky nalezení optimální prahovací úrovně u nativních snímků.....	- 35 -
Tabulka 2: Evaluace aktivních kontur, část 1	- 45 -
Tabulka 3: Evaluace aktivních kontur, část 2.....	- 46 -

Úvod

Rozvoj výpočetní techniky zapříčinil to, že se magnetická rezonance jako zobrazovací metoda stala nedílnou součástí dnešní moderní medicíny. Lidský mozek je řídicí jednotkou člověka a obsahuje struktury, zajišťující základní životní funkce. Zobrazování mozku magnetickou rezonancí umožňuje lékařům tyto struktury lokalizovat. Zobrazením tkání to však nekončí. Další a velice důležitou fází je analýza a modelování objektů z obrazových dat. S nástupem moderních zobrazovacích metod roste i význam segmentace medicínských obrazových dat, jako nástroje pro jejich analýzu. Vzhledem k nárůstu množství obrazových dat získaných při vyšetření MR je téměř nemožné, aby byla segmentace prováděna manuálně. Navíc manuální segmentace je významně ovlivněna subjektivním faktorem, který vede k nepřesné interpretaci a jednotnosti výsledků. Proto narůstá požadavek na poloautomatické či automatické metody segmentace.

Cílem této práce je analýza a geneze algoritmů pro segmentaci patologických oblastí z MR mozkových dat. Obsahem není pouze samotné prezentování navrženého algoritmu, ale také přiblížení oblastí potřebných k pochopení dané problematiky. Jednotlivé anatomické a tkáňové struktury jsou uvedeny v první kapitole, na kterou navazuje kapitola druhá, popisující patologii mozku. Třetí kapitola se věnuje využitelnosti metod k zobrazování mozkové tkáně. Ve čtvrté kapitole jsou popsány obecné principy segmentace obrazu. Rešeršní část je uvedena v kapitolách pět a šest, které pojednávají o metodách a SW využívající se k detekci patologických oblastí mozku. Samotná praktická část je uvedena v kapitole 7, která se zabývá předzpracováním obrazu, popisem a realizací Otsu metody a metody aktivních kontur a následným testováním algoritmu na reálných MR datech. V poslední osmé kapitole je uvedeno vyhodnocení a testování segmentačního modelu.

1 Anatomie mozku

V této kapitole jsou uvedeny základní anatomické struktury mozku, včetně tří tkáňových struktur, a to bílé hmoty, šedé hmoty a mozkomíšního moku, které jsou zobrazeny na Obr. 2.

1.1 Anatomické struktury

Mozek je hlavní řídicí centrum uložené v lebce. Mozek tvoří s míchou centrální nervovou soustavu, která přenáší informace z celého těla do všech tkání a orgánů. Od kostí jsou odděleny třemi obaly, mozkovými plenami a tekutinou. Tvrdá plena tvoří zevní obal vystýlající lebku. Mezi ní a periostem (okosticí) lebečních kostí se nachází žilní splavy, ve kterých proudí krev vracející se z mozku k srdci. Pod tvrdou plenu je pavučnice, bezcévná vrstva. Pod pavučnicí je měkká plena, která obsahuje cévy mozku. Mezi těmito dvěma vnitřními obaly mozku se nachází mozkomíšní mok [1].

Mozek vzniká z hlavové části nervové trubice, která se dělí na tři části:

- Přední čichový mozek (prosencephalon) – v dalším vývoji se diferencoval na přední mozek (telencephalon) a mezimozek (diencephalon).
- Střední zrakový mozek (mesencephalon)
- Zadní sluchový mozek (rhombencephalon) – rozšířen o mozeček (cerebellum) a prodlouženou míchu (medulla oblongata) [1].

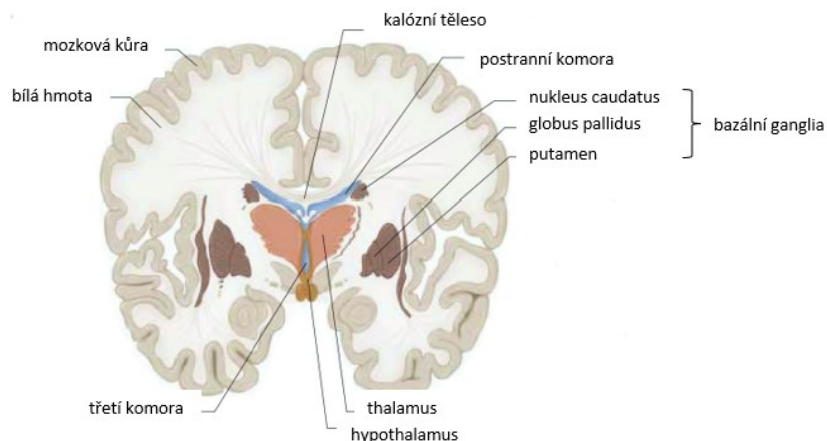
Val nad prodlouženou míchou tvoří Varolův most (pons Varoli) a spojuje koncový mozek s mozečkem. Most Varolův se významně podílí na řízení životně nezbytných reflexů – dýchacích, srdečních, cévních a trávicích [1], [2].

Mozeček (Cerebellum) se skládá ze dvou hemisfér, které jsou spojeny červem mozečkovým. Povrch mozečku je tvořen z šedé hmoty, nitro mozečku vyplňuje bílá hmota. Na řezu se tak vytváří stromečková kresba nazývaná „strom života“. Mozeček je důležitým koordinačním centrem pohybů [1].

Střední mozek (Mesencephalon) je nejmenší část mozku, ukrytý mezi mezimozkem a Varolovým mostem. Jeho středem probíhá Sylviov kanálek. Střední mozek je významný pro udržení vzpřímené polohy těla [1], [2].

Mezimozek (Diencephalon) se skládá ze dvou částí – thalamus a hypothalamus. Nachází se v něm III. mozková komora. K hypothalamu je připojen stopkou podvěsek mozkový a ke stropu komory se vzadu připojuje šišinka. V hypothalamu jsou centra pro řízení tělesné teploty, hospodaření s vodou nebo k regulaci spánku a bdění [1].

Koncový mozek (Telencephalon) tvoří největší část mozku. Shora překrývá ostatní části mozku. Skládá se ze dvou hemisfér, které jsou navzájem propojeny kalózním tělesem. Uvnitř hemisfér je dutina, ve které vzniká mozkomíšní mok. Na povrchu se nachází plášť rozčleněný hlubokými brázdami v laloky čelní, temenní, týlní a spánkový. Čelní lalok se podílí na řízení motoriky, spánkový lalok slouží ke zpracování sluchových podnětů a týlní lalok ke zpracování zrakových podnětů. Centrum kožní citlivosti představuje temenní lalok [1], [2], [3].



Obrázek 1: Frontální řez mozkiem, upraveno podle [4]

1.2 Tkáňové struktury

Mozkomišňí mok

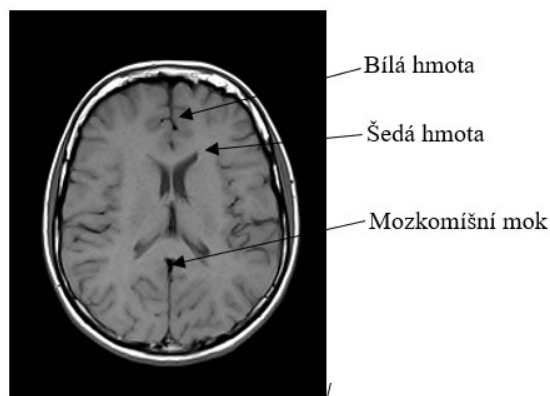
Likvor, neboli mozkomíšňí mok, je čirá, bezbarvá tekutina, jejíž objem činí 150 ml. Neustále cirkuluje a za den se třikrát obmění. Cirkuluje z postranních komor do třetí komory a přes Sylviovův kanálek do čtvrté komory. Odtud odtéká do subarachnoidálního prostoru, kde obklopuje mozek a míchu, a část odtéká do centrálního kanálu míchy [5].

Šedá hmota

Převážnou část šedé hmoty tvoří nervové buňky – neurony, a jejich krátké výběžky. Na příčných řezech prodlouženou míchou má šedá hmota motýlovitý tvar [2].

Bílá hmota

Bílá hmota mozková je tvořena dlouhými výběžky neuronů, sdružující se v nervové dráhy. Důvodem bílého zbarvení je přítomnost myelinu, který je podstatnou částí bílé hmoty [2].




Obrázek 2: Nativní snímek z MR mozku [35]

2 Patologie mozku

Na tomto místě jsou uvedeny patologické oblasti mozku, v této práci konkrétně mozkové nádory. Nádory se obecně dělí na maligní a benigní, přičemž maligní nádory rostou velmi rychle, jsou neohraničené a metastazují. Benigní nádory rostou naopak velmi pomalu, jsou ohraničené a netvoří metastáze. U mozkových nádorů je problém ten, že rostou v uzavřeném prostoru lebky, takže i benigní nádory mohou postiženého usmrtit. Důležitým poznatkem je, že patologické oblasti se projevují odlišným jasovým spektrem od fyziologických struktur.

2.1 Multiformní glioblastom


Multiformní glioblastom tvoří 20–30 % gliomů. Postihuje převážně starší osoby, přičemž průměrná doba přežití je okolo jednoho roku. U dětí je poměrně vzácný. Roste neohraničeně, je měkké konzistence, prokrvácený a nekrotický. Vzniká z buněk nazývaných astrocyty, které se podílí na ochraně mozku před škodlivinami z krevního oběhu. Multiformní glioblastom je u většiny případů nezhoubný, ale člověka ohrožuje svým růstem [6].



Obrázek 3: Multiformní glioblastom na T2 obrazu MR, upraveno podle [6]

2.2 Meningiomy


Benigní meningiom je dobře ohraničen a v 50–60 % je doprovázen edémem. Často lze pozorovat cysty, nekrózy nebo drobné hemoragie. Nádor se častěji vyskytuje u žen a starších osob. Meningeomy tvoří přibližně 25 % všech intrakraniálních nádorů. Jde o nádory dobře ohraničené, kulovitého nebo ovoidního tvaru. Rostou pomalu a mohou recidivovat [7], [8].



Obrázek 4: Meningeom na T1 obraze MR, upraveno podle [9]

2.3 Glioblastom

Glioblastom se řadí mezi zhoubné nádory, který vychází z gliových buněk. Vyskytuje se v jakémkoliv věku, častěji však v dospělosti. I přes to, že se jedná o zhoubný nádor, velice vzácně metastazuje. Škodí však rychlým růstem a utlačuje tak okolní struktury mozku. Glioblastom se pro neohraničenost a nepravidelnost nedá vyoperovat a špatně reaguje na ostatní léčebné metody. Proto je prognóza glioblastomu velmi špatná [10].




Obrázek 5: Glioblastom

2.4 Infekční a zánětlivá onemocnění

2.4.1 Mozkový absces

Absces mozku je ohraničený zánět CNS. U mozkového abscesu je charakteristické cystoidní ložisko, které po podání kontrastní látky po okrajích prstencovitě sytí jak v CT, tak i v MR obraze. Mnohočetné abscesy mozku mohou být přítomny u infekční endokarditidy nebo u imunodeficientních nemocných. Mozkový absces se podobá nádorům, proto je důležitý klinický nález. Odlišit absces od glioblastomu, metastázy nebo herpetické encefalitidy na základě MR není vždy možné [7].



Obrázek 6: Absces mozku na snímku MR [7]

2.4.2 Jiná infekční a zánětlivá onemocnění

Mezi další infekční a zánětlivá onemocnění se řadí meningitidy a encefalitidy. Meningitida, neboli zánět mozkových blan, vzniká v důsledku infekce viry, bakteriemi nebo jinými mikroorganismy. Encefalitidou se rozumí zánět mozku, který se bez včasné léčby stává stavem smrtelným [12].

3 Zobrazovací metody

V této části je popsána využitelnost metod k zobrazování mozkové tkáně a patologií v oblasti mozku. Jde tedy hlavně o magnetickou rezonanci, ale i CT, PET a další.

3.1 Magnetická rezonance

Magnetická rezonance je moderní vyšetřovací metoda, která velmi podrobně zobrazuje požadované oblasti lidského těla. Jednotlivé orgány lidského těla jsou snímány v tenkých vrstvách (řezech) o tloušťce obvykle 1–5 mm. Tato metoda umožňuje rozlišit normální tkáň od tkáně poškozené patologickým procesem. Magnetická rezonance využívá velmi silné magnetické pole a fyzikálních vlastností jader atomu vodíku. Vodíková jádra, která jsou vystavena silnému magnetickému poli, jsou zdrojem radiofrekvenčního vlnění. Toto vlnění je zachycováno systémem přijímacích cívek. Výsledky poskytují lékařům velmi důležité informace prakticky o všech orgánech v těle [13].

Velmi často je tato metoda používána při vyšetření mozku, míchy, při podezření na cévní a nádorová onemocnění mozku nebo při poranění páteře. Magnetická rezonance neumožňuje zachytit kosti, jelikož neobsahují téměř žádnou vodu. Výhodou je, že pacient není vystaven rentgenovým paprskům, na rozdíl od výpočetní tomografie. Nevýhodou je poměrně dlouhé vyšetření, které obvykle trvá 20–50 minut. Vyšetření magnetickou rezonancí patří k finančně nákladnějším vyšetřením a není jím vybavena každá nemocnice [13].

Magnetická rezonance je nejdůležitější zobrazovací metodou pro zobrazování tkání mozku a míchy. Použity jsou sekvence T2 vážené s potlačením signálu likvoru (FLAIR) pro posouzení struktury tkání a s potlačením tuku (STIR), které jsou používány pro detekci poranění míchy. U T1 vážené frekvence se kontrastní látky nepodávají, podání KL se používá k posouzení porušení hematoencefalitické bariéry [13].


3.2 Další metody

Další vyšetřovací metodou, používanou k zobrazování mozku je CT. Toto vyšetření se provádí bez použití kontrastní látky a hodnotí se stav mozkové tkáně, šíře komorové soustavy nebo také zda je přítomno krvácení. Podstatou počítačové tomografie je matematická rekonstrukce příčného řezu tělem pacienta [13].




Obrázek 7: Snímek z CT mozku [35]

Další používanou metodou je sonografie, která se uplatňuje v posuzování mozkové tkáně u plodů, novorozenců a kojenců, a to až do doby, kdy se jim uzavírá velká fontanela [13].



Obrázek 8: Snímek ze sonografie mozku [35]

Pro detekci tumorů se také využívá funkční magnetická rezonance (fMRI). Využívá toho, že oblasti mozku, které aktivně pracují, spotřebují více kyslíku, proto jsou více prokrveny než oblasti v klidu. Toto zvýšené prokrvení lze zobrazit. Vyšetření fMRI je časově náročné, trvá obvykle 30–60 minut [35].




Obrázek 9: Snímek z fMRI mozku [35]

4 Obecné principy segmentace obrazu

Segmentace obrazu znamená rozdělení obrazu na části, skládající se z pixelů podobných vlastností (barvy nebo jasu). Obrazová data jsou tvořena pravidelnou maticí čísel, kterou označujeme jako digitální hodnoty. Čísla jsou tedy uspořádána do řádků a sloupců. Každá hodnota dat je zobrazena obrazovou jednotkou = pixelem. Pixel představuje jeden obrazový bod nesoucí informaci o hodnotě jasu a barvě (v případě barevného snímku). Pixely pokrývají celou plochu diskretními hodnotami/barvami [14], [15].

K popsání obrazu byl založen souřadnicový systém. Nejčastěji se používá souřadnicová soustava P, L (pixel, line) – sloupec, řádek, která jednoznačně určuje polohu pixelu v obraze [14].



Obrázek 10: Vymezení oblasti zájmu obrazu o velikosti 3 x 3 pixely, kde každá digitální hodnota je znázorněna stupněm šedi [14]

4.1 Prahování

Prahování využívá histogram jasu obrazu. Histogram ukazuje odhad hustoty pravděpodobnosti jasových hodnot. Jako segmentační práh se může použít hodnota jasu, která odpovídá minimu údolí v histogramu. Pixely nad touto hodnotou prahu se řadí do objektů. Pixely, které mají hodnotu jasu pod prahem, náleží do pozadí. Tímto se pixely rozdělí do dvou skupin. Komplikací určení globálního prahu je, pokud histogram nemá výrazné údolí. Dalším problémem mohou být pixely, které se řadí jak do objektů, tak do pozadí. V tomto případě je řešením použití dvou prahů [16].

4.2 Narůstání oblastí

Tuto metodu lze použít, pokud je obtížné určit hranice oblastí, takže selhává i metoda prahování. Metoda narůstání oblastí rozčlení obrazy do jednotlivých oblastí tak, aby byly homogenní. Zde je nezbytné stanovit kritérium homogenity. Toto kritérium souvisí s jasovými nebo barevnými vlastnostmi [16].

Metoda narůstání oblastí je použita tehdy, pokud se v oblasti nachází „semínkový pixel“, který se řadí do oblasti objektů. Od tohoto semínkového pixelu jsou zkoumány pixely jeho okolí. Na základě známých atributů homogenity je rozhodnuto, zda pixely z okolí patří do oblasti, nebo nepatří. Pokud nejsou k dispozici semínkové pixely, používají se metody spojování, slučování nebo kombinace obojího [16].

4.3 Štěpení a spojování oblastí

Obraz se na počátku zpracování považuje za jednu oblast. U obrazů pouze se dvěma druhy oblastí se určí kritéria homogenity pro oblast objektů a oblast pozadí. Pokud ale vypočítané hodnoty pixelů nepatří do tolerance kritérií, je oblast považována za nehomogenní. Poté je obraz rozdělen do čtyř kvadrantů a každý kvadrant je testován stejně jako v předcházejícím kroku. Pokud kvadranty nesplní kritérium homogenity, štěpí se dále. Ve stejném kroku jsou testovány dvojice, které vznikly štěpením, a spojí se do jedné oblasti za předpokladu, že splňují stejné kritérium homogenity. V posledním kroku nastává proces spojování malých oblastí, které přiléhají k větším [16].

4.4 Detektory hran

Hrany jsou množiny pixelů v určitém místě obrazu, kde se náhle mění hodnota jasu. Hrana je definována rychlostí změny obrazové funkce $f(x, y)$.

4.4.1 Laplaceův operátor

V popředí zájmu bývají někdy místa v obraze s významnějšími hranami. V těchto místech se prudce mění jasová funkce. Pro detekci těchto hran se používá lineární Laplaceův operátor, neboli Laplaceův ∇^2 . Ten vychází z druhých parciálních derivací. Hrany, používající se pro hledání hranic jednotlivých objektů, se hledají pomocí lokálních operátorů. Pokud objektu náleží oblast homogenního jasu, budou hranicové body pixely s vysokou hodnotou gradientu. Při určení orientace hrany se hranové pixely mohou samovolně spojovat do hranic. Tento operátor udává velikost hrany, ne její směr [16].

4.4.2 Cannyho hranový detektor

Cannyho hranový detektor umožňuje hledat různá rozlišení, a to nejlepší z nich realizovat. Princip spočívá v tom, že skokovou hranu v obraze si lze představit jako schod a lze ji hledat filtrem. Cannyho detektor hledá skokové hrany vzhledem k těmto kritériím:

- Detekční kritérium – u tohoto kritéria se požaduje, aby významné hrany nebyly přehlédnuty a aby na jednu hranu nepřipadaly vícenásobné odezvy.
- Lokalizační kritérium – rozdíl mezi skutečnou a nalezenou polohou hrany má být co nejmenší.
- Požadavek jedné odezvy – detektor nesmí reagovat na jednu hranu v obraze vícenásobně. To se týká hlavně zašuměných hran.

Realizace Cannyho detektoru je tedy následující. Nejprve je hranový detektor aplikován na 1D signál s použitím prvních dvou kritérií. Po přidání třetího kritéria je hledána optimální odezva filtru. Poté je detektor hran zobecněn do 2D. Každá hrana je určena velikostí, polohou a orientací. V posledním kroku je výstup detektoru prahován. Tím se určí, kterou hranu lze považovat za významnou a kterou ne. Důležité je zvolit správné měřítko pro operátor a poté všechny měřítka vyzkoušet [16].


5 Rešerše komerčních SW pro diagnostiku mozku

Tato část se věnuje krátkému výčtu vybavení, které lze použít pro práci s obrazovými MRI daty. Softwary byly vybrány ze stránky <https://www.nitrc.org/>, kde vědecké zaměření NITRC zahrnuje: PET, SPECT, CT, EEG, výpočetní neurovědy a softwarové nástroje pro zobrazování genomiky, dat a výpočetní zdroje. Obsahuje také přehledné dělení dostupného softwaru. Pro tuto práci bylo vybráno 5 následujících softwarů.

5.1 3D Slicer

3D Slicer je bezplatná, volně dostupná softwarová aplikace pro zpracování obrazu a trojrozměrnou vizualizaci. Volně dostupný software pracuje na několika operačních systémech, jako jsou Linux, MacOSX a Windows. 3D Slicer má také funkce pro přidávání algoritmů a aplikací, například funkce více orgánů, nebo podpora zobrazování MR a CT [17].

3D Slicer je výkonný vizualizační nástroj, který umožňuje prohlížení obrazových dat ve dvou, třech a čtyřech rozměrech. Umožňuje sloučení funkčních a anatomických dat a poskytuje celou řadu obecných a specializovaných nástrojů pro jejich zpracování a analýzu. Jedním z hlavních cílů 3D Slicer je poskytnout základní komponenty pro rychlé prototypování a efektivní vývoj nástrojů pro analýzu biomedicínských obrazů [18].



Obrázek 11: V levém podokně je zesílená oblast vymezena na obrazu T1, uprostřed je identifikována oblast abnormality. V pravém podokně je odvozena oblast edému [18]

5.2 Analýze

ANALYZE poskytuje komplexní sadu nástrojů pro vizualizaci, segmentaci, registraci a analýzu vícerozměrných biomedicínských zobrazovacích dat. Komplexní programový balík ANALYZE umožňuje podrobné vyšetření a vyhodnocení 3D a 4D biomedicínských obrazů. Tento software lze použít s libovolným modelem 3D zobrazování, včetně počítačové tomografie a magnetické rezonance. K dispozici je několik originálních algoritmů, zlepšujících efektivitu a kvalitu zobrazení. Jedním z nich je všestranný a výkonný algoritmus vykreslování objemu. ANALYZE běží na standardních počítačích Unix bez speciálního hardwaru [19].

5.3 FreeSurfer

FreeSurfer je soubor softwarových nástrojů pro studium kortikální a subkortikální anatomie. Jedná se o vytváření modelů hranic mezi bílou a šedou hmotou. FreeSurfer je strukturální software pro analýzu MRI. Zpracovává strukturální data MRI, včetně:

- Odstranění lebky a segmentace šedobílých látek.
- Rekonstrukce modelů kortikálních povrchů (šedobílý hraniční povrch a povrch kůže).
- Označení oblastí na kortikálním povrchu, stejně jako subkortikální struktury mozku.
- Nelineární záznam kortikálního povrchu jedince se stereotaxickým atlasem [20].




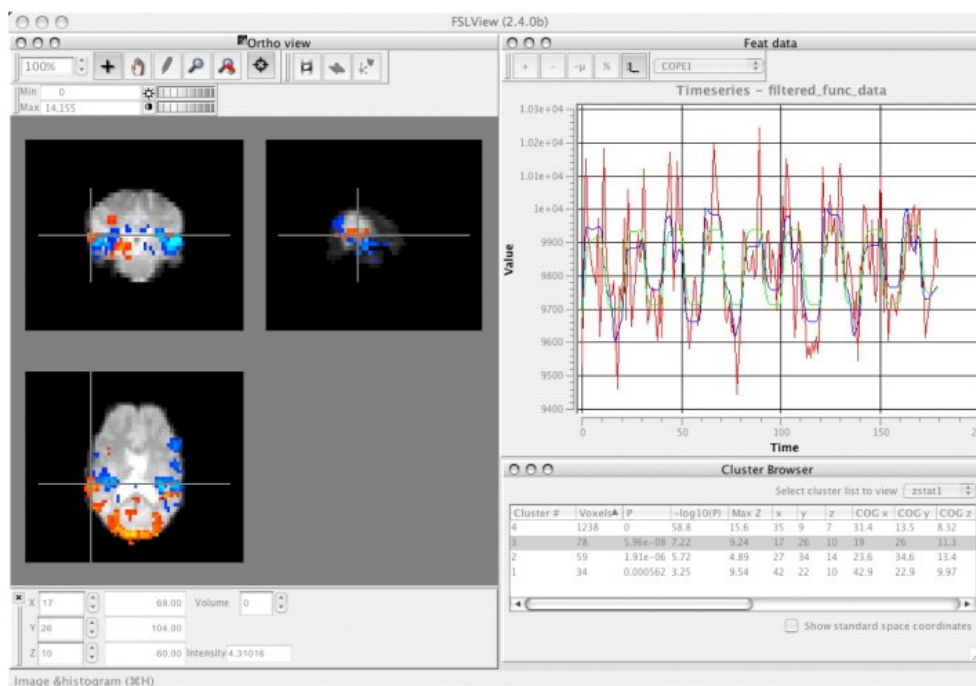
Obrázek 12: Tři stupně z kortikální analýzy FreeSurfer. Nejprve obrázek lebky, dále segmentace bílé hmoty, a nakonec povrch mezi bílou a šedou hmotou (žlutou čarou) a mezi šedou a měkkou plenou mozkovou (červenou čarou) překrytá na původním objemu [20]

FreeSurfer je sada výkonných nástrojů, které poskytují rozsáhlou a automatickou analýzu klíčových vlastností lidského mozku. Provádí prostřednictvím metody rozvodí segmentaci mozku a tuto metodu používá rovněž ke stanovení hodnot intenzit objemových voxelů pro všechny tři mozkové struktury (šedá hmota, bílá hmota a mozkomíšní mok), jejichž vlastní segmentaci provádí automaticky na základě atlasů TPM. Software FreeSurfer pracuje konkrétně s Talairachovými anatomickými atlasy. Vstupní obrazová data MRI jsou tak rozdělena na segmenty odpovídající pravděpodobnostním mapám [21].

5.4 FSL

FSL (Knihovna softwaru FMRIB) je komplexní knihovna analytických nástrojů pro funkční zobrazování magnetickou rezonancí (fMRI), MRI a DTI (data pro zobrazování mozku), napsané členy Analysis Group, FMRIB, Oxford. Funguje na Apple a PC (jak Linux, tak Windows), přičemž se dá velmi snadno nainstalovat. Většina nástrojů může být spuštěna jak z příkazového řádku, tak z grafického uživatelského rozhraní (GUI). Kromě sledování dat a výsledků má FSLView také několik vestavěných atlasů (strukturální atlasy Harvard-Oxford). Základním úkolem je identifikovat voxel, který ukazuje změny signálu v závislosti na měnících se stavech mozku [22].

FSL má širokou škálu využití – kromě identifikování voxelů obsahuje také výkonný 3D a 4D obrazový nástroj FSLView, který umožňuje více barevných přeryvů. FSL se aktivně používá ve více než 1000 laboratořích po celém světě [23].



Obrázek 13: Horní panel: snímek obrazovky FSLView se dvěma aktivačními mapami (červené a modré) společně s výsledky seskupování. Spodní panel: obrazovka 3D vykreslování difuzní traktografie (neinvazivní zobrazovací metoda, která umožňuje viditelnost průběhu nervových vláken) [23]

5.5 SPM

Softwarový balík SPM je navržen pro analýzu datových sekvencí zobrazování mozku. Sekvence mohou být série snímků z různých kohort nebo časových řad ze stejného předmětu. SPM je volně dostupný. Software představuje implementaci teoretických konceptů statistického parametrického mapování v kompletním analytickém balíčku. Přístup statistického parametrického mapování je založen na voxelu. Software SPM je sada funkcí a podprogramů MATLAB [24].

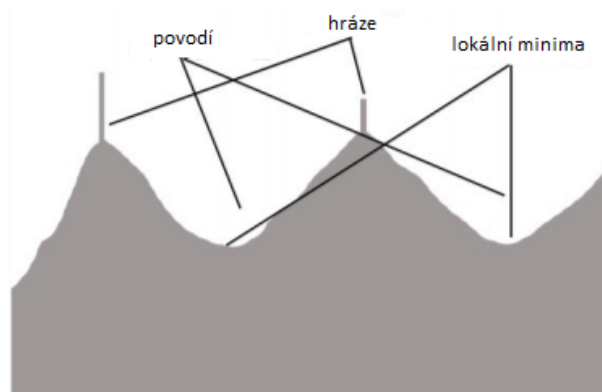
SPM softwarový balík byl původně navržen pro statistické parametrické mapování dat PET a fMRI. Aktuální verze je určena pro analýzu fMRI, PET, SPECT, EEG a dále se vyvíjí [24].

6 Rešerše metod k detekci patologických oblastí mozku z dat MR

V dnešní době existuje celá řada segmentačních metod používaných pro detekci patologických oblastí mozku. Existující algoritmy lze klasifikovat do tří skupin, a to manuální, poloautomatické a plně automatické metody. Manuální segmentace je časově nejnáročnější, ale dosud nejpoužívanější metoda. Poloautomatické metody vyžadují interakci uživatele, např. výběr počátečního bodu. Automatické metody nevyžadují žádnou interakci uživatele. S rozvojem výpočetní techniky je tendence nahrazovat manuální segmentaci automatickými metodami. Jakkoli ale mohou být výsledky automatické segmentace přesné, je třeba je ověřit člověkem, zvláště v medicíně.

6.1 Watershed transformace


Watershed transformace neboli metoda rozvodí, je založena na podobném principu jako metoda dělení a spojování oblastí. Používá se na extrahování oblasti nádoru z obrazu MRI mozku. Obraz je chápán jako reliéf, který se postupně plní vodou. Voda zaplavuje reliéf od lokálních minim obrazu. Aby se při zvedání hladiny na nejvyšší bod reliéfu povodí nespojily dohromady, jsou vytvořeny hráze, umístěné na hřebenech. Tyto hráze, nazývané watershed, udávají hranice mezi segmenty. Voda zaplavuje reliéf až do chvíle, dokud nedosáhne nejvyššího bodu terénu (maxima obrazu). Výsledkem je obraz oddělený hrázemi do regionů [25].



Obrázek 14: Představa metody rozvodí, s ukázkou povodí, hráze a lokálních minim [25]

Tato metoda, protože hledá lokální minima, je citlivá na šum v obraze. V zašumělých obrazech je výsledkem velký počet regionů, tedy přesegmentovaný obraz. Tento problém je možno řešit při předzpracování obrazu, kdy šum potlačíme, nebo při použití značek v obraze. Existují dva typy těchto značek, a to interní a externí. Interní značky jsou spojeny s objekty zájmu, externí značky jsou spojeny s pozadím. Nejprve se vypočte funkce segmentace z daného obrazu, určí se interní a externí značky, dále se upraví funkce segmentace tak, aby existovala pouze minima na interním a externím umístění značky a vypočte se změna modifikovaného obrazu [25].


Mozkové nádorové buňky mají vysoce proteinovou tekutinu, která má velmi vysokou intenzitu. Na základě intenzity je tato metoda efektivnější než ostatní metody [25].



Obrázek 15: Vlevo originální obraz, vpravo obraz po watershed transformaci [25]

6.2 Region growing

Jak již bylo uvedeno výše (v kapitole 4.2), u metody segmentace narůstání oblastí jsou nejprve ručně vybrány počáteční body (semínka – seeds). V dalších krocích jsou zkoumány pixely v oblasti semínek a ty jsou potom začleněny do určitého regionu, pokud splňují určité kritérium homogenity. Do oblasti nebudou začleněny ty pixely, které kritériu nevyhovují. Tento proces se opakuje, dokud všechny pixely nepatří do určité oblasti [26].



Obrázek 16: V inicializačním kroku vlevo je viditelná léze, vpravo je konečný výsledek segmentace region growing [26]

Tato metoda může být aplikována na mozkové nádory, ale také se uplatňuje v segmentaci ledvin nebo srdce. Nevýhodou této metody je, že pro každou oblast vyžaduje výběr semínek, což představuje časově náročný proces. Volbou jiného počátečního semínka může být výsledek segmentace zcela odlišný. Pokud kritéria počátku a homogenity nejsou správně definována, rostoucí oblast se může sloučit s oblastmi, které nepatří k objektu zájmu [26].

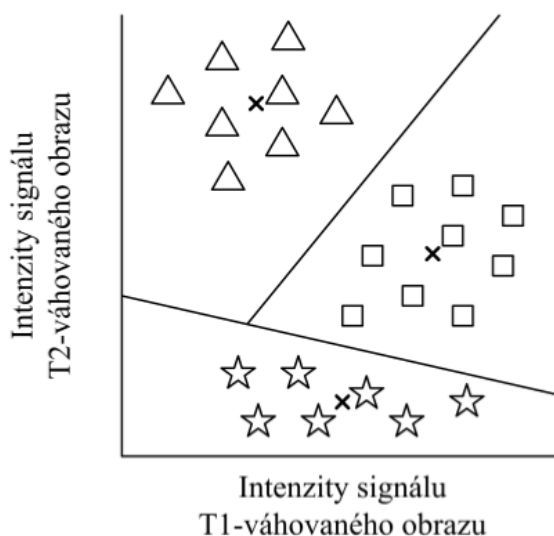
6.3 K-means algoritmus

Algoritmus K-means se používá k nalezení nádorů pomocí detekce hran a řadí se mezi neparametrické metody analýzy shluků. Principem algoritmu je klasifikace objektů do konečného počtu shluků. Středů shluků se označují těžiště. Počáteční hodnoty těžiště je nutné nastavit ručně.

Kroky algoritmu:

1. Nejprve se uvede počet shluků k ,
2. V prostoru dat se náhodně umístí k ,
3. Objekty se přiřadí k nejbližším těžištím,
4. Těžiště shluků se přepočítávají,
5. Proces se opakuje, dokud se poloha těžišť neustálí.

K-means algoritmus je velmi užitečný pro nalezení nádoru v obrazech MRI. Princip této metody lze použít k segmentaci základních tkáňových struktur WM, GM a CSF [27].



Obrázek 17: K-means algoritmus. Trojúhelníky značí voxely WM, čtverce odpovídají voxelům GM a hvězdičky reprezentují voxely CSF. Centroid shluků je vyznačen křížkem, upraveno podle [28]


6.4 BIANCA – Algoritmus klasifikace abnormality intenzity mozku

Algoritmus BIANCA (algoritmus klasifikace abnormality intenzity mozku) slouží k detekci WMH (hyperintenzita bílé hmoty) s předpokládaným cévním původem. Jedná se například o roztroušenou sklerózu, akutní infarkty nebo mozkové nádory. Algoritmus BIANCA využívá k -NN algoritmus [29].

Algoritmus k -NN (k -nearest neighbor) patří mezi neparametrické shlukovací metody. To znamená, že nevyžadují žádné předpoklady o rozdělení intenzit jednotlivých tkání mozku. Nejprve je vytvořena trénovací sada, která odpovídá voxelům z jednotlivých typů mozkových tkání. Principem k -NN algoritmu je zařazení jednotlivého voxelu v prostoru do mozkové tkáně podle blízkosti k trénovacím bodům. Voxel je poté zařazen do té třídy, kam spadá většina nejbližších sousedů [29].

Algoritmus BIANCA vyžaduje trénovací sadu vybranou manuálně, takže tato metoda není plně automatická. Pro detekci WMH nejvíce vyhovuje $k = 40$, použitý práh byl 0,9. Byly testovány FLAIR obrazy (mají nejvyšší kontrast pro WMH, ale nižší rozlišení) a jako referenční byly použity T1 vážené obrazy [29].

Díky algoritmu BIANCA se podstatně zlepšila přesnost segmentace. Tento algoritmus je vysoce flexibilní, umožňuje použít i jiné obrazy, které nebyly zahrnuty do této studie. BIANCA bude brzy volně dostupná jako součást knihovny FSL [29].



Obrázek 18: k-NN algoritmus. Trojúhelníky značí prototypy WM, čtverce odpovídají prototypům GM a hvězdičky reprezentují prototypy CSF. Voxel, který má být zařazen do třídy je označen hvězdičkou. V tomto případě je $k = 5$ nejbližších prototypů. Voxel bude tedy klasifikován jako voxel GM, upraveno podle [28]

6.5 Fuzzy C–Means

Algoritmus Fuzzy C–Means představuje zobecnění shlukování k–means, protože umožňuje shlukování jednoho objektu do více shluků. Fuzzy algoritmus pracuje s koeficientem příslušnosti, který určuje příslušnost k určitému shluku. Tento algoritmus rozděluje konečný počet bodů do shluků podle daného kritéria, např. barva, vzdálenost a další [30].

Jednotlivé kroky algoritmu:

1. Výběr center shluků v daném obrázku.
2. Náhodně přiřadit každému bodu jednotlivé centrum shluků.
3. Přepočítat nové centra shluků.
4. Kontrola rozdílu příslušnosti – pokud tabulka příslušnosti zůstane stejná, je shlukování ukončeno. V opačném případě se začíná prvním krokem znovu.

Fuzzy C–Means algoritmus oproti K–means algoritmu umožňuje kratší čas výpočtu, jelikož Fuzzy C–Means má výpočty měření již zahrnuty v algoritmu [30].

7 Modelování zájmových objektů z MR mozku

Tato kapitola se věnuje návrhu a řešení algoritmu pro segmentaci a modelování patologických oblastí z MR mozkových obrazových dat. V rámci analýzy jsou diskutovány dva variabilní přístupy pro modelování zájmových objektů z MR. Jedná se o multiregionální segmentaci na bázi OTSU metody a model iteračních křivek, který je reprezentován aktivními konturami. Modelování zájmových objektů je verifikováno na základě objektivních evaluačních metrik.


7.1 Charakteristika obrazových dat použitých k analýze

Snímky pro tuto práci byly vybrány z databáze <http://www.cancerimagingarchive.net/>. Jedná se o velký archiv lékařských snímků u pacientů s diagnózou rakoviny, který je přístupný veřejnosti. Analyzovaný dataset obsahuje snímky z magnetické rezonance. Data jsou rozdělena podle oblasti onemocnění, přičemž pro tuto práci byl vybrán mozek. Rozlišení snímků je 256x256, kromě oddílu Glioblastom – tam je rozlišení snímků 512x512. Čím větší je požadované rozlišení, tím se doba vyšetření prodlužuje. Snímky jsou uloženy ve formátu DICOM, což je standard pro zobrazování dat pořízených zobrazovacími metodami. K dispozici jsou také údaje o pacientovi, patologii a podrobnost léčby.


Byly vybrány 4 analyzované skupiny patologických nálezů:

- gliomy nízkého stupně malignity,
- glioblastom,
- multiforní glioblastom,
- gliomy nízkého a vysokého stupně malignity.


Z každé skupiny bylo vybráno několik testovacích snímků. Formát DICOM není vhodný pro účely segmentace a je tedy potřeba ho převést do formátu PNG.




Obrázek 19: Multiforní glioblastom



Obrázek 20: Gliom nízkého stupně malignity




Obrázek 21: Gliom nízkého a vysokého stupně malignity



Obrázek 22: Glioblastom

7.2 Předzpracování MR obrazu

Prvním krokem je předzpracování obrazu. Cílem předzpracování je zlepšení vlastností snímků pro následnou segmentaci. Hlavním smyslem předzpracování v této práci je nastavit jednotlivé funkcionality tak, aby byl co největší kontrast mezi jednotlivými tkáněmi. Vhodným předzpracováním snímku se zvýší úspěšnost dalších kroků detekce lézí. Pro úpravu je využito ošetření obrazu, jasové transformace a výběr zájmové oblasti ROI.



Obrázek 23: Blokové schéma kroků předzpracování obrazu


7.2.1 Ostření obrazu

Cílem ostření obrazu je upravit obraz tak, aby se v něm nacházely strmější hrany. Tomu odpovídá zdůraznění vysokých frekvencí. Pro obraz f , který je výsledkem ostření obrazu g , lze vyjádřit:

$$f(x, y) = g(x, y) - CS(x, y) \quad (7.1)$$

kde C je součinitel, udávající sílu ostření, $S(i, j)$ je operátor, udávající strmost změny obrazové funkce v příslušném bodě a g – výchozí obraz [16].

V algoritmu ostření obrazu je použita metoda *unsharp*, která detekuje oblasti s vysokým kontrastem. Tento algoritmus je založen na odečtení rozostřeného obrazu od původního. Rozostřený obraz má vyšší podíl složek nižších frekvencí, odečtením tedy vzniká obraz, který má zvýrazněné složky vyšších frekvencí (hran).



Obrázek 24: Původní snímek (vlevo), snímek po aplikaci „unsharp“ (vpravo)


7.2.2 Jasové transformace

Následující operace je jasová transformace. Jasové transformace jsou důležité zejména pro úpravy obrazu. Tyto úpravy poskytují jednodušší interpretaci objektu, který je v popředí jejich zájmu. Jasové transformace jsou vyjádřeny podle následujícího matematického zápisu:

$$q = T(p) \quad (7.2)$$

kde T je transformační funkce, p je původní stupnice jasu a q – nová stupnice jasu [16].


Podle velikosti okolí vyšetřovaného bodu lze rozlišit jasové transformace globální, lokální a bodové. V navrženém algoritmu je aplikována bodová transformace. U bodové transformace je nová hodnota pixelu vypočítána jen z hodnoty téhož prvku [16].




Obrázek 25: Snímek před jasovou transformací (vlevo) a po jasové transformaci (vpravo)

7.2.3 Vymezení oblasti zájmu ROI

Posledním krokem předzpracování obrazu je výběr zájmové oblasti ROI (region of interest). Vytvořením ROI lze snížit počet pixelů v obraze. Je zapotřebí vybrat určitou oblast s konkrétní lézí. Tímto uživatel vybere část obrazu, která je v popředí zájmu. V MATLABu k tomuto slouží funkce *imcrop*, přičemž existují dva způsoby, jakými lze oblast zájmu vybrat, a to manuálně nebo zadáním konkrétních souřadnic. Pro tuto práci byla zvolena manuální cesta, kvůli variabilitě snímků. Uživatelem je pomocí kurzoru vybrána zájmová oblast s lézí a poté je snímek ořezán podle vybrané oblasti.



Obrázek 26: Původní snímek se zaznačenou lézí



Obrázek 27: Extrahovaný ROI

7.3 Regionální segmentace MR obrazových dat

Tato kapitola se věnuje samotnému návrhu Otsu multiregionální metody pro segmentaci MR obrazových dat. Řešení se skládá z jednotlivých podkroků, které budou v následujících podkapitolách dále rozebrány.


7.3.1 Regionální segmentace obrazu

Regionální segmentace obrazu se zakládají na nalezení takových pixelů, mající podobné charakteristiky, jako může být jasové spektrum, nebo úroveň monochromatického spektra. Metody založené na regionálně orientované segmentaci v obraze nehledají hrany a umožňují segmentovat i obraz s velkým šumem [31].

7.3.2 Princip Otsu metody

Otsu metoda prahování spočívá ve stanovení optimální úrovně prahu pro daný snímek. Tento práh je získáván na základě hodnot mezi-rozptylu. Hodnota mezi-rozptylu je vyjádřena pro každý odstín šedi v daném snímku. Jako nejvíce vyhovující práh je určen odstín šedi s nejvyšší hodnotou mezi-rozptylu. Poté je podle nejideálnějšího prahu snímek segmentován [32].

Pro pochopení principu výpočtu je uveden na Obr. 25 ilustrativní snímek s jeho histogramem. Na ose x je uvedeno rozložení intenzit barev, které jsou vyznačeny čísly (0–5) a na vertikální ose y je znázorněna četnost pixelů v určitém odstínu šedi [32].



Obrázek 28: Vlevo ilustrativní snímek, vpravo jeho histogram

V tomto ilustrativním příkladu je 6 odstínů šedi, tedy šestkrát je vypočítán mezi-rozptyl. Mezi-rozptyl je obecně počítán takto:

$$\sigma_B^2 = W_b * W_f * (\mu_b - \mu_f)^2 \quad (7.3)$$

kde W_b je váha pozadí a W_f je váha popředí, μ_b je průměrná hodnota intenzity pozadí a μ_f je průměrná hodnota intenzity popředí.

Ty jsou počítány:

$$W_b = \sum_{i=1}^k \frac{n_i}{N} \quad (7.4)$$

$$W_f = \sum_{i=k+1}^L \frac{n_i}{N} \quad (7.5)$$

$$\mu_b = \sum_{i=1}^k \frac{n_i * i}{N_k} \quad (7.6)$$

$$\mu_f = \sum_{i=k+1}^L \frac{n_i * i}{N - N_k} \quad (7.7)$$

kde L jsou označeny pixely určitého snímku, které mají různé odstíny šedi s intervalem $[0,1,\dots,L]$, i je odstín šedi, n_i je počet pixelů v určitém odstínu šedi a N je celkový počet pixelů, který je vypočítán jako $n_0 + n_1 + n_L$.

Výsledné pixely jsou následně rozděleny na dvě skupiny b a f , kde b znamená pozadí snímku a f popředí snímku, podle prahovací úrovně k [32].

7.3.3 Implementace algoritmu v prostředí MATLAB

Otsu metoda popsána v předchozí podkapitole segmentuje snímek pouze podle jedné prahovací úrovně. Tato kapitola se zabývá algoritmem založeným na Otsu metodě, který hledá více prahovacích úrovní a snímek poté segmentuje. Při hledání jedné prahovací úrovně je úroveň hledána z celého histogramu snímku, kdežto u hledání více úrovní je histogram snímku rozdělen na stejné oblasti. Pro každou oblast je dána vlastní prahovací úroveň. Hlavní rozdíl těchto algoritmů tedy spočívá v počtu zvolených prahovacích úrovní. Snímek je tedy segmentován podle všech prahovacích úrovní. Rozdělený histogram podle počtu prahovacích úrovní je roven počtu oblastí. Takže pro jakýkoliv snímek s 5 prahovacími úrovněmi by počet oblastí byl roven také 5.



Obrázek 29: Vývojový diagram kroků algoritmu

7.3.4 Testování algoritmu na reálných datech

V této kapitole je řešeno nalezení optimálního počtu prahovacích úrovní a následné testování na různých typech snímků.


V MATLABU existuje vestavěná funkce *multithresh*. Nejprve tedy bylo potřeba nalézt optimální počet prahovacích úrovní. V následující tabulce jsou zobrazeny celkové počty snímků patřících do určité skupiny a jejich vyhovující prahovací úrovně.

Tabulka 1: Výsledky nalezení optimální prahovací úrovně u nativních snímků


Analyzovaná skupina	Glioblastom		Gliomy nízkého a vysokého stupně malignity			Gliomy nízkého stupně malignity		Multiformní glioblastom				
	Celkem snímků	7		4			4		6			
Počet snímků	6	1	1	2	1	3	1	1	1	1	1	2
Optimální prahovací úroveň	4	8	2	3	7	4	8	5	2	3	4	8

Z tabulky uvedené výše vyplývá, že neoptimálnější prahovací úroveň je 4. Nelze to ovšem říct o všech snímcích, protože závisí na povaze jednotlivých snímků. Problém je, pokud zájmový objekt (nádor) má podobný odstín šedi jako okolní pozadí. U těchto snímků je nutno nastavit větší prahovací úroveň, jelikož při nastavení nízké úrovně prahu není zájmový objekt viditelný. Názorný příklad tohoto problému lze vidět na Obr. 30, kde bylo nutné zvolit prahovací úroveň 7, aby byla léze detekovatelná. Na Obr. 31 je viditelné, že pokud zvolíme místo snímku z databáze předzpracovaný snímek, stačí nám prahovací úroveň 4. Předzpracováním obrazu se tedy zvyšuje efektivita segmentační procedury.


Jinak je tomu u snímků, které mají odstín šedi velmi odlišný. U takových snímků stačí nastavit prahovací úroveň 2 nebo 3. Těmto snímkům naopak škodí příliš velká prahovací úroveň. Ilustrativní obrázek je uveden na Obr. 32.



Obrázek 30: Vlevo nativní snímek z databáze, vpravo snímek po implementaci algoritmu s prahovací úrovní 4




Obrázek 31: Vlevo předzpracovaný snímek, vpravo nastavená prahová hodnota 4



Obrázek 32: Vlevo nativní snímek, uprostřed snímek s nastavenou prahovací úrovní 2, vpravo snímek s nastavenou prahovací úrovní 6


7.3.4.1 Analýza segmentačního modelu pro nativní a předzpracovaná data

Tato část testování se věnuje porovnání nativních a předzpracovaných snímků. Z následujícího testování snímků vyplývá, že mnohem lepší je snímek předzpracovat. Je to z toho důvodu, že zájmová oblast snímku je lépe ohraničená a viditelná, což byl hlavní cíl předzpracování obrazu. Na následujících obrázcích je rozdíl mezi nativními a předzpracovanými snímkami dobře viditelný.



Obrázek 33: Testování metody na nativních snímcích (nahore) a na předzpracovaných snímcích (dole) při nastaveném počtu prahovacích úrovní 4

Na Obr. 33 je znázorněn glioblastom. Prahovací úroveň u nativního snímku byla zvolena 4, stejně jako u předzpracovaného snímku. Glioblastom se mnohem lépe vykreslil a ohraničil. Kromě glioblastomu je ale ve snímku obsaženo i pozadí. Pozadí se ale vyskytuje v malé míře a glioblastom je stále dobře viditelný.



Obrázek 34: Testování metody na nativních snímcích (nahore) a na předzpracovaných snímcích (dole) při nastaveném počtu prahovacích úrovní 3

Na Obr. 34 je znázorněn multiformní glioblastom. U nativního snímku byla prahovací úroveň nastavena 3, stejně jako u snímku předzpracovaného. Stejně jako u předchozích snímků je zde obsaženo i pozadí, ale multiformní glioblastom je více viditelný a ohraničený u předzpracovaného snímku než u nativního.

7.3.5 Zhodnocení

Na výše uvedených snímcích je implementován algoritmus založen na Otsu metodě pro analýzu medicínských snímků pro různá nastavení. Tato různá nastavení spočívají v nastavení optimálního počtu prahovacích úrovní. U Otsu multiregionální metody je obtížná jednotná selekce počtu segmentačních tříd pro variabilní MR obrazy. Obecně se dá říci, že čím je zájmový objekt více odlišný od pozadí, tím menší prahovací úroveň se může zvolit.

Problém nastává, jestliže zájmový objekt disponuje stejným jasovým spektrem jako obrazové pozadí. U takových snímků je nutné nastavit větší prahovací úroveň. Takový problém se dá vyřešit předzpracováním obrazu, kde se zvýší jeho kontrast. Předzpracované snímky dosahují lepších výsledků než nativní snímky z databáze.

7.4 Metoda aktivních kontur

Druhou aplikovanou metodou v této bakalářské práci je metoda aktivních kontur. Metoda aktivních kontur se řadí mezi pokročilejší metody segmentace obrazu. Je to určitá deformovatelná křivka v obraze, která deformuje svůj tvar na základě působení energie. Deformace jejího tvaru probíhá do té doby, dokud nedosáhne hranice námi segmentovaného zájmového objektu [33].

Výhodou aktivní kontury je její uzavřenost. Pokud hrana chybí, aktivní kontura je schopna tuto hranu nahradit. Dále je metoda aktivních kontur vhodná i pro složité tvary a umožňuje nastavit parametry ovlivňující výsledný tvar kontury. Nejdůležitější při počátečním umístění v obraze je, aby se křivka deformovala blízko objektu, který chceme segmentovat. Kdyby tomu tak nebylo, křivka by byla přitahována artefakty a segmentace by nebyla úspěšná. Za nevýhodu lze považovat nutnou počáteční inicializaci, která lokalizuje umístění prvotní kontury [33].

Aktivní kontury jsou nazývány jako „hadi“, neboli snakes. Jedná se o křivku uvnitř obrazu, deformovanou energiemi. Vnitřní energie ovlivňují hladkost průběhu křivky, energie obrazu se zabývá deformací kontur k hranám a vnější energie přitahují křivku k lokálním minimům. Celková energie se dá vyjádřit jako součet vnitřní a vnější energie a energie obrazu [33].

Aktivní kontura je definována jako parametrická rovnice:

$$v(s) = [x(s), y(s)], \quad s \in [0,1] \quad (7.8)$$

kde $s = 0$ znamená počátek křivky a $s = 1$ značí konec křivky, $x(s)$ a $y(s)$ jsou souřadnice bodu, který leží na křivce.

Celková energie aktivní kontury je vypočítána pomocí vztahu:

$$\int_0^1 E_{snake}(v(s))ds = \int_0^1 [E_{internal}(v(s)) + E_{image}(v(s)) + E_{con}(v(s))]ds \quad (7.9)$$

kde $E_{internal}$ je vnitřní energie, E_{con} je energie bodů počáteční kontury a E_{image} je energie obrazu.

7.4.1 Vnitřní energie

Vnitřní energie je dána vzorcem:

$$E_{int} = \alpha(s) \left| \frac{\partial s}{\partial s} \right|^2 + \beta(s) \left| \frac{\partial s}{\partial s} \right|^2 \quad (7.10)$$

kde parametr α udává pevnost křivky a parametr β udává tuhost kontury. Pomocí těchto parametrů lze určit, jak se bude kontura formovat [33].

7.4.2 Energie obrazu

E_{image} je součástí vnější energie a skládá se ze tří složek označovaných jako E_{line} , E_{edge} a E_{term} .

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term} \quad (7.11)$$

E_{line} určuje, jak bude kontura inklinovat ke světlým, nebo k tmavým oblastem obrazu podle volby w_{line} .

Funkcí E_{edge} je kontura přitahována k místům s vysokou hodnotou gradientu (lokální minimum).

E_{term} má za úkol detekovat ostré rohy a konce hran pomocí zkoumání křivosti. Využívá se zde rozmazaného obrazu kvůli možnému šumu [33].

7.4.3 Implementace metody aktivních kontur v prostředí MATLAB

V této podkapitole je uvedena implementace metody aktivních kontur a práce s parametry metody. Jednotlivé kroky algoritmu jsou zobrazeny na Obr. 35.




Obrázek 35: Vývojový diagram kroků algoritmu

Nejprve bylo nutné nastavit optimální parametry funkce pro detekci zájmového objektu:

- **NumIter** – počet iteračních kroků
- **timestep** – časový krok posunu křivky. Čím větší hodnota parametru, tím méně je přesná křivka, ale rychleji se pohybuje.
- **mu** – konstanta zajišťující křivku tak, aby se neodchýlila daleko od své pozice během svého rozvíjení
- **sigma** – parametr Kernelovy funkce, zkoumající nehomogenitu jasové intenzity. Čím je tento parametr vyšší, tím se křivka více vzdaluje od aktuální pozice.
- **epsilon** – určuje šířku Diracova impulsu, který zrychluje počáteční pohyb inicializované kontury. Čím vyšší je tato hodnota, tím je kontura na konci méně přesná.
- **c₀** – touto konstantou se násobí hodnoty pixelů uvnitř kontury (má zápornou hodnotu) a vně kontury (má kladnou hodnotu) Čím vyšší je tato konstanta, tím rychlejší je počáteční pohyb kontury.
- **lambda1** – konstanta, přiřkládající váhu oblasti vnitřní kontury při pohybu křivky
- **lambda2** – konstanta, přiřkládající váhu oblasti vnější kontury při pohybu křivky. Závisí také na poměru mezi lambda1 a lambda2. Pokud je lambda1 > lambda2, křivka se smršťuje. Jestliže je lambda1 < lambda2, křivka se rozpíná.
- **nu** – konstanta určující délku kontury. Čím vyšší hodnota, tím kratší je kontura a nepřitahuje žádné nežádoucí artefakty v obraze.
- **alf** – parametr, kterým se může nastavit důraz kladený na energii obrazu, přitahující křivku ke hranám [33].

Dalším krokem je vhodné umístění inicializační kontury. Tento krok je velmi důležitý kvůli správné segmentaci obrazu. U každého snímku je nutné nastavit velikost inicializační kružnice individuálně. Na Obr. 36 lze vidět jednotlivé kroky algoritmu. Jakmile jsou provedeny všechny iterační kroky, vznikne kontura, která ohraničuje námi zvolený objekt.




Obrázek 36: Vývoj kontury od inicializační po konečnou, počet iteračních kroků = 300

Evoluce kontury je doprovázena energetickou funkcí $E(\varphi)$ diferencující oblasti obrazu na:

- Vnější: oblast mimo segmentovaný objekt (kladná energie).
- Vnitřní: oblast vně segmentovaný objekt (záporná energie).
- Hraniční: nulová energie reprezentující hrany objektu.

Matematický model patologické tkáně: $E(\varphi) \leq 0$.



Obrázek 37: Vlevo energetická mapa, vpravo binární model objektu

Na Obr. 37 je zobrazena energetická mapa a binární model objektu. Tato energetická mapa zobrazuje rozložení energie při rozvoji kontury. Patologická tkáň vyobrazená modrou barvou má zápornou hodnotu, okolní žlutá oblast má hodnotu kladnou. V pravém okně je extrahován zájmový objekt pomocí prahování, kdy záporné oblasti je přiřazena bílá barva a kladné oblasti černá barva.

7.4.4 Testování algoritmu na reálných datech


Tato část se bude věnovat testování na všech typech snímků, tedy nativní snímky, předzpracované snímky bez ROI, a nakonec samotné ROI. Algoritmus byl testován na 21 snímcích. Pro ilustraci byly vybrány 3 snímky reprezentující určitou skupinu. Na obrázcích vždy horní snímek charakterizuje snímky s nejasnou hranicí objektu, snímek uprostřed dobře kontrastní snímky a dolní snímek reprezentuje snímky, kde to není zcela jasné.

Při testování snímků byly měněny pouze parametry NumIter, timestep a sigma. Ostatní parametry byly nastaveny takto: $\epsilon = 1$; $c_0 = 2$; $\lambda_1 = 1,02$; $\lambda_2 = 1,2$; $\nu = 0,0005 \cdot 255 \cdot 255$, $\alpha = 20$.

7.4.4.1 Testování na nativních snímcích

Při testování na nativních snímcích byly nastaveny parametry takto:

- Snímek nahoře: NumIter = 300, timestep = 0,01, sigma = 5,
- Snímek uprostřed: NumIter = 400, timestep = 0,1, sigma = 10,
- Snímek dole: NumIter = 200, timestep = 0,01, sigma = 12.



Obrázek 38: Testování na nativních snímcích: nativní MR snímky (vlevo), energetická mapa aktivních kontur (uprostřed) a binární model objektů zájmu (vpravo)

Na Obr. 38 jsou v levých oknech vidět finální kontury na nativních snímcích. V prostředním okně je zobrazena mapa energie, v pravém okně je extrahován zájmový objekt. Na těchto snímcích proběhla segmentace úspěšně.


7.4.4.2 Testování na předzpracovaných snímcích bez ROI

U předzpracovaných snímků bez ROI (tedy s ostřením obrazu a jasovou transformací) došlo ke zkomplikování segmentace.

Pro účinnou segmentaci bylo potřeba zvýšit hodnotu sigma. U nativních snímků byla průměrná hodnota sigma 9,63, zatímco u snímků s jasovou transformací se průměrná hodnota zvedla na 23,05. Zvýšení hodnoty sigma mělo negativní dopad na výpočetní náročnost.

Nastavené parametry snímků:

- Snímek nahoře: NumIter = 1100, timestep = 0,001, sigma = 15,
- Snímek uprostřed: NumIter = 100, timestep = 0,01, sigma = 25,
- Snímek dole: NumIter = 400, timestep = 0,01, sigma = 20.



Obrázek 39: Testování na předzpracovaných snímcích: předzpracované MR snímky (vlevo), energetická mapa aktivních kontur (uprostřed) a binární model objektů zájmu (vpravo)

Stejně jako v předchozí kapitole je na výše uvedených snímcích v levém okně vidět finální kontura na předzpracovaných snímcích, v prostředním okně pak mapa energie a v pravém okně extrahován zájmový objekt.


U snímku nahoře došlo k nepřesné extrakci. To je dáno nejasnou hranicí mezi objektem a okolní tkání. Snímek uprostřed vykazuje zhoršených výsledků v porovnání s nativním snímkem. Kontura se nerozepíná až k záhybům a výsledek je nepřesný. Mnohem horších výsledků dosahuje snímek dole, kdy výsledná extrakce je neúplná.

7.4.4.3 Testování na ROI

Při testování těchto snímků často dochází ke zkreslení výsledků připočtením pixelů nežádoucích objektů. Jestliže se v ROI nachází nežádoucí objekty o podobném odstínu šedi, dochází k nechtěnému připočítávání pixelů nežádoucích částí.

U testování snímků na ROI byly nastaveny parametry takto:

- Snímek nahoře: NumIter = 300, timestep = 0,01, sigma = 10,
- Snímek uprostřed: NumIter = 400, timestep = 0,1, sigma = 10,
- Snímek dole: NumIter = 800, timestep = 0,01, sigma = 8.



Obrázek 40: Testování na ROI: ROI MR snímky (vlevo), energetická mapa aktivních kontur (uprostřed) a binární model objektů zájmu (vpravo)

U snímku nahoře kontura neaproximuje celý objekt. To je způsobeno opět nepřesnou hranicí mezi objektem a pozadím. Snímek uprostřed je srovnatelný s předzpracovanými snímky bez ROI. U těchto snímků byl glioblastom úspěšně detekován. U snímku dole se opět neohraničil celý objekt a výsledná extrakce je neúplná.

7.4.4.4 **Zhodnocení**

Na předchozí snímky byla implementována metoda aktivních kontur. Pro detekci příslušného objektu byla zvolena optimální kombinace parametrů u každého snímku individuálně.

Velký vliv na výslednou segmentaci má umístění inicializační kontury. Pokud má objekt nejasnou hranici, kontura se nemá čeho přichytit. Dva snímky se nepodařilo detekovat vůbec, z důvodu nízké viditelnosti objektu. Proto je dobře viditelná hranice nádoru a okolních tkání velmi důležitá. Dalším bodem je velikost inicializační kontury. Zde platí, že v případě použití malé kontury dojde ke zmenšování křivky až k jejímu zmizení. Naopak v případě velké kontury se může přichytit k ostatním strukturám.

Nejlepších výsledků dosahují nativní data, naopak nejhorších výsledků dosáhly snímky s ROI. To dokazuje i fakt, že se podařilo detekovat 19 snímků z 21 u nativních dat, a pouze 15 snímků z 21 u snímků s ROI. Pokud je objekt u nativních snímků světlejší než pozadí, pomůže předzpracování obrazu, kde dojde ke zvýraznění světlé barvy a lepšího kontrastu mezi objektem a pozadím. Je-li ale nádor tmavší než pozadí, dojde u předzpracování snímku k zvýraznění pozadí a ne objektu. Výsledkem je pak nepřesná segmentace.

8 Evaluace a testování segmentačního modelu

Evaluace efektivity segmentace proběhlo na bázi korelačního koeficientu. V následující podkapitole bude korelační koeficient blíže popsán.

8.1 Korelace

Korelační analýza se zabývá mírou závislosti náhodných dat. Standardním výstupem korelační analýzy je koeficient, který určuje míru závislosti – korelační koeficient [34].

Korelační koeficient vyjadřuje míru „těsnosti lineární vazby“, jelikož korelační analýza popisuje lineární vztahy mezi veličinami. Korelační koeficient R nabývá hodnot od -1 do +1. Druhá mocnina korelačního koeficientu R^2 , zvaného koeficient determinace, nabývá hodnot od 0 do +1. Kde:

- 0 znamená žádnou závislost,
- 1 znamená plnou závislost.

Párový (pearsonův) korelační koeficient R je vyjádřen:


$$R = \frac{\sum(x_i - \bar{x}) \cdot (y_i - \bar{y})}{(n - 1)s_x s_y} \quad (8.12)$$

$$R = \frac{\sum(x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \cdot \sum(y_i - \bar{y})^2}} \quad (8.13)$$

kde s_x a s_y jsou směrodatné odchylky, \bar{x} a \bar{y} jsou aritmetické průměry [34].

8.2 Testování segmentačního modelu

Testování segmentačního modelu proběhlo v kontrastu se zlatým standardem, který je dán manuální segmentací. U každého snímku je dán zlatý standard, který je porovnáván s binárním modelem. Ten je dán výsledkem metody aktivních kontur. Poté je vypočítán korelační koeficient, který je následně převeden na procenta. Testování bylo provedeno pouze na nativních a předzpracovaných snímcích, jelikož ROI snímky nedosáhly uspokojivých výsledků.



Obrázek 41: Vlevo binární model snímku, vpravo zlatý standard

Tabulka 2: Evaluace aktivních kontur, část 1

Snímek	Rozlišení snímku [px]	Nativní snímky [%]		Předzpracované snímky [%]	
1.	512x512	1.	95,63	1.	92,24
		2.	94,11	2.	92,76
		3.	95,71	3.	92,64
		Průměr:	95,15	Průměr:	92,54
2.	512x512	1.	89,05	1.	93,07
		2.	88,77	2.	92,74
		3.	87,19	3.	92,92
		Průměr:	88,33	Průměr:	92,91
3.	512x512	1.	92,88	1.	90,80
		2.	94,39	2.	91,72
		3.	94,96	3.	92,24
		Průměr:	94,07	Průměr:	91,58
4.	256x256	1.	92,87	1.	87,97
		2.	95,96	2.	88,87
		3.	95,85	3.	86,54
		Průměr:	94,89	Průměr:	87,79
5.	256x256	1.	87,98	1.	93,99
		2.	89,07	2.	94,98
		3.	90,90	3.	94,41
		Průměr:	89,31	Průměr:	94,46
6.	256x256	1.	93,36	1.	89,34
		2.	92,49	2.	87,57
		3.	92,22	3.	87,08
		Průměr:	92,69	Průměr:	87,99

Tabulka 3: Evaluace aktivních kontur, část 2

Snímek	Rozlišení snímku [px]	Nativní snímky [%]		Předzpracované snímky [%]	
7.	256x256	1.	90,98	1.	84,79
		2.	90,62	2.	84,38
		3.	89,62	3.	82,64
		Průměr:	90,40	Průměr:	83,93
8.	256x256	1.	90,39	1.	90,91
		2.	90,06	2.	90,92
		3.	90,57	3.	91,12
		Průměr:	90,34	Průměr:	90,98
9.	256x256	1.	92,02	1.	93,43
		2.	88,69	2.	93,30
		3.	92,10	3.	94,48
		Průměr:	90,93	Průměr:	93,73
10.	256x256	1.	85,00	1.	94,55
		2.	85,65	2.	94,45
		3.	87,56	3.	93,26
		Průměr:	86,07	Průměr:	94,08
11.	256x256	1.	92,23	1.	89,23
		2.	94,90	2.	91,42
		3.	93,74	3.	90,69
		Průměr:	93,62	Průměr:	90,44
12.	256x256	1.	86,61	1.	85,85
		2.	83,89	2.	86,28
		3.	85,15	3.	85,44
		Průměr:	85,21	Průměr:	85,85
Průměrný výsledek všech snímků			90,92		90,52

Výsledná průměrná hodnota nativních snímků je rovna 90,92 % a průměrná hodnota předzpracovaných snímků je rovna 90,52. Nejvyšší procentuální rozdíl je zaznamenán u desátého snímku, kde nabývá hodnot 8,01 %. Tento snímek má tmavé okolní pozadí a lézi světlejší, takže předzpracováním snímků dojde k zesílení kontrastu a léze je lépe ohraničená a viditelná.

Shrnutí

V této kapitole byla vyhodnocena metoda aktivních kontur, aby došlo k ověření úspěšnosti této metody pro segmentaci a extrakci patologických oblastí mozku a také aby se zjistilo, zda jsou pro tuto metodu lepší nativní nebo předzpracované snímky. Výsledné hodnoty jsou si velmi podobné, takže nelze přesně určit, zda jsou pro metodu aktivních kontur lepší nativní nebo předzpracované snímky. Předzpracované snímky mají negativní dopad na výpočetní náročnost, z tohoto důvodu jsou lepší volbou nativní snímky.

Vzhledem k tomu, že u většiny snímků vyšla průměrná hodnota okolo 90 %, metoda aktivních kontur dosahuje uspokojivých výsledků pro segmentaci patologických oblastí mozku.

Závěr

Tato bakalářská práce se zabývá metodikou segmentace a následné extrakce patologických oblastí mozku. Konkrétně hodnotí efektivitu použití segmentační procedury aktivních kontur na snímky z magnetické rezonance mozku.

Cílem této práce je návrh automatizované procedury pro segmentaci obrazových dat z magnetické rezonance a návrh modelu patologických oblastí z dat magnetické rezonance. V této práci je také řešeno porovnání efektivity předzpracování obrazu pro zlepšení výsledků segmentace a následně testování a verifikace navrženého algoritmu na reálných obrazových datech.

Všechny testované snímky z datasetu zobrazují mozek s viditelným patologickým nálezem. Jedním z úkolů této práce bylo ověření, zda použitý algoritmus dokáže tyto patologické oblasti detekovat. Dataset obsahoval 21 snímků z magnetické rezonance, z něhož u 19 snímků se podařilo úspěšně detekovat patologickou oblast, u 2 snímků nikoliv. Důvodem byla špatně viditelná léze.

Pro účely předzpracování obrazu bylo použito: ostření obrazu, jasová transformace a výběr zájmové oblasti (ROI). Následným zjištěním se ROI snímky nejevily jako vhodné, proto byla zhodnocena efektivita pouze na nativních snímcích a předzpracovaných snímcích bez ROI.

Pro účinnou segmentaci snímků je zapotřebí ke každému snímku přistupovat individuálně, z důvodu jasových charakteristik variabilních MR mozkových nálezů. V této práci byly aplikovány dvě metody. Nejprve byla použita Otsu multiregionální segmentace, která je brána jako protiváha a alternativní metoda. Mnohem lepších výsledků však dosahuje metoda aktivních kontur. Vhodným nastavením parametrů pro daný snímek lze docílit kvalitní a účinné segmentace a extrakce patologických oblastí mozku. Následně byl vytvořen model patologických oblastí mozku, který je jedním z cílů bakalářské práce.

Na závěr proběhlo testování navrženého algoritmu na reálných obrazových datech. Vyhodnocení efektivit segmentace proběhlo na bázi korelačního koeficientu, který vyjadřuje míru lineární závislosti. Porovnáván je binární model, který je výsledkem metody aktivních kontur a zlatý standard, který je dán manuální segmentací. Pro nativní snímky vyšla míra závislosti 90,92 %, pro předzpracované snímky bez ROI vyšla míra závislosti 90,52 %. Z tohoto testování vyplývá, že předzpracování obrazu nebylo zapotřebí provádět, jelikož výsledky jsou velmi podobné. Předzpracování obrazu má také negativní dopad na výpočetní náročnost, lepší volbou jsou proto nativní snímky. To ale neznamená, že použití předzpracování obrazu bylo v této práci zbytečné. U Otsu multiregionální segmentace předzpracování obrazu zvyšuje efektivitu segmentační procedury.

Vzhledem k tomu, že u většiny snímků vyšla míra závislosti okolo 90 % se domnívám, že metoda aktivních kontur je vhodnou volbou pro detekci a modelování zájmových objektů z magnetické rezonance mozkových dat, a do budoucna může být využívána jako spolehlivá diagnostická metoda.

Návrh a implementace algoritmu jsem prováděla v software MATLAB R2017b.

Použitá literatura

- [1] ROBERTS, Alice M. *Kompletní lidské tělo: unikátní obrazový průvodce*. Praha: Knižní klub, 2012. ISBN 978-802-4229-584.
- [2] JELÍNEK, Jan a Vladimír ZICHÁČEK. *Biologie pro gymnázia: (teoretická a praktická část)*. 9. vyd. Olomouc: Nakladatelství Olomouc, 2007. ISBN 978-807-1822-134.
- [3] TROJAN, Stanislav. *Lékařská fyziologie*. Vyd. 3., dopl. a rozš. Praha: Grada, 1999. ISBN 80-716-9788-5.
- [4] ARTHUR J. VANDER, JAMES H. SHERMAN a DOROTHY S. LUCIANO. *Human physiology: the mechanisms of body function*. 8. ed. New York: McGraw-Hill, 2001. ISBN 978-007-1180-887.
- [5] Likvor, hematoencefalická a hematolivorová bariéra. *Funkce buněk a lidského těla* [online]. [cit. 2017-10-19]. Dostupné z: <http://fbt.cz/skripta/regulacni-mechanismy-2-nervova-regulace/12-likvor-hematoencefalicka-a-hematolivorova-bariera/>
- [6] STRÍTESKÝ, Jan. *Patologie: [učebnice pro zdravotnické školy a bakalářské studium]*. Olomouc: Epava, 2001. ISBN 80-862-9706-3.
- [7] FERDA, Jiří, Hynek MÍRKA, Jan BAXA a Alexander MALÁN. *Základy zobrazovacích metod*. Praha: Galén, 2015. ISBN 978-807-4921-643.
- [8] SEIDL, Zdeněk a Manuela VANĚČKOVÁ. *Magnetická rezonance hlavy, mozku a páteře*. Praha: Grada, 2007. ISBN 978-802-4711-065.
- [9] Meningeom. *Neurologienetz* [online]. [cit. 2017-11-20]. Dostupné z: <http://www.neurologienetz.de/fachliches/neuroradiologie/meningeom/>
- [10] Glioblastom. *Medixa* [online]. 2012 [cit. 2018-04-11]. Dostupné z: <http://cs.medixa.org/nemoci/glioblastom>
- [11] HORÁČEK, Jaroslav a Jana VACULOVÁ. *Patologie: studijní opora*. Ostrava: Ostravská univerzita v Ostravě, 2014. ISBN 978-807-4646-096.
- [12] Infekční onemocnění mozku. *Wikiskripta* [online]. [cit. 2018-02-15]. Dostupné z: https://www.wikiskripta.eu/w/Infek%C4%8Dn%C3%AD_onemocn%C4%9Bn%C3%AD_mozku
- [13] FERDA, Jiří, Hynek MÍRKA, Jan BAXA a Alexander MALÁN. *Základy zobrazovacích metod*. Praha: Galén, 2015. ISBN 978-807-4921-643.
- [14] HALOUNOVÁ, Lena. *Zpracování obrazových dat*. V Praze: České vysoké učení technické, 2009. ISBN 978-80-01-04253-3.

- [15] DOBEŠ, Michal. *Zpracování obrazu a algoritmy v C#*. Praha: BEN - technická literatura, 2008. ISBN 978-80-7300-233-6.
- [16] KUBÍČEK, Jan. *Zpracování medicínských obrazových dat*. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. ISBN 978-807-2489-411.
- [17] SOJKA, Eduard. *Digitální zpracování a analýza obrazů*. Ostrava: VŠB-Technická univerzita, 2000. ISBN 80-707-8746-5.
- [18] FEDOROV, Andriy, Reinhard BEICHEL, Jayashree KALPATHY-CRAMER, et al. 3D Slicer as an image computing platform for the Quantitative Imaging Network. *Magnetic Resonance Imaging* [online]. 2012, 30(9), 1323-1341
- [19] ROBB, R.A. a D.P. HANSON. ANALYZE: a software system for biomedical image analysis. [1990] *Proceedings of the First Conference on Visualization in Biomedical Computing* [online]. IEEE Comput. Soc. Press, 1990, , 507-518
- [20] FreeSurfer. *3D Slicer* [online]. [cit. 2017-10-19]. Dostupné z: <https://surfer.nmr.mgh.harvard.edu/>
- [21] FISCHL, Bruce. FreeSurfer. *NeuroImage* [online]. 2012, 62(2), 774-781
- [22] FSL. *FSL* [online]. [cit. 2017-10-19]. Dostupné z: <https://fsl.fmrib.ox.ac.uk/fsl/fslwiki>
- [23] JENKINSON, Mark, Christian F. BECKMANN, Timothy E.J. BEHRENS, Mark W. WOOLRICH a Stephen M. SMITH. FSL. *NeuroImage*. 2012, 62(2), 782-790. DOI: 10.1016/j.neuroimage.2011.09.015. ISSN 10538119.
- [24] SPM Software. *SPM* [online]. [cit. 2017-10-19]. Dostupné z: <http://www.fil.ion.ucl.ac.uk/spm/software/>
- [25] BENSON C. C., LAJISH V. L. a Kumar RAJAMANI. Brain tumor extraction from MRI brain images using marker based watershed algorithm. *2015 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. IEEE, 2015, 2015, , 318-323. DOI: 10.1109/ICACCI.2015.7275628. ISBN 978-1-4799-8790-0.
- [26] DESPOTOVIĆ, Ivana, Bart GOOSSENS a Wilfried PHILIPS. MRI Segmentation of the Human Brain: Challenges, Methods, and Applications. *Computational and Mathematical Methods in Medicine*. 2015, 2015, 1-23. DOI: 10.1155/2015/450341. ISSN 1748-670X.
- [27] NAVEEN, A. a T. VELMURUGAN. Identification of Calcification in MRI Brain Images by k-Means Algorithm. *Indian Journal of Science and Technology*. 2015, 8(29), -. DOI: 10.17485/ijst/2015/v8i29/83379. ISSN 0974-5645.
- [28] SCHWARZ, Ing. Daniel a Bc. Eva JANOUŠOVÁ. *Metody zpracování a analýzy medicínských obrazových dat: možnosti využití v neurovědním výzkumu* [online].

- [29] GRIFFANTI, Ludovica, Giovanna ZAMBONI, Aamira KHAN, et al. BIANCA (Brain Intensity AbNormality Classification Algorithm): A new tool for automated segmentation of white matter hyperintensities. *NeuroImage* [online]. 2016, 141, 191-205
- [30] Mrs. Bharati R. Jipkate a Dr. Mrs. V. V. Gohokar. A Comparative Analysis of Fuzzy C-Means Clustering and K Means Clustering Algorithms. *International Journal Of Computational Engineering Research*. 2012, (Vol. 2), 737-739. ISSN 2250–3005.
- [31] KLÁSEK, Pavel. *Segmentace základních částí lidského mozku v MR datech*. Brno, 2012. Bakalářská práce. Vysoké učení technické v Brně.
- [32] VALOŠEK, Jan. *Automatizovaný software pro úpravu a analýzu medicínských snímků* [online]. Ostrava, 2015 [cit. 2018-02-22]. Dostupné z: <http://hdl.handle.net/10084/108897>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.
- [33] VICIANOVÁ, Veronika. *Extrakce objektů z medicínských obrazů na základě metody aktivních kontur*. Ostrava, 2017. Bakalářská práce. VŠB – Technická univerzita Ostrava.
- [34] Korelace. *Univerzita Palackého v Olomouci* [online]. 2011 [cit. 2018-04-12]. Dostupné z: <http://ach.upol.cz/user-files/intranet/15-korelace-2011-1321473930.pdf>
- [35] Radiologické zobrazování mozku: Magnetická rezonance (MR). *E-learningová podpora mezioborové integrace výuky tématu vědomí na UP Olomouc* [online]. 2012 [cit. 2018-04-13]. Dostupné z: <http://pfyziolmysl.upol.cz/?p=2036>

Seznam příloh

Součástí BP je CD.

Adresářová struktura přiloženého CD/DVD: ukázky kódu, testovací snímky