

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2020

Alexandra Krajčiová



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

DETEKCE ANATOMICKY VÝZNAČNÝCH BODŮ V CT SNÍMCÍCH HLAVY

ANATOMY BASED LANDMARK DETECTION IN BRAIN CT SCANS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Alexandra Krajčiová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček

BRNO 2020



Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Alexandra Krajčiová

ID: 195190

Ročník: 3

Akademický rok: 2019/20

NÁZEV TÉMATU:

Detekce anatomicky význačných bodů v CT snímcích hlavy

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou zobrazování pomocí CT modality, anatomie hlavy a možnostmi vyšetření touto modalitou. Nastudujte techniky skenování hlavy - projekce ve směru orbitomeatální roviny. 2) Zpracujte literární rešerši na metody pro určení skenovacích rovin vycházející z automatické detekce anatomicky význačných bodů. Zaměřte se zejména na metody strojového učení. 3) Navrhněte vhodné postupy pro automatickou detekci význačných bodů s využitím právě metod strojového učení. Vytvořte učební množinu z dostupných CT dat mozku. 4) Zvolenou metodu realizujte a implementujte ve vybraném programovém prostředí. 5) Provedte statistické zhodnocení výsledků úspěšnosti detekce a optimalizujte parametry učení. 6) Diskutujte dosažené výsledky, vliv na určení skenovací roviny a přínosy navrženého algoritmu pro medicínu.

DOPORUČENÁ LITERATURA:

[1] ZHANG, Dongqing, et al. Automatic localization of landmark sets in head CT images with regression forests for image registration initialization. In: Medical Imaging 2016: Image Processing. International Society for Optics and Photonics, 2016. p. 97841M.

[2] GHAYOOR, Ali; VAIDYA, Jatin G.; JOHNSON, Hans J. Robust automated constellation-based landmark detection in human brain imaging. NeuroImage, 2017.

Termín zadání: 3.2.2020

Termín odevzdání: 5.6.2020

Vedoucí práce: Ing. Roman Jakubíček

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

UPOZORNĚNÍ:

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

ABSTRAKT

Manuálna detekcia anatomicky význačných bodov z CT snímok hlavy je časovo náročná úloha, náchylná na chyby pozorovateľa. Presnosť tejto detekcie navyše koreluje s kvalitou obrazu. Cieľom tejto práce je vytvorenie algoritmu, ktorý bude vykonávať automatickú detekciu anatomicky význačných bodov. Tieto anatomicky význačné body môžu byť neskôr použité pre vytvorenie rádiologických línií, čo nachádza svoje uplatnenie v CT skenovaní. Pre detekciu anatomicky význačných bodov bola zvolená metóda SVM (metóda podporných vektorov) v kombinácii s príznakmi HOG (histogramy orientovaných gradientov). V závere sú zhrnuté dosiahnuté výsledky a možnosti ďalšieho napredovania a zlepšenia detekcie.

KLÚČOVÉ SLOVÁ

anatomicky význačné body, detekcia, HOG, klasifikátory, klasifikácia obrazov, mozog, príznaky, rádiologické línie, strojové učenie, SVM, VGG-16, výpočtová tomografia

ABSTRACT

Manual detection of anatomical landmarks from head CT (Computed Tomography) scans is time-consuming task prone to observer errors. In addition, the accuracy of the detection correlates with image quality. The aim of this work is to create an algorithm that will perform automatic detection of anatomical landmarks. These landmarks can be later used to form radiological lines, which finds its application in CT scanning. SVM (Support Vector Machines) and HOG (Histograms of Oriented Gradients) features was chosen for anatomical landmark detection. The achieved results, possibilities of further progress and improvement of detection are summarized in the conclusion.

KEYWORDS

anatomical landmarks, brain, classifiers, computed tomography, detection, features, image classification, HOG, machine learning, radiological lines, SVM, VGG-16

KRAJČIOVÁ, Alexandra. *Detekce anatomicky význačných bodů v CT snímcích hlavy*. Brno, 2020, 97 s. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací. Vedúci práce: Ing. Roman Jakubíček

VYHLÁSENIE

Vyhlasujem, že svoju bakalársku prácu na tému „Detekce anatomicky významných bodů v CT snímcích hlavy“ som vypracovala samostatne pod vedením vedúceho bakalárskej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autorka uvedenej bakalárskej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto bakalárskej práce som neporušila autorské práva tretích osôb, najmä som nezasiahla nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomá následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákonníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autorky

POĎAKOVANIE

Rada by som srdečne poďakovala vedúcemu bakalárskej práce Ing. Romanovi Jakubíčkovi za to, že si našiel vždy čas na konzultácie, za jeho trpezlivosť, pedagogickú a odbornú pomoc a cenné rady, ktoré mi bol ochotný poskytnúť pri písaní mojej bakalárskej práce.

Obsah

Úvod	19
1 ANATÓMIA HLAVY	21
1.1 Anatomicky význačné body	22
2 VÝPOČTOVÁ TOMOGRAFIA	25
2.1 Definícia CT, Hounsfieldova jednotka	25
2.2 Vyšetrenie prostredníctvom CT modality	26
2.2.1 Priebeh vyšetrenia mozgu pomocou CT modality	26
2.2.2 Normálny obraz CT mozgu	26
2.2.3 Najčastejšie patologické nálezy	26
2.2.4 Indikácie a kontraindikácie CT vyšetrenia	27
2.3 Referenčné línie používané v neurorádiológii	27
2.3.1 Orbitomeatálna línia	29
2.3.2 Supraorbitomeatálna línia	29
2.3.3 Línia AC-PC	30
2.3.4 Reidova línia	31
2.3.5 TS-OP línie	31
2.3.6 Ďalšie používané línie	31
2.4 Klinické aplikácie uvedených rádiologických línií	32
3 STROJOVÉ UČENIE	33
3.1 Rozdelenie strojového učenia	33
3.1.1 Učenie s učiteľom	33
3.1.2 Učenie bez učiteľa	34
3.1.3 Kombinované učenie	34
3.1.4 Hlboké učenie	35
3.2 Strojové učenie v medicíne	36
3.3 Príznaky	37
3.3.1 Obecné rozdelenie príznakov	37
3.3.2 Príznaky ako body záujmu	37
3.3.3 Štatistické príznaky založené na pixeloch	38
3.3.4 Jasové príznaky vrátane farby	39
3.3.5 Príznaky textúry	39
3.3.6 Šedotónové matice vzájomného výskytu	40
3.3.7 Príznaky tvaru	40
3.4 Extrakcia príznakov	40

3.5	Typy detektorov a deskriptorov príznakov	41
3.5.1	Detekcia príznakov	42
3.5.2	Prehľad používaných deskriptorov	42
3.5.3	Prehľad používaných detektorov	43
3.6	Histogramy orientovaných gradientov	43
3.7	Selekcia príznakov	44
3.8	Klasifikátory	44
3.8.1	K-najbližších susedov	44
3.8.2	Naive Bayes algoritmus	45
3.8.3	Rozhodovacie stromy a náhodné lesy	45
3.8.4	Metóda podporných vektorov	46
3.8.5	Hlboké neurónové siete	49
3.8.6	VGG	49
4	LITERÁRNA REŠERŠ	51
5	VLASTNÉ RIEŠENIE	55
5.1	Návrh algoritmu detekcie	55
5.2	Dostupné dáta a ich príprava	55
5.3	Vytvorenie databázy	56
5.3.1	Výber detekčného algoritmu	56
5.3.2	Voľba klasifikátora	56
5.3.3	Extrakcia príznakov	57
6	IMPLEMENTÁCIA V PROGRAMOVOM PROSTREDÍ	59
6.1	Spracovanie vstupných dát	59
6.2	Tvorba učebnej databázy	59
6.3	Detekčný algoritmus	60
6.4	Extrakcia príznakov	61
6.5	Vytvorenie klasifikátora a proces detekcie	62
6.6	Testovanie navrhnutého detekčného algoritmu	62
6.7	Úprava procesu detekcie	63
6.8	Kontrola funkčnosti detektoru	64
6.9	Databáza pre vyhodnotenie	64
7	VYHODNOTENIE ALGORITMU	65
	Záver	69
	Literatúra	71

Zoznam symbolov, veličín a skratiek	81
Zoznam príloh	85
A Density tkanív	87
B Prehľad používaných detektorov	89
C Súhrn výsledkov	91
C.1 Výsledky VGG	91
C.1.1 Pacient 46	91
C.1.2 Pacient 47	93
C.2 Výsledky HOG	96
D Obsah prílohy	97

Zoznam obrázkov

1.1	Kostra lebky	21
1.2	Vnútorňý reliéf spodiny lebečnej	22
2.1	Fyziologický nález mozgu	27
2.2	Šesť referenčných línií pre axiálne zobrazovanie mozgu	28
2.3	Základné anatomické roviny	28
2.4	Priebeh AC-PC línie	30
2.5	Zobrazenie priebehu AC-PC línie	30
2.6	Línie TS-IOP a TS-EOP	31
2.7	CT topogramy mozgu	32
3.1	Lokálne príznaky	38
3.2	Lineárny model SVM pre klasifikáciu 2 tried	47
6.1	Príklad extrahovania pozitívnej detekcie	60
6.2	Príklad ručne segmentovaných detekcií	60
6.3	Genéza detekčného algoritmu.	61
7.1	Závislosť mIOU na detekčnom kroku pre pacienta 46	66
7.2	Príklad výstupu detekčného algoritmu SVM+VGG-16	67
7.3	Príklad výstupu detekčného algoritmu SVM+HOG	67
C.1	Závislosť aIOU na detekčnom kroku pre pacienta 47	95

Zoznam tabuliek


A.1	Denzita tkanív	87
C.1	VGG výsledky pre pacienta 46	91
C.2	VGG výsledky pre pacienta 46	92
C.3	VGG výsledky pre pacienta 47	93
C.4	VGG výsledky pre pacienta 47	94
C.5	HOG výsledky pre pacienta 46 a 47	96

Úvod

Táto bakalárska práca je venovaná tematike automatickej detekcie anatomicky významných bodov v CT snímkach hlavy. Cieľom tejto práce je vytvorenie algoritmu, ktorý bude vykonávať automatickú detekciu anatomicky významných bodov, ktoré budú neskôr použité pre vytvorenie rádiologických línií, čo nachádza svoje uplatnenie pri CT skenovaní. Podľa typu roviny, v ktorej sú CT snímky požadované, je zvolená referenčná línia na základe ktorej sú CT skeny vyhotovené. Každá referenčná línia je zložená z bodov, anatomických štruktúr, ktoré je na začiatku potrebné detegovať v pilotnom CT skene - tzv. scoute tak, aby po nasnímaní CT obrazov boli dôležité anatomické štruktúry v danej rovine zreteľné, a aby pri následnej interpretácii nedošlo k chybám spôsobeným neočakávaným náklonom obrazu. V súčasnosti je táto časovo náročná úloha v rukách rádiologických asistentov. Jeden z prínosov tejto bakalárskej práce spočíva v šetrení času, ktorý je cenný najmä v medicínskom prostredí. V rámci teoretickej časti tejto práce je prebraná problematika CT všeobecne, ale dôraz je kladený predovšetkým na CT techniky skenovania mozgu. Nadväzujúca časť sa zaoberá problematikou strojového učenia, a to najmä v oblasti spracovania obrazovej informácie. V tejto časti je rozobratá problematika príznakov, bližšie je priblížená metóda detekcie s dôrazom na detekčné algoritmy využívané v medicíne. Ďalšia časť je zhrnutím literárnej rešerše k problematike detekcie anatomických štruktúr v obraze, najmä v CT snímkach mozgu. Zobrazuje rôzne možnosti výberu detekčného algoritmu a zahrňuje kvality, nedostatky a získané presnosti týchto detekčných algoritmov. Posledná časť je už opisom praktickej časti práce, popisuje použité dáta a vybrané detekčné algoritmy, dosiahnutú presnosť, hodnotenie kvality týchto algoritmov a uvádza možnosti budúceho zlepšenia a rozšírenia práce.


1 ANATÓMIA HLAVY

Lebka (*lat. cranium*) sa obecné delí na dve základné časti, ktorými je tvárová časť (*lat. splanchnocranium*) a mozgová časť (*lat. neurocranium*). Hranica medzi týmito dvoma základnými časťami sa nachádza približne 1 cm nad koreňom nosa odkiaľ pokračuje pozdĺž nadočnicových oblúkov cez vonkajšie zvukovody k *protuberantia occipitalis externa*. Obe tieto časti sú ďalej zložené z väčšieho počtu kostí, ktoré sú znázornené na obr. 1.1 [1]



Obr. 1.1: Kostra lebky. 1 - cavum nasi, 2 - os zygomaticum, 3 - os frontale, 4 - os nasale, 5 - os lacrimale, 6 - maxilla, 7 - mandibula, 8 - ala major ossis sphenoidalis, 9 - sutura coronalis, 10 - os parietale, 11 - sutura squamosa, 12 - squama temporalis, 13 - sutura lambdoidea, 14 - os occipitale, 15 - processus mastoideus ossis temporalis, 16 - pars tympanica, 17 - processus styloideus, 18 - pons zygomaticus. Prevzaté z [1].

Mozgová časť lebky sa ďalej delí na vyklenutú klenbu lebečnú (*lat. calva*) tvoriacu pevný ochranný obal mozgu a spodinu lebečnú (*lat. basis cranii*). Mozog (*lat. cerebrum*) je často označovaný ako najzložitejší a najkomplexnejší orgán ľudského tela. Jeho štruktúra je pomerne komplikovaná, preto sa obmedzíme v tejto časti len na popis tých častí mozgu, ktoré sú najvýznamnejšie z hľadiska rádiologického zobrazovania a nastávajúcej detekcie. Keďže väčšina dôležitých bodov pre CT zobrazovanie hlavy sa nachádza v oblasti spodiny lebečnej a jej blízkom okolí, bude táto kapitola zameraná najmä na popis tejto oblasti. [1]



Obr. 1.2: Vnútorý reliéf spodiny lebečnej (*lat. basis cranii interna*).

1 - predná jama lebečná, 2 - canalis opticus, 3 - sella turcica, 4 - fissura orbitalis sup., 5 - foramen lacerum, 6 - foramen rotundum, 7 - foramen ovale, 8 - foramen spinosum, 9 - foramen magnum, 10 - canalis hypoglossalis, 11 - porus acusticus int., 12 - foramen jugulare, 13 - protuberantia occipitalis interna, 14 - ala minor, 15 - ala major, 16 - lamina cribrosa ossis ethmoidalis, 17 - os frontale - očnicová časť, 18 - predná plocha pyramídy, 19 - zadná plocha pyramídy Prevzaté z [1].

1.1 Anatomicky významné body

Medzi významné anatomické štruktúry pre CT zobrazovanie mozgu patria: *tuberculum sellae*, *protuberantia occipitalis interna*, *protuberantia occipitalis externa*, *commissura anterior*, *commissura posterior*, *meatus acusticus externus*, *orbita*.

Tuberculum sellae je malá vyvýšenina nachádzajúca sa v klinovej kosti obklopujúca z prednej strany anatomickú štruktúru, nazývanú turecké sedlo (*lat. sella turcica*). Táto vyvýšenina je lokalizovaná pred jamkou, v ktorej sa nachádza podmozgová žľaza (*lat. hypophysis*). Táto jamka je označovaná ako *fossa hypophysialis*. Hypofýza je drobná žľaza uložená z väčšej časti v spomínanej kostenej štruktúre nazývanej turecké sedlo. [2, 3]

Ďalšou významnou anatomickou štruktúrou v rádiológii je *protuberantia occipitalis externa*. Jedná sa o výčnelok nachádzajúci sa na externej strane záhlavnej kosti (*lat. os occipitale*). Na záhlavnej kosti sa nachádza tzv. záhlavná šupina (*lat. squama occipitale*), pričom *protuberantia occipitalis* leží presne v mieste najväčšieho vykle-

nutia tejto šupiny. Tento výčnelok je zreteľnejšie viditeľný na mužskej lebke. Pri pohľade na internú plochu záhlavnej šupiny môžeme pozorovať tzv. krížovú vyvýšenu (*lat. eminentia cruciformis*) a v jej centre leží *protuberantia occipitalis interna*. Tieto dve anatomické štruktúry sú spolu s *tuberculum sellae* podstatnými anatomickými štruktúrami pre zostrojenie TS-OP (*tuberculum sellae - occipital protuberance*) línií. [2, 4, 18]

Commissura anterior alebo predné mozgové spojenie je útvar, ktorý na sagitálnom reze mozgu vyzerá ako okrúhly biely útvar na frontálnej stene III. mozgovej komory. Prebiehajú ním nervové vlákna prepájajúce temporálne laloky oboch hemisfér. *Commissura anterior* je spolu s *commissura posterior* základom pre vytvorenie línie AC-PC (*commissura anterior - commissura posterior*), štandardnej referenčej línie pre zobrazovanie mozgu prostredníctvom magnetickej rezonancie. [3, 18]

Commissura posterior je významná anatomická štruktúra v rádiológii. Jedná sa o tenký, šikmý zväzok umiestnený pred epifýzou. Týmto zväzkom prechádzajú vlákna spájajúce zhodné oblasti oboch hemisfér, napr. komisurálne vlákna. Tento zväzok je fylogeneticky veľmi starý a jeho vykľutie smeruje dorzálne do III. mozgovej komory. [3, 5]

Vonkajší zvukovod (*lat. meatus acusticus externus*) je tvorený šupinou spánkovej kosti (*lat. pars squamosa*) a bubienkovou časťou spánkovej kosti (*lat. pars tympanica*). Určenie polohy vonkajšieho zvukovodu je v rádiológii dôležité pre vytvorenie Orbitomeatálnej línie (OML), referenčej línie pre CT skenovanie mozgu. [2, 18]

Očnica (*lat. orbita*) je stranovo symetrický, dutý, kostený priestor v lebke, v ktorom je uložené oko. Tvarovo tento útvar pripomína štvorbokú pyramídu, pričom báza tejto pyramídy je otočená dopredu a tvorí vstup očnice, hrot naopak smeruje dozadu a zľahka mediálne. [2, 4]

Ďalší anatomický bod dôležitý pre následnú detekciu je vonkajší kútik oka (*lat. angulus oculi lateralis*) popisovaný ako bod, v ktorom sa spája horné a dolné očné viečko. Orbita je druhým bodom, na ktorom je založené vytvorenie orbitomeatálnej línie. [6, 11, 18]

2 VÝPOČTOVÁ TOMOGRAFIA

Počítačové metódy v medicínskom zobrazovaní umožňujú náhľad do ľudského tela so zámerom zjednodušiť diagnostiku. Medzi najdôležitejšie techniky medicínskeho zobrazovania patria: *výpočtová tomografia* (CT) a *zobrazovanie magnetickou rezonanciou* (MRI). Medicínske zobrazovacie metódy, ku ktorým patrí napríklad CT, MR a RTG zobrazovanie, sú zdrojmi medicínskej obrazovej informácie, ktorú je možné ďalej využiť pre diagnostiku rôznych patológií. [27, 49]

Výpočtová tomografia (*angl. Computed Tomography*) je v dnešnej dobe už štandardnou zobrazovacou metódou používanou v medicíne. Jedná sa o prvú zobrazovaciu metódu, ktorá zachytila mozgové tkanivo *in vivo* a bolo pomocou nej možné rozlíšiť bielu a šedú mozgovú hmotu. [7, 8]

2.1 Definícia CT, Hounsfieldova jednotka

CT je zobrazovacia metóda využívajúca Röntgenové žiarenie, ktoré je prechodom cez tkanivá rozdielnej hustoty (spôsobenej rozdielnym zložením) absorbované s rôznou mierou. Intenzita útlu je potom matematicky popísaná prostredníctvom denzity v Hounsfieldovej škále. Hounsfieldove jednotky vznikli porovnaním denzity skúmaného tkaniva v porovnaní s denzitou vody, ktorá má hodnotu 0 HU. [8, 10, 13, 15]

Hounsfieldova škála má rozpätie približne -1000 až $+3096$ HU. Avšak v medicínskom zobrazovaní sa využíva len určitý výsek tejto škály. Denzity tkanív, ktoré najviac súvisia s CT zobrazovaním mozgu sú k nahliadnutiu uvedené v prílohe A v tabuľke A.1. [10, 15]

Rôzne hodnoty denzity sú potom vo výslednom obraze znázornené na základe rôzneho stupňa šedi. Ľudské oko však nie je schopné registrovať toľko odtieňov šedej farby a preto sa volia len určité rozsahy hodnôt, ktoré sa nazývajú okná. Tým, že si vyberieme menší rozsah hodnôt, dokážeme niektoré typy tkanív od seba jednoduchšie odlíšiť. Pre lepšie zobrazenie kostných štruktúr sa používa tzv. kostené okienko, nazývané aj široké, ktorého rozsah je približne 1200 až 3000 HU. Naopak, ak chceme detailnejšie znázorniť mäkké tkanivá, použijeme mäkko-tkanivové okienko (*angl. soft window*). Jeho rozsah sa pohybuje v rozmedzí 150 až 500 HU. Podľa druhu anatomickej lokality sa zvolí vhodná kombinácia technických parametrov, so zámerom dosiahnutia čo najlepšieho zobrazenia štruktúr nachádzajúcich sa v tejto lokalite. Pre lepšie hodnotenie obrazu sa používajú denzity v oblasti záujmu (*angl. Regions Of Interest - ROI*) a možnosť spätnej rekonštrukcie obrazu i v iných obrazových rovinách. [7, 8, 9, 10, 13, 15, 16]

2.2 Vyšetrenie prostredníctvom CT modality

Nesmiernymi výhodami tejto metódy sú rýchlosť, dostupnosť, výborná priestorová rozlišovacia schopnosť a možnosť vykonania virtuálneho 3D prípadne 4D vyšetrenia. Medzi jej najväčšie výhody však patrí jej zaradenie medzi neinvazívne diagnostické metódy. CT má však i značnú nevýhodu a to, že pracuje s ionizujúcim žiarením a preto pre vyšetrenie prostredníctvom tejto modality platí princíp ALARA (*angl. „As Low As Reasonably Achievable“*). Tento princíp teda vyjadruje určitý optimalizačný princíp, ktorý pri práci s ionizujúcim žiarením platí a ktorý by sme mohli vyjadriť tým, že dávky žiarenia by mali byť čo najnižšie ako je rozumne dosiahnuteľné. [7, 8, 10, 11, 16]

2.2.1 Priebeh vyšetrenia mozgu pomocou CT modality


Pacient si ľahne v supinačnej polohe na stôl s hlavou uloženou v opierke hlavy. K správne položeniu pacienta dochádza pomocou laserových svetiel - axiálneho, koronárneho a sagitálneho tak, aby pacient ležal presne uprostred skeneru. Aby bola lebka správne zobrazená, je potrebné skontrolovať, či vonkajšie zvukovody majú na oboch stranách rovnakú vzdialenosť voči opierke hlavy. [11]

2.2.2 Normálny obraz CT mozgu

Tkanivá viditeľné na CT snímkach mozgu by mali mať denzity približne odpovedajúce hodnotám uvedených v tab. A.1 v prílohe A. CT nález by nemal obsahovať žiadne krvné zrazeniny, kalcifikácie ani rozsiahle čerstvé krvácanie. Pri kontrole CT skenov je potrebné dbať na to, aby na náleze neboli žiadne fraktúry, lézie a aby všetky štruktúry odpovedali fyziologickému nálezu. [7, 9, 11]

2.2.3 Najčastejšie patologické nálezy

Zmeny v komorovom systéme patria medzi najčastejšie patologické nálezy na CT snímkach. Ide najmä o zmeny týkajúce sa pozície a tvaru. K týmto zmenám môže dochádzať v dôsledku prítomnosti nádoru, krvácania prípadne hematómu. Ďalšími častými nálezmi sú zmeny v denzite. Na CT obraze sú viditeľné buď ako prejasnenia (hyperdenzné útvary) alebo ako tmavšie miesta (hypodenzné útvary). K hyperdenzným zmenám patria čerstvé krvácania, výdatne prekrvené nádory a kalcifikácie. Naopak hypodenzne sa prejavuje nekróza, zápal, markantné zväčšenie objemu tekutín, napr. mozgovomiechového moku a ďalšie. Po podaní kontrastnej látky môže dochádzať k zvýrazneniu niektorých typov patologických štruktúr, napríklad určité typy tumorov a cievne malformácie. [7, 8, 9, 10]



Obr. 2.1: Fyziologický obraz CT mozgu. Prevzaté z [10].


2.2.4 Indikácie a kontraindikácie CT vyšetrenia

Medzi jediné kontraindikácie CT zobrazovania patrí v podstate alergia na kontrastnú látku, ktorá však v praxi nie je až tak častá a taktiež nie je súčasťou každého vyšetrenia. Ako relatívna kontraindikácia je uvádzané tehotenstvo. O niečo lepšie zobrazovanie z hľadiska špecificity a senzitivity poskytuje magnetická rezonancia (MR), avšak sú prípady, kedy je vyšetrenie prostredníctvom CT modality vhodnejšie. Takýmto prípadom môže byť napríklad akútne krvácanie, ktoré je práve lepšie viditeľné na CT obrazoch. CT hrá významnú rolu v diagnostike cievnych mozgových príhod a taktiež sa uprednostňuje v urgentných prípadoch a v prípadoch akútnej traumy vzhľadom na menšiu časovú náročnosť a lepšiu dostupnosť tohto vyšetrenia v porovnaní s magnetickou rezonanciou. CT je taktiež metódou prvej voľby v prípadoch, kedy je vyšetrenie prostredníctvom MR z nejakej príčiny kontraindikované. [7, 8, 10, 11, 16]

2.3 Referenčné línie používané v neurorádiológii


Dôležitou súčasťou práce rádiológov pri zobrazovaní pomocou výpočtovej tomografie, prípadne magnetickej rezonancie je určenie vhodného zobrazovacieho uhla v danej zobrazovacej rovine. [30]

Pri zobrazovaní pomocou magnetickej rezonancie sa bežne využíva šesť zobrazovacích uhlov pre zobrazovanie v axiálnej rovine, pričom každý uhol je určený referenčnou líniou. Pre určenie referenčnej čiary je potrebné vybrať príslušné referenčné body - anatomicky význačné štruktúry. Výber týchto bodov sa ideálne vykonáva na sagitálnom reze mozgu. [30]



Obr. 2.2: Šesť referenčných línií pre axiálne zobrazovanie mozgu. Prevzaté z: [30].

Zobrazovanie v rádiológii rešpektuje terminológiu základných anatomických rovin popísaných na obr. 2.3.



Obr. 2.3: Základné anatomické roviny. Prevzaté z [11].

Medzi 6 líniami najčastejšie používaných pre axiálne skenovanie mozgu prostredníctvom magnetickej rezonancie patria: supraorbitomeatálna línia (SML), orbitomeatálna línia (OML), AC-PC línia (*commissura anterior (AC) - commissura posterior (PC)*), subkalózna línia (*angl. subcallosal line - SC*), Reidova základná línia a línia mozgového kmeňa. Na obr.2.2 môžeme pozorovať týchto 6 referenčných línii pre axiálne zobrazovanie mozgu a rozdiely medzi nimi. Možnosť zobrazovania z rôznych uhlov je veľmi dôležitá, pretože umožňuje náhľad na rôzne štruktúry a vzťahy medzi nimi. [30]

2.3.1 Orbitomeatálna línia


Pravdepodobne najznámejšou a zároveň najdôležitejšou referenčnou líniovou pre CT skenovanie mozgu je orbitomeatálna línia - OML (*angl. orbitomeatal line*). OM línia sa stala štandardnou líniovou pre CT zobrazovanie. Jedná sa o líniu, ktorá spája stred vonkajšieho zvukovodu s vonkajším kútikom oka. K CT skenovaniu mozgu potom dochádza paralelne s touto líniovou. Výhoda tejto metódy spočíva v jej relatívne jednoduchom rozpoznaní na topograme mozgu. V praxi sa zistilo, že použitie tejto línie má svoje limitácie a nevýhody. Medzi nedostatky OM línie patrí zložité rozpoznanie jej priebehu z laterálneho pohľadu. Ako značná limitácia sa ukázala i nemožnosť okamžitého porovnania takto nasnímaných axiálnych CT snímok mozgu s axiálnymi snímkami získanými z magnetickej rezonancie, pretože táto línia má veľký odklon od línie konvenčne používanej pre snímanie mozgu magnetickou rezonanciou. Odklon od línie používanej na magnetickej rezonancii sa udáva až okolo hodnoty 16°. Ďalší zreteľný nedostatok tejto metódy spočíva v anatomických bodoch, o ktoré sa metóda opiera. Vzhľadom na to, že tieto anatomické body sú uložené extrakraniálne, môžu sa objaviť problémy pri jej využití v aplikácii na hlboko uložené anatomické štruktúry mozgu. V prípade výberu OM línie ako referenčnej línie pri MR zobrazovaní a porovnaním získaného obrazu danej oblasti s CT obrazom tejto oblasti, môžeme pozorovať vzájomnú koreláciu týchto obrazov. Táto súvislosť je veľmi výhodná najmä u pacientov, ktorých zdravotný stav vyžaduje sledovanie progresie a v prípadoch, kedy dochádza k striedaniu zobrazovacích modalít. V týchto prípadoch teda volíme pre zobrazovanie v axiálnej rovine OM líniu. [18, 30]

2.3.2 Supraorbitomeatálna línia


Supraorbitomeatálna línia (*angl. supraorbitomeatal line - SML*) prebieha ponad orbitu (na sagitálnom reze sa tento bod javí ako najviac dopredu klenutý na superiornej stene orbity) a centrum vonkajšieho zvukovodu. Táto línia nachádza svoje použitie v prípadoch, kedy sa chceme vyhnúť nežiaducemu ožiareniu orbity vzhľadom na to, že táto čiara vedie mimo nej. [18, 30]

2.3.3 LÍNIA AC-PC

I napriek návrhu viacerých nových línii, štandardnou líniou pre zobrazovanie mozgu prostredníctvom magnetickej rezonancie naďalej ostáva línia AC-PC (*lat. commissura anterior - commissura posterior*). AC-PC línia prechádza cez horný okraj *commissura anterior* a dolný okraj *commissura posterior*. Táto línia nemôže byť použitá ako referenčná línia na CT, pretože jej základné anatomické štruktúry - *commissura anterior* a *commissura posterior* sú na CT obrazoch náročne lokalizovateľné. Z tohto dôvodu ostala OM línia naďalej tradične využívanou líniou. Pre porovnanie, odklon tejto línie od OM línie sa udáva približne 9° - 12° . Táto línia však našla svoje využitie v magnetickej rezonancii, pre ktorú sa stala konvenčnou referenčnou líniou. [18, 30]



Obr. 2.4: Priebeh AC-PC línie. Prevzaté z [19].




Obr. 2.5: Zobrazenie priebehu AC-PC línie. Prevzaté z [61].

2.3.4 Reidova línia

Obdobou OM línie je tzv. Reidova línia, ktorá sa niekedy označuje ako nižšia orbitomeatálna línia. Jedná sa o líniu prechádzajúcu od dolného okraju očnice k vonkajšiemu zvukovodu. Táto línia je tiež jednou z často používaných línií pre CT skenovanie mozgu. Vzhľadom na to, že sa od OM línie veľmi nelíši, sú i jej nevýhody obdobné. [18, 30]

2.3.5 TS-OP línie

Meraniami bolo zistené, že TS-OP (*tuberculum sellae - protuberantia occipitalis*) línie sú línie, ktorých priebeh je takmer rovnobežný s líniou AC-PC, ale využívajú iné anatomické body. Použitie línií tohto typu je výhodné pre CT skenovanie mozgu, pretože uľahčuje a upresňuje porovnanie týchto obrazov s obrazmi poskytovanými magnetickou rezonanciou. To je podstatné pre niektoré klinické aplikácie. Používajú sa 2 typy TS-OP línií: TS-IOP (*tuberculum sellae – internal occipital protuberance*) línia a TS-EOP (*tuberculum sellae – external occipital protuberance*) línia. [18]



Obr. 2.6: Línie TS-OP A) TS-IOP, plnou šípkou označené *tuberculum sellae*, prerušovanou šípkou označená *protuberantia occipitalis interna*; B) TS-EOP, prerušovanou šípkou označená *protuberantia occipitalis externa*. Prevzaté z [18]

2.3.6 Ďalšie používané línie

Vzhľadom na nevýhody, ktoré CT zobrazovanie mozgu na základe OM línie prináša boli navrhnuté a skúmané ďalšie referenčné línie používané v neurorádiológii. [18]

Nedostatky spojené s vyššie zmienenými líniami sa pokúšali vyriešiť i autori v práci [19]. Navrhnutý postup bol založený na detekcii tvrdého podnebia a odklonení referenčnej línie o 12° od tejto štruktúry. Širokému používaniu tejto línie zabránil fakt, že praktické lokalizovanie jej priebehu predstavuje veľmi náročnú úlohu. [19]

2.4 Klinické aplikácie uvedených rádiologických línii

AC-PC línia je líniou najčastejšie používanou pri vyšetovaní magnetickou rezonanciou. OM línia je zase líniou, ktorá sa najčastejšie používa pri CT zobrazovaní. Supraorbitomeatálna línia (SML) je používaná v prípadoch, kedy je vhodné vyhnúť sa ožiareniu orbity. Pre vyšetovanie roztrúsenej sklerózy sa odporúča použitie subkalóznej (SC) línie. Reidova línia je vhodná pre zobrazovanie pri podozrení na lézie v orbitálnej kavite, paranasálnej dutine alebo na lebečnej báze. [30]



Obr. 2.7: A) CT topogram mozgu na základe OM línie, B) čiernou šípkou je označená *commissura posterior*, C) CT topogram mozgu na základe TS-OP línie, D) bielou šípkou je označená *commissura anterior*, čiernou šípkou je označená *commissura posterior*. Prevzaté z [18]

3 STROJOVÉ UČENIE

Strojové učenie patrí do oblasti umelej inteligencie. Toto zaradenie vyplýva z paralely medzi učením strojov a prácou ľudského mozgu, ktorý bol inšpiráciou pre vytvorenie algoritmov strojového učenia. Jedna z definícií umelej inteligencie ju vysvetľuje ako počítačovú metódu, ktorá vykonáva úlohu, pre realizáciu ktorej je normálne potrebná ľudská inteligencia. Strojové učenie je teda podmnožinou umelej inteligencie, pričom sa jedná o algoritmus, ktorý umožňuje počítačom učiť sa z existujúcich dát bez presného programovania. Príkladom strojového učenia môžu byť rôzne klasifikačné úlohy, zhukovanie, regresia a ďalšie. Ako príklad strojového učenia v oblasti počítačového videnia môžeme uviesť extrakciu určitých zmysluplných príznakov z obrazov a ich využitie pre následnú klasifikáciu týchto obrazov. Strojové učenie pre medicínske aplikácie obvykle začína výpočtom príznakov, o ktorých sa predpokladá, že sú kľúčové pre následnú diagnostiku alebo predikciu. Niektoré algoritmy strojového učenia dokonca dokážu vidieť aj príznaky, ktoré sú mimo vnímania ľudského oka. [20, 27, 32, 42, 44, 45]

3.1 Rozdelenie strojového učenia

Najčastejším delením strojového učenia je delenie na učenie s učiteľom a učenie bez učiteľa. V prípade učenia s učiteľom existujú určité vstupné označené dáta, použité pre tréning algoritmu. Príkladom takýchto vstupných dát môžu byť súbory CT skenov mozgu označené neurológmi do viacerých kategórií, napríklad na základe vyskytujúcej sa patológie. Na druhej strane učenie bez učiteľa nepožaduje žiadne označené vstupné tréningové dáta. Tretou kategóriou strojového učenia je semi-supervised learning. Jedná sa o algoritmus predstavujúci kategóriu medzi oboma vyššie zmienenými kategóriami. [24, 29, 32, 47]

3.1.1 Učenie s učiteľom

Ako už bolo uvedené vyššie, učenie s učiteľom (*angl. supervised learning*) je vlastne súborom algoritmov strojového učenia, ktoré pre svoj tréning vyžadujú vopred označené tréningové dáta. V klinických aplikáciách je dôležité dbať na to, aby tieto dátové označenia pochádzali od experta v danej aplikačnej oblasti. Proces učenia s učiteľom je možné pre jeho popis rozdeliť na dve základné časti. Prvú časť by sme mohli pracovne nazvať tréningová časť, ktorá zahŕňa využitie tréningových vzoriek s príslušným označením pre zostavenie klasifikátora, ktorý na základe určitých parametrov vytvorí rozdeľovacie hranice pre klasifikáciu medzi triedami. Druhá časť

tohto procesu už pozostáva z využitia klasifikátora naučeného na tréningových dátach pre predikciu označenia tried neznámych testovacích vzoriek. Klasifikátory sú dobrým príkladom algoritmu založeného na učení s učiteľom. V medicíne môže ísť napríklad o klasifikácie obrazov na patologické prípadne fyziologické. Ako príklady algoritmov založených na učení s učiteľom môžeme uviesť SVM (*angl. Support Vector Machines*), DT (*Decision Tree*), kNN (*angl. k-Nearest Neighbors*), RF (*angl. Random Forest*) alebo neurónové siete. [20, 24, 32]

3.1.2 Učenie bez učiteľa

Učenie bez učiteľa (*angl. unsupervised learning*) pracuje bez toho, aby na začiatku do algoritmu vstupovali označené tréningové vzorky. Algoritmus sám hľadá podobnosti v dátach na základe určitej vnútornej paralely, ktorej voľba vyplýva z výberu typu algoritmu učenia bez učiteľa. Najčastejšie používaný algoritmus zaraďovaný do tejto skupiny strojového učenia je zhľukovanie. Zhľukovanie je algoritmus, ktorý dokáže dáta rozdeliť do skupín na základe určitých metrík podobnosti bez toho, aby bolo jasne stanovené na základe čoho bude k triedeniu dochádzať. Príkladom využitia učenia bez učiteľa pre klinické aplikácie môže byť uvedené fuzzy zhľukovanie, ktoré v rámci medicínskych aplikácií bolo použité pre automatickú detekciu mozgového tumoru. Tento algoritmus sa ukázal ako úspešný pre zoskupenie zdravého a tumorózneho tkaniva. Vzhľadom na veľký nárast použitia klinického zobrazovania je automatická anotácia obrazov veľmi výhodná. Učenie bez učiteľa teda predstavuje sľubnú časť využitia strojového učenia pre medicínu. [20, 21, 24, 28, 29, 32, 44, 47]

3.1.3 Kombinované učenie

Tretím variantom strojového učenia je učenie, ktoré sa v angličtine označuje ako *semi-supervised learning*. Táto metóda strojového učenia bola navrhnutá a využíva sa najmä pre úlohy, kde je náročné získať klasifikačné označenia pre jednotlivé triedy prípadne je počet označených dát limitovaný. V medicínskych aplikáciách sa často stretávame s náročným označením niektorých stavov pacientov. Príkladom takejto situácie môže byť označenie vývoju nádoru prípadne iného ochorenia. Tento typ strojového učenia využíva pre svoj tréning nielen neoznačené dáta ale i tie označené, ktorých je ale obyčajne len pár. Táto metóda teda disponuje výhodou oproti učeniu s učiteľom, ktorou je jej funkčnosť i v prípade chýbajúcich označení v tréningových dátach. Tieto modely nachádzajú teda svoje uplatnenie v klinických aplikáciách, pri ktorých nie je možné poskytnúť pre tréning všetky označenia tréningových dát. Ako príklad konkrétnej aplikácie tejto metódy môže byť spomenutá predikcia štádia vývoja mozgového nádoru. [24, 29, 47]

3.1.4 Hlboké učenie

Hlboké učenie (*angl. deep learning*) predstavuje veľmi silnú a v dnešnej dobe široko využívanú metódu strojového učenia. Hlboké učenie je druh strojového učenia, ktorého architektúra bola inšpirovaná štruktúrou neurónov ľudského mozgu. Táto metóda sa ukázala ako veľmi výhodná pre riešenie mnohých problémov počítačového videnia. V súčasnosti sa jedná o jeden z najvyužívanejších algoritmov strojového učenia vzhľadom na jeho viaceré výhody, medzi ktoré patrí najmä jeho výborný výkon pre rozmanité aplikácie počítačového videnia. V posledných rokoch došlo k rozsiahlemu preniknutiu tohto algoritmu aj do medicínskej sféry a tento algoritmus je často aplikovaný pri spracovaní medicínskych obrazov. Jedno z najčastejších odvetví použitia hlbokého učenia v medicíne je neurorádiológia. [24, 32, 42, 45, 47, 48]

Táto metóda má sieťovú architektúru zloženú z viacerých vrstiev. Jedná sa o modely s výborným výkonom, ale ich nevýhodou je, že pre správne naučenie vyžadujú veľmi veľkú tréningovú databázu na vstupe algoritmu. Tu môžeme naraziť na problém najmä u klinických patientskych dát, ktoré nie je tak jednoduché vyhotoviť ako dáta z iných experimentov, kde opakovanie nie je tak náročné a obmedzené, ako je tomu napríklad u rádiologického zobrazovania. Ďalším problémom je legislatíva a poskytovanie patientskych dát na účely výskumu. Je potrebná určitá anonymizácia týchto dát, pretože sa jedná o citlivé informácie, ktoré by mali byť chránené pred prípadným zneužitím. Obmedzením vytvorenia efektívneho a spoľahlivého modelu hlbokého učenia pre použitie v medicíne je teda dostupnosť dostatočného množstva označených medicínskych dát. [24, 32, 33, 42, 45]

Aplikáciou hlbokého učenia na medicínske obrazy algoritmus prijme obrazovú informáciu ako vektor zložený z intenzít voxelov, pričom každý voxel slúži ako vstupný neurón. Pri vytváraní neurónovej siete je potrebné dobre zvoliť jej architektúru, ktorú opisujú dva základné parametry. Prvým parametrom je hĺbka siete, ktorá vyjadruje počet vrstiev neurónovej siete a druhým parametrom je počet neurónov na vrstvu, ktorý udáva aká široká sieť bude. Každý neurón takejto siete uchováva určitú hodnotu a každé prepojenie medzi neurónmi predstavuje váhu. [32, 42, 48]

Veľkou výhodou tohto algoritmu je jeho schopnosť automaticky extrahovať dôležité príznaky. Do algoritmu strojového učenia teda stačí vložiť označené vstupné dáta a algoritmus na ich základe automaticky vyberie dôležité príznaky pre požadovanú klasifikačnú úlohu. Hlboké učenie je teda typom strojového učenia, ktoré je svojim fungovaním blízke učeniu s učiteľom, avšak využíva špeciálnu architektúru, presnejšie ide o formu neurónovej siete. Hlboké učenie umožnilo vytvoriť klasifikátor automaticky z označených dát v oveľa kratšom časovom úseku, ako tomu bolo u klasického strojového učenia. Príkladom algoritmu hlbokého učenia môžu byť konvolučné neurónové siete. [32, 42, 45, 48]

Konvolučné neurónové siete (CNN) sú modelom hlbokého učenia, ktorý zahŕňa zretázané konvolučné vrstvy a združovacie vrstvy (*angl. pooling layers*), po ktorých nasledujú plne spojené vrstvy (*angl. fully-connected layers*). Výsledkom takejto konfigurácie vrstiev je dobrá reprezentácia vstupných dát. Tento algoritmus preukázal dobré výsledky i v medicínskych aplikáciách vďaka čomu vzrastá počet štúdií zaoberajúcich sa touto tematikou a vďaka čomu sa tieto siete zaradili k jedným z najčastejšie používaných modelov hlbokého učenia v aplikáciách na medicínske obrázky. Príkladom využitia CNN v medicíne môže byť aplikácia tohto modelu pre segmentáciu mozgových tumorov. [20, 24, 48]

3.2 Strojové učenie v medicíne

Rozpoznanie obrazov a ich klasifikácia má svoje využitie i v medicíne. Výhodou nahradenia ľudského experta umelou inteligenciou je potlačenie ľudských faktorov ako je únava, rozptýlenie, nálada, rozdiel medzi rozhodovaním o závažných a nezávažných diagnózach a ďalšie. Strojové učenie teda umožňuje zvýšenie presnosti pri interpretácií nálezov z medicínskych obrazov. Jeho hlavnou výhodou však je zníženie času potrebného pre túto interpretáciu. Interpretácia obrazu je v ľudskom podaní obmedzená i prítomnosťou šumu. Presnosť interpretácie teda koreluje s obrazovou kvalitou, čo je obzvlášť dôležité v medicíne. Pri zlej obrazovej kvalite môže dôjsť k nesprávnej diagnostike stavu pacienta, čím môže byť ovplyvnený jeho zdravotný stav. Použitie strojového učenia v medicíne teda vedie k objektivizácii diagnostického procesu. Nárast množstva dát v medicíne umožnil použitie AI i v tomto obore. Najväčší vplyv mal tento nárast v rádiologickom zobrazovaní, kde použitie AI viedlo k vyššej efektívnosti, redukcii subjektivity a úspore času. [33, 42, 45]

Počítačové videnie a strojové učenie prinášajú do medicíny nový uhol pohľadu. Zaujímavou novou možnosťou využitia je radiomika, ktorá pomocou metód strojového učenia extrahuje kvantitatívne príznaky z klinických obrazov, s cieľom využitia týchto príznakov ako kvantitatívne zobrazovacie prediktívne biomarkery pre diagnostiku, prognózu a terapeutické plánovanie. [20, 24, 33, 42]

V dnešnej dobe sa už relatívne často môžeme stretnúť so slovným spojením počítačom podporovaná diagnostika (*angl. computer-aided diagnosis*). Tento pojem označuje také systémy, ktoré s využitím počítačov pomáhajú uľahčovať a spresňovať diagnostický proces. Tieto systémy sú špeciálne upravené podľa funkcie, pre ktorú sú určené. V poslednom čase vzrastá záujem o tieto systémy a mnoho výskumov sa zaoberá touto tematikou. Okrem použitia strojového učenia na medicínske obrázky je zaujímavý taktiež jeho eventuálne využitie predikciu ochorení i z iných dát a taktiež pre predpisovanie vhodných liečiv a vedenú terapiu. [20, 31, 33, 42, 45, 48, 49]

3.3 Príznyaky

Príznyaky sú dôležitou súčasťou počítačového videnia. Definícia príznaku sa v strojovom učení vždy viaže na konkrétne použitie. Obrazovými príznakmi môžeme zjednodušene nazývať určité zaujímavé časti v obraze, prípadne nimi označujeme určitú vlastnosť obrazu, ktorú je možné kvantifikovať a použiť ju pre popis obrazu. Príznakom je teda označovaná metrika, poprípade určitá kvantifikovateľná hodnota slúžiaca ako charakteristika obrazu. Ako príklady vlastností obrazu môžeme uviesť farbu, textúru, tvar, hrany, rohy a ďalšie. Pre dobrý popis obrazu je teda podstatné nájsť také vlastnosti, ktoré budú obraz čo najpresnejšie popisovať. Tieto vlastnosti budú teda pre daný obraz typické, výstižné a budú opakovateľné, aby bolo možné ich zaznamenanie aj z iných obrazov a za iných zobrazovacích podmienok. Tým sa zaistí možnosť využitia príznakov k porovnaniu obrazov a detekcii určitých objektov záujmu v obrazoch. [20, 22, 23, 33, 43]

3.3.1 Obecné rozdelenie príznakov

Príznyaky môžu byť rozdelené do dvoch základných kategórií a to na lokálne a globálne príznaky. [43]

Globálne príznaky popisujú vstupný obraz ako celok, prípadne jeho väčšiu časť. Jedná sa teda o vlastnosti, ktorých výpočet sa počíta z veľkého počtu pixelov, často z celého obrazu. Tieto vlastnosti môžeme označiť ako štatistické informácie, ktoré sú prostredníctvom jedného vektora schopné poskytnúť zovšeobecnený popis určitých vlastností obrazu. Ako príklady globálnych príznakov môžeme uviesť energiu, entropiu, koreláciu. Často sa tiež vyskytujú globálne príznaky spojené s textúrou a farbou, najčastejšie sa jedná o histogramy farby. Ďalším dobrým príkladom je priemerná intenzita obrazu, inverzný rozdielový moment a ďalšie. [41, 43]

Lokálnymi obrazovými príznakmi môžeme označiť špecifické vzory v obraze vyznačujúce sa určitou jedinečnosťou oproti pixelom, ktoré sa nachádzajú v blízkom okolí. Jedinečnosť v tomto prípade označuje vlastnosti obrazu ako sú rohy, kraje, oblasti a niektoré ďalšie. [24, 41, 51]

3.3.2 Príznyaky ako body záujmu

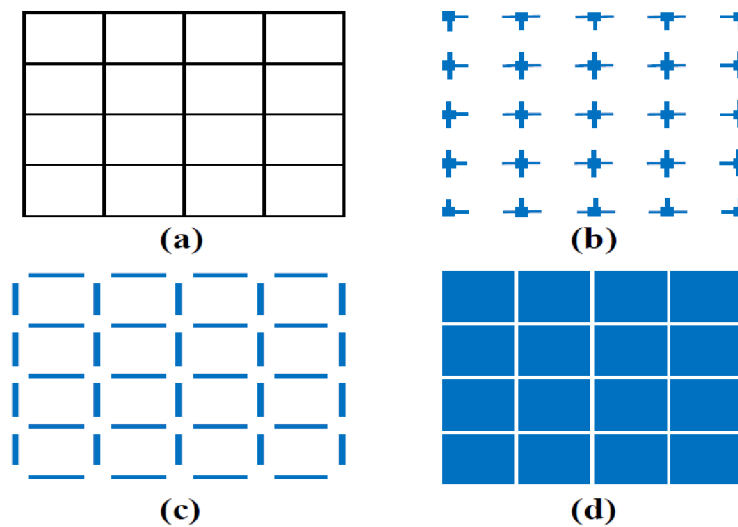
Pre dobrý popis obrazov sú podstatné určité lokálne vlastnosti týchto obrazov. Ako príklady takýchto vlastností môžeme uviesť: hrany (*ang. edges*), rohy / body záujmu (*ang. corners / interest points*), oblasti záujmu (*regions of interest / škvryny (ang. blobs)*), vrcholy (*ang. ridges*). [22]

Roh v obraze znamená bod, v ktorom sa stretávajú aspoň 2 hrany. [41, 51]

Hranou alebo okrajom rozumieme pixely, na ktorých dochádza k značnej zmene intenzity, t.j. zmena intenzity s veľkým gradientom. Porovnaním susedných pixelov môžeme pozorovať viditeľné rozdiely v ich intenzite. Ide teda o body, ktoré sa nachádzajú na hranici medzi rôznymi oblasťami. [41, 22, 51]

Oblasťami sa označujú lokálne, menšie uzavreté skupiny prepojených bodov vyznačujúce sa určitým typom homogenity (najčastejšie sa jedná o homogenitu hodnôt intenzity). [51]

Škvrny (*ang. blobs*) sú v podstate podkategóriou príznakov oblastí. Na základe tohto typu príznakov môžeme získať doplnkové informácie o štruktúre obrazov. Blob detektory dokážu detegovať i také oblasti v obraze, ktoré vzhľadom na ich plynulosť nie sú iné detektory schopné detegovať. [58]



Obr. 3.1: Lokálne príznaky a) vstupný obraz, b) rohy, c) hrany, d) oblasti. Prevzaté z [51]

3.3.3 Štatistické príznaky založené na pixeloch

Kvantitatívne informácie o pixeloch v segmentovanej oblasti môžeme získať prostredníctvom tzv. štatistických príznakov založených na pixeloch (*angl. Statistical Pixel-Level*) (SPL). Ide o kvantitatívne vyjadrenie vlastností oblasti obrazu ako napríklad: stredná hodnota, rozptyl a histogramy šedých hodnôt pixelov v určitej oblasti obrazu. Okrem toho môžeme prostredníctvom týchto príznakov získať informácie o kontraste pixelov, prípadne gradienty hrán hraničných pixelov v obrazovej oblasti. [49]

3.3.4 Jasové príznaky vrátane farby

Farba patrí medzi jeden z najčastejšie používaných príznakov pre popis obrazov a videí. Príznaky farby majú nesmiernu výhodu voči iným typom príznakov, a to že sú odolné a nezávislé na orientácii a veľkosti obrazu. Môžu byť teda použité na popis statických obrazov i video obsahu. Farba je jednou zo základných vlastností obrazu. Využitie farby ako príznaku pre identifikáciu objektu v obraze je veľmi výhodné vzhľadom na odolnosť tejto obrazovej vlastnosti voči rotácii, skoseniu a zmenám mierky obrazu. Jej využitie pre popis medicínskych obrazov je však značne limitované. Pre popis farby v obraze sa najčastejšie používajú histogramy. Histogramy predstavujú rozdelenie počtu pixelov pre daný obraz. Počet zložiek v histograme závisí na počte bitov v každom pixely daného obrazu. Najčastejšie typy používaných histogramov sú: RGB histogramy, Opponent histogramy, Hue histogramy. Okrem histogramov sa pre deskripciu farby uvádzajú farebné SIFT deskriptory. [23]

3.3.5 Príznaky textúry

Príznaky textúry môžu byť pre detekciu objektov v obrazoch veľmi užitočnými vlastnosťami. Pre textúru je ťažké nájsť nejakú výstižnú definíciu, preto ju môžeme charakterizovať na základe vlastností, ktoré tieto deskriptory kvantifikujú. Sú nimi drsnosť, jemnosť a pravidelnosť obrazovej oblasti. Textúra označuje vizuálne vzory, ktoré majú alebo nemajú vlastnosti homogenity ako výsledok prítomnosti viacerých farieb a intenzít v obraze. Jedná sa v podstate o vlastnosti všetkých povrchov a objektov v obrazoch, preto je využiteľnosť textúry ako príznaku veľmi široká. Obsahujú dôležité informácie o povrchoch a ich vzťahoch k prostrediu. Pre výpočet a kvantifikovanie textúrnych príznakov sa používajú štatistické, štruktúrne a spektrálne metódy. Ako konkrétne príklady metód pre výpočet textúrnych príznakov sa uvádzajú štatistické histogramy druhej rady prípadne matice vzájomného výskytu. Jeden z najpoužívanejších deskriptorov textúry je GLCM (*angl. Gray Level Co-occurrence Matrix*). Jedná sa o príznaky, ktoré skúmajú priestorový vzťah medzi pixelmi pomocou serie štatistických meraní. Pre výpočet a kvantifikovanie textúry sa v spracovaní obrazu používajú skupiny metrík, ktoré poskytujú informáciu o priestorovom rozložení farieb prípadne intenzít v obraze alebo vo vybranej časti obrazu. Ide o jeden z nástrojov pre segmentáciu alebo klasifikáciu obrazov. HOG (*angl. Histogram of Oriented Gradient*) príznaky sa tiež ukázali ako efektívne deskriptory príznakov kvantifikujúce štatistiku gradientu obrazu. [23, 24, 31, 49, 53, 58]

3.3.6 Šedotónové matice vzájomného výskytu

Tento deskriptor označujeme skartkou GLCM (*angl. Gray Level Co-occurrence Matrix*). Jedná sa o jeden z najznámejších a najpoužívanejších príznakov textúry. Matice vzájomného výskytu popisujú obraz na základe tzv. štatistík druhej rady. Ide v podstate o popis vzťahov medzi pixelmi, prípadne skupinami pixelov. GLCM je 2D histogram popisujúci určitým spôsobom výskyt párov pixelov. Prostredníctvom koincidenčnej matice je definovaných 8 rôznych textúrnych príznakov, ku ktorým patrí: korelácia, entropia, homogenita, absolútna hodnota, kontrast, energia, inverzný rozdielový moment, maximálna pravdepodobnosť. [26, 23, 40]

3.3.7 Príznyaky tvaru

Tvar predstavuje dôležitú vlastnosť pre popis objektov v obraze prípadne obrazov ako celku. Príznyaky tvaru charakterizujú obsah obrazu na základe popisu hraníc regiónov v obraze. Ako príklady atribútov založených na tvare môžu byť uvedené: kruhovitost, kompaktnost, momenty a Houghova transformácia. Pre popis tvaru objektu v obraze je taktiež podstatná detekcia a popis hrán. [49, 58]

3.4 Extrakcia príznakov

Strojové učenie začína extrakciou príznakov t.j. objektov, ktoré môžu byť dôležité pri následnom rozhodovaní. Ich výber vždy podlieha danej aplikácii, danému typu obrazu so zameraním na tie vlastnosti, ktoré sú pre daný obraz jedinečné a vyznačujú sa opakovateľnosťou. Vybrané obrazové príznaky by mali byť odolné voči rôznym zmenám vyskytujúcim sa v obrazoch. Najčastejšie sa jedná o zmeny šumu, intenzity a rotácie obrazu, čo sú zároveň aj najčastejšie sa vyskytujúce zmeny v medicínskych obrazoch. Po výbere vhodného typu príznaku pre danú aplikáciu a daný typ obrazu nasleduje výpočet deskriptoru pre zvolený (detegovaný) zaujímavý bodu. Pre správne fungovanie algoritmu je dôležité vhodné zvolenie rozmeru deskriptora. Ak je zvolený deskriptor veľmi veľký, bude takýto proces výpočtovo náročný. Ak je naopak zvolený deskriptor veľmi malý, môže jeho použitie viesť k vypusteniu určitej potrebnej informácie. Pre použitie extraktorov v aplikáciách na rádiologické obrazy je potrebné, aby boli vybrané príznaky charakteristické a aby korelovali s klinickým výstupom pacienta. Pre tieto aplikácie sa ďalej požaduje aby boli deskriptory odolné voči zmenám snímacích parametrov, čo je častý nález najmä pri snímaní z rôznych prístrojov. [20, 22, 23, 24]

V kontexte výberu príznaku sa uvádzajú 2 termíny – detekcia a deskripcia príznakov. Detekcia je pojem označujúci proces vyhľadávania oblastí obrazu, ktoré

sú určitým spôsobom zaujímavé a deskripcia je už priamo popis konkrétnych hodnôt v týchto oblastiach, ako napríklad hodnoty intenzity daných pixelov a ďalšie. Posledným pojmom objavujúcim sa v tejto súvislosti je extrakcia príznakov, čo je pojem označujúci výpočet deskriptora v danej oblasti. Pojem extrakcia príznakov v sebe teda zhrňuje oba vyššie zmienené pojmy, t.j. detekciu a deskripciu príznakov. [22, 41, 43, 51]

Extrakciu obrazových informácií môžeme všeobecne rozdeliť na dva základné prístupy, prvý využíva lokálnu extrakciu a druhý extrahuje globálne. Lokálna extrakcia príznakov využíva pre extrakciu príznakov porovnávanie pixelu s jeho bezprostrednými susedmi. Tento prístup teda pracuje len s malým okolím pixelu. Globálna extrakcia berie do úvahy celkovú kompozíciu celého regiónu záujmu. [24, 41, 43, 51]

K extrakcii príznakov dochádza väčšinou v rámci určitej oblasti v obraze, ktorá sa v angličtine označuje skratkou ROI (*angl. region of interest*). Jedná sa teda o oblasť, ktorá obsahuje dôležitú informáciu v obraze. Obmedzenie extrakcie príznakov iba na tieto zaujímavé oblasti namiesto ich extrahovania z celého obrazu môže výrazne ušetriť výpočtový čas a je obzvlášť dôležitá pri aplikáciách, ktoré vyžadujú detekciu v reálnom čase. [22, 23, 24]

Deskripcia a detekcia príznakov sú základom viacerých algoritmov počítačového videnia, ako sú obrazová klasifikácia, detekcia, reprezentácia, objektové rozpoznanie a ďalšie. Vzhľadom na rozmanité použitie boli navrhnuté viaceré príznakové extrakčné metódy. Výber detektoru a deskriptoru príznakov musí byť uskutočnený s ohľadom na druh obrazovej informácie, pretože každá aplikácia si vyžaduje extraktor špecializovaný a vhodný pre daný typ obrazu. Pre popisy rôznych obrazov sú dôležité rôzne príznaky. V tejto práci dochádza k spracovaniu obrazov z CT modality, preto pre popis týchto obrazov musí byť zvolený vhodný typ príznakových extraktorov. Vhodné zvolenie typu príznakov pre použitie na medicínske obrazy je náročnejšie, ako ich výber pre popis obrazov objektov, s ktorými sa bežne stretávame. Dôvodom je, že sa jedná o vizuálne podobnejšie objekty. Navyše je väčšina medicínskych obrazov tvorená iba rôznymi odtieňmi sivej farby prípadne bielou a čiernou, preto sú príznaky založené na farbe nevyužiteľné. Tak je tomu i u snímok z CT, ktorých spracovanie je súčasťou tejto práce. Ďalej je treba myslieť na to, že pri práci s medicínskymi obrazmi môže už maličký rozdiel v intenzite znamenať patologický stav. Z tohto dôvodu potrebujeme vybrať detektor, ktorý takéto zmeny spoľahlivo zachytí, aby došlo k čo najpresnejšej klasifikácii týchto obrazov. [22, 23, 33, 43]

3.5 Typy detektorov a deskriptorov príznakov

Existuje viacero typov detektorov a deskriptorov príznakov pričom každý z nich kladie dôraz na iný typ príznakov. Táto kapitola je zhrnutím najzákladnejších a

najčastejšie používaných detekčných a deskripčných metód s dôrazom na tie, ktoré sa najčastejšie objavujú v literatúre zameranej na aplikácie počítačového videnia v medicíne. Niektoré metódy spájajú funkciu detektoru a deskriptoru, preto je ich kategorizácia pomerne komplikovaná. [23, 43]

3.5.1 Detekcia príznakov

Detekcia príznakov je zjednodušené postupy, ktorého úlohou je vyhľadanie unikátnych bodov v obraze, ktoré sa nazývajú i kľúčové body alebo príznaky. V prípadoch, kedy je cieľom vytvoreného algoritmu napríklad detekcia určitej anatomickej štruktúry, dochádza k vyhľadávaniu príznakov v tréningových dátach a obdobným spôsobom potom dochádza k vyhľadávaniu rovnakého typu príznakov aj z testovacích dát. Zjednodušené môžeme tento postup vysvetliť na princípe porovnania dvoch obrazov. Ak dôjde k detekcii príznakov na jednom obraze, potom sa deteguje rovnaký typ príznakov aj z druhého obrazu, pričom sa vyhodnocuje či obrazy obsahujú rovnaké príznaky, alebo nie. Z toho vyplýva dôležitá vlastnosť detektorov príznakov, ktorou je opakovateľnosť potrebná pri porovnávaní obrazov. [22, 23, 43, 51]

Algoritmy strojového učenia s dôrazom na počítačové videnie často začínajú práve detekciou príznakov, preto sa tieto stávajú ich dôležitou súčasťou a na ich kvalite stojí aj kvalita celého algoritmu. Detekcia príznakov sa v obraze vykonáva buď pixel po pixeli, pričom sa kontroluje, či sa na danom pixeli nachádza nejaký zaujímavý bod, resp. príznak, alebo nie. Niekedy sa však obraz prechádza len po určitých zaujímavých oblastiach (ROI), čím sa znižuje výpočtová náročnosť algoritmu. [22, 23, 43, 51]

3.5.2 Prehľad používaných deskriptorov

Deskriptory kvantifikujú rôzne vizuálne charakteristiky z regiónu záujmu podľa typu obrazu a zamerania strojového učenia. [23]

- SURF
- SIFT
- LBP
- BRIEF
- ORB
- GLCM
- GLRLM
- HOG

Výhodným riešením pre niektoré aplikácie môže byť i použitie kombinácie deskriptorov. [22, 23]

3.5.3 Prehľad používaných detektorov

Medzi najznámejšie a najčastejšie používané detekčné metódy patria: SURF, SIFT, BRISK, FREAK, SUSAN, FAST, HESSIAN. [43]

Podrobnejšie rozdelenie je uvedené v prílohe B. Podľa typu príznakov, ktoré je potreba vyhľadať v obraze, použijeme príslušnú metódu detekcie príznakov.

3.6 Histogramy orientovaných gradientov

Histogramy orientovaných gradientov (HOG) patria medzi jedny z najobľúbenejších a najčastejšie používaných deskripčných metód pre detekciu objektov v obrazoch za rôznych podmienok. Jedná sa vlastne o extrakčnú metódu, ktorá preukázala dobrý výkon vo viacerých aplikáciách spracovania obrazov a počítačového videnia. Tento deskriptor využíva fakt, že tvar a vzhľad objektu môže byť popísaný na základe rozloženia miestnych gradientov intenzity alebo smeru hrán. HOG deskriptory extrahujú informácie o rozložení hrán v cieľových lokálnych obrazových oblastiach. Prostredníctvom deskripčného algoritmu HOG je obraz rozdelený na malé spojité oblasti, ktoré sa nazývajú bunky. [22, 26, 36, 54, 55]

Pre každú bunku a všetky pixely, ktoré táto bunka obsahuje sú počítané miestne histogramy smerov gradientov alebo orientácie hrán. Kombinácia týchto jednotlivých histogramov získaných zvlášť z každej bunky tvorí výsledný deskriptor. [26, 36, 57]

Pre výpočet histogramov orientovaných gradientov je potrebné vykonať nasledujúce kroky. Vypočítať gradienty pre daný obraz. Tieto gradienty sú počítané v dvoch smeroch: zvisle a horizontálne. Pre gradienty v horizontálnom smere použijeme premennú G_H a v zvislom smere G_Z . [55, 56]

Na základe gradientov z oboch smerov je potreba vypočítať veľkosť a smer výsledného gradientu. Pre výpočet veľkosti a smeru gradientu sa používajú nasledujúce výrazy: [54]

$$N_G(x, y) = \sqrt{G_H(x, y)^2 + G_Z(x, y)^2} \quad (3.1)$$

$$O_G(x, y) = \alpha \tan\left(\frac{G_H(x, y)}{G_Z(x, y)}\right) \quad (3.2)$$

Obrázok sa pri výpočte tohto deskriptoru rozdelí na niekoľko buniek. Pre každú bunku sa potom vypočíta histogram smeru. [22, 26, 35, 36, 57]

3.7 Selekcia príznakov

Pre každú aplikáciu je potrebné zvážiť nie len aké príznaky detegovať, ale aj ich množstvo. Zvolenie príliš veľkého množstva príznakov môže namiesto zlepšenia odhadu a rozhodovania viesť k tzv. overfittingu alebo preučeniu modelu. Veľké množstvo príznakov okrem toho kladie veľké nároky na výpočtový čas. Je teda dôležité z príznakov vybrať tie, ktoré prispievajú k rozhodovaniu a odstrániť spomedzi nich nepotrebné a redundantné príznaky, ktoré neprispievajú k rozhodovaciemu procesu. Pre výber podmnožiny príznakov z pôvodne extrahovanej množiny sa používajú rôzne štatistické metódy ako korelačná, diskriminačná analýza prípadne metóda analýzy hlavných komponent - PCA (z angl. Principal Component Analysis). [20, 31, 33]

3.8 Klasifikátory

Pre proces klasifikácie je podstatné vyhladať príznaky, ktoré budú čo najlepšie popisovať danú kategóriu a zároveň, aby tieto príznaky poukazovali na čo najväčšie rozdiely medzi klasifikovanými triedami tak, aby k tejto klasifikácii došlo s čo najväčšou presnosťou. Klasifikácia sa teda opiera o príznaky, ktoré boli prvotne extrahované a na ich základe prebieha klasifikácia. Príznakový vektor je unikátny pre každý objekt (obraz). Úlohou klasifikátora je potom rozdeliť príznakový priestor na oblasti odpovedajúce rôznym triedam. Obrazy (resp. ich príznakové vektory), ktorých kategória je vopred známa sa označujú ako tréningové obrazy (tréningové príznakové vektory). Klasifikácia vlastne označuje proces, pri ktorom dochádza k označeniu skupiny pixelov v obraze, prípadne celého obrazu nejakou konkrétnou triedou. Príkladom môže byť označenie určitej časti medicínskeho snímku ako tumorózneho. Pre voľbu vhodného klasifikátora je ale potrebné zohľadniť klasifikačný zámer, pre ktorý je klasifikátor určený. [20, 24, 31]

3.8.1 K-najbližších susedov

Metóda k-najbližších susedov je jednoduchá metóda strojového učenia opäť zaradená do skupiny učenia s učiteľom. Metóda je často využívaná pre riešenie klasifikačných problémov. Tento algoritmus vykonáva triedenie na základe zaradenia vzorky do triedy, ktorej hodnota je najviac podobná hodnote tréningovej vzorky. Tento algoritmus teda nevyužíva zložitú matematiku a nevytvára komplikovaný model pre klasifikáciu, ale ide v podstate o jednoduché porovnávanie. Ak do tohto algoritmu vstupuje nová vzorka, jej klasifikácia prebieha na základe porovnávania s tréningovými vzorkami a vyhľadania najpodobnejšej tréningovej vzorky. [33]

3.8.2 Naive Bayes algoritmus

Bayesov algoritmus pracuje na základe Bayesovho teorému:

$$P(x|y) = [P(y) \times P(x|y)]/P(x) \quad (3.3)$$

[20] [33]

Tento teorém vyjadruje pravdepodobnosť určitej udalosti ako funkciu súvisiacich udalostí. Tento teorém sa v strojovom učení uplatňuje tak, že do algoritmu vstupuje mnoho vstupných príznakov, pričom každý ma svoju pravdepodobnosť. Pravdepodobnosti týchto jednotlivých príznakov je potreba skĺbiť do spoločnej výslednej pravdepodobnosti, ktorá popisuje celú triedu a zohľadňuje jednotlivé vstupné príznaky. [20, 33]

Z vyššie uvedeného princípu fungovania tohto algoritmu vyplýva významný rozdiel medzi týmto algoritmom a ostatnými algoritmi strojového učenia. Táto odlišnosť je znateľná najmä v spôsobe výpočtu vzťahu medzi vstupnými a výstupnými dátami. Súčasťou tohto algoritmu teda nie je žiadny tréningový iteračný proces, ako je tomu u väčšiny ostatných typov metód strojového učenia. [20, 33]

3.8.3 Rozhodovacie stromy a náhodné lesy

Rozhodovacie stromy (*angl. decision trees*) sú široko využívanou nelineárnou klasifikačnou metódou. Veľkou výhodou tohto typu klasifikátora je to, že v procese klasifikácie poskytuje pravidlá, v ktorých sú ľudia schopní vidieť ich zmysel. Táto možnosť nahliadnutia do procesu rozhodovania je výhodná najmä v medicínskych aplikáciách, v ktorých sa lekári neradi spoliehajú na algoritmy typu tzv. čiernej skrinky, kedy nevidia resp. nerozumejú, ako takýto algoritmus skutočne pracuje. Pravidlá tohto algoritmu sú typicky písané vo forme otázok, na ktoré postačuje len krátka odpoveď áno/nie. Obvykle sa jedná len o rôzne porovnávacie otázky. Príkladom takéhoto pravidla môže byť otázka, či je určitá vstupná hodnota vyššia ako nejaká konkrétna hraničná hodnota. [20, 33, 45]

Metóda rozhodovacích stromov predstavuje viacstupňový rozhodovací systém, pričom je vstupný príznakový dataset rozdelený na časti, ktoré korešpondujú s triedami. Podskupiny príznakov sú postupne prechádzané algoritmom a na základe prípadného splnenia/nesplnenia pravidla sa algoritmus postupne po vetvách posúva ďalej až ku konečnému rozhodnutiu. [20, 33]

Podobne ako algoritmus SVM aj rozhodovacie stromy je možné využiť nielen pre klasifikáciu ale i pre riešenie regresných problémov. Na základe tohto algoritmu a jeho vylepšením vznikol pokročilejší algoritmus Náhodných lesov (*angl. Random forests*). Rozhodovacie stromy i náhodné lesy patria do kategórie strojového učenia typu učenia s učiteľom. [20, 33]

3.8.4 Metóda podporných vektorov

Metóda podporných vektorov (SVM) patrí medzi najpopulárnejšie klasifikačné algoritmy vďaka jej širokému záberu na množstvo klasifikačných problémov. Okrem toho tento algoritmus preukázal vysokú učebnú rýchlosť a to i na veľkých dátach. Klasifikáciou však využiteľnosť tohto algoritmu nekončí a môžeme ho použiť taktiež pre úlohy, ako je analýza dát, obrazové rozpoznávanie ale i regresnú analýzu. [27, 31, 44, 47]


Princíp tejto metódy spočíva vo vytvorení tzv. hyperroviny (*angl. hyperplane*). Jedná sa o metódu spadajúcu do kategórie metód strojového učenia založených na učení s učiteľom. Metódu podporných vektorov navrhol v roku 1995 Vápnik. V jej počiatkoch bola metóda určená pre klasifikáciu binárnych problémov. Jej neskorší rozvoj a ďalšie úpravy dopomohli k jej rozšíreniu pre riešenie multi-klasifikačných problémov. Výkonnosť tohto algoritmu bola testovaná na množstve klasifikačných a regresných problémov nemedicínskeho ale i medicínskeho charakteru, pričom tento algoritmus preukázal dobrú generalizačnú schopnosť. Príklady použitia tohto algoritmu pre medicínske aplikácie môžeme sledovať na príkladoch klasifikácie a detekcie mozgových nádorov. [20, 28, 33, 35, 46, 57]

Cieľom metódy je vytvoriť hranicu rozhodovania medzi dvoma alebo viacerými triedami, ktorá umožňuje klasifikáciu vzorky do jednej z týchto tried na základe jedného alebo viacerých príznakových vektorov. Táto hranica rozhodovania, označovaná ako hyperrovina, je orientovaná takým spôsobom, aby bola maximalizovaná jej vzdialenosť od najbližších dátových bodov z každej triedy. Tieto najbližšie body sa nazývajú podporné vektory. Vzdialenosť medzi týmito podpornými vektormi a hyperrovinou sa označuje ako odstup (*angl. margin*). Všeobecne platí, že čím je odstup v tomto algoritme väčší, tým menšia je chyba. Tým, že dochádza k maximalizácii odstup, dochádza vlastne k čo najväčšiemu oddeleniu medzi vstupnými dátami. [20, 31, 46, 47]

Cieľom algoritmu SVM je teda vytvorenie tzv. hyperroviny, ktorú je možné popísať vzťahom [29, 31]:

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0 \quad (3.4)$$

kde \mathbf{w} označuje jej smer, hodnota w_0 označuje presné umiestnenie v priestore a premenná \mathbf{x} označuje vstupný vektor príznakov. Premenné ω_1 a ω_2 v tomto prípade označujú najbližšie sa vyskytujúce body z oboch klasifikačných skupín. Hyperrovina by mala mať rovnakú vzdialenosť, t.j. rovnaký odstup od najbližších bodov oboch klasifikačných skupín. To je odôvodnené tým, že nechceme zvýhodniť ani jednu klasifikačnú skupinu. Prostredníctvom algoritmu dochádza k prehľadávaniu priestoru v zmysle hľadania smeru, v ktorom umožňuje hyperrovina (v tomto prípade priamka),



Obr. 3.2: Lineárny model SVM pre klasifikáciu 2 tried. Prevzaté z [34]

čo najväčší odstup medzi jednotlivými podpornými vektormi. Pre výpočet vzdialenosti medzi bodom a hyperrovinou je možné využiť vzťah [29, 31]:

$$z = \frac{|g(\mathbf{x})|}{\|\mathbf{w}\|} \quad (3.5)$$

Prostredníctvom škálovania \mathbf{w} a w_0 , dostaneme hodnotu $g(\mathbf{x}) = 1$ pre bod ω_1 a hodnotu $g(x) = -1$ pre bod ω_2 . Odstup medzi jednou skupinou (resp. podporným vektorom jednej skupiny) a rozhodovacou hranicou (hyperrovinou) môžeme vyjadriť vzťahom [31]:

$$\gamma = \frac{1}{\|\mathbf{w}\|} \quad (3.6)$$

Z toho vyplýva, že celkový odstup medzi jednotlivými klasifikačnými triedami môžeme vyjadriť prostredníctvom jednotlivých odstupov medzi rozhodovacou hranicou a daným podporným vektorom nasledovne [28, 29]: $\frac{1}{\|\mathbf{w}\|} + \frac{1}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|}$

Všetky vektory z tréningovej množiny môžeme teda zaradiť do jednej alebo druhej skupiny na základe nasledujúcich nerovníc [29]:

$$\mathbf{w}^T \mathbf{x} + w_0 \geq 1, \quad \forall \mathbf{x} \in \omega_1 \quad (3.7)$$

$$\mathbf{w}^T \mathbf{x} + w_0 \leq -1, \quad \forall \mathbf{x} \in \omega_2 \quad (3.8)$$

kde ω_1 je jedna klasifikačná skupina a ω_2 je druhá klasifikačná skupina. [29]

Každému tréningovému vektoru \mathbf{x}_i môžeme prideliť príslušné označenie klasifikačnej triedy y_i , pričom $y_i \in \{-1, 1\}$ podľa [28]:

$$y_i = 1, \quad \forall \mathbf{x}_i \in \omega_1 \quad (3.9)$$

$$y_i = -1, \quad \forall \mathbf{x}_i \in \omega_2 \quad (3.10)$$

Máme teda k dispozícii N označených tréningových vzoriek $(\mathbf{x}, y)_i, i = 1, \dots, N$ $x_i \in R^n$. [31]

Jedná sa teda o príslušné príznakové vektory, pričom každému príznakovému vektoru patrí príslušné klasifikačné označenie podľa skupiny, do ktorej spadá (napr. pozitívna alebo negatívna skupina).[29]

Cieľom algoritmu je teda určenie takých hodnôt parametrov \mathbf{w} a w_0 , ktoré budú riešením nasledujúceho optimalizačného problému [29]:

$$\text{minimalizácia} \quad J(\mathbf{w}, w_0) \equiv \frac{1}{2} \|\mathbf{w}\|^2 \quad (3.11)$$

Za podmienky [29]:

$$y_i (\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1, \quad i = 1, 2, \dots, N \quad (3.12)$$

Tento optimalizačný problém dostaneme úpravou optimalizačného problému [29]:

$$\text{maximalizácia} \quad J(\mathbf{w}, w_0) \equiv 2 \cdot \frac{1}{\|\mathbf{w}\|} \quad (3.13)$$

z čoho riešením pomocou kvadratického programovania dostaneme vzťah (3.11). Vyššie zmienený vzťah vyjadruje fakt, že chceme týmto algoritmom dospieť k takému riešeniu, aby bol celkový odstup γ medzi jednotlivými triedami maximálny. Vektory x_i pre ktoré platí: $\mathbf{w}^T \mathbf{x} + w_0 = \pm 1$ sa nazývajú podporné vektory. Pre riešenie optimalizačného problému (3.11) sa používa tzv. Lagrangov súčiniteľ. [28, 29, 31]

Alternatívou algoritmu SVM je kernel metóda (metóda jadra), ktorá umožňuje vytváranie nelineárnych modelov a modelov vyššej dimenzie. Nelineárny problém môže byť riešený prostredníctvom kernel funkcie tak, že sú pridané ďalšie dimenzie do raw dát, čím je problém vlastne prevedený z nelineárneho na lineárny vo výslednom vyššie dimenzionálnom priestore. Výhodou kernel metódy je transformácia dát neseparovateľných pomocou lineárneho SVM do viac-dimenzionálneho priestoru, čím je umožnené ich oddelenie. [20, 52, 29]

SVM je algoritmus náročnejší na výstavbu príznakov, kým neurónové siete príznaky vyberajú samy. Avšak nevýhodou, ktorá sa potvrdila aj v tejto práci je potreba väčšieho množstva tréningových dát vzhľadom na množstvo vrstiev. Vzhľadom na menšiu učebnú databázu je v riešení tejto práce vhodnejšie zvoliť metódu SVM oproti hlbokému učeniu. [31, 45]

3.8.5 Hlboké neurónové siete

Hlboké učenie je tiež známe ako hlboké neurónové siete (*angl. deep neural networks*). Hlboké neurónové siete vznikli vďaka zdokonaleniu klasických neurónových sietí prostredníctvom pridania viacerých skrytých vrstiev do ich pôvodnej architektúry. Udáva sa, že pôvodné neurónové siete mali len niekoľko vrstiev, približne do päť vrstiev. Toto obmedzenie vyplývalo najmä z výpočtovej sily, ktorá bola oproti dnešným možnostiam podstatne limitovaná a nebola schopná poňať viac vrstiev. Hlboké učenie dnes označuje neurónové siete obsahujúce väčší počet vrstiev, typicky sa jedná o dvadsať a viac vrstiev. Využitie takého počtu vrstiev bol umožnený najmä vďaka vývoju paralelnej výpočtovej sily grafických procesorov. Pre aplikácie na obrazové informácie prevládajú použitia konvolučných neurónových sietí (CNN). [20, 42, 45]

Konvolučné neurónové siete sú veľmi podobné bežným neurónovým sieťam, avšak rozdielom je, že konvolučné neurónové siete očakávajú na vstupe geometrický vzťah. Presne tak, ako tomu je medzi stĺpcami a riadkami obrazu. Vstupná vrstva CNN má usporiadanie neurónov usporiadané pre konvolúciu malého obrázku, nazývaného i jadro (*angl. kernel*), s daným obrazom. Jadro sa potom pohybuje naprieč obrazu, pričom tento obraz prechádza po menších oblastiach a z každej oblasti vstupného obrázku vytvára výstup, ktorý prispieva k výslednej výstupnej hodnote. Okrem spomínanej konvolučnej vrstvy obsahuje tento algoritmus i iné dôležité vrstvy, ktoré sú už ale spoločné pre všetky typy algoritmov hlbokého učenia. Jadrá určené pre detekciu dôležitých príznakov v obraze majú veľké výstupy prispievajúce ku konečnej detekcii objektov v obraze. Výhodou tohto algoritmu je, že nepotrebuje využívať aditívny príznakový detektor, pretože si príznaky vie vyhľadať sám. [20, 24, 42]

3.8.6 VGG

VGG (*angl. Visual Geometry Group*) je typom konvolučnej neurónovej siete s hlbokou architektúrou. Vstupom tejto siete sú RGB obrazy s pevne daným rozmerom 224x224 pixelov, preto v prípade spracovania obrazov inej veľkosti je nutné jeho predspracovanie. VGG neurónové siete môžu mať premenný počet vrstiev, udáva sa 11 až 19 vrstiev. Dosiahnutie takto hlbokých sietí je umožnené vďaka použitiu malých konvolučných filtrov s rozmerom 3x3 a krokom 1 pixel. Tým je možné vytvorenie sietí obsahujúcich 16-19 vrstiev. VGG konvolučná sieť so 16 vrstvami (VGG-16), ktorá bola využitá i v tejto práci obsahuje 13 konvolučných vrstiev a 3 plne prepojené vrstvy (*angl. fully-connected layers*). Okrem týchto vrstiev sa v jej konfigurácii nachádzajú i združené vrstvy (*angl. pooling layers*), konkrétne ide o 5 združovacích vrstiev. Združovacie vrstvy, ako už z názvu vyplýva, slúžia k združovaniu konvolučných vrstiev. Tieto vrstvy však nie sú pevne umiestnené po každej konvolučnej vrstve. [66]

4 LITERÁRNA REŠERŠ

Táto kapitola je zhrnutím literárnej rešerše k problematike detekcie anatomicky významných bodov najmä v oblasti hlavy. Rozoberá navrhnuté detekčné metódy s dobrým výkonom, sú v nej uvedené práce a štúdie, ktoré sa zaoberajú podobnou tematikou a načrtáva najčastejšie použité prístupy autorov k danej problematike.

V práci [26] sa autori pokúsili o vytvorenie vhodného, plne automatizovaného detekčného algoritmu pre detekciu a segmentáciu nádorov na základe snímok magnetickej rezonancie hlavy. V tejto štúdii urobili autori porovnanie a vyhodnotenie účinnosti štatistických príznakov oproti Gaborovým príznakom, ktoré označili ako dve hlavné príznakové skupiny pre úspešný popis textúry tumorózneho tkaniva. Tieto príznaky použili ako vstup do piatich rôznych algoritmov zmienených ďalej. Okrem toho porovnali výkonnosť viacerých klasifikačných algoritmov v závislosti na zvolených typoch príznakov. Algoritmy testované v tejto práci sú: SVM, kNN, k-means, NSC a SRC klasifikátory. Hodnotenie výkonnosti týchto klasifikátorov bolo vykonané prostredníctvom troch kritérií výkonnosti algoritmu a to: presnosť, senzitivita a špecificita. V tejto štúdii sa autorom podarilo vytvoriť plne automatizovaný systém schopný nielen detekcie tumorózných rezov ale i vymedzenia nádorovej oblasti s vysokou presnosťou a nízkou výpočtovou náročnosťou. Prostredníctvom klasifikátora SVM dosiahli vysokú detekčnú presnosť, a to nielen s lineárnym ale najmä s RBF jadrom. Presnosť tohto algoritmu sa pohybovala až okolo hodnôt 91 – 96%. Trošku nižšiu, ale stále obstojnú presnosť ukázal i algoritmus K-NN. V prípade použitia tohto detekčného algoritmu sa presnosť pohybovala okolo 87 – 92%. [26]

V práci [25] sa autori venovali diagnostike Alzheimerovej choroby (AD) s využitím štruktúrnych snímok z magnetickej rezonancie a strojového učenia. Navrhli počítačom podporovaný diagnostický systém založený na metóde podporných vektorov (SVM). Pre tréning algoritmu zvolili lokálne morfológické príznaky. Vzhľadom na to, že ide o neurodegeneratívne ochorenie postihujúce mozog, detegovali sa v práci anatomické štruktúry významné pre toto ochorenie. Vzhľadom na to, že táto práca má za cieľ detekciu v rovnakej anatomickej oblasti, je tento zdroj dobrým príkladom, ako je možné detegovať anatomické štruktúry v oblasti hlavy a mozgu. Chyba navrhnutého detekčného algoritmu anatomicky významných bodov sa v tomto prípade uvádza 2,41 mm medzi manuálne anotovanými a automaticky detegovanými bodmi. Presnosť klasifikácie AD založenej na anatomicky významných bodoch v tomto prípade dosahuje hodnotu 83,7%. Autori navrhnutú metódu porovnali s existujúcimi metódami založenými na regiónoch a voxeloch a uvádzajú porovnateľné, dokonca lepšie výsledky v porovnaní s týmito metódami. Ako výhodu ich algoritmu oproti týmto existujúcim algoritmom ale uvádzajú rýchlosť ich metódy, pričom deklarujú ich algoritmus ako približne 50-krát rýchlejší. [25]

V práci [27] bol navrhnutý hybridný prístup k detekcii a klasifikácii nádorov mozgu z obrazov získaných prostredníctvom magnetickej rezonancie. Tento prístup je nazývaný hybridným z dôvodu kombinácie viacerých metód – metód založených na regióne a metód založených na textúre. Navrhovaný prístup začína predspracovaním obrazu, ktoré zahŕňa filtráciu šumu a detekciu lebky. Nasledujúca fáza zahŕňa extrakciu príznakov z obrazov magnetickej rezonancie mozgu použitím Šedotónových matíc vzájomného výskytu (GLCM). Jedná sa o metódu zameranú na textúru. Algoritmus pokračuje klasifikáciou vstupov do dvoch skupín: normálne a abnormálne. K tejto klasifikácii bol využitý klasifikátor metódy podporných vektorov - najmenších štvorcov s viacvrstvovým perceptronovým jadrom (LS-SVM spolu s MLP kernel funkciou) (*angl. Least Squares Support Vector Machines*). Nakoniec sa z obrázku segmentujú tumorové časti prostredníctvom ohraničujúcich rámečkov (*angl. bounding box*). Autori pre túto prácu využili sto obrázkov pričom sa jednalo o časť reálnych záznamov a časť záznamov synteticky vytvorených. Týmto prístupom bola dosiahnutá dobrá presnosť klasifikácie, ktorej hodnota sa pohybovala okolo 96%. Jedná sa teda o relatívne účinný algoritmus pre detekciu mozgových nádorov. [27]

V článku [28] bol autormi navrhnutý hybridný prístup pre detekciu mozgových nádorov založený na kombinácii metódy podporných vektorov (SVM) a mäkkého zhlukovania fuzzy c-means. Extraktorom príznakov zvoleným pre trénovanie klasifikátora SVM boli GLRLM. Vstupom navrhnutého algoritmu bolo 120 reálnych patientských MR záznamov mozgu. Pre nájdenie podozrivých oblastí mozgu bola zvolená metóda fuzzy c-means. Prostredníctvom fuzzy c-means zhlukovania dochádza k segmentácii obrazov. Po segmentácii obrazu dochádza k extrakcii príznakov. 96 záznamov bolo použitých pre trénovanie navrhnutého algoritmu a zvyšných 24 záznamov pre testovanie navrhnutého klasifikačného modelu. Výkonnosť algoritmu bola hodnotená prostredníctvom 3 kritérií a to senzitivita, špecificita a presnosť. Pri návrhu boli v metóde podporných vektorov použité 3 rôzne jadrá - polynomicke, lineárne a kvadraticke. Najlepšiu výkonnosť preukázala metóda podporných vektorov s lineárnym jadrom, kedy boli všetky 3 kritéria vykonnosti algoritmu najvyššie. V tomto prípade dosahoval algoritmus senzitivitu 83,3%, špecificitu 100% a presnosť 91,66%. [28]

V práci [55] bol navrhnutý nový prístup pre detekciu Alzheimerovej choroby prostredníctvom rozšíreného deskriptora HOG pre 3 kolmé roviny. Deskriptor bol vytvorený pre popis textúrnych príznakov z 3D snímok mozgu. Databáza bola vytvorená z 3D MR skenov mozgu vytvorených prostredníctvom magnetickej rezonancie s polom 1,5T, pričom išlo o T1 vážené skeny. Pre redukciu dimenzionality bola použitá metóda výberu príznakov, konkrétne metóda analýzy hlavných komponent (PCA), čím došlo k redukcii príznakov. Následne bola pre klasifikáciu použitá metóda náhodných lesov (*angl. random forest*). Autori rozšírili metódu HOG do 3D tak, že po-

čítajú orientované gradienty z 3 kolmých rovín XY (axiálna rovina), XZ (koronálna rovina) a YZ (sagittálna rovina). Túto metódu pomenovali HOG-TOP (angl. three orthogonal of planes). Počíta orientácie gradientov zo všetkých 3 rovín samostatne. Pre každú rovinu bol získaný príznakový vektor a tieto výsledné príznakové vektory boli označené. Následne došlo k zlúčeniu všetkých 3 vytvorených histogramov do 1 vektoru príznakov obsahujúceho informácie zo všetkých 3 rovín. Po úspešnom výbere príznakov zo všetkých troch kolmých rovín a ich zlúčení do 1 spoločného vektora nasledoval výber príznakov prostredníctvom rozšírenej metódy PCA. Tým došlo k výberu príznakov dôležitých pre následnú detekciu. Prostredníctvom selekčného algoritmu je vybraných 50 najlepších príznakov pre každý príznakový vektor. Následne je príznakový vektor klasifikovaný prostredníctvom algoritmu náhodných lesov s použitím 10-násobnej krížovej validácie. Použité boli 3 veľkosti stromov v náhodných lesoch - 100, 250, 500. [55]

V štúdiu [62] autori navrhli algoritmus pre klasifikáciu mamografických obrazov ako podporný diagnostický prostriedok pre diagnostiku rakoviny prsníka. Tieto obrazy klasifikuje do 3 skupín: normálne, benígne a malígne. Pre vytvorenie algoritmu bol použitý súbor 113 rôznych mamografických obrazov. Z obrazov sa extrahuje 26 príznakov. V navrhnutej metóde je použitý hybridný prístup pre výber dôležitých príznakov. Pre selekciu príznakov bola použitá kombinácia tzv. *greedy stepforward* algoritmu a genetických algoritmov. Tento selektor príznakov znižuje počet vybraných príznakov na 25% pôvodného počtu príznakov. Tieto príznaky slúžia ako vstup do vybraného klasifikátora. Klasifikátor následne vybrané príznaky priraduje do tried, ktoré reprezentujú, v tomto prípade normálne, benígne a malígne. Príznaky extrahované v tomto prípade sú intenzitné histogramy (*angl. intensity histogram features*) a Šedotónové matice vzájomného výskytu (*angl. Gray Level Co-Occurrence Matrix - GLCM*). Tieto príznaky boli rozdelené na 6 príznakov získaných prostredníctvom histogramov intenzity a 20 príznakov poskytnutých prostredníctvom GLCM. Klasifikátorom použitým v tom prípade bol algoritmus náhodných lesov (RF). Ako priemernú dosiahnutú presnosť tohto algoritmu autori uvádzajú 95%. [62]

V štúdiu [64] autori navrhli metódu pre segmentáciu mozgových nádorov z kolekcií snímok MR mozgu. Navrhnutá segmentačná metóda je založená na konvolučných neurónových sieťach (CNN). Konvolučné neurónové siete skúmajú malé jadrá 3x3. Výhodou použitia malých jadier je umožnenie návrhu hlbšej architektúry a menšia pravdepodobnosť preučenia. S prihliadnutím k tomu, že detekcia nádorov je komplikovaná vzhľadom na rozmanitú priestorovú lokalizáciu a štrukturálne zloženie, autori navrhli rozšírenie databázy. Uviedli, že zväčšenie databázy napr. prostredníctvom rotácie malo priaznivý vplyv na efektívnosť navrhnutého algoritmu. V práci taktiež uvádzajú porovnanie navrhnutej metódy s prácami využívajúcimi plytkú ar-

chitektúru pričom uvádzajú, že navrhnutá metóda s menšími jadrami poskytuje lepší výkon. [64]

Autori v práci [63] priniesli návrh metódy pre klasifikáciu mozgových tumorov. Metóda je založená na obrazových informáciách získaných z snímok MR mozgu. Na začiatku algoritmu sú MR snímky predspracované so zámerom redukcie šumu. Pre výber príznakov z týchto predspracovaných obrazov bol použitý extraktor GLCM pre popis príznakov tvaru a textúry. Tréning algoritmu je uskutočnený prostredníctvom dvojstupňového systému, ktorý začína použitím neurónových sietí SOM (Samoorganizujúca sa mapa), čo napomohlo urýchleniu následnej klasifikácie. Algoritmus pokračuje v klasifikácii obrazov použitím metódy podporných vektorov, čo je vlastne druhý stupeň tohto procesu. Autori uvádzajú, že tento dvojstupňový proces klasifikácie zvyšuje jej výkon a rýchlosť oproti klasickým metódam. Presnosť navrhnutého algoritmu autori uvádzajú maximálne na 89,5%. [63]

V článku [67] autori navrhli plne automatizovaný model pre detekciu ľubovoľného počtu anatomických bodov. Podľa ich návrhu sa rozhodli o kombináciu štatistických modelov tvaru a morfometrických meraní mozgu. Pre tréning a testovanie navrhnutého algoritmu si autori zvolili snímky z magnetickej rezonancie, na ktorých detekovali 30 anatomických bodov. S navrhnutým algoritmom dosiahli priemerný rozdiel medzi anatomickou štruktúrou určenou expertom a anatomickou štruktúrou automaticky detekovanou pomocou navrhnutého algoritmu menej ako 1 mm. Navrhnutý algoritmus je dokonca odolný i voči rôznym podmienkam skenovania a je ho teda možné použiť pre rozsiahle výskumy, kde sa využívajú dáta snímané z rôznych pracovísk, z rôznych skenovacích zariadení, s rôznymi orientáciami, vzorkovaním a rôznou silou poľa použitou pri skenovaní. [67]

V článku [68] autori navrhli ako metódu pre detekciu anatomicky významných bodov algoritmus založený na metóde Náhodných lesov (*angl. Random forest*). Ako výhody tohto riešenia autori uvádzajú robustnosť výsledného algoritmu, ktorú sa snažia demonštrovať na obsiahlom súbore mozgových skenov, pričom tieto majú dostatočne odlišné zorné pole a sú taktiež odlišne orientované. Zastúpenie rôznych skenov v algoritme je podstatný krok pre plnú automatizáciu vzniknutého algoritmu. V tomto článku sú použité CT snímky ucha, pretože autori sa pokúšajú o detekciu význačných bodov pre následnú aplikáciu kochleárneho implantátu. Tieto význačné body sa nazývajú i body záujmu. Aplikácia síce nie je zameraná priamo na skeny mozgu, ale detegujú sa anatomicky význačné body priamo v oblasti hlavy, konkrétne body záujmu v oblasti vnútorného ucha. Robustnosť navrhutej metódy je demonštrovaná na obrázkových súboroch z rôznych skenerov, ktoré majú veľmi odlišné zorné pole a podstatne odlišné orientácie. [68]

5 VLASTNÉ RIEŠENIE

5.1 Návrh algoritmu detekcie

Cieľom tejto práce bolo navrhnutie vhodného algoritmu strojového učenia, ktorý bude efektívne a s čo najvyššou presnosťou detegovať anatomicky význačné body v objemových 3D CT dátach.

Výber programovacieho prostredia bol vykonaný čisto z praktických dôvodov, vzhľadom na predošlú skúsenosť s programovaním v tomto prostredí. Vzhľadom na to, že sa jedná o spracovanie obrazovej informácie a navyše ide o medicínsku aplikáciu, bolo potrebné zvoliť algoritmus vhodný na tieto účely. Na začiatku bol algoritmus otestovaný pre 2D obrazovú informáciu a po skúsenosti s prácou s 2D obrazmi došlo k implementácii algoritmu do 3D tým, že algoritmus postupne prechádza všetky rezy CT záznamu, teda 3D matice.

5.2 Dostupné dáta a ich príprava

Z dostupných CT skenov bolo na začiatku potrebné vysegmentovať oblasti, tzv. význačné body, ktoré sa v rádiológii využívajú pri určovaní skenovacej roviny na CT vyšetrení, ale i pri vykonávaní vyšetrenia magnetickou rezonanciou. Keďže možnou aplikáciou tejto práce je automatické určovanie skenovacej roviny, bolo potrebné vybrať význačné body, ktoré túto rovinu určia. Po vykonaní literárnej rešerše bolo zvolených 7 bodov, ktoré bolo potrebné ručne vysegmentovať z celého CT záznamu od každého pacienta a takto upravené obrazy boli následne použité ako vstupy do navrhnutého algoritmu. Jedná sa o *tuberculum sellae*, *meatus acusticus externus (dexter et sinister)*, *protuberantia occipitalis interna*, *protuberantia occipitalis externa*, *angulus oculi lateralis (dexter et sinister)*.

Pri návrhu algoritmu boli k dispozícii CT skeny hlavy uložené vo formáte *raw*. Jedná sa o formát obsahujúci dve časti, samotný súbor obsahujúci obrazovú informáciu a súbor vo formáte *tif* obsahujúci textový súbor s popisom obsiahnutých dát, v tomto prípade CT záznamov. Dáta boli z formátu *raw* prevedené do formátu *.mat* a uložené v tomto formáte. Z poskytnutých CT dát bol vytvorený dáta-set obsahujúci 11 patientskych CT súborov hlavy. Navyše u dvoch pacientov - pacient 45 a 46 došlo k prevzorkovaniu a úprave tak, aby sa tieto dáta zhodovali s ostatnými poskytnutými dátami. Každý CT rez obsahuje 512x512 pixelov a počet rezov sa pohybuje v rozmedzí od 316 do 361. Poskytnuté dáta neboli predtým vyhodnotené, preto nevieme, či sa jedná o dáta obsahujúce patológie. Zároveň nemáme informácie

o tom, či sa jedná o snímky mužských alebo ženských pacientov. Poskytnuté dáta boli anonymizované a pre naše účely boli označené číslami 37 až 47.

5.3 Vytvorenie databázy

Z poskytnutých dát bola vytvorená databáza pozitívnych a negatívnych detekcií postupom opísaným v kapitole 6. Databáza bola rozdelená na tréningovú a testovaciu množinu v pomere 8:2. Z jedenástich pacientov boli teda pre testovanie navrhnutého algoritmu vybrané dva patientske záznamy - konkrétne sa jedná o záznamy číslo 46 a 47, dáta od zvyšných pacientov boli použité pre tréningovanie navrhnutého algoritmu.

Vzhľadom na menšiu učebnú databázu bolo u niektorých štruktúr potrebné umelé rozšírenie ich databázy. Pre augmentáciu databázy použité metódy umelého pridať šumu a rotácia obrazu. Výsledná databáza bola následne využitá ako vstup do navrhnutého detekčného algoritmu.

5.3.1 Výber detekčného algoritmu

Pri výbere vhodného detekčného algoritmu je nutné zvážiť viacero faktorov, ktoré ovplyvňujú kvalitu takéhoto algoritmu. Samozrejme najdôležitejší faktor pre výber detekčného algoritmu je zámer použitia tohto algoritmu. Jedným z takých faktorov však je i veľkosť tréningovej databázy a druh obrazovej informácie, ktorá bude do algoritmu vstupovať.

5.3.2 Voľba klasifikátora

Po zvážení vyššie uvedených skutočností sa zdá vhodnejšie použitie jednoduchšieho algoritmu ako použitie algoritmu hlbokého učenia. Po vykonaní literárnej rešerše sa ako veľmi spoľahlivé a často používané ukázali dva jednoduchšie algoritmy, Metóda podporných vektorov (SVM) a algoritmus Náhodných lesov (RF). Články obsahujúce využitie týchto jednoduchších algoritmov v aplikáciách na medicínske obrázky a dosiahnuté úspešnosti boli zhrnuté v kapitole 4. Na jej základe bola pre túto prácu bola zvolená Metóda podporných vektorov.

Podľa literatúry sa ako jeden z najpresnejších a v dnešnej dobe najčastejšie používaných javí algoritmus hlbokého učenia, konkrétne použitie konvolučných neurónových sietí (CNN). Pri ich použití však môžeme naraziť na problém s menšou tréningovou databázou, ktorou disponujeme. S prihliadnutím na obmedzené množstvo dát, ktoré môžeme pre učenie použiť, sa vhodnejšie javí použitie predtrénovaných neurónových sietí.

V článku [65] autori klasifikovali a detekovali anatomické štruktúry z CT skenov prostredníctvom konvolučných neurónových sietí VGG16. Prostredníctvom týchto predtrénovaných sietí dosiahli autori v článku vysokú detekčnú presnosť v ich aplikáciach pre klasifikáciu a detekciu CT obrazov.

V tejto bakalárskej práci sú konvolučné neurónové siete VGG-16 využité v zmysle extraktorov príznakov, preto sú tieto siete skrátene za výsledok je považovaný výstup z ich piatej poolingovej vrstvy. Tento výstup je následne použitý ako vstup do detekčného algoritmu.

5.3.3 Extrakcia príznakov

Výber príznakov vhodných pre daný algoritmus bol náročnejší, pretože vykonávaním literárnej rešerše sa ukázalo, že k výberu príznakov sa stavali rôzni autori veľmi rozmanito. Keďže v článkoch [26] [55] bolo pre extrakciu príznakov uvedené použitie histogramov orientovaných gradientov (HOG) boli pre tento klasifikačný problém vybrané HOG príznaky ako jedny z príznakov vstupujúcich do nasledujúceho detekčného algoritmu. Ako ďalší vstup do tohto algoritmu boli vybrané príznaky extrahované prostredníctvom predtrénovanej neurónovej siete VGG-16, konkrétne z jej pooling vrstvy číslo 5. Pre návrh algoritmu s najoptimálnejším výkonom pre daný klasifikačný alebo detekčný problém je však veľmi dôležitá osobná skúsenosť a metóda pokus-omyl.

6 IMPLEMENTÁCIA V PROGRAMOVOM PROSTREDÍ


Navrhnutý algoritmus bol implementovaný v programovacom prostredí MATLAB. Konkrétne bola využitá verzia MATLAB R2019b. Pre plné fungovanie algoritmu je potrebné pridať Image Processing Toolbox, Deep Learning Toolbox a VGG-16 Support Package.

6.1 Spracovanie vstupných dát


Pre vytvorenie algoritmu boli použité dáta, ktorých bližší popis je poskytnutý v podkapitole 5.2 tejto práce. Pacientske dáta bolo najprv potrebné prevzorkovať, aby boli rezy rovnako navzorkované u všetkých pacientov. Konkrétne došlo k prevzorkovaniu pacientov č. 45 a 46 prostredníctvom skriptu s názvom *'prevzorkovanie.m'*. Po úspešnom načítaní všetkých dát prostredníctvom skriptu *'nacitanie_dat.m'* došlo k vytvoreniu tréningovej databázy, do ktorej však vstupoval len určitý počet týchto dát vzhľadom na rozdelenie databázy na tréningovú a testovaciu množinu.

6.2 Tvorba učebnej databázy

Databáza bola na začiatku rozdelená na tréningovú a testovaciu množinu v pomere 8:2, ako bolo uvedené v predchádzajúcej kapitole. Z každého patientskeho záznamu z tréningovej databázy boli ručne vysegmentované obrazy, t.j. pozitívne a negatívne detekcie zvlášť pre každú anatomickú štruktúru. Vzniklo tak 5 samostatných skriptov pre 7 anatomických štruktúr (uvedených v podkapitole 5.1), pričom dve z nich t.j. vonkajší zvukovod (*lat. meatus acusticus externus*) a vonkajší kútik oka (*lat. angulus oculi lateralis*) sú stranovo súmerné štruktúry, preto bol pre každú z nich využitý rovnaký skript. Každý skript prechádza dáta od každého pacienta z tréningovej množiny s cieľom vyrezať danú anatomickú štruktúru v 3D, ktorú potom uloží do bunkového poľa ako pozitívne detekcie. Od každého pacienta boli následne náhodne vybrané negatívne detekcie ako obrazy s rovnakou veľkosťou ako vyrezané pozitívne detekcie, ale bez obsahu anatomickej štruktúry. Každý skript teda prechádza 9 tréningových patientskych záznamov a vyberá pozitívne a negatívne detekcie, ktoré slúžia ako vstup do následného detekčného algoritmu. Vytváranie tréningovej databázy pre anatomickú štruktúru (*meatus acusticus externus*) je uvedené a okomentované v prílohe v skripte *MAE_databaza.m*. Takto vznikla databáza *MAE_databaza_augment.mat* Príklady obrazov vstupujúcich do databázy pozitívnych tréningových detekcií je zobrazený na obr. 6.2.



Obr. 6.1: Príklad extrahovania pozitívnej detekcie pre anatomickú štruktúru *meatus acusticus externus*.



Obr. 6.2: Príklad ručne segmentovanej a) pozitívnej, b) negatívnej detekcie pre anatomickú štruktúru *meatus acusticus externus*.

6.3 Detekčný algoritmus

Po skompletizovaní databázy pozitívnych a negatívnych detekcií nasleduje už jej použitie pre tréovanie detekčného algoritmu. Detekčný algoritmus sa vždy skladá z dvoch častí. Prvú časť tvorí extrakcia príznakov, ktoré v nasledujúcom kroku vstupujú do procesu tréovania klasifikátora SVM.



Obr. 6.3: Genéza detekčného algoritmu

6.4 Extrakcia príznakov

K výberu príznakov dochádza buď prostredníctvom príkazu *extractHOGFeatures* pre výber histogramov orientovaných gradientov alebo boli príznaky vybraté prostredníctvom neurónových sietí VGG-16, konkrétne ako výstup jej poolingovej vrstvy č. 5. Pre každý obraz, či už pozitívnu alebo negatívnu tréningovú databázu je takto vytvorený príznakový vektor.

Pri výbere príznakov prostredníctvom príkazu *extractHOGFeatures* je nutné určiť parameter *cellsize*, ktorý ako uvádza dokumentácia má vplyv na množstvo informácie, ktorú takto získame. Čím je tento rozmer väčší, tým získavame menej informácii o detailoch v obraze. Veľkosť bunky sa teda znižuje pre lepšie zachytenie detailov a zvyšuje v prípade rozsiahlych priestorových informácií. Tento parameter bolo potrebné otestovať metódou pokus-omyl, pretože jeho výber vždy závisí na type vstupnej obrazovej informácie. Preto bolo pre všetky anatomické štruktúry testovaných 5 rôznych nastavení tohto parametru a to *cell size*: [2 2], [4 4], [8 8], [10 10] a [12 12]. Vzhľadom na veľký vizuálny rozdiel detekovaných anatomických štruktúr sa najvhodnejšie nastavenie tohto parametru líši. Po extrahovaní príznakov z celej databázy je potrebné vytvoriť k príznakom príslušné popisky, ktoré budú označovať do ktorej skupiny daný príznakový vektor patrí. Boli teda vytvorené dve skupiny popisov - pozitívne a negatívne, tieto popisky je možné uvádzať číselne ako 0 pre negatívne popisy a 1 pre pozitívne.

Druhým typom testovaných príznakov boli príznaky poskytnuté prostredníctvom neurónových sietí, konkrétne sa jedná o VGG-16. Ide o predtrénované neurónové siete s 16 vrstvami. Pre našu aplikáciu sme použili len časť týchto vrstiev, konkrétne výstup z pooling vrstvy (*angl. pooling layer*) číslo 5, čím boli extrahované príznaky, ktoré boli následne použité ako vstup do navrhnutého detekčného algoritmu vytvoreného prostredníctvom metódy podporných vektorov (SVM).

6.5 Vytvorenie klasifikátora a proces detekcie

K vytvoreniu a natrérovaniu klasifikátora SVM došlo prostredníctvom príkazu *fitccoc*, do ktorého vstupovali predošle vytvorené príznakové vektory a k nim príslušné označenia. Obraz bol následne prechádzaný v oknách veľkosti anatomickej štruktúry s určitým krokom, ktorý bol zvolený na základe najlepších výsledkov dosiahnutých pri návrhu algoritmu. V tomto bode bolo ale potrebné urobiť kompromis medzi veľkosťou kroku a výpočtovou náročnosťou takto vytvoreného detektoru. Ďalším parametrom, ktorý mal vplyv na zvolenú veľkosť kroku je veľkosť detekovanej anatomickej štruktúry a teda veľkosť zvoleného detekčného okna. Ideálne pre väčšinu anatomických štruktúr by bolo zvolenie čo najmenšieho kroku a teda čo najväčšieho prekrytia posúvajúcich sa okien, čo zvyšuje detekčnú presnosť. Veľké prekrytie detekčných okien sú ale výrazne časovo náročné najmä u detekcie menších anatomických štruktúr, ako je napríklad *tuberculum sellae*, čo komplikuje ich využitie v reálnych aplikáciach zakladajúcich si na rýchlosti navrhnutého algoritmu. Rýchlosť detekčného algoritmu je určite dôležitý faktor i v medicínskych aplikáciach, preto je dôležité na to pri vytváraní takto zameraných algoritmov myslieť. V každom okne došlo k vyhodnoteniu obrazu prostredníctvom príkazu *predict*, z ktorého bolo získané skóre určujúce, ako veľmi sa štruktúra v okne podobá anatomickej štruktúre zahrnutej v tréningovej databáze. Takto získané hodnoty skóre boli uložené do matice hodnôt H , ktorej veľkosť sa zhoduje s veľkosťou celého rezu v ktorom je anatomická štruktúra vyhľadávaná. Vďaka tomu sa hodnota skóre uloží vždy na rovnaké miesto, kde sa nachádza detekčné okno, konkrétne sa jedná o súradnice ľavého horného rohu tohto detekčného okna. Pre každý rez je možné následne nájsť hodnotu maximálneho skóre tejto matice a následne zo všetkých takto vzniknutých matíc vybrať globálne maximum, ktoré by malo korešpondovať s hľadanou anatomickou štruktúrou.

6.6 Testovanie navrhnutého detekčného algoritmu

Na záver už bol algoritmus testovaný na celých CT záznamoch dvoch pacientov - pacienta číslo 46 a 47. Celkovo teda boli použité dva typy príznakov pre každého pacienta. Pre každú anatomickú štruktúru teda vznikli dva rôzne typy detektorov. Prvý typ vznikol použitím metódy podporných vektorov (SVM) na vstup ktorej boli privádzané príznaky v podobe histogramov orientovaných gradientov. Druhý typ detektoru vznikol kombináciou metódy podporných vektorov v spojení s príznakmi získanými z predtrénovanej neurónovej siete VGG-16. Pred vstupom obrazov do týchto neurónových sietí je potrebné zmeniť ich rozmer na požadovaných 224x224x3 pixely, k čomu bola využitá funkcia *imresize* a následne *cat* pre vytvorenie RGB obrazu.

Popísané dva typy detektorov boli použité pre každú vyššie zmienenú anatomickú zvlášť, pričom vždy došlo k doladeniu parametrov, ktoré mali vplyv na presnosť detekcie konkrétnej anatomickej štruktúry.

Vo vytvorenom skripte s názvom *'detektor.m'* je možnosť nastaviť typ príznakov, ktorý bude použitý ako vstup pre tréning klasifikátora SVM z dvoch možností - HOG alebo VGG. V oboch prípadoch je možné meniť detekčný krok, ktorý má vplyv nielen na rýchlosť detekcie ale i na rýchlosť detekčného algoritmu. O vplyve jeho nastavovania na presnosť a rýchlosť detekcie bude detailne pojednané v nasledujúcej kapitole. V prípade zvolenia príznakov HOG je možné nastavovať hodnotu veľkosti bunky tzv. parametru *cell size*. V tejto práci boli pre každú anatomickú štruktúru a každého pacienta vždy otestované 5 rôznych nastavení tohto parametru a to *cell size*: [2 2], [4 4], [8 8], [10 10] a [12 12]. Vzhľadom na to, že pre každú detekovanú anatomickú štruktúru je jeho ideálne nastavenie rôzne, vzhľadom na rozdielnosť detekovaných anatomických štruktúr boli všetky postupne otestované. Nešlo len o jednoduché otestovanie parametru *cell size* ale jeho kombinácia s nastavením detekčného kroku. Pre každého testovaného pacienta a každú anatomickú štruktúru je vďaka následnému detailnému vyhodnoteniu možné nájsť najvhodnejšie nastavenie parametrov ovplyvňujúcich detekciu.

6.7 Úprava procesu detekcie

Okrem toho bol v navrhnutom algoritme využitý dynamický post-processing, ktorý mal vplyv nielen na redukcii falošne pozitívnych detekcií ale najmä na zníženie výpočtového času, ktorý bol v prípade niektorých kombinácií nastavených parametrov veľmi výrazný. Tento post-processing funguje na základe percentuálneho zastúpenia pixelov pod určitou hranicou hodnoty intenzity. Jedná sa o tmavé pixely, ktoré sa nachádzajú v okolí hlavy, pričom ich zastúpenie je výrazné najmä v posledných rezoch, ktoré neobsahujú detekovanú anatomickú štruktúru a obsahujú iba malú časť hlavy čím zbytočne zvyšujú výpočtovú náročnosť. Percentuálne zastúpenie pixelov pod hraničnou jasovou hodnotou bolo vyhodnotené pre prvý a posledný rez, kde je ich rozdiel väčšinou najväčší, preto bolo percentuálne zastúpenie v 1. reze označené ako *blackMin* a naopak približne najviac tmavých pixelov sa nachádza v poslednom reze, preto je tam ich percentuálne zastúpenie najväčšie a bolo označené ako *blackMax*. Na základe rozdielu týchto hodnôt a zvoleniu určitého percenta tohto rozdielu sa rezy s vysokým obsahom tmavých pixelov vynechajú z procesu detekcie.

6.8 Kontrola funkčnosti detektoru

Pre vizuálnu kontrolu navrhnutého detektoru boli vytvorené dva samostatné skripty '*detektor_HOG_SVM.m*' a '*detektor_VGG_SVM.m*' prostredníctvom ktorých je na tréningovej databáze možnosť sledovať proces extrakcie príznakov prostredníctvom danej extrakčnej metódy, následný proces tvorby klasifikátora SVM ale najmä proces detekcie anatomickej štruktúry (*meatus acusticus externus*). Na konci je pre oboch testovacích pacientov (č. 46 a 47) zobrazené okno s výslednou najlepšou detekciou.

6.9 Databáza pre vyhodnotenie

Prostredníctvom skriptu *oznacenie_dat.m* boli vytvorené tzv. dáta so správnou odpoveďou, ktoré by ideálne vytvoril rádiologický pracovník a vzhľadom ku ktorým boli výsledné detekcie porovnávané, pre určenie výkonu navrhnutého detekčného algoritmu na základe detekčnej presnosti (*angl. precision*), úplnosti (*angl. recall*) a priemerná hodnota prekryvu aIoU (*angl. average Intersection over Union*) cez všetky rezy označená ako mIoU detekčného algoritmu. Výstupom zo skriptu je príslušný označujúci box (*angl. bounding box*), konkrétne súradnice jeho ľavého horného rohu. Takto sú za sebou označené rezy na ktorých sa daná anatomická štruktúra nachádza zvlášť pre jednotlivých testovaných pacientov. Navyše sú extrahované obrazy obsahujúce anatomicnú štruktúru, označené ako *vysledok_pozitivne* a *vysledok_negativne*, ktoré následne slúžia pre vyhodnotenie detekčného algoritmu prostredníctvom matice zámen (*angl. confusion matrix*), ktorú je možné tiež získať na výstupe navrhnutého detekčného algoritmu. V poslednom kroku došlo k vyhodnoteniu výkonu navrhnutého algoritmu zvlášť pre každú anatomicnú štruktúru a každý typ príznakov. Toto vyhodnotenie je uvedené v nasledujúcej kapitole.

7 VYHODNOTENIE ALGORITMU


Testovaním navrhnutého algoritmu detekcie na rôznych typoch vstupných dát, t.j. na rôznych anatomických štruktúrach bol viditeľný vplyv zmien jednotlivých parametrov na presnosť detekcie. Pri detekcii je možné meniť viacero parametrov, ktoré majú vplyv na detekčnú presnosť a výkon celého algoritmu. Veľmi záleží už na kvalite a parametroch učebnej databázy, ktorá do detektora vstupuje. Záleží nielen na jej veľkosti ale i na rozmere obrazov, ktoré obsahuje. Pri väčšej veľkosti vstupných pozitívnych a negatívnych detekcii sa detektor javil presnejší. Jedná sa teda o väčšie anatomické štruktúry ako je napríklad *meatus acusticus externus* (MAE). To však môže byť spôsobené i jeho štruktúrou, ktorá sa dostatočne líši od ostatných štruktúr a tým nedochádza k takým výrazným zámenám ako je tomu u iných štruktúr ako napríklad *tuberculum sellae* (TS). Veľký vplyv má i nastavenie veľkosti bunky t.j. parametru *cellsize* v príkaze *extractHOGFeatures*. O jeho vplyve bolo pojednané v predchádzajúcej kapitole. Vplyv na presnosť detekcie má i veľkosť kroku, o ktorom je taktiež zmienka v predošlej kapitole. Vplyvy jednotlivých parametrov na presnosť detekcie sú viditeľné v grafoch 7.1, C.1.

Kedže sa sú niektoré mozgové štruktúry vizuálne veľmi podobné je ich detekcia pomerne náročná. Najzložitejšie pre detekciu sa javila anatomická štruktúra *tuberculum sellae* s prihliadnutím na náročnosť jej označovania už pri vytváraní tréningovej databázy. Táto skutočnosť je taktiež zreteľná na výsledkoch detekčnej presnosti, ktorá nebola najvyššia.

Dosiahnutiu optimálnejších výsledkov detekcie napomohli dodatočné úpravy zmienené v predchádzajúcej kapitole, vďaka čomu došlo k odstráneniu množstva rezov, na ktorých sa už nenachádzajú žiadne anatomické štruktúry dôležité pre detekciu. V tejto práci bola použitá metóda ktorá vyhodnocovala percentuálne zastúpenie tmavých pixelov, pričom pri prekročení určitej hodnoty percenta týchto pixelov označenej ako *threshold* dochádza k vypusteniu týchto rezov z detekčného algoritmu, čím dochádza k zníženiu výpočtového času. K zlepšeniu výkonu detektora v prípadoch niektorých anatomických štruktúr prispelo i zväčšenie databázy pozitívnych a negatívnych detekcii prostredníctvom metód umelého rozšírenia databázy, ktorými je pridanie šumu prípadne rotácia obrazu.

Hodnotenie kvality navrhnutého algoritmu bolo vykonané prostredníctvom parametrov, ktorými sú: aIoU (angl. average Intersection over Union), čo je v tomto prípade priemerná hodnota prekryvu cez všetky rezy, priemerná presnosť a priemerná úplnosť cez všetky rezy. Na základe týchto parametrov boli porovnané i výkony príznakov HOG a príznakov z VGG-16. Hodnotenia detekčného výkonu pro-


Obr. 7.1: Závislosť mIOU na detekčnom kroku pre pacienta 46




stredníctvom týchto metrik sú pre nahliadnutie uvedené v tabuľkách v prílohe C. Z porovnania výsledkov vyplýva, že sa spoľahlivejšie pre našu aplikáciu javilo použitie príznakov

Najväčším problémom s ktorým sa táto práca potýka je výpočtová náročnosť navrhnutých metód. Vysoký výpočtový čas bol znižovaný prostredníctvom spomínaných dodatočných úprav. Je ale potrebné voliť kompromis medzi presnosťou a výpočtovým časom. Táto bakalárska práca sa ale zamerala na presnosť detekcie na úkor výpočtového času, ktorý je následne možné zredukovať viacerými metódami.

Pri hodnotení kvality algoritmu je potrebné myslieť i na to, že kvalitu tohoto algoritmu významne ovplyvnil fakt, že anatomické štruktúry neboli určované skúseným lekárom, ktorý by vytvoril tréningovú databázu s anatomickými štruktúrami oveľa presnejšie. Pre zvýšenie presnosti, by bolo vhodné aby v tréningovej databáze



Obr. 7.2: Příklad výstup detekčního algoritmu pre rez 60, pacienta č.46 prostřednictvím VGG-16.



Obr. 7.3: Příklad výstup detekčního algoritmu pre rez 61, pacienta č.46 prostřednictvím HOG.

vytvoril obrazy a k nim príslušné popisy anatomických bodov skúsený odborník v oblasti rádiologického zobrazovania mozgu. O dátach použitých do tréningovej databázy nemáme bližšie informácie – nevieme teda určiť, či ide o prevažne ženských/mužských pacientov, nepoznáme vek pacientov a hlavným nedostatkom je fakt, že nemáme informáciu o tom, či sa v snímkach nachádzajú patológie. Jednoznačne by bolo vhodné vyhodnotenie snímok vstupujúcich do učebnej databázy z hľadiska patológie. Tieto nedostatky môžu spôsobiť skreslenie a zníženie presnosti navrhnutého detekčného algoritmu. Kvalitu algoritmu výrazne ovplyvňuje i prítomnosť šumu v obrazoch.

Následné zlepšenie detekcie by mohlo priniesť zväčšenie databázy o snímky z rôznych pracovísk a rôznych skenovacích zariadení, čím by mohol vzniknúť viac generalizovaný algoritmus so širším záberom aplikácii. Výhodou by bolo i rozšírenie použiteľnosti algoritmu i pre obrazové informácie poskytované z inej modality ako CT, napríklad by sa mohlo jednať o snímky z magnetickej rezonancie, ktoré poskytujú v prípade niektorých štruktúr detailnejšie obrazy.

Zlepšenie navrhnutého algoritmu by mohlo priniesť ďalej použitie tzv. krížovej validácie (*angl. cross-validation*), použitie kombinácie príznakov prípadne použitie úplne iného typu príznakov, napríklad využitie matíc vzájomného výskytu (GLCM), ktoré boli v prácach s podobnou tematikou často používané a na základe ktorých dosahovali autori priaznivé výsledky. K urýchleniu algoritmu by mohlo viesť prvotné klasifikovanie rezov veľkosti 512x512 pixelov ako celku na rezy obsahujúce prípadne neobsahujúce anatomickú štruktúru a až následná aplikácia detekčného okna na rezy vyhodnoteného ako tie obsahujúce anatomickú štruktúru. Iným riešením je možnosť prechádzania celého datasetu väčším oknom a až následné zmenšovanie okna v prípade vyhodnotenia väčšieho okna ako okna obsahujúceho anatomickú štruktúru. Ako už bolo zmienené zlepšenie presnosti detekcie je často v kontraste s časovou náročnosťou algoritmu, preto je na toto nutné myslieť pri zásahu do týchto algoritmov.

Záver

V tejto práci bol navrhnutý detekčný algoritmus pre detekciu anatomicky významných bodov z CT snímok hlavy. Metóda bola navrhnutá pre použitie na CT snímkach hlavy, ale nevyklučujú sa jej aplikácia i na obrazy z iných modalít a pre iné anatomické štruktúry. Zlepšením presnosti detekovaných štruktúr a ďalšími úpravami algoritmu by algoritmus mohol nájsť uplatnenie v rádiológii. V súčasnosti je ručné segmentovanie týchto anatomických štruktúr náplňou práce rádiológov. Takáto detekcia anatomických štruktúr je dôležitá pre vytvorenie rádiologických línií. Táto úloha je nielen časovo náročná, ale i náchylná na ľudské chyby, preto by automatizácia tohto procesu mohla viesť k šetreniu času rádiológov pre dôležitejšie úlohy a taktiež k zníženiu chybovosti a tým i k menšiemu množstvu nesprávne diagnostikovaných pacientov. Vzhľadom na medicínsku aplikáciu, kde chyba môže znamenať ujmu na ľudskom zdraví, je presnosť nesmierne dôležitá. V podstate sa jedná o aplikáciu, ktorú je možné zaradiť do systému CAD (angl. Computer Aided Diagnostics), ktorá s použitím umelej inteligencie a metód strojového učenia napomáha lekárom v správnej diagnostike pacientov. Rozhodovanie však stále prenecháva v rukách ľudských odborníkov. Predstavuje len podporný rozhodovací systém a teda nepredstavuje ohrozenie pre lekárov, pretože rozhodovanie o diagnostike prenecháva stále na nich. Tým rieši legislatívne a etické problémy, ktoré by nastali pri úplnom prenechaní diagnostiky počítačom. Jedná sa najmä o právne dôsledky pochybenia v diagnostike a s tým spojenou spôsobenou zdravotnou ujmou. Môže však predstavovať silný podporný nástroj umožňujúci spoluprácu viacerých svetových odborníkov a navyše prináša využitie poznatkov a súvislostí, ktoré sú človekom nepostrehnuteľné a ktoré dokáže zachytiť len umelá inteligencia.

Strojové učenie sa už uplatňuje v rádiologickej praxi a tieto aplikácie budú v blízkej budúcnosti pravdepodobne rásť. Použitie strojového učenia v rádiológii má dôležité dôsledky pre medicínsku prax a je dôležité, aby bol výskum zameraný na vývoj takých systémov, ktoré zabezpečia pacientom čo najlepšiu zdravotnú starostlivosť. Pochopenie vlastností nástrojov strojového učenia je rozhodujúce pre zabezpečenie toho, aby bola umelá inteligencia použitá v medicíne čo najbezpečnejšie a najefektívnejšie.

V prípadoch niektorých anatomických štruktúr dosahoval navrhnutý detektor obstojnú detekčnú presnosť. Jedná sa najmä o anatomickú štruktúru (*lat. meatus acusticus externus*) u ktorej vyšlo aIoU 0.988 detekovaných prostredníctvom príznakov HOG s veľkosťou bunky 10, detekčným krokom 9 na reze 61 pre pacienta 46. Pre VGG bolo IoU malinko menšie a to 0.97. Jedná sa o VGG-16 s detekčným krokom 15.

Protredníctvom dosiahnutia dobrej detekčnej presnosti niektorých detekovaných

anatomických štruktúr v tejto práci, doladením algoritmu a zvýšením detekčnej presnosti zvyšných anatomických štruktúr by si tento algoritmus mohol nájsť uplatnenie v rádiológii pri vytváraní rádiologických línií pre CT skenovanie mozgu.

Literatúra

- [1] HOLIBKOVÁ, Alžběta a Stanislav LAICHMAN. *Přehled anatomie člověka*. 5. vyd. Olomouc: Univerzita Palackého v Olomouci, 2010. ISBN 978-80-244-2615-0.
- [2] MRÁZ, Peter, Alexander BINOVSÝ, Anna HOLOMÁŇOVÁ, Mária OSVALDOVÁ a Eva RUTTKAY-NEDECKÁ. *Anatómia ľudského tela 1*. Bratislava: Slovak Academic Press, 2004. ISBN 80-89104-57-6.
- [3] MRÁZ, Peter, Kamil BELEJ, Jozef BEŇUŠKA, Anna HOLOMÁŇOVÁ, Mária MACKOVÁ a Jana ŠTEŇOVÁ. *Anatómia ľudského tela 2*. Bratislava: SAP - Slovak Academic Press, 2006. ISBN 80-89104-96-7.
- [4] ČIHÁK, Radomír. *Anatomie*. Třetí, upravené a doplněné vydání. Ilustroval Ivan HELEKAL, ilustroval Jan KACVINSKÝ, ilustroval Stanislav MACHÁČEK. Praha: Grada, 2011. ISBN 978-80-247-3817-8.
- [5] ČIHÁK, Radomír. *Anatomie 3*. Třetí, upravené a doplněné vydání. Ilustroval Ivan HELEKAL, ilustroval Jan KACVINSKÝ, ilustroval Stanislav MACHÁČEK. Praha: Grada, 2016. ISBN 978-80-247-5636-3.
- [6] FEHRENBACH, Margaret J. a Susan W. HERRING. *Illustrated anatomy of the head and neck*. 4th ed. St. Luis: Elsevier, c2012. ISBN 978-1-4377-2419-6.
- [7] VOMÁČKA, Jaroslav, Josef NEKULA a Jiří KOZÁK. *Zobrazovací metody pro radiologické asistenty*. V Olomouci: Univerzita Palackého, 2012. ISBN 978-80-244-3126-0.
- [8] SEIDL, Zdeněk. *Radiologie pro studium i praxi*. Praha: Grada, 2012. ISBN 978-80-247-4108-6.
- [9] NEKULA, Josef. *Radiologie*. 3. vyd. V Olomouci: Univerzita Palackého, 2005. ISBN 8024410117.
- [10] HEŘMAN, Miroslav. *Základy radiologie*. V Olomouci: Univerzita Palackého, 2014. ISBN 978-80-244-2901-4.
- [11] WHITLEY, A. S., Charles SLOANE, Gail JEFFERSON, Ken HOLMES, Craig ANDERSON a A. S. WHITLEY. *Clark's pocket handbook for radiographers*. Second edition. Boca Raton: Taylor & Francis, 2016. ISBN 9781498726993.
- [12] FERDA, Jiří, Boris KREUZBERG a Milan NOVÁK. *Výpočetní tomografie*. Praha: Galén, c2002. ISBN 80-7262-172-6.

- [13] FERDA, Jiří, Hynek MÍRKA, Jan BAXA a Alexander MALÁN. *Základy zobrazovacích metod*. Praha: Galén, [2015]. ISBN 978-80-7492-164-3.
- [14] OREL, Miroslav a Roman PROCHÁZKA. *Vyšetření a výzkum mozku: pro psychology, pedagogy a další nelékařské obory*. Praha: Grada, 2017. Psyché (Grada). ISBN 978-80-247-5539-7.
- [15] BRYANT, J.A, N.A DRAGE a S RICHMOND. CT number definition. *Radiation Physics and Chemistry* [online]. Elsevier, 2012, **81**(4), 358-361 [cit. 2020-03-22]. DOI: 10.1016/j.radphyschem.2011.12.026. ISSN 0969-806X. Dostupné z URL: <https://www.sciencedirect.com/science/article/abs/pii/S0969806X11005081>.
- [16] CHARVÁT, František a Bohumil MARKALOUS. *Zobrazení hlavy: metodika vyšetřování, anatomie, patologie, klinika : CT, MR, RTG, PET, PET/CT, sonografie, endoskopie, angiografie, intervenční neuroradiologie, navigovaná chirurgie*. 2. upr. a rozš. vyd. Praha: Triton, c2006. ISBN 80-7254-904-9.
- [17] PETEROVA, Vera. CT - zaklady vysetreni, indikace, kontraindikace, moznosti, prakticke zkusenosti. *Medicína pro praxi*. Solen, 2010, **7**(2), 90-94. ISSN 12148687. Dostupné z URL: <https://www.medicinapropraxi.cz/artkey/med-201002-0012.php>.
- [18] KIM, Y.I., K.J. AHN, Y.A. CHUNG a B.S. KIM. A New Reference Line for the Brain CT: The Tuberculum Sellae-Occipital Protuberance Line is Parallel to the Anterior/Posterior Commissure Line. *American Journal of Neuroradiology*. 2009, **30**(9), 1704-1708. DOI: 10.3174/ajnr.A1676. ISSN 0195-6108. Dostupné z URL: <http://www.ajnr.org/lookup/doi/10.3174/ajnr.A1676>.
- [19] WEISS, Kenneth L, Judd STORRS, Jane L WEISS, William STRUB a Kenneth L WEISS. CT brain prescriptions in Talairach space: a new clinical standard. *AJNR. American journal of neuroradiology* [online]. 2004, **25**(2), 233-237 [cit. 2020-03-26]. ISSN 0195-6108. Dostupné z URL: <https://pubmed.ncbi.nlm.nih.gov/14970022/>.
- [20] ERICKSON, Bradley J., Panagiotis KORFIATIS, Zeynettin AKKUS a Timothy L. KLINE. Machine Learning for Medical Imaging. *RadioGraphics* [online]. 2017, **37**(2), 505-515 [cit. 2020-03-23]. DOI: 10.1148/rg.2017160130. ISSN 0271-5333. Dostupné z URL: <http://pubs.rsna.org/doi/10.1148/rg.2017160130>.

- [21] ALANSARY, Amir, Ozan OKTAY, Yuanwei LI, et al. Evaluating reinforcement learning agents for anatomical landmark detection. *Medical Image Analysis* [online]. 2019, **53**, 156-164 [cit. 2019-11-25]. DOI: 10.1016/j.media.2019.02.007. ISSN 13618415. Dostupné z URL: <https://linkinghub.elsevier.com/retrieve/pii/S1361841518306121>.
- [22] ANGRISH, Hitul a Sandeep KAUR. A Survey on Feature Description Techniques. *International Journal of Science and Research (IJSR)* [online]. 2015, **4**(5), 38 - 41 [cit. 2020-03-26]. ISSN 2319-7064. Dostupné z URL: <https://www.ijsr.net/archive/v4i5/27041503.pdf>.
- [23] *International Journal of Computer Science and Information Technologies: A Survey on Image Feature Descriptors* [online]. 2014, **5**(6) [cit. 2020-03-23]. ISSN 0975-9646.
- [24] ZHOU, M, J SCOTT, B CHAUDHURY, et al. Radiomics in Brain Tumor: Image Assessment, Quantitative Feature Descriptors, and Machine-Learning Approaches. *AJNR. American journal of neuroradiology* [online]. 2018, **39**(2), 208 [cit. 2020-03-22]. DOI: 10.3174/ajnr.A5391. ISSN 0195-6108. Dostupné z URL: <http://www.ajnr.org/content/39/2/208>.
- [25] ZHANG, Jun, Yue GAO, Yaozong GAO, Brent C. MUNSELL a Dinggang SHEN. Detecting Anatomical Landmarks for Fast Alzheimer-s Disease Diagnosis. *IEEE Transactions on Medical Imaging*. 2016, **35**(12), 2524-2533. DOI: 10.1109/TMI.2016.2582386. ISSN 0278-0062. Dostupné z URL: <http://ieeexplore.ieee.org/document/7494619/>.
- [26] NABIZADEH, Nooshin a Miroslav KUBAT. Brain tumors detection and segmentation in MR images: Gabor wavelet vs. statistical features. *Computers & Electrical Engineering* [online]. 2015, **45**, 286-301 [cit. 2020-03-23]. DOI: 10.1016/j.compeleceng.2015.02.007. ISSN 00457906. Dostupné z URL: <https://linkinghub.elsevier.com/retrieve/pii/S0045790615000324>.
- [27] PRAVEEN, G. B a Anita AGRAWAL. Hybrid approach for brain tumor detection and classification in magnetic resonance images. In: *2015 Communication, Control and Intelligent Systems (CCIS)* [online]. IEEE, 2015, s. 162-166 [cit. 2020-03-22]. DOI: 10.1109/CCIIntelS.2015.7437900. Dostupné z URL: <https://ieeexplore.ieee.org/abstract/document/7437900>.

- [28] PARVEEN a Amritpal SINGH. Detection of brain tumor in MRI images, using combination of fuzzy c-means and SVM. In: *2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN)* [online]. Noida: IEEE, 2015, 2015, s. 98-102 [cit. 2020-03-28]. DOI: 10.1109/SPIN.2015.7095308. ISBN 978-1-4799-5991-4. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/7095308/>>.
- [29] THEODORIDIS, Sergios a Konstantinos KOUTROUMBAS. *Pattern recognition*. 4th ed. Burlington, Mass.: Academic Press, c2009. ISBN 978-1-59749-272-0.
- [30] OTAKE, Shoichiro, Toshiaki TAOKA, Masayuki MAEDA a William TC YUH. A guide to identification and selection of axial planes in magnetic resonance imaging of the brain. *The Neuroradiology Journal* [online]. 2018, **31**(4), 336-344 [cit. 2020-03-23]. DOI: 10.1177/1971400918769911. ISSN 1971-4009. Dostupné z URL:
<<http://journals.sagepub.com/doi/10.1177/1971400918769911>>.
- [31] MEYER-BÄESE, Anke a Volker SCHMID. *Pattern recognition and signal analysis in medical imaging*. Second edition. Waltham, MA: Elsevier/Academic Press, 2014. ISBN 978-0-12-409545-8.
- [32] ZAHARCHUK, G., E. GONG, M. WINTERMARK, D. RUBIN a C.P. LANGLOTZ. Deep Learning in Neuroradiology. *American Journal of Neuroradiology* [online]. 2018, **39**(10), 1776-1784 [cit. 2020-03-23]. DOI: 10.3174/ajnr.A5543. ISSN 0195-6108. Dostupné z URL:
<<http://www.ajnr.org/lookup/doi/10.3174/ajnr.A5543>>.
- [33] GIGER, Maryellen L. Machine Learning in Medical Imaging. *Journal of the American College of Radiology* [online]. 2018, **15**(3), 512-520 [cit. 2020-03-16]. DOI: 10.1016/j.jacr.2017.12.028. ISSN 15461440. Dostupné z URL:
<<https://linkinghub.elsevier.com/retrieve/pii/S1546144017316733>>.
- [34] HUANG, Shujun, Nianguang CAI, Pedro Penzuti PACHECO, Shavira NARRANDES, Yang WANG a Wayne XU. Applications of Support Vector Machine (SVM) Learning in Cancer Genomics. *Cancer genomics & proteomics* [online]. 2018, **15**(1), 41-51 [cit. 2020-03-23]. DOI: 10.21873/cgp.20063. ISSN 1109-6535. Dostupné z URL:
<<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5822181/>>.

- [35] BOUGHARRIOU, S., F. HAMDAOUI a A. MTIBAA. Linear SVM classifier based HOG car detection. In: *2017 18th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)* [online]. Monastir, Tunisia: IEEE, 2017, 2017, s. 241-245 [cit. 2020-03-23]. DOI: 10.1109/STA.2017.8314922. ISBN 978-1-5386-1084-8. ISSN 2573-539X. Dostupné z URL: <http://ieeexplore.ieee.org/document/8314922/>.
- [36] DAVIS, Matt a Ferat SAHIN. HOG feature human detection system. In: *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* [online]. Budapest: IEEE, 2016, 2016, s. 002878-002883 [cit. 2020-03-23]. DOI: 10.1109/SMC.2016.7844676. ISBN 978-1-5090-1897-0. Dostupné z URL: <http://ieeexplore.ieee.org/document/7844676/>.
- [37] ZELJKOVIC, V., C. DRUZGALSKI, Y. ZHANG, Z. ZHU, Z. XU, D. ZHANG a P. MAYORGA. Automatic brain tumor detection and segmentation in MR images. In: *2014 Pan American Health Care Exchanges (PAHCE)* [online]. Brasilia: IEEE, 2014, 2014, s. 1-1 [cit. 2020-03-23]. DOI: 10.1109/PAHCE.2014.6849645. ISBN 978-1-4799-3555-0. ISSN 2327-817X. Dostupné z URL: <http://ieeexplore.ieee.org/document/6849645/>.
- [38] RAJESHWARI, S. a T. Sree SHARMILA. Efficient quality analysis of MRI image using preprocessing techniques. In: *2013 IEEE CONFERENCE ON INFORMATION AND COMMUNICATION TECHNOLOGIES* [online]. Thuckalay: IEEE, 2013, 2013, s. 391-396 [cit. 2020-03-23]. DOI: 10.1109/CICT.2013.6558127. ISBN 978-1-4673-5758-6. Dostupné z URL: <http://ieeexplore.ieee.org/document/6558127/>.
- [39] YAN, Junjie, Xuzong ZHANG, Zhen LEI a Stan Z. LI. Face detection by structural models. *Image and Vision Computing*. 2014, **32**(10), 790-799. DOI: 10.1016/j.imavis.2013.12.004. ISSN 02628856. Dostupné z URL: <https://linkinghub.elsevier.com/retrieve/pii/S0262885613001765>.
- [40] PANTIC, IGOR, SENKA PANTIC, JOVANA PAUNOVIC a MILAN PEROVIC. Nuclear entropy, angular second moment, variance and texture correlation of thymus cortical and medullar lymphocytes: Grey level co-occurrence matrix analysis. *Anais da Academia Brasileira de Ciências*. 2013, **85**(3), 1063-1072. DOI: 10.1590/S0001-37652013005000045. ISSN 0001-3765.

- [41] YAGHOUBIAN, S, Mohd MAAROF, Anazida ZAINAL a Mahdi OGHAZ. A SURVEY OF FEATURE EXTRACTION TECHNIQUES IN CONTENT-BASED ILLICIT IMAGE DETECTION. *Journal of Theoretical and Applied Information Technology* [online]. Islamabad: Journal of Theoretical and Applied Information, 2016, **87**(1), 110-125 [cit. 2020-03-24]. ISSN 18173195. Dostupné z URL:
<<https://www.researchgate.net/publication/303435667/>>.
- [42] PESAPANE, Filippo, Marina CODARI a Francesco SARDANELLI. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental* [online]. 2018, **2**(1) [cit. 2020-03-09]. DOI: 10.1186/s41747-018-0061-6. ISSN 2509-9280. Dostupné z URL:
<<https://pubmed.ncbi.nlm.nih.gov/30353365/>>.
- [43] HASSABALLAH, M., Aly Amin ABDELMGEID a Hammam A. ALSHAZLY. Image Features Detection, Description and Matching. AWAD, Ali Ismail a Mahmoud HASSABALLAH, ed. *Image Feature Detectors and Descriptors* [online]. Cham: Springer International Publishing, 2016, 2016-02-23, s. 11-45 [cit. 2020-03-12]. Studies in Computational Intelligence. DOI: 10.1007/978-3-319-28854-3_2. ISBN 978-3-319-28852-9. Dostupné z URL:
<http://link.springer.com/10.1007/978-3-319-28854-3_2>.
- [44] LEE, June-goo, Sanghoon JUN, Young-won CHO, Hyunna LEE, Guk Bae KIM, Joon Beom SEO, Namkug KIM a June-goo LEE. Deep Learning in Medical Imaging: General Overview. *Korean journal of radiology* [online]. 2017, **18**(4), 570-584 [cit. 2020-03-24]. DOI: 10.3348/kjr.2017.18.4.570. ISSN 12296929. Dostupné z URL:
<<https://pubmed.ncbi.nlm.nih.gov/28670152/>>.
- [45] RAZZAK, Muhammad Imran, Saeeda NAZ a Ahmad ZAIB. Deep Learning for Medical Image Processing: Overview, Challenges and the Future. DEY, Nilanjan, Amira S. ASHOUR a Surekha BORRA, ed. *Classification in BioApps* [online]. Cham: Springer International Publishing, 2018, 2018-11-14, s. 323-350 [cit. 2020-03-24]. Lecture Notes in Computational Vision and Biomechanics. DOI: 10.1007/978-3-319-65981-7_12. ISBN 978-3-319-65980-0. Dostupné z URL:
<http://link.springer.com/10.1007/978-3-319-65981-7_12/>.
- [46] WERNICK, Miles, Yongyi YANG, Jovan BRANKOV, Grigori YOURGANOV a Stephen STROTHER. Machine Learning in Medical Imaging. *IEEE Signal Processing Magazine* [online]. 2010, **27**(4), 25-38 [cit. 2020-03-13]. DOI:

- 10.1109/MSP.2010.936730. ISSN 1053-5888. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/5484160/>>.
- [47] WANG, Shijun a Ronald M SUMMERS. Machine learning and radiology. *Medical Image Analysis* [online]. Elsevier B.V, 2012, **16**(5), 933-951 [cit. 2020-03-16]. DOI: 10.1016/j.media.2012.02.005. ISSN 1361-8415. Dostupné z URL:
<<https://www.sciencedirect.com/science/article/pii/S1361841512000333>>.
- [48] SUZUKI, Kenji. Overview of deep learning in medical imaging. *Radiological Physics and Technology* [online]. 2017, **10**(3), 257-273 [cit. 2020-03-13]. DOI: 10.1007/s12194-017-0406-5. ISSN 1865-0333. Dostupné z URL:
<<http://link.springer.com/10.1007/s12194-017-0406-5>>.
- [49] MIRANDA, Eka, Mediana ARYUNI a E. IRWANSYAH. A survey of medical image classification techniques. In: *2016 International Conference on Information Management and Technology (ICIMTech)* [online]. Bandung: IEEE, 2016, 2016, s. 56-61 [cit. 2020-03-24]. DOI: 10.1109/ICIMTech.2016.7930302. ISBN 978-1-5090-3352-2. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/7930302/>>.
- [50] KOHLI, Marc, Luciano M. PREVEDELLO, Ross W. FILICE a J. Raymond GEIS. Implementing Machine Learning in Radiology Practice and Research. *American Journal of Roentgenology* [online]. 2017, **208**(4), 754-760 [cit. 2020-03-24]. DOI: 10.2214/AJR.16.17224. ISSN 0361-803X. Dostupné z URL:
<<http://www.ajronline.org/doi/10.2214/AJR.16.17224>>.
- [51] SALAHAT, Ehab a Murad QASAIMAH. Recent advances in features extraction and description algorithms: A comprehensive survey. In: *2017 IEEE International Conference on Industrial Technology (ICIT)* [online]. Toronto: IEEE, 2017, s. 1059-1063 [cit. 2020-04-03]. DOI: 10.1109/ICIT.2017.7915508. ISBN 978-1-5090-5320-9. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/7915508/>>.
- [52] YE, Zhiwei, Lie MA, Mingwei WANG, Hongwei CHEN a Wei ZHAO. Texture image classification based on support vector machine and bat algorithm. In: *2015 IEEE 8th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)* [online]. Warsaw: IEEE, 2015, 2015, s. 309-314 [cit. 2020-03-24]. DOI: 10.1109/IDAACS.2015.7340749. ISBN 978-1-4673-8359-2. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/7340749/>>.

- [53] BEN HAJ AYECH, Marouane a Hamid AMIRI. Texture description using statistical feature extraction. In: *2016 2nd International Conference on Advanced Technologies for Signal and Image Processing (ATSIP)* [online]. Monastir: IEEE, 2016, 2016, s. 223-227 [cit. 2020-03-24]. DOI: 10.1109/ATSIP.2016.7523072. ISBN 978-1-4673-8526-8. Dostupné z URL: <http://ieeexplore.ieee.org/document/7523072/>.
- [54] KORKMAZ, Sevcan Aytac, Aysegul AKCICEK, Hamidullah BINOL a Mehmet Fatih KORKMAZ. Recognition of the stomach cancer images with probabilistic HOG feature vector histograms by using HOG features. In: *2017 IEEE 15th International Symposium on Intelligent Systems and Informatics (SISY)* [online]. Subotica: IEEE, 2017, 2017, s. 000339-000342 [cit. 2020-03-24]. DOI: 10.1109/SISY.2017.8080578. ISBN 978-1-5386-3855-2. ISSN 1949-0488. Dostupné z URL: <http://ieeexplore.ieee.org/document/8080578/>.
- [55] SARWINDA, Devvi a Alhadi BUSTAMAM. 3D-HOG Features —Based Classification using MRI Images to Early Diagnosis of Alzheimer-s Disease. In: *2018 IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS)* [online]. Singapore: IEEE, 2018, 2018, s. 457-462 [cit. 2020-03-24]. DOI: 10.1109/ICIS.2018.8466524. ISBN 978-1-5386-5892-5. Dostupné z URL: <https://ieeexplore.ieee.org/document/8466524/>.
- [56] SERAG, Ahmed, Gillian MACNAUGHT, Fiona C. DENISON, Rebecca M. REYNOLDS, Scott I. SEMPLE a James P. BOARDMAN. Histograms of Oriented 3D Gradients for Fully Automated Fetal Brain Localization and Robust Motion Correction in 3-T Magnetic Resonance Images. *BioMed Research International* [online]. 2017, **2017**, 1-8 [cit. 2020-03-23]. DOI: 10.1155/2017/3956363. ISSN 2314-6133. Dostupné z URL: <https://www.hindawi.com/journals/bmri/2017/3956363/>.
- [57] ALHINDI, Taha J., Shivam KALRA, Ka Hin NG, Anika AFRIN a Hamid R. TIZHOOSH. Comparing LBP, HOG and Deep Features for Classification of Histopathology Images. In: *2018 International Joint Conference on Neural Networks (IJCNN)* [online]. Rio de Janeiro: IEEE, 2018, 2018, s. 1-7 [cit. 2020-03-23]. DOI: 10.1109/IJCNN.2018.8489329. ISBN 978-1-5090-6014-6. ISSN 2161-4407. Dostupné z URL: <https://ieeexplore.ieee.org/document/8489329/>.

- [58] P, Soumya Balan. Survey on Feature Extraction Techniques in Image Processing. *International Journal for Research in Applied Science and Engineering Technology*. 2018, **6**(3), 217-222. DOI: 10.22214/ijraset.2018.3035. ISSN 23219653. Dostupné z URL:
<<http://ijraset.com/files/serve.php?FID=14067>>.
- [59] LI, Yali, Shengjin WANG, Qi TIAN a Xiaoqing DING. A survey of recent advances in visual feature detection. *Neurocomputing* [online]. Elsevier B.V, 2015, **2015**(149), 736-751 [cit. 2020-03-15]. DOI: 10.1016/j.neucom.2014.08.003. ISSN 0925-2312. Dostupné z URL:
<<https://www.sciencedirect.com/science/article/pii/S0925231214010121>>.
- [60] MUKHERJEE, Dibyendu, Q WU a Guanghui WANG. A comparative experimental study of image feature detectors and descriptors. *Machine Vision and Applications* [online]. New York: Springer Nature B.V, 2015, **26**(4), 443-466 [cit. 2020-03-15]. DOI: 10.1007/s00138-015-0679-9. ISSN 09328092. Dostupné z URL:
<<https://link.springer.com/article/10.1007/s00138-015-0679-9/>>.
- [61] BANKMAN, I. N. *Handbook of medical imaging: processing and analysis*. San Diego, CA: Academic Press, c2000. ISBN 0120777908.
- [62] M.VASANTHA, BHARATHI, DR.V.SUBBIAH a S.DHAMODHARAN. Medical Image Feature, Extraction, Selection And Classification. *International Journal of Engineering Science and Technology*. 2010, **2**(6), 2071-2076. ISSN 0975-5462.
- [63] BALAKUMAR, B., P. RAVIRAJ a E.Divya DEV. Brain Tumor Classification Using Machine Learning Algorithms. *Elysium Journal of Engineering Research And Management* [online]. 2017, **4**(2), 30-41 [cit. 2020-04-18]. ISSN 2347-4734. Dostupné z URL:
<http://www.ejerm.com/vol4_april_2017/img/pdf/5.%20Brain-Tumor-Classification-Using-Machine-Learning-Algorithms.pdf>.
- [64] PEREIRA, Sergio, Adriano PINTO, Victor ALVES a Carlos A. SILVA. Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. *IEEE Transactions on Medical Imaging* [online]. 2016, **35**(5), 1240-1251 [cit. 2020-04-18]. DOI: 10.1109/TMI.2016.2538465. ISSN 0278-0062. Dostupné z URL:
<<http://ieeexplore.ieee.org/document/7426413/>>.

- [65] PRANATA, Yoga Dwi, Kuan-Chung WANG, Jia-Ching WANG, Irwansyah IDRAM, Jiing-Yih LAI, Jia-Wei LIU a I-Hui HSIEH. Deep learning and SURF for automated classification and detection of calcaneus fractures in CT images. *Computer Methods and Programs in Biomedicine* [online]. 2019, **171**, 27-37 [cit. 2020-05-28]. DOI: 10.1016/j.cmpb.2019.02.006. ISSN 01692607. Dostupné z URL: <<https://linkinghub.elsevier.com/retrieve/pii/S0169260718314652>>.
- [66] SIMONYAN, Karen a Andrew ZISSERMAN. Very Deep Convolutional Networks for Large-Scale Image Recognition. *ArXiv.org* [online]. Ithaca: Cornell University Library, arXiv.org, 2015 [cit. 2020-06-01]. Dostupné z URL: <<http://search.proquest.com/docview/2081521649/>>
- [67] GHAYOOR, Ali, Jatin G VAIDYA a Hans J JOHNSON. Robust automated constellation-based landmark detection in human brain imaging. *NeuroImage* [online]. Elsevier, 2018, **170**, 471-481 [cit. 2020-03-23]. DOI: 10.1016/j.neuroimage.2017.04.012. ISSN 1053-8119. Dostupné z URL: <<https://www.sciencedirect.com/science/article/abs/pii/S1053811917303014/>>.
- [68] ZHANG, Dongqing, Yuan LIU, Jack H NOBLE a Benoit M DAWANT. Automatic localization of landmark sets in head CT images with regression forests for image registration initialization. *Proceedings of SPIE - The International Society for Optical Engineering*. 2016/02/27, **9784**, 97841M [cit. 2020-03-23]. DOI: 10.1117/12.2216925. ISSN 1996-756X. Dostupné z URL: <<https://pubmed.ncbi.nlm.nih.gov/28503017>>

Zoznam symbolov, veličín a skratiek

AC-PC	Anterior Commissure - Posterior Commisure
AD	Alzheimerova choroba, <i>angl. Alzheimer's Disease</i>
AI	umelá inteligencia, <i>angl. Artificial Intelligence</i>
ALARA	„tak nízke ako je rozumne dosiahnutelné”, <i>angl. „As Low As Reasonably Possible”</i>
BRIEF	<i>angl. Binary Robust Independent Elementary Feature</i>
BRISK	<i>angl. Binary Robust Invariant Scalable Keypoints</i>
CAD	počítačom podporovaná diagnostika, <i>angl. Computer Aided Diagnostics</i>
CNN	konvolučné neurónové siete, <i>angl. Convolutional Neural Network</i>
CT	výpočtová tomografia, <i>angl. Computed Tomography</i>
DoG	<i>angl. Difference of Gaussian</i>
DT	rozhodovacie stromy, <i>angl. Decision Trees</i>
FREAK	<i>angl. Fast Retina Keypoint</i>
GLCM	šedotónové matice vzájomného výskytu, <i>angl. Gray-Level Co-occurrence Matrix</i>
GLOH	<i>angl. Gradient Localization Oriented Histogram</i>
GLRLM	šedotónové run-length matice <i>angl. Gray-Level Run Length Matrix</i>
HOG	histogramy orientovaných gradientov, <i>angl. Histogram of Oriented Gradient</i>
HOG-TOP	histogramy orientovaných gradientov z troch kolmých rovín, <i>angl. Histogram of Oriented Gradients from Three Orthogonal of Planes</i>
HP	tvrde podnebie, <i>angl. Hard Palate</i>
HU	Houndsfieldova jednotka, <i>angl. Hounsfield Unit</i>
IDM	Inverse Difference Moment
IOP	<i>angl. Internal Occipital Protuberance</i>

kNN	k-najbližších susedov, <i>angl. k-Nearest Neighbors</i>
LBP	lokálne binárne vzory, <i>angl. Local Binary Patterns</i>
LoG	<i>angl. Laplacian of Gaussian</i>
LS-SVM	Least Squares Support Vector Machines
MAE	<i>lat. Meatus Acusticus Externus</i>
MAEL	<i>lat. Meatus Acusticus Externus Left</i>
MLP	Viacvrstvový perceptrón, <i>angl. Multilayer Perception</i>
MR	magnetická rezonancia
MRI	zobrazovanie magnetickou rezonanciou
MSER	<i>angl. Maximally Stable Extremal Regions</i>
NSC	<i>angl. Nearest Subspace Classifier</i>
OM	orbitomeatálny
OML	orbitomeatálna línia
ORB	Oriented FAST and rotated BRIEF
pb	pineálny orgán, <i>angl. pineal body</i>
PCA	analýza hlavných komponent, <i>angl. Principal Component Analysis</i>
POE	<i>lat. Protuberantia Occipitalis Externa</i>
RF	náhodný les, <i>angl. Random Forest</i>
RGB	červená, zelená a modrá, <i>angl. Red, Green, and Blue</i>
ROI	oblasť záujmu, <i>angl. Regions Of Interest</i>
RTG	röntgenové
SC	subkalózna línia, <i>angl. Subcallosal line</i>
sc	<i>lat. colliculus superior</i>
SIFT	<i>angl. Scale-Invariant Feature Transform</i>
SOM	Samoorganizujúca sa mapa, <i>angl. Self-Organizing Map</i>

SRC	<i>angl. sparse representation classifier</i>
SML	supraorbitomeatálna línia
SPL	<i>angl. Statistical Pixel-Level</i>
SURF	<i>angl. Speeded-up Robust Features</i>
SUSAN	<i>angl. Smallest Univalve Segment Assimilating Nucleus</i>
SVM	metóda podporných vektorov, <i>angl. Support Vector Machines</i>
TS	<i>lat. Tuberculum Sellae</i>
TS-EOP	Tuberculum Sellae – External Occipital Protuberance
TS-IOP	Tuberculum Sellae – Internal Occipital Protuberance
TS-OP	Tuberculum Sellae – Occipital Protuberance
VGG	<i>angl. Visual Geometry Group</i>
3D	trojrozmerný
4D	štvorrozmerný

Zoznam príloh

A	Denzity tkanív	87
B	Prehľad používaných detektorov	89
C	Súhrn výsledkov	91
C.1	Výsledky VGG	91
C.1.1	Pacient 46	91
C.1.2	Pacient 47	93
C.2	Výsledky HOG	96
D	Obsah prílohy	97

A Density tkanív

Druh tkaniva	denzita [HU]
Vzduch	-1000 HU
Tuk	-100 až -50 HU
Voda	0 HU
Mozgovomiechový mok	+15 HU
Biela mozgová hmota	+20 až +30 HU
Šedá mozgová hmota	+37 až +45 HU
Nekoagulovaná krv	+30 až +45 HU
Koagulovaná krv	+60 až +80 HU
Kosti	viac ako +700 HU
Kovy	až +3000 HU

Tab. A.1: Densita tkanív. Prevzaté z [13]

B Prehľad používaných detektorov

Najznámejšie a najčastejšie používané detektory:

- SURF
- SIFT
- MSER
- BRISK
- FREAK

Jednorozmerné detektory

- Moravcov detektor - detektor rohov
- Harrisov detektor
- SUSAN
- FAST
- HESSIAN

Multirozmerné detektory

- LoG
- Dog
- Harris-Laplace
- Hessian-laplace
- Gabor-welvet
- FAST
- HESSIAN [43]

C Súhrn výsledkov

C.1 Výsledky VGG

C.1.1 Pacient 46

Tab. C.1: VGG výsledky pre pacienta 46

Typ	Detekčný krok	Řez	aIOU	Presnosť	Úplnosť
IOP	3	73	0.74756	1.0	1.0
IOP	6	72	0.72739	1.0	1.0
IOP	9	69	0.82952	1.0	1.0
IOP	12	73	0.59715	1.0	1.0
IOP	15	72	0.64027	1.0	1.0
IOP	18	71	0.45472	0.0	0.0
IOP	21	73	0.56956	1.0	1.0
IOP	24	73	0.52138	0.90909	0.90909
MAE	3	60	0.84745	1.0	1.0
MAE	6	60	0.80163	1.0	1.0
MAE	9	62	0.93627	1.0	1.0
MAE	12	60	0.77874	1.0	1.0
MAE	15	62	0.97054	1.0	1.0
MAE	18	60	0.61839	1.0	1.0
MAE	21	60	0.65251	1.0	1.0
MAE	24	58	0.41177	0.0	0.0
MAEL	3	41	0.67587	0.9	0.9
MAEL	6	41	0.668	0.9	0.9
MAEL	9	42	0.64053	0.9	0.9
MAEL	12	42	0.54959	0.7	0.7
MAEL	15	41	0.59197	1.0	1.0
MAEL	18	42	0.53529	0.9	0.9
MAEL	21	43	0.47405	0.0	0.0
MAEL	24	44	0.73979	1.0	1.0

Tab. C.2: VGG výsledky pre pacienta 46

Typ	Detekčný krok	Řez	aIOU	Presnosť	Úplnosť
ORBITA	3	89	0.69476	1.0	1.0
ORBITA	6	89	0.6911	1.0	1.0
ORBITA	9	89	0.70871	1.0	1.0
ORBITA	12	95	0.57953	1.0	1.0
ORBITA	15	89	0.57469	1.0	1.0
ORBITA	18	95	0.0	0.0	0.0
ORBITA	21	89	0.25654	0.5	0.5
ORBITA	24	95	0.57953	1.0	1.0
POE	3	92	0.78386	1.0	1.0
POE	6	92	0.78641	1.0	1.0
POE	9	92	0.67995	1.0	1.0
POE	12	86	0.61992	1.0	1.0
POE	15	92	0.63959	1.0	1.0
POE	18	82	0.74959	1.0	1.0
POE	21	86	0.46028	0.36364	0.36364
POE	24	82	0.77435	1.0	1.0
TS	3	86	0.2719	0.0	0.0
TS	6	86	0.47932	0.57143	0.57143
TS	9	90	0.36934	0.14286	0.14286
TS	12	87	0.20562	0.14286	0.14286
TS	15	86	0.24299	0.0	0.0
TS	18	90	0.0	0.0	0.0
TS	21	90	0.0	0.0	0.0
TS	24	87	0.23756	0.0	0.0

C.1.2 Pacient 47


Tab. C.3: VGG výsledky pre pacienta 47

Typ	Detekčný krok	Řez	aIOU	Presnosť	Úplnosť
IOP	6	65	0.89227	1.0	1.0
IOP	9	65	0.79043	1.0	1.0
IOP	12	75	0.63419	1.0	1.0
IOP	15	75	0.65141	1.0	1.0
IOP	18	75	0.57176	1.0	1.0
IOP	21	73	0.56696	1.0	1.0
IOP	24	75	0.58086	1.0	1.0
IOP	3	65	0.82402	1.0	1.0
MAE	3	50	0.74574	1.0	1.0
MAE	6	52	0.73732	1.0	1.0
MAE	9	52	0.79363	1.0	1.0
MAE	12	52	0.64266	1.0	1.0
MAE	15	60	0.69344	0.76923	0.76923
MAE	18	51	0.65644	1.0	1.0
MAE	21	52	0.61202	1.0	1.0
MAE	24	61	0.71334	1.0	1.0
MAEL	3	41	0.76016	1.0	1.0
MAEL	6	40	0.77874	1.0	1.0
MAEL	9	39	0.70236	1.0	1.0
MAEL	12	39	0.64266	1.0	1.0
MAEL	15	39	0.74346	1.0	1.0
MAEL	18	41	0.70762	1.0	1.0
MAEL	21	41	0.58989	1.0	1.0
MAEL	24	39	0.68972	1.0	1.0

Tab. C.4: VGG výsledky pre pacienta 47

Typ	Detekčný krok	Řez	aIOU	Presnosť	Úplnosť
ORBITA	3	77	0.91469	1.0	1.0
ORBITA	6	77	0.93716	1.0	1.0
ORBITA	9	71	0.8336	1.0	1.0
ORBITA	12	77	0.93716	1.0	1.0
ORBITA	18	77	0.58031	0.94118	0.94118
ORBITA	21	64	0.30849	0.0	0.0
ORBITA	24	77	0.93716	1.0	1.0
POE	3	76	0.77072	1.0	1.0
POE	6	76	0.82539	1.0	1.0
POE	9	76	0.78151	1.0	1.0
POE	12	76	0.7239	1.0	1.0
POE	15	76	0.78151	1.0	1.0
POE	18	76	0.80665	1.0	1.0
POE	21	73	0.64011	1.0	1.0
POE	24	76	0.80665	1.0	1.0
TS	3	84	0.0	0.0	0.0
TS	6	84	0.0	0.0	0.0
TS	9	82	0.0	0.0	0.0
TS	12	83	0.0	0.0	0.0
TS	15	81	0.0	0.0	0.0
TS	18	83	0.0	0.0	0.0
TS	21	91	0.10796	0.15385	0.15385
TS	24	91	0.070168	0.0	0.0

Obr. C.1: Závislosť aIOU na detekčnom kroku pre pacienta 47



C.2 Výsledky HOG

Tab. C.5: HOG výsledky pre pacienta 46 a 47

pacient	Typ	Detekčný krok	Řez	Cell size	aIOU	Presnosť	Úplnosť
46	MAE	9	61	10	0.98775	1	1
46	MAE	9	62	12	0.98775	1	1
46	MAE	15	61	10	0.98775	1	1
46	MAE	15	62	12	0.98775	1	1
47	ORBITA	12	71	2	0.93716	1	1
47	ORBITA	12	76	4	0.93716	1	1
47	ORBITA	12	76	6	0.93716	1	1
47	ORBITA	12	72	8	0.93716	1	1
47	ORBITA	12	73	10	0.93716	1	1
47	ORBITA	24	71	2	0.93716	1	1
47	ORBITA	24	76	4	0.93716	1	1
47	ORBITA	24	76	6	0.93716	1	1
47	ORBITA	24	72	8	0.93716	1	1
47	ORBITA	24	73	10	0.93716	1	1
47	ORBITA	24	74	12	0.93716	1	1
47	MAEL	6	45	10	0.93309	1	1
46	IOP	9	72	6	0.90376	1	1
46	IOP	9	70	8	0.90376	1	1
46	IOP	9	72	10	0.90376	1	1
46	IOP	9	71	12	0.90376	1	1
46	MAEL	3	41	6	0.77621	1	1
46	POE	24	84	10	0.77435	1	1
46	POE	24	85	12	0.77435	1	1
46	TS	12	86	4	0.48017	0.57143	0.57143
46	TS	12	86	6	0.48017	0.57143	0.57143
47	IOP	3	72	12	0.88994	1	1
47	MAE	3	58	6	0.78168	1	1
47	MAE	9	58	8	0.78152	1	1
47	MAE	9	58	10	0.78152	1	1
47	MAE	9	54	12	0.78152	1	1
47	POE	6	72	8	0.81411	1	1
47	TS	3	87	2	0	0	0

D Obsah prílohy

augmentace_sum.m	1 KB
data_46.mat.....	637145 KB
data_47.mat.....	89864 KB
detektor.m.....	12 KB
detektor_HOG_SVM.m.....	6 KB
detektor_VGG_SVM.m.....	6 KB
imshow4.m.....	10 KB
MAE_databaza.m.....	5 KB
MAE_databaza_augment.mat	10949 KB
MAE_oznacene46.mat	814 KB
MAE_oznacene47.mat	150 KB
nacitanie_dat.m.....	6 KB
oznacenie_dat.m.....	5 KB
prevzorkovanie.m.....	2 KB
readMe.txt.....	1 KB