

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2020

Bc. Jakub Nemček



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 INTRAKRANIÁLNÍCH HEMORAGIÍ V CT SNÍMCÍCH HLAVY

DETECTION OF INTRACRANIAL HEMORRHAGES IN HEAD CT DATA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Nemček

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček

BRNO 2020

Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Student: Bc. Jakub Nemček

ID: 185952

Ročník: 2

Akademický rok: 2019/20

NÁZEV TÉMATU:

Detekce intrakraniálních hemoragií v CT snímcích hlavy

POKYNY PRO VYPRACOVÁNÍ:

1) Nastudujte anatomii mozku a možnosti zobrazení pomocí CT modality pro diagnostiku intrakraniálních hemoragií. Seznamte se s metodami zpracování obrazů pro detekci a klasifikaci, zejména s možnostmi využití strojového učení. 2) Vypracujte rešerši metod pro detekci hemoragií a jejich klasifikaci v CT snímcích hlavy. Seznamte se a popište volně dostupnou databázi CT skenů mozků s lékařskou anotací. 3) Navrhněte postup detekce patologií s využitím strojového učení; vytvoření učební databáze, její augmentace, výběr metody a návrh její architektury. 4) Implementujte navržený přístup ve vhodném programovém prostředí. 5) Optimalizujte architekturu a hyperparametry navrženého algoritmu. Proveďte statistické vyhodnocení úspěšnosti. 6) Diskutujte dosažené výsledky a jejich možné využití v lékařské diagnostice.

DOPORUČENÁ LITERATURA:

[1] LECUN, Yann, BENGIO Yoshua a HINTON Geoffrey. Deep learning. Nature. 2015-5-27, 521(7553), 436-444. DOI: 10.1038/nature14539. ISSN 0028-0836.

[2] CHILAMKURTHY, Sasank, Rohit GHOSH, Swetha TANAMALA, Mustafa BIVIJI, Norbert G CAMPEAU, Vasantha Kumar VENUGOPAL, Vidur MAHAJAN, Pooja RAO a Prashant WARIER. Development and Validation of Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans. ArXiv. 2018, abs/1803.05854.

Termín zadání: 3.2.2020

Termín odevzdání: 29.5.2020

Vedoucí práce: Ing. Roman Jakubíček

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové 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

Práca sa zaoberá detekciou intrakraniálnych hemoragií a určením ich typov v CT snímkach hlavy. Popísaná metóda detekcie hemoragií je založená na využití série klasifikátorov prítomnosti a typu hemoragie v 2D CT rezoch z axiálnej, sagitálnej a koronárnej roviny, čo následne umožňuje tiež ich lokalizáciu. Klasifikátory vychádzajú z architektúry konvolučnej neurónovej siete Inception-ResNet-v2. Práca popisuje využitie a prídavnú manuálnu anotáciu dát z verejne dostupnej databáze CT skenov hlavy CQ500, ktorej zahrnuté anotácie nie sú pre účely práce dostačujúce. V práci je zahrnutý teoretický popis základných lekárskejších poznatkov, klasifikačných a detekčných metód strojového učenia, a ďalej návrh, realizácia a testovanie detekčného algoritmu. Presnosť funkčnosti algoritmu je kvantitatívne ohodnotená a diskutovaná, vrátane možností využitia navrhutej metódy v lekárskej diagnostike.

KĽÚČOVÉ SLOVÁ

Intrakraniálna hemoragia, klasifikácia, detekcia, CT, hĺbkové učenie, konvolučná neurónová sieť, CQ500

ABSTRACT

This thesis deals with the detection of intracranial haemorrhages and their type classification in head CT images. The method of haemorrhages detection is based on a series of classifiers of the presence and type of haemorrhages in 2D CT slices in axial, sagittal and coronal plane, that may localise the bleedings and determine their types. The classifiers are based on the convolutional neural network architecture Inception-ResNet-v2. The head CT dataset CQ500 which is made available for public access, is used for the experiments. The thesis describes an additional manual annotation of the data, as the available annotations are insufficient for the purposes of the experiments. This thesis includes a theoretical basis of the essential medical knowledge, machine learning based classification and detection methods, and the detection algorithm proposal, realisation and testing. The algorithm performance is evaluated and discussed together with the potential implementation of the algorithm in computer-aided diagnosis systems.

KEYWORDS

Intracranial hemorrhage, classification, detection, CT, deep learning, convolutional neural network, CQ500

NEMČEK, Jakub. *Detekce intrakraniálních hemoragií v CT snímcích hlavy*. Brno, Rok, 77 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedúci práce: Ing. Roman Jakubíček

VYHLÁSENIE

Vyhlasujem, že svoju diplomovú prácu na tému „Detekce intrakraniálních hemoragií v CT snímcích hlavy“ som vypracoval samostatne pod vedením vedúceho diplomovej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej diplomovej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý 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 autora

POĎAKOVANIE

Rád by som poďakoval vedúcemu diplomovej práce pánovi Ing. Romanovi Jakubíčkovi za odborné vedenie, konzultácie, trpezlivosť a podnetné návrhy k práci.

Obsah

Úvod	9
1 Anatomické, patologické a rádiologické východiská	10
1.1 Anatomia hlavy	10
1.2 Patológia hlavy	16
1.3 Možnosti zobrazenia základných patológií	18
2 Metódy strojového učenia	21
2.1 Príznakové metódy	21
2.2 Konvolučné neurónové siete	27
3 Klasifikácia a detekcia pomocou CNN	32
3.1 Klasifikácia pomocou CNN	32
4 Databáza CQ500	35
5 Súvisiace práce	37
6 Návrh detekcie hemoragií	39
6.1 Všeobecný návrh riešenia	39
6.2 Predspracovanie dát	40
6.3 Návrh metódy pre lokalizáciu hemoragií	41
6.4 Návrh metódy pre klasifikáciu hemoragií	42
7 Realizácia detekcie hemoragií	44
7.1 Experimentálne dáta	44
7.2 Realizácia predspracovania	45
7.3 Použitá architektúra	46
7.4 Klasifikácia prítomnosti hemoragie	47
7.5 Klasifikácia typu hemoragie	50
8 Výsledky a diskusia	53
8.1 Miery kvantitatívneho vyhodnotenia výsledkov	53
8.2 Výsledky klasifikácie prítomnosti hemoragie	53
8.3 Výsledky klasifikácie typu hemoragie	57
8.4 Diskusia nastavenia algoritmu	61
8.5 Diskusia možného využitia algoritmu v lekárskej diagnostike	64
Záver	66

Literatúra	68
A Príloha	76
A.1 Tabulky počtov rezov v databázach pre klasifikáciu prítomnosti a typu hemoragie	76
A.2 Tabulky výsledkov klasifikácie	76

Zoznam obrázkov

1.1	CT zobrazenie hemoragií.	18
2.1	Schéma neurónu s N vstupmi a jedným výstupom.	24
2.2	Schéma dvojvrstvovej doprednej neurónovej siete.	24
2.3	Schéma funkcie jedného neurónu konvolučnej vrstvy.	28
2.4	Schéma vzniku aktivačnej mapy prechodom obrazu 3×3 konvolučnou vrstvou.	29
6.1	Navrhnutý detekčný systém.	39
6.2	Zarovnanie CT skenu.	40
6.3	Transformácie kontrastu podľa rádiologických okien.	40
6.4	CT rezy s ohraničenou hemoragiou.	41
6.5	CT rezy s ohraničenými a klasifikovanými hemoragiami.	42
6.6	Bloková schéma klasifikačného subsystému.	43
7.1	Zobrazenie vlastných anotácií.	45
7.2	3 rezy CT snímky pacienta.	46
8.1	Ukážka správnych klasifikácií axiálnych rezov.	54
8.2	Ukážka správnych klasifikácií sagitálnych a koronárnych rezov.	55
8.3	Ukážka falošne negatívnych klasifikácií v troch rovinách.	56
8.4	Ukážka falošne pozitívnych klasifikácií v troch rovinách.	57
8.5	Ukážka falošne negatívnych klasifikácií u klasifikácie typu hemoragie.	59
8.6	Ukážka falošne pozitívnych výsledkov u klasifikácie typu hemoragie.	60
8.7	Ukážka ROC krivky a jej bodov pre rôzne prahy.	64

Úvod

V hlave sú umiestnené štruktúry nevyhnutné k funkčnosti ľudského tela a jeho kontrolujúce systémy, a ďalej orgány umožňujúce základne zmysly a emócie. Lekárske vedy popisujú množstvo patológií postihujúcich štruktúry mozgu, ktoré môžu mať vážne následky. Intrakraniálne hemoragie predstavujú závažnú diagnózu s pomerne vysokou incidenciou (25 prípadov na 100 000 ľudí celosvetovo [1]). Jedná sa o vnútrolebkové krvácanie, ktoré možno podľa postihnutej oblasti rozdeliť na päť typov: intraparenchymálna (IPH), intraventrikulárna (IVH), subdurálna (SDH), epidurálna (EDH) a subarachnoidálna hemoragia (SAH).

Najčastejšou zobrazovacou modalitou pre diagnostiku intrakraniálnych hemoragií je výpočtová tomografia (CT). Diagnostika musí byť extrémne rýchla, keďže už oneskorenie rádovo v minútach môže viesť k závažným dôsledkom až úmrtiu pacienta. Hodnotenie CT obrazov je pritom proces náročný na sústredenie rádiológa. Z toho dôvodu sú vyvíjané podporné diagnostické systémy schopné detekovať ochorenie v CT skene, ktoré môžu dopomôcť k rýchlemu a správne lekárskemu úsudku. Podporné detekčné systémy (CAD) sú v dnešnej dobe často založené na moderných metódach hĺbkového učenia vďaka ich schopnosti rýchleho riešenia komplexných úloh. [51] Konvolučné neurónové siete (CNN) predstavujú obrovský prínos v oblasti detekcie a klasifikácie obrazov vďaka schopnosti dosahovať dobré výsledky bez nutnosti voľby relevantných príznakov pre popis dát. [31]

Táto práca sa zaoberá návrhom a overením algoritmov detekcie intrakraniálnych hemoragií v 3D CT snímkach hlavy pomocou metód hĺbkového učenia. Popísané sú základné teoretické anatomické a patologické východiská spolu s možnosťami zobrazenia intrakraniálnych hemoragií pomocou CT modality. Práca zahŕňa rešerš publikovanej literatúry v oblasti detekcie intrakraniálnych hemoragií a popisuje verejne dostupnú anotovanú databázu CT snímkov hlavy CQ500. Hlavnými cieľmi práce sú návrh, realizácia a testovanie algoritmu pre detekciu hemoragií s využitím metód strojového učenia. Navrhnutým riešením je systém klasifikátorov 2D rezov založených na architektúre CNN Inception-ResNet-v2. Systém lokalizuje hemoragiu a určuje jej typ tak, že v rezoch CT skenu v troch kolmých anatomických rovinách (axiálnej, sagitálnej a koronárnej) je najskôr určená prítomnosť hemoragie a následne jednotlivé typy. Práca popisuje realizáciu algoritmu, vytvorenie a augmentáciu tréningových dát, tréning sietí a testovanie na testovacích databázach. V práci sú popísané dosiahnuté výsledky, ich diskusia a ďalej diskusia možného využitia metódy detekcie hemoragií v lekárskej diagnostike.

1 Anatomické, patologické a rádiologické východiská

Hlava je miestom operačného strediska tela, čo vypovedá o dôležitosti jednotlivých štruktúr v nej obsiahnutých. Táto kapitola popisuje základné anatomické, patologické a rádiologické znalosti nutné pre základnú orientáciu v oblasti hľadania patológie v CT snímkach.

1.1 Anatómia hlavy

Hlava je z anatomického pohľadu komplexným objektom. Je zložená z lebky, útrobných orgánov nevyhnutných k funkčnosti ľudského tela a zo svalov používaných k mastikácii a mimike. V rámci štruktúry hlavy možno taktiež popísať orgány kontrolujúce funkcie celého tela, rovnako ako orgány sprostredkujúce základné zmysly ako zrak, sluch, čuch, chuť, a tiež rovnováhu. [2]

1.1.1 Lebka

Lebka je pevná a pružná kostená schránka slúžiaca na ochranu a podporu mozgu a hlavných zmyslových orgánov, a taktiež slúži ako ukotvujúce miesto na úpon svalov. Je tvorená lebečnými kosťami, ktoré možno z hľadiska pôvodu a uplatnenia rozdeliť na tvárové kosti (tzv. *viscerocranium*) a kosti mozgovej časti lebky (tzv. *neurocranium*). Mozgová časť je ešte ďalej rozdelená na lebečnú spodinu, alebo tiež bázu (z lat. *basis*), a na lebečnú klenbu (z lat. *calvaria* alebo *calva*). [2, 3]

Tvárová časť

Tvárová časť lebky určuje črty tváre, poskytuje miesta na pripojenie svalov a formuje očnicu, nosnú a ústnu dutinu, a ďalej tvorí oporu pre zuby. Na jej tvorbe sa podieľa šesť párových a dve nepárové kosti. Medzi párové kosti patrí nosná kosť (*os nasale*), ktorej pravá a ľavá časť tvoria nosnú striešku. Za ňou je na vnútornej strane očnice umiestnená párová slzná kosť (*os lacrimale*). Kosť lícna (*os zygomaticus*) je párová kosť prispievajúca k určovaniu tvaru tváre a taktiež, spolu s temporálnou kosťou, svojim výbežkom tvorí jarmový oblúk (*arcus zygomaticus*). Párová podnebná kosť (*os palatinum*) tvorí zadnú časť tvrdého podnebia a skladá sa z vertikálnej a horizontálnej lamely. Ďalšou párovou kosťou patriacou do tvárovej časti je párová horná čeľusť (*maxilla*), ktorej výbežky vybiehajú k čelnej, podnebnnej a lícnej kosti. V poslednom, alveolárnom, výbežku sú umiestnené zuby hornej čeľuste. Mediálna stena tvorí bočnú stenu nosnej dutiny a telo hornej čeľuste je vyplnené jednou z nosných

dutín, dutinou hornej čeluste (tzv. *sinus maxillaris*). Spomínané kosti boli všetky párové. Tvárová časť lebky zahŕňa dve nepárové kosti: radlicová kosť (*vomer*), ktorá tvorí zadnú časť nosnej prepážky, a dolná čelust (*mandibula*). Podkovité telo dolnej čeluste prechádza dozadu hore do pravého a ľavého ramena. Na tele sú výbežky (*processus alveolares*), v ktorých sú zasadené zuby. Ramená sú zakončené výbežkom pre úpon spánkového svalu (*processus coronoideus*) a kĺbovým výbežkom pre čelustný kĺb (*processus condylaris*). Spojenie jednotlivých kostí vedie k vzniku dutín: očníca (*orbita*), nosná dutina (*cavum nasi*), a ďalej jamky: spánková a podspánková. [3, 4]

Lebečná spodina

Bazálna časť mozgovej časti lebky tvorí štruktúru, na ktorej leží mozog. [2] Spredu do zadu ju tvoria kosť čelná (*os frontale*), čuchová kosť (*os ethmoidale*), klinové kosti (*os sphenoidale*), spánkové kosti (*ossa temporalia*) a záhlavná kosť (*os occipitale*). Lebečnou bázou prechádza množstvo ciev a nervov. Čelná kosť je na čele tvorená čelnou šupinou a časťami tvoriacimi strop očníc. Kaudálne sa švom napája na nosné kostičky a dolná časť šupiny obsahuje vedľajšie nosné dutiny (*sinus frontales*). Čuchová kosť je nepárovou kosťou medzi očnicovými časťami frontálnej kosti. Prispieva k formovaniu stropu, prepážky a horno-bočných stien nosnej dutiny. Okrem toho formuje nosné dosky: „*concha nasalis superior*“ a „*media*“. Klinová kosť je komplexná kosť o tvare motýľa umiestnená medzi frontálnou a temporálnou kosťou. Skladá sa z tela, malého a veľkého krídla a výbežkov (*processus pterygoidei*). Malým krídlom prechádza optický kanál, veľkými krídlami prestupujú cez otvory: „*foramen rotundum*“ a „*foramen ovale*“ vetvy trojkľaného nervu. Otvorom „*foramen spinosum*“ prechádza tepna „*arteria meningea media*“ vyživujúca časť mozgových obalov. Po stranách tela leží „*arteria carotis interna*“, ktorá vyživuje mozog. Spánková kosť je párová kosť, ktorá sa skladá z niekoľkých častí. Prvou časťou je šupina, po ktorej vnútornej ploche prebieha „*arteria meningea media*“ a v dolnom okraji je jamka pre skĺbenie s dolnou čelustou. Druhou časťou je kosť skalná (*os petrosum*), v ktorej je uložené sluchové a rovnovážne ústrojenstvo a prebieha ňou VII. hlavový nerv. Tretou časťou je vonkajší zvukovod. Jeho kostenú časť tvorí bubienková kosť (*os tympanicum*) a začína tu Eustachova trubica. Temporálna kosť vybieha dozadu a von do výbežku „*processus mastoideus*“ a kaudálne do „*processus styloideus*“. Záhlavná kosť tvorí zadnú dolnú časť lebky a je umiestnená medzi pravou a ľavou spánkovou kosťou. V jej báze je otvor „*foramen magnum*“, ktorým do lebečnej dutiny vstupuje miecha a ďalej dve „*arteriae vertebrales*“. Po bokoch otvoru sa nachádzajú vyvýšeniny pre skĺbenie s atlasom. Dozadu hore postupuje šupina záhlavnej kosti. Kostí bazálnej časti sú spojené chrupavkami. Vnútorňá časť je nerovná a tvorí 3 jamy. V telách čelnej, čuchovej, klinovej kosti a hornej čeluste sú vytvorené vedľajšie nosné dutiny

otvárajúce sa do vlastnej dutiny nosnej. [2, 4]

Lebečná klenba

Lebečná klenba je tvorená časťami čelnej, spánkovej, záhlavnej a klinovej kosti, ktoré sa napájajú na temennú kosť (*os parietalis*). Temenné kosti majú tvar štvorhraných doštičiek. [4] Kosti lebečnej klenby sú navzájom pospájané lebkovými švami (*suturæ cranii*), čo sú väzivové spojenia, ktoré, pokiaľ nedochádza k ich osifikácii, zvyšujú pružnosť lebky. [3] „*Sutura coronalis*“ spája frontálnu a temenné kosti, „*Sutura sagittalis*“ je medzi temennými kosťami, „*Sutura lambdoidea*“ spája záhlavnú kosť a temenné kosti, a „*Sutura sphenoidalis*“ sa nachádza medzi veľkými krídlami klinovej kosti a šupinou spánkovej kosti. [2, 4]

1.1.2 Obaly mozgu

Kostená lebka je len jedným z ochranných obalov mozgu. Centrálny nervový systém je chránený i väzivovými obalmi, tzv. mozgovými plénami, pričom rozlišujeme tri vrstvy: tvrdú plénu (tzv. *dura mater*), pavúčnicu (tzv. *arachnoidea*) a mäkkú plénu (tzv. *pia mater*).

Dura mater sa skladá z hustého kolagénového väziva. [5] Základ tvrdej plény v lebečnej dutine splýva s vnútorným periostom lebečných kostí. Medzi obe hemisféry potom v stredovej čiare odstupuje veľká srpovitá riasa „*falx cerebri*“, ktorá začína od čelnej a čuchovej kosti a je pripojená v strednej čiare lebečnej klenby až po záhlavnú kosť, kde sa rozbieha na obe strany ako „*tentorium cerebelli*“, čo je riasa kryjúca mozoček. *Dura mater* od seba oddeľuje supratentoriálny priestor (kde leží koncový mozog a medzimotozog), a infratentoriálny priestor (kde leží mozgový kmeň). [4, 5]

Arachnoidea je obal tvorený väzivom s jemnou sieťou kolagénových vlákien. [5] Jedná sa o tenkú blanu bez ciev, ktorá je priložená k tvrdej pléne a voľne obaľuje mozog. Z vonkajšej strany ohraničuje subdurálny priestor, ktorý je fyziologicky iba pomyslený, pretože *arachnoidea* s tvrdou plénou k sebe priliehajú. Z vnútornej strany je tzv. subarachnoidálny priestor, kde sa nachádza mozgomiechový mok. Na niektorých miestach vznikajú rozšírené miesta subarachnoidálneho priestoru. Jedným z takýchto miest je „*cisterna cerebellomedullaris*“ medzi kmeňom a mozočkom. *Arachnoidea* vytvára drobné výbežky, do *dura mater*, kde dochádza k resorpcii mozgomiechového moku do krvi. [4, 5]

Mäkká pléna je tvorená jemným väzivom s fibrocytmi, histiocytmi, mastocytmi a lymfocytmi. [5] Táto blana prilieha tesne k povrchu mozgu a teda kopíruje všetky zárezy a záhyby. Obaľuje tiež cievky na povrchu mozgu a spolu s nimi tiež preniká do určitej hĺbky pod povrch. [4, 5]

1.1.3 Cievne zásobenie mozgu

Mozog je veľmi citlivý na dodávku kyslíka. Pri náhlom znížení prietoku krvi nastáva do 10 sekúnd stav bezvedomia. [5] Príjem látok všeobecne je však obmedzený tzv. hematoencefalickou bariérou.

Hlavnými zdrojmi ciev pre mozog sú „*arteria vertebralis*“ a „*arteria carotis interna*“, ktoré spolu s ďalšími cievami uzatvárajú tzv. Willisov okruh. Pravá i ľavá „*a. vertebralis*“ vstupuje do lebky cez otvor „*foramen occipitale magnum*“ a obe sa spájajú vytvárajúc „*a. basilaris*“, ktorá je umiestnená na ventrálnej strane mozgového kmeňa a odstupujú k nemu vetvy. Vetvy odstupujú i pre mozoček a „*a. basilaris*“ sa delí na dve vetvy „*a. cerebri posterior*“ prechádzajúce na vnútornú a spodnú plochu záhlavného laloku. „*Arteria carotis interna*“ vstupuje do lebečnej dutiny cez karotídový kanál, kladie sa k Tureckému sedlu a vytvára oblúk, z ktorého odstupuje artéria do očné. Okrem toho vydáva „*a. cerebri anterior*“ zásobujúcu mediálnu plochu hemisféry, a ďalej „*a. cerebri media*“ zásobujúcu laterálnu stranu hemisféry. Zo zmienovaných tepien odstupujú do hĺbky mozgu skupiny menších tepien „*arteriae centrales*“. Rozlišujeme i tzv. „*arteriae choroideae*“ pre *choroidný plexus*, ktorý produkuje mozgomiechový mok.[4, 5]

Žily mozgu prechádzajú skrz *duru mater* a *arachnoideu* a vlievajú sa do žilných splavov. Môžeme ich rozdeliť na odtokové žily mozgového kmeňa a mozgových hemisfér. [5] Z mozgového kmeňa krv odteká do „*v. basalis*“ vznikajúcej na spodku frontálneho laloku, ktorá sa vlieva do veľkej mozgovej žily. Na hemisférach rozoznávame povrchové a hlboké žily. Povrchové žily zbierajú krv z mozgovej kôry a cestou premostujúcich žíl sa vlievajú do vnútrolebečných splavov. Hlboké žily prechádzajú pri hornej časti *thalamu* (napr. „*venae cerebri internae*“) a spájajú sa do veľkej mozgovej žily, ktorá ústi do „*sinus rectus*“. Odtiaľ krv odteká do „*sinus transversus*“ a ďalej do „*v. jugularis int*“.[4]

1.1.4 Mozgový kmeň a mozoček

Mozgový kmeň (lat. *truncus encephali*) je kraniálnym pokračovaním miechy. Skladá sa z predĺženej miechy, Varolovho mostu a stredného mozgu. Sú v ňom umiestnené centrá nevyhnutné pre vitálne funkcie. Obsahuje typicky usporiadanú šedú hmotu vo forme jadier a bielu hmotu odpovedajúcu spojom. Leží na záhlavnej kosti v zadnej lebečnej jame.

Predĺžená miecha (lat. *medulla oblongata*) plynule pokračuje z miechy. Má kuželovitý tvar. Prednú stranu tvoria dva pozdĺžne valy obsahujúce bielu hmotu vo forme vlákien pyramídových dráh. [4, 5] Táto časť mozgového kmeňa obsahuje kardiovaskulárne a respiračné centrá regulujúce srdcovú a dychovú frekvenciu. [2]

Varolov most (lat. *pons Varoli*) tvorí priečny val viditeľný na mozgovom kmeni. Kaudálne hraničí s predĺženou miechou a kraniálne so stredným mozgom. Do mozočku z *pontu* odstupujú „*penduculi cerebellares medii*“, ktoré zabezpečujú prevod vzruchov z kôry. Od mozočku je oddelený štvrtou komorou. *Pons* obsahuje motorické jadrá a jadrá, kde sa prepájajú dráhy z kôry do mozočku, o ktoré sa roztrieštuje pyramídová dráha. [2, 4, 5]

Stredný mozog (lat. *mesencephalon*) je posledná kraniálna časť mozgového kmeňa. Kraniálne sa spája s medzimotozgom. Stredný mozog obsahuje ventrálne uloženú „*crura cerebri*“ obsahujúcu výhradne bielu hmotu. Pozdĺžne prebieha úzky kanálik „*aqueductus mesencephali*“ - mokovod spájajúci 3. a 4. komoru. Od kanálika dorzálne sa nachádza tzv. štvorhrbolie obsahujúce dva páry hrbolčekov: „*colliculi superiores*“ (zapojené do zrakových dráh) a „*colliculi inferiores*“ (zapojené do sluchovej dráhy). [2, 4, 5] Keby stredným mozgom vedieme priečny rez, vieme rozoznať „*tectum*“ obsahujúce šedú hmotu, ktorá je v „*colliculi superiores*“ preložená vrstvičkami bielej hmoty, ďalej „*tegmentum*“ obsahujúce väčší počet jadier šedých hmôt, a potom „*crura cerebri*“ (viď vyššie). [5]

Mozoček (lat. *cerebellum*) je umiestnený v zadnej lebečnej jame, ktorú celkom zapĺňa spolu s mozgovým kmeňom, od ktorého je umiestnený dorzálne. Od ostatného mozgu je oddelený *dura mater*. S mozgovým kmeňom je prepojený tromi zväzkami vlákien a dvomi platničkami tvoriacimi strop 4. komory. Odlišujeme na ňom pozdĺžny úzky stredný pás, tzv. mozočkový červ, a dve postranné symetrické poglobule, tzv. mozočkové hemisféry. Povrchom prechádzajú početné priečne priehlbiny oddelujúce jednotlivé úseky mozočku. Najhlbšie brázdy oddelujú laloky, menšie lalôčiky a najmenšie oddelujú prúžky nazývané „*folia cerebelli*“. Povrch mozočku pokrýva šedá hmota (tzv. mozočková kôra), vo vnútri je potom biela hmota, v ktorej sú umiestnené párové zhluky šedej hmoty.[5] Mozoček funkčne pozostáva zo senzoryckých vstupov dráh z vestibulárneho aparátu a zo svalov. Koordinuje rovnováhu a plynulé pohyby kostrového svalstva.[2]

1.1.5 Medzimotozog

Medzimotozog (lat. *diencephalon*) sa nachádza medzi mozgovým kmeňom a koncovým mozgom. Skladá sa z *epithalamu*, *metathalamu*, *thalamu*, *subthalamu* a *hypothalamu*. [2]

Hlavnou štruktúrou *epithalamu* je *epifýza* ležiaca pri zadnom hornom okraji 3. komory, ktorej základnou funkciou je produkcia melatonínu riadiaceho rytmus bdenia resp. spánku. [2, 4] *Metathalamus* je zapojený do špecifického zmyslového vnímania a tvorí dve vyvýšeniny, ktorými vedú sluchové resp. zrakové dráhy. [4]

Párový *thalamus* je funkčne i štruktúrne komplexná štruktúra ohraničujúca

3. komoru a laterálne zrastajúca s *telencephalonom*. Je zložený z vpredu zúžených a dozadu sa rozširujúcich vajcovitých útvarov. Naprieč dutinou 3. komory prechádza mostík („*adhesio interthalamica*“) obsahujúci bielu i šedú hmotu spájajúce oba útvary. Laterálne *thalamus* nalieha na mozgovú hemisféru, dorzálna časť je voľná. *Thalamus* obsahuje šedé hmoty komplexu jadier rôznych funkcií, ktoré sú rozdelené lamelami bielej hmoty. Funkčne dostávajú jadrá *thalamu* vzruchy zo všetkých zmyslových dráh mimo čuchových a tieto podnety ďalej predávajú mozgovej kôre. [4, 5]

Hypothalamus je štruktúra tvoriaca dno a prednú stenu 3. komory. Od *Thalamu* je oddelený žliabkom „*sulcus hypothalamicus*“. Bazálnymi úsekmi sú párové polgulovité telieska „*corpora mammilaria*“, „*tuber cinereum*“, nálievkovitý výbežok „*infundibulum*“ a *hypofýza*, žľaza s vnútornou sekréciou. Bunky sú usporiadané do jadier a areí, pričom jadrá tvoria bunky jedného typu, ktoré sú dobre ohraničené od okolia. *Areae* sú tvorené viacerými bunecnými typmi s neostrými hranicami. Jadrá a *areae* sú usporiadané do dvoch predozadných pruhov, pričom hovoríme o mediálnom a laterálnom *hypothalamu*. Funkčne *hypothalamus* kontroluje množstvo životne dôležitých funkcií a reflexov a ovplyvňuje neurosekrečnú činnosť. [4, 5]

1.1.6 Koncový mozog

Koncový mozog (*telencephalon*) je najväčším mozgovým komponentom. Tvoria ho dve hemisféry - pravá a ľavá, oddelené ryhou „*fissura longitudinalis cerebri*“. Hemisféry sú navzájom prepojené vláknami spájajúcimi rovnaké miesta. Na hemisférach rozlišujeme mozgovú kôru tvorenú šedou hmotou, kde sú telá neurónov, pod ňou bielu hmotu tvorenú výbežkami neurónov a vo vnútri uložené bazálne gangliá. Okrem toho sú v hemisférach obsiahnuté postranné mozgové komory. [2, 4]

Bazálne gangliá sú zhluky neurónov tvoriace šedú hmotu zanorenú hlboko do bielej hmoty *telencephalu* a slúžia k spracovaniu podnetov pre hybnosť, pričom spracované podnety posielajú ďalej do motorických centier mozgového kmeňa a frontálnej kôry.[4]

Každá hemisféra je rozdelená na štyri laloky: frontálny (čelový), parietálny (temenný), temporálny (spánkový) a okcipitálny (záhlavný). Tieto laloky sú navzájom oddelené ryhami. „*Fissura lateralis*“ je hlboká ryha medzi čelným a spánkovým lalokom, „*sulcus centralis*“ oddeľuje čelný a temenný lalok, „*sulcus parietooccipitalis*“ rozdeľuje záhlavný lalok od temenného a „*incisura preoccipitalis*“ je hranicou medzi záhlavným a spánkovým lalokom. [4, 5]

Predný lalok obsahuje 4 závit: „*gyrus precentralis*“, „*gyrus frontalis superior*“, „*gyrus frontalis medius*“, „*gyrus frontalis inferior*“. Kôra v „*gyrus precentralis inferior*“ je primárnou motorickou oblasťou kontrolujúcou hlavné pohyby tela. V oblasti

„*gyrus precentralis inferior*“ je tiež lokalizované tzv. Borocove centrum, motorické centrum reči. [2, 5] Ďalšie oblasti čelného laloku sú oblasťami kontrolujúcimi asociáciu, posudzovanie, kritické myslenie, emócie a inteligenciu. [2]

Temenný lalok obsahuje „*gyrus postcentralis*“, v ktorom je umiestnená senzitívna oblasť zodpovedná za vnímanie podnetov ako bolesť, teplota, dotyk. [2] Spánkový lalok obsahuje závit „*gyri temporales transversi*“, medzi ktoré patrí Heschlov závit, kde sa nachádzajú kôrové centrá sluchu a sluchové centrum reči. [5] Záhlavný lalok primárne slúži na spracovanie vizuálnej informácie. Závit obklopujúci „*fissura calcarina*“ je primárnym vizuálnym kortexom. [2]

1.1.7 Mozgové komory

V mozgu sú 4 komory (lat. *ventriculi cerebri*). Dve postranné komory sú umiestnené v hemisférach, 3. je umiestnená medzi lalokmi *thalamu* a 4. leží medzi mozočkom a mozgovým kmeňom. Postranné komory sú dutiny oblúkovitého tvaru, pričom rozlišujeme výbežky do jednotlivých lalokov. Cez „*foramen interventriculare*“ sú spojené s 3. komorou. Zo zadnej steny 3. komory odstupuje „*aquaeductus mesencephali*“ spájajúci túto komoru so 4. komorou. Na miestach, kde *pia mater* nalieha na steny komory, cievy vytvárajú hroznovité útvary s názvom „*plexus choroideus*“ slúžiace k filtrácii plazmy pre produkciu mozgomiechového moku. „*Plexus choroideus*“ sa nachádza v každej z komôr. V 4. komore prebieha komunikácia komorového systému so subarachnoidálnym priestorom.

Mozgomiechový mok nadnáša mozog, tlmí nárazy a vyrovnáva tlakové zmeny zapríčinené pulzáciou tepien. Zložený je z bielkovín, glukózy, lymfocytov a ďalších súčastí. [4]

1.2 Patológie hlavy

Hlava je miestom uloženia časti centrálného nervového systému - mozgu, najzložitejšieho orgánu z hľadiska vnútorného usporiadania. Tkanivo centrálnej nervovej sústavy (CNS) pozostáva z neurónov a neuroglií. Neuróny sú bunky špecializované na prijímanie podnetov z vnútorného resp. vonkajšieho prostredia, spracovanie a odovzdávanie informácie a vydávanie príkazov cieľovému orgánu alebo tkanivu. Neurogliá majú podporné a nutritívne funkcie. Tkanivá CNS majú vysoko špecializované funkcie, zabezpečujú komunikáciu, spätnú väzbu organizmu, integráciu funkcií organizmu, čo vypovedá o dôležitosti tohoto systému. Tkanivá sú však citlivé na rôzne druhy poškodenia a degeneratívnych procesov. Fyzikálne a chemické vplyvy môžu spôsobiť reverzibilné i ireverzibilné poškodenia, pričom dôsledky závisia od stupňa poškodenia a zachovania integrity neurónov. [6]

Pre ochranu mozgu má základný význam lebka ako rigidný kostný kryt. V dôsledku pôsobenia vonkajších fyzikálnych faktorov, ako je náraz, môže dôjsť ku vzniku zlomeniny, teda fraktúry lebky. [6] Fraktúry možno klasifikovať na zlomeniny lebečnej klenby a zlomeniny lebečnej spodiny (báze).

Edém (opuch) mozgu vzniká zvýšením obsahu tekutín v mozgovom tkanive. Pri jeho rozvoji dochádza k zvýšeniu intrakraniálneho tlaku. K intrakraniálnej hypertenzii dochádza expanzívnymi procesmi (napr. pri hematóme) alebo obštrukciou prietoku mozgomiechového moku (tzv. *hydrocefalus*), pretože objem lebečnej dutiny sa za fyziologických okolností (okrem detského veku) nemení. [6, 7]

Závažnými ochoreniami sú mozgové nádory, pričom rozlišujeme primárne nádory vychádzajúce neuroektodermálnych buniek mozgu, primárne nádory z iných buniek a metastatické nádory. [6]


1.2.1 Poruchy krvného obehu CNS

Hlavnými príčinami porúch krvného obehu v mozgu sú poruchy ciev, poruchy hemokoagulácie, pokles krvného tlaku či zvýšenie intrakraniálneho tlaku. Prejavujú sa ako ischémie alebo hemoragie. Ischémie spôsobujú zníženie parciálneho tlaku kyslíka v mozgu z dôvodu zníženia perfúzie mozgu krvou. Globálna ischémia nastáva pri zástave obehu alebo hypotenzii, či šokových stavoch. Regionálna ischémia sa tiež označuje ako mozgový infarkt. Príčinou sú často tromboembolický uzáver cievy, stlačenie cievy, edém mozgu alebo nádor, atď. Rozsah a distribúcia ischemického ložiska sú ovplyvnené miestom oklúzie, rýchlosťou vzniku uzáveru a možnosťami kolaterálneho obehu. [6, 7] Úplné prerušenie prietoku krvi mozgom vedie ku strate vedomia a neskôr k ireverzibilnému poškodeniu mozgu. Regionálna ischémia vedie k výpadku príslušného mozgového regiónu. [8]

V prípade hemoragií hovoríme o intrakraniálnom krvácaní, ktoré môžeme rozdeliť na intracerebrálne a extracerebrálne. K extracerebrálnemu vnútrolebkovému krvácaniu patria epidurálne (EDH), subdurálne (SDH) a subarachnoidálne (SAH) hemoragie. Epidurálna hemoragia je krvácanie do priestoru medzi lebkou a *duru mater* a spravidla má traumatický pôvod. Zdrojom sú durálne cievy, hlavne „*a. meningea media*“, avšak môže byť i venózneho pôvodu. Hematóm sa rozvíja pomaly. Subdurálna hemoragia je krvácanie medzi *duru mater* a *arachnoideu* a najčastejšie je traumatického pôvodu. Zdrojom krvácania sú kortikálne vény, durálne sínusy alebo príslušné artérie. Rozoznávame akútne a chronický subarachnoidálny hematóm. Akútne vzniká bezprostredne po úraze, trvá do 3 dní a býva tvorený zmesou krvi a mozgomiechového moku. Môže prejsť do chronického hematómu. Chronický subdurálny hematóm (starší ako 21 dní) vzniká zo starého ložiska, ktorého obsah skvapalní a typicky sa pozvoľne zväčšuje, pričom utláča mozgové tkanivo. Subarach-

noidálnou hemoragiou je označovaná prítomnosť krvi v subarachnoidálnom priestore. Najčastejšie dochádza k tomuto krvácaniu z dôvodu ruptúry arteriálnej aneurizmy, menej často potom z rôznych cievnych malformácií alebo dôsledkom traumy. Pri subarachnoidálnom krvácaní sa zvyšuje intrakraniálny tlak a dochádza k zhoršovaniu prekrvenia.

Intracerebrálne krvácanie je krvácanie do mozgu. Najčastejšie vzniká ruptúrou cievy, menej často je pôvodom krvácania arteriálna aneurizma, trauma, tumory. Vzniká náhle a má vážne následky, ako je poškodenie CNS až smrť. Ložisko pozostáva z krvi a zvyškov tkaniva, má nepravidelný tvar, okolité tkanivá sú utlačené. Pokiaľ je postihnuté mozgové tkanivo, hovoríme o intraparenchymálnej (IPH) hemoragii. Krvácanie sa môže prevaliť aj do mozgových komôr a hovoríme o intraventriculárnom (IVH) krvácaní (*hemocefale*). [6, 7]



Obr. 1.1: CT zobrazenie hemoragií. a) IPH; b) SAH; c) SAH; d) EDH; e) IVH; f) SDH.

1.3 Možnosti zobrazenia základných patológií

V súčasnej dobe sa pre diagnostické zobrazovanie mozgu a lebky najviac využíva výpočtová tomografia (CT, z angl. Computed Tomography), magnetická rezonancia

(MRI), u kojencov i ultrasonografia. CT i MRI treba považovať za komplementárne metódy, keďže každá má svoje výhody v určitých diagnostických situáciach. [9, 12]

CT má základný význam predovšetkým u akútnych stavov z dôvodu vyššej dostupnosti v porovnaní s magnetickou rezonanciou, a rýchlejšiemu priebehu samotného vyšetrenia. Hlavnými indikátormi CT vyšetrenia sú trauma hlavy, náhle cievne mozgové príhody, podozrenie na nádor mozgu, degeneratívne ochorenia mozgu, CT angiografia. Pri podozrení na tumor, cievne ochorenie alebo zápal sa využíva i snímanie s kontrastnou látkou. [9]

Magnetická rezonancia je najlepšou metódou pre zobrazenie detailov mäkkých tkanív v neurorádiológii. Hlavnými indikátormi sú ochorenia bielej hmoty, diagnostika nádorov, anomálie mozgu, zápaly, diagnostika akútnych ischemií. [9]

1.3.1 Snímanie a interpretácia CT hlavy

CT hlavy je vyšetrenie hlavy a okolitých štruktúr pomocou výpočtovej tomografie. Vyšetrenie môže byť bezkontrastné, alebo je kombináciou bezkontrastného a postkontrastného snímania. Často sú snímané skeny o hrúbke 2,5 - 5 mm. [9]

Pre dobrú interpretáciu CT skenov hlavy v zmysle optimálnej detekcie patológií je nutné využívať transformáciu kontrastu v rádiologickej literatúre častejšie nazývanú ako rádiologické okná, ktoré môžu byť definované šírkou a stredom. Historicky sa najviac hodnotili axiálne rezy, avšak dnes sa čoraz viac používajú aj ďalšie roviny - sagitálna a koronárna, alebo zobrazenie celého objemu. Mozgové tkanivo je zobrazované rádiologickým oknom o šírke 80 HU a strede v 40 HU, čiže sa jedná o transformáciu kontrastu, kedy hodnoty nad 80 HU budú biele a hodnoty pod 0 HU čierne. Subdurálne okno má stred v 50 - 100 HU a šírku medzi 350 - 400 HU a zameriava sa na subdurálnu a extradurálnu krv. Pomocou tohoto okna môžeme spozorovať malé subdurálne hemoragie. Kostné okno má stred v 600 HU a šírku 2800 HU a predstavuje transformáciu kontrastu pre hodnotenie kostí. [10]

V normálnom obraze CT mozgu má biela hmota denzitu približne 25 HU, šedá hmota 35 HU, teda je svetlejšia, a likvor v komorovom systéme má denzitu 10 HU. Komory sú za fyziologických podmienok bez dislokácie. [9, 11, 12]

1.3.2 CT zobrazovanie hemoragií

Pri zobrazovaní patológií sledujeme zmeny tvaru a umiestnenia komorového systému a subarachnoidálneho priestoru, a ďalej dislokáciu štruktúr stredovej čiary. Pozorujeme tiež zmeny denzity tkaniva. Hyperdenzné ložiská zvyčajne odpovedajú čerstvému krvácaniu, niektorým nádorom a patologickým kalcifikáciam. Hypodenzné ložiská môžu byť známkami nekrózy mozgového tkaniva, namnoženia tekutiny (ako napr. u edému) alebo väčšiny gliálnych nádorov. [11]

CT je vhodnou metódou pre diagnostiku hemoragií. Epidurálny hematóm sa nachádza medzi lebkou a *durou mater*, pričom *dura mater* pevne prilieha k lebke v miestach švov a teda hemoragia nepresahuje hranice jednotlivých kostí kalvy. Najčastejšie sa nachádza temporálne. CT zobrazí epidurálny hematóm ako hyperdenzné (svetlé) šošovkovité ložisko (50 - 80 HU) s hladkými okrajmi uložené pri *kalve*, často pri mieste *fisury* a preto môžeme v okolí nachádzať i bubliny vzduchu, čo ho odlišuje od subdurálneho krvácania. [9, 11, 13] Subdurálna hemoragia je umiestnená medzi *dura mater* a *arachnoideou*. Zaberá väčší priestor okolo hemisfér a môže sa nachádzať iba interhemisferálne alebo pozdĺž *tentoria*. Môžu byť tiež obojstranné. Akútna subdurálna hemoragia, predstavuje nezrazenú krv a prejavuje sa ako hyperdenzné ložisko polmesiacovitého tvaru o denzite 50-80 HU. Pokiaľ sa jedná o chronický subdurálny hematóm, ten sa prejavuje ako hypodenzný v porovnaní s okolitým tkanivom. V prípade subarachnoidálneho krvácania pozorujeme abnormálnu hyperdenzitu v subarachnoidálnom priestore. SAH je typicky distribuovaná v mozgových žliabkoch a cisternách na báze. Toto ochorenie môže byť spojené s krvácaním do komôr prípadne s intracerebrálnym hematómom. [9, 13, 14]

Intracerebrálne hematómy sa prejavujú ako nápadné hyperdenzné ložiská o denzite 60 - 100 HU s expanzívnym charakterom, pričom denzita sa s časom postupne znižuje z dôvodu resorpcie hemoragie. Po niekoľkých hodinách sa v jeho okolí objavuje prstencovitý edém. Ak je krvácanie do parenchýmu, pozorujeme intraparenchymálne hemoragie. Krvácanie sa však môže prevaliť i do komôr a potom hovoríme o intraventriculárnom krvácaní. [9, 11, 13]

2 Metódy strojového učenia

Strojové učenie je disciplínou umelej inteligencie, pričom základnou myšlienkou je navrhnúť resp. analyzovať algoritmy, ktoré umožnia počítaču učiť sa. [17] Výsledkom algoritmu strojového učenia je funkcia $\mathbf{y} = f(\mathbf{x})$, ktorá na základe vstupnej informácie uloženej vo vektore \mathbf{x} vypočíta požadovaný výstup \mathbf{y} . [18]

Návrhu algoritmu strojového učenia odpovedá reťazec štyroch krokov. V prvom kroku je nutné získať vhodné dáta, ktoré sú rozdelené do množiny tréovacích a testovacích dát. Druhým krokom je transformácia dát do priestoru premenných, v ktorom dúfame, že bude náš problém jednoduchšie riešiteľný. Tejto fáze sa hovorí extrakcia príznakov a výsledné premenné sú potom príznaky, ktoré sú vstupmi algoritmu. Tretia fáza je tréovacou fázou, ktorej cieľom je naučiť matematický model tak, aby dokázal zistiť požadovaný výstup. Vstupom tejto fáze je množina tréovacích dát (resp. ich príznakov). Na základe dát chceme matematickou optimalizáciou zistiť najvhodnejšie parametre modelu. Posledným krokom je vyhodnotenie funkčnosti modelu na testovacích dátach.

Pred začatím prvej fáze návrhu algoritmu, je nutné stanoviť problém, ktorý je algoritmom riešený. Dva najčastejšie prediktívne problémy sú klasifikácia a regresia. Pokiaľ je vstupný vektor príznakov \mathbf{x} priradovaný niektorej z konečného množstva diskretných tried, hovoríme o klasifikačnom probléme. Pokiaľ je výstup množinou jednej alebo viacerých spojitých hodnôt, hovoríme o regresnom probléme. [17, 18]

Algoritmy môžeme deliť na základe spôsobu, akým sú trévané. Rozlišujeme učenie s učiteľom a bez učiteľa. V prípade učenia s učiteľom sú využívané anotované dáta, teda okrem vlastných hodnôt príznakov daného pozorovania poznáme i cieľovú hodnotu výstupnej premennej (v prípade klasifikácie výslednú triedu). Vstupnými dátami v prípade učenia bez učiteľa sú príznakové vektory bez znalosti požadovaného výstupu. Cieľom potom môže byť rozdelenie dát do zhlukov podľa spoločných vlastností (tzv. zhluková analýza) alebo určenie pravdepodobnostného rozloženia dát. [17, 18]

Z princípu algoritmov strojového učenia možno konštatovať, že funkčnosť je závislá na zvolených príznakoch popisujúcich spracovávané dáta. Krok voľby vhodných príznakov je často robený manuálne. Novšie algoritmy umožňujú počítačom naučiť sa príznaky, ktoré optimálne reprezentujú dáta pre riešenie daného problému. Do tohoto konceptu spadajú tzv. konvulučné neurónové siete. [19]

2.1 Príznakové metódy

Ako už bolo zmienené, metódy strojového učenia mapujú vstupný vektor hodnôt na výstupný vektor hodnôt. Oblasť strojového učenia v súčasnej dobe zahŕňa veľké

množstvo algoritmov. Výsledok je teda vždy závislý na použitých príznakoch a na zvolenej metóde. Pri voľbe metódy a príznakov je vždy vhodné najskôr stanoviť problém, ktorý chceme riešiť. Okrem toho je výhodou mať prvotné znalosti o spracovávaných dátach. [20]

2.1.1 Obrazové príznaky

Pre správne fungovanie modelu je kľúčový výber rozlišujúcich príznakov, ktorý je závislý na riešenom probléme. Pri výbere zvyčajne zvažujeme jednoduchosť získania príznaku, varianciu resp. invarianciu voči transformáciám, citlivosť voči šumu a relevantnosť z hľadiska riešeného problému. [20] Príznaky môžeme deliť na príznaky nižšieho stupňa, ktoré môžu byť odvodené priamo z obrazu, a príznaky vyššieho stupňa, kde sa v obrazoch hľadajú tvary. [21]

Z hľadiska extrakcie príznakov nižšieho stupňa sú často využívané lokálne príznaky, ktoré vypovedajú o určitých lokálnych vlastnostiach obrazu (v extrémnom prípade môžu popisovať každý pixel samostatne, ako napr. jasová hodnota). Lokálne príznaky zvyčajne popisujú pixel spoločne s jeho okolím a z obrazu môžu byť odvodené lokálnymi operátormi (napr. filtrácia priemerovacou maskou, smerovou diferenčnou maskou apod.). Lokálnymi príznakmi tiež môžu byť parametre lokálnych štatistík (napr. moment alebo centrálny moment n -tého rádu v určitej oblasti), parametre vychádzajúce z lokálnych histogramov (lokálna entropia, modus, medián), či príznaky zo spektier častí obrazu. [15] Do oblasti lokálnych operátorov spadajú hranové operátory aproximujúce prvé parciálne derivácie (napr. Robertsov, Previtovej alebo Sobelov operátor) a druhé parciálne derivácie (napr. Laplacián). Medzi rohové detektory patria Moravecov a Harrisov rohový detektor. [15, 21]

Príznaky vyššieho stupňa hľadajú tvary v obrazoch. Príkladmi môže byť jednoduché porovnávanie obrazu so vzorom, ktorým je subobraz o tvare, ktorý chceme nájsť. Pre hľadanie hraníc tvarov môže byť používaná tiež Houghova transformácia. [21]

2.1.2 Algoritmy strojového učenia

Voľba vhodného algoritmu je často závislá od problematiky, ktorú chceme riešiť. Máme dáta popísané vektorom príznakov $\mathbf{x} = [x_1, x_2, \dots, x_n]$, kde n označuje počet príznakov, ktorými je daný objekt popísaný. Pokiaľ chceme riešiť problém rozdelenia dát do tried, potrebujeme klasifikátor, ktorý rozhodne o triede na základe vstupného príznakového vektoru. Množina všetkých možných hodnôt príznakov tvorí n -dimenzionálny príznakový priestor. Klasifikačný problém je potom problém oddelenia tried v príznakovom priestore prostredníctvom diskriminačnej nadroviny (v prípade dvoch dimenzií krivky). [16] V prípade predikcie spojitej hodnoty pre daný

príznačkový vektor ide o regresný problém, kedy je fitovaná krivka resp. nadrovina na rozptýlené dáta. [17]

Jedným z často využívaných metód lineárnej klasifikácie je metóda podporných vektorov (SVM, z angl. Support Vector Machines). Metóda je založená na myšlienke rozdelenia dát v príznakovom priestore takou priamkou (resp. nadrovinou), ktorá maximalizuje vzdialenosť medzi priamkou a najbližšími vzorkami. Najbližšie vzorky sú nazývané podporné vektory. V praxi sa často triedy v príznakovom priestore prekrývajú (teda nie sú separovateľné) a preto sa využíva varianta C-SVM, ktorá povoľuje prítomnosť vzoriek v zóne medzi deliacou nadrovinou a podpornými vektormi. Existuje i nelineárna varianta, kedy sú dáta najskôr transformované do vyššej dimenzie. [18, 17]

Ďalšou často využívanou metódou sú tzv. rozhodovacie stromy. V prípade stromov rozlišujeme tzv. uzly, ktoré rozdeľujú dáta do vetví na základe hodnôt príznaku. Po niekoľkých rozdeleniach sú dáta rozdelené do kategórií podľa hodnoty v tzv. liste. Často sú používané tzv. CART stromy (z angl. Classification and Regression Trees), ktoré môžu byť natrénované na riešenie klasifikačného i regresného problému. Princípom učenia klasifikačného stromu je minimalizovanie klasifikačnej chyby tak, že stanovujeme prahy pre príznaky, ktoré rozdeľujú dáta v príznakovom priestore, pokiaľ nie je splnená určitá ukončovacia podmienka. Jednotlivé deliace prahy potom reprezentujú uzly v strome. [20] Aj keď sú rozhodovacie stromy často využívanou a atraktívnou metódou, častým problémom býva strata generalizačnej schopnosti pri zvyšujúcej sa zložitosti stromu. V [22] je publikovaná metóda tzv. náhodných rozhodovacích lesov, v ktorej sú obchádzané tieto limitácie použitím klasifikátora založeného na rozhodovacích lesoch, ktorý sa skladá z viacerých menej zložitých stromov, pričom každý strom pracuje v náhodne vybranom podprieštore príznakového priestoru. [22]

2.1.3 Neurónové siete

Významnou oblasťou strojového učenia sú neurónové siete. Tento pojem vychádza zo snahy o matematickú reprezentáciu biologických systémov. Neurónová sieť je zložená z prvkov, tzv. neurónov a cieľom je opäť mapovanie vstupného vektora všeobecne na požadovaný výstupný vektor. Jeden neurón má definovaný vektor parametrov, váh $\mathbf{w} = [w_1, w_2, \dots, w_n]$ a prah w_0 . Funkciou je potom transformácia vstupného vektora $\mathbf{x} = [x_1, x_2, \dots, x_n]$ na výstupnú hodnotu y :


$$y = f\left(\sum_{i=1}^N w_i x_i - \theta\right), \quad (2.1)$$

pričom člen $\sum_{i=1}^N w_i x_i - \theta$ je nazývaný aktivácia a a funkcia $f(a)$ je nazývaná aktivačnou funkciou. Môžeme zaviesť $x_0 = 1$ a $w_0 = -\theta$. Potom je zmieňovaná transfor-

mácia:


$$y = f\left(\sum_{i=0}^N w_i x_i\right). \quad (2.2)$$

Schéma neurónu je vyobrazená na Obr. 2.1.



Obr. 2.1: Schéma neurónu s N vstupmi a jedným výstupom.

Na neurónovú sieť možno pozeráť ako na graf s uzlami tvorenými neurónmi, a potom so smerovými hranami s váhami, ktoré tvoria spoje medzi vstupmi a výstupmi neurónov. Architektúry sietí možno potom rozdeliť na dopredné, kde sa v grafe nevyskytujú slučky, a rekurentné, v ktorých sa vyskytujú slučky ako spätná väzba. U väčšiny dopredných sietí sú neuróny organizované do vrstiev, pričom L -vrstvová sieť sa skladá z $(L - 1)$ skrytých vrstiev a výstupnej vrstvy. Vrstvy sú úplne alebo lokálne prepojené bez spojov medzi jednotkami v rámci jednej vrstvy. Usporiadanie siete potom ovplyvňuje jej vlastnosti a správanie. [23] Schéma dvojvrstvej úplne prepojenej neurónovej siete so skrytou vrstvou s tromi neurónmi a s výstupnou vrstvou s dvomi neurónmi je vyobrazená na Obr. 2.2.



Obr. 2.2: Schéma dvojvrstvej doprednej neurónovej siete.

Aktivačné funkcie

Hlavným významom aktivačnej funkcie je zavedenie nelineárneho vzťahu medzi vstupom a výstupom neurónu. [24] Existuje viacero typov používaných aktivačných funkcií. Medzi základné patrí skoková, alebo lineárna (pričom sa v podstate jedná o funkciu identity):

$$f(a) = a. \quad (2.3)$$

[23] Častou využívanou je sigmoidálna funkcia:

$$f(a) = \frac{1}{1 + \exp\left(\frac{-a}{T}\right)}, \quad (2.4)$$

kde T je parameter. Sigmoidálna funkcia nadobúda funkčné hodnoty z intervalu $< 0, 1 >$ Podobnou funkciou je hyperbolický tangens s funkčnými hodnotami z intervalu $< -1, 1 >$:

$$f(a) = \frac{\exp(a) - \exp(-a)}{\exp(a) + \exp(-a)}. \quad (2.5)$$

[25] Obe funkcie sú derivovateľné, nelineárne, avšak dochádza u nich k saturácii. [20, 18] V dnešnej dobe častou aktivačnou funkciou je tzv. ReLU (z angl. Rectified Linear Unit), ktorá je definovaná ako:

$$f(a) = \max(0, a). \quad (2.6)$$

[26] [25] Aktivačná funkcia využívaná často pri riešení problému viacerých tried je „softmax“, definovaná ako:

$$f(a) = \frac{\exp(a_k)}{\sum_{j=1}^K \exp(a_j)}, \quad (2.7)$$

kde K je počet tried. Vstupom sú reálne čísla, výstupom je potom hodnota pravdepodobnosti. [18]

Algoritmus spätného šírenia chyby

Pokiaľ je architektúra siete navrhnutá, základným problémom je správne určenie parametrov (váh a prahov) jednotlivých neurónov v neurónovej sieti. Riešenie nachádzame v procese učenia, ktorý spočíva v minimalizácii tzv. kriteriálnej (chybovej) funkcie $E(\mathbf{w})$, pričom sú porovnávané požadované výstupy (určené anotáciami z tréningovej množiny dát) a výstupy odhadnuté sieťou. Ide o iteračnú optimalizáciu riešenú množstvom techník, ktoré často využívajú informáciu o gradiente chybovej funkcie. [18]

Úprava parametrov siete je riešená algoritmom spätného šírenia chyby, ktorý zostáva z výpočtu derivácií chybovej funkcie, ktoré sú spätne šírené sieťou a slúžia

k úprave parametrov jednotlivých neurónov. Prvým krokom je inicializácia parametrov (napr. malé náhodné hodnoty). Následne je na vstup privedený vektor \mathbf{x} z tréningovej databázy a vypočítané sú postupne aktivácie a výstupy h_i^l všetkých neurónov označených i v každej vrstve označenej l . Nasleduje výpočet chyby vo výstupnej vrstve podľa:

$$\boldsymbol{\delta}^L = \nabla_{h^L} \mathbf{E} \odot f'(\mathbf{a}^L), \quad (2.8)$$

kde $\nabla_{h^L} \mathbf{E}$ predstavuje gradient chybovej funkcie vo výstupnej vrstve a $f'(\mathbf{a}^L)$ je derivácia aktivačnej funkcie podľa aktivácií. Symbol \odot predstavuje násobenie prvok po prvku. Nasleduje samotný proces spätného šírenia chýb do l -tej vrstvy:

$$\boldsymbol{\delta}^l = ((\mathbf{w}^{l+1})^T \boldsymbol{\delta}^{l+1}) \odot f'(\mathbf{a}^l), \quad (2.9)$$

kde \mathbf{w} predstavuje vektor parametrov. Gradient chybovej funkcie podľa vektoru váh v l -tej vrstve je potom:

$$\nabla_{\mathbf{w}^l} \mathbf{E} = \mathbf{h}^{l-1} \boldsymbol{\delta}^l. \quad (2.10)$$

Parametre sú potom pozmenené podľa zvoleného algoritmu. [18, 23, 27]

Algoritmy učenia

Existuje množstvo prístupov k zmene, teda učeniu váh a prahov. Najjednoduchším prístupom v prípade využitia informácie o gradiente chybovej funkcie je metóda klesajúceho gradientu, kedy sú parametre neurónov menené proti smeru gradientu chybovej funkcie:

$$\mathbf{w}^{\tau+1} = \mathbf{w}^{\tau} - \mu \nabla_{\mathbf{w}^{\tau}} \mathbf{E}(\mathbf{w}^{\tau}), \quad (2.11)$$

kde τ označuje epochu a μ je tzv. krok učenia, ktorý určuje rýchlosť konvergencie optimalizačného procesu. Jeho hodnota musí byť dostatočne malá, aby bola zaručená konvergencia, avšak ak je príliš malá, konvergencia je pomalá. Voľba hodnoty kroku učenia závisí na probléme a na tvare kritériálnej funkcie v danej oblasti. Metóda má okrem problému vhodného nastavenia kroku učenia viaceré obmedzenia, ako je tendencia skončiť v lokálnom minime a pomalá konvergencia kvôli aktualizácii parametrov až po celej epoche učenia (teda po prejdení celého datasetu). Existuje aj „online“ verzia, tzv. metóda stochastického klesajúceho gradientu. V tom prípade sú parametre menené po každej iterácii, teda po každej vzorke z tréningového datasetu:

$$\mathbf{w}^{t+1} = \mathbf{w}^t - \mu \nabla_{\mathbf{w}^t} \mathbf{E}(\mathbf{w}^t), \quad (2.12)$$

kde t označuje iteráciu. Výhodou takéhoto prístupu je rýchlejšia konvergencia a schopnosť uniknúť z lokálneho minima. [18, 28] Existuje i varianta pre tzv. „mini-batch“, definovaný ako množina k dát zo vstupnej databázy. Parametre sú potom upravované po k iteráciách. [27]

V dnešnej dobe často využívanou metódou učenia je metóda adaptívneho stanovenia momentu ADAM (z angl. Adaptive Moment Estimation) publikovaná v [29]. Algoritmus pozostáva z výpočtu prvého momentu:

$$\mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \nabla_{\mathbf{w}^t} \mathbf{E}(\mathbf{w}^t), \quad (2.13)$$

kde β_1 je hyperparameter exponenciálneho zabúdania starých momentov prvého rádu. Ďalej je vypočítaný moment druhého rádu:

$$\mathbf{v}_t = \beta_2 \mathbf{v}_{t-1} + (1 - \beta_2) (\nabla_{\mathbf{w}^t} \mathbf{E}(\mathbf{w}^t))^2, \quad (2.14)$$

kde β_2 je hyperparameter exponenciálneho zabúdania starých momentov druhého rádu. Oba vypočítané momenty sú ešte skorigované podľa:

$$\mathbf{m}_t = \frac{\mathbf{m}_t}{(1 - \beta_1^t)}, \quad (2.15)$$

$$\mathbf{v}_t = \frac{\mathbf{v}_t}{(1 - \beta_2^t)}. \quad (2.16)$$

Nasleduje samotný prepočet parametrov:

$$\mathbf{w}_t = \mathbf{w}_{t-1} - \frac{\alpha \mathbf{m}_t}{\sqrt{\mathbf{v}_t} + \epsilon}, \quad (2.17)$$

kde ϵ je kladné malé reálne číslo. Algoritmus si adaptívne mení krok posunu a parameter α určuje hornú hranicu posunu v priestore parametrov. Algoritmus je jednoduchý a výpočtovo efektívny, rieši problém nastavenia kroku učenia a tiež je do určitej miery schopný uniknúť z lokálneho minima. [29]

2.2 Konvolučné neurónové siete


Konvolučné neurónové siete (CNN, z angl. Convolutional Neural Networks) sú špeciálnym typom neurónových sietí, ktoré sú dizajnované na spracovanie dát vo forme mriežky (ako sú napr. farebné 2D obrazy s tromi kanálmi pre farby). Tieto siete vykazujú mimoriadnu úspešnosť pri praktických aplikáciach v porovnaní s ďalšími prístupmi strojového učenia. Názov „konvolučné“ siete dostali vďaka operácii konvolúcie, ktorú siete používajú v aspoň jednej vrstve. [30, 31] Základnými spoločnými znakmi pre konvolučné siete sú vrstvy s lokálnymi prepojeniami (teda neuróny v jednej vrstve nie sú úplne prepojené) a zdieľanými váhami, pričom je využívané množstvo vrstiev. Konvolučné siete teda spadajú do oblasti hĺbkového učenia. Patria do skupiny tréovania s učiteľom a pre učenie je použitý algoritmus spätného šírenia chyby. [31]

2.2.1 Vrstvy siete

Typická konvolučná sieť má špecifickú architektúru. Vstupom tentokrát nie je vektor príznakov ale celý obraz. Prvá časť architektúry je zložená z dvoch typov vrstiev: konvolučných a podvzorkovacích. Výstupy konvolučných vrstiev sú zvyčajne ešte upravené aktivačnou funkciou (ako napr. ReLU). Kombinácia týchto vrstiev je inšpirovaná štruktúrou zrakovej kôry. Na koniec architektúry sa dáva jedna alebo viacej úplne prepojených vrstiev. Jednotlivé vrstvy a ich funkcie sú popísané v nasledujúcich sekciách. [27, 31]


Konvolučná vrstva

Konvolučná vrstva je špecifikum konvolučných sietí a predstavuje operáciu konvolúcie. Vstupný obraz má rozmery $h \times w \times d$, kde h je výška, w je šírka a d je hĺbka (teda počet kanálov). Jeden neurón, ktorý možno považovať za filter, má počet váh $h_f \times w_f \times d_f$, pričom platí: $d_f = d$, h_f resp. w_f sú menšie ako rozmery obrazu, a zvyčajne $h_f = w_f = f$. Neurón je prepojený iba s určitou lokalitou vstupného obrazu, pričom definujeme toľko rovnakých filtrov so zdieľanými váhami, aby bol pokrytý celý obraz. Môžeme definovať i „krok“, ktorý určí, koľko pixelov je preskočených v danom smere pred ďalšou lokálnou filtráciou. Výstupom jedného neurónu je jedna hodnota. Vznik jednej hodnoty z viackanálového obrazu po filtrácii jedným neurónom je znázornený na Obr. 2.3, kde lokálne prepojenia a výstupná hodnota aktivačnej mapy sú znázornené tmavomodrou farbou. Výstupom filtrácie všetkými



Obr. 2.3: Schéma funkcie jedného neurónu konvolučnej vrstvy.

neurónmi s rovnakými váhami, pokiaľ krok je rovný 1, je tzv. aktivačná mapa o veľkosti $(h-f+1) \times (w-f+1) \times 1$. Príklad konvolúcie filtrom o veľkosti: $f = 3$ je na Obr. 2.4. V jednej konvolučnej vrstve je definovaných k typov neurónov, ktoré predstavujú filtráciu rôznymi typmi filtrov. Výstupom jednej konvolučnej vrstvy je potom k aktivačných máp, teda trojrozmerná matica s hĺbkou k . Aktivačné mapy môžu byť



Obr. 2.4: Schéma vzniku aktivačnej mapy prechodom obrazu 3×3 konvolučnou vrstvou.

transformované nelineárnou aktivačnou funkciou. Váhy lokálnych prepojení jednotlivých filtrov sú učené v procese tréovania siete tak, aby získavali vhodné príznaky na riešenie danej problematiky. Pri zapojení viacerých konvolučných vrstiev do hlbokjej siete sú získavané postupne špecifickejšie príznaky prinášajúce vysokú úroveň abstrakcie. [27, 30, 31, 32]

Podvzorkovacia „pooling“ vrstva

V CNN sú často po konvolučných vrstvách a transformácii aktivačnou funkciou zaradené tzv. podvzorkovacie (v angl. „pooling“) vrstvy, ktoré majú za úlohu podvzorkovať výstupnú informáciu z predošlých vrstiev. Cieľom je nahradiť určitú oblasť výstupu jednou hodnotou pomocou určitej štatistickej metódy (napr. priemer z oblasti, maximum, L^2 norma oblasti). Hlavnou myšlienkou je zavedenie invariance ku malým posunom vstupu. [30] Typicky je hľadané maximum z oblasti, potom hovoríme o tzv. „max-poolingu“. „Max-pooling“ podvzorkovacia jednotka počíta maximálnu aktiváciu z malej oblasti jednej alebo viacerých príznakových máp, pričom tieto oblasti sú posunuté o viac ako jeden riadok resp. stĺpec, čím je dosiahnuté tiež podvzorkovanie. [31] Tento fakt má za následok zníženie počtu parametrov potrebných v ďalších vrstvách. [27]

Úplne prepojená vrstva

U CNN sú často po sérii konvolučných a podvzorkovacích vrstiev do architektúry zaradené úplne prepojené vrstvy, ktoré sú identické s vrstvami štandardných neurónových sietí. [31, 32] Vstupom sú potom aktivačné resp. príznakové mapy. Počet neurónov tejto siete je závislý na aplikácii a určuje dĺžku výstupného vektora. Každý neurón je prepojený s každou hodnotou výstupu predošlej časti siete a funkciou úplne prepojenej vrstvy je naučiť sa integrovať celkovú informáciu zo vstupného obrazu. [27]

„DropOut“ vrstva

U neuronových sietí je veľkým problémom preučenie, teda strata generalizačnej schopnosti siete. Tento problém sa dá do istej miery riešiť regularizáciou. Poznáme mnoho regularizačných techník, medzi ktoré patrí i tzv. „DropOut“. [27] Základnou myšlienkou je počas procesu učenia neurónovej siete dočasne náhodne vypnúť niektoré neuróny, čo zabráni sieti príliš sa adaptovať na tréningové dáta. [33]

Učenie siete s „DropOut“ vrstvami prebieha tak, že najskôr náhodne vypneme určité percento neurónov v skrytých vrstvách dané Bernoulliho náhodnou premennou (výstupnú vrstvu necháme nedotknutú). Je daný parameter p , ktorý určuje pravdepodobnosť vypnutia neurónu a často ho volíme $p = 0,5$. Po vypnutí niektorých neurónov propagujeme sieťou časť vzoriek vstupnej databázy („mini-batch“) a upravíme váhy nezakázaných jednotiek. Tento proces opakujeme, čo sa môže prirovnáť k tréningu rozličných neuronových sietí. Po celkovom naučení môžeme konštatovať, že využívame priemer veľkého množstva rozličných sietí. V procese testovania siete vynásobíme váhy siete parametrom p kvôli zachovaniu energie. Výsledná sieť je potom testovaná a využívaná bez „DropOutu“. [27, 33]

„Batch“ normalizácia

Počas učenia siete sa so zmenami parametrov mení rozloženie vstupov každej vrstvy, čo spomaľuje učenie a komplikuje učenie sietí so saturujúcimi nelinearitami. Riešením je „batch“ normalizačná vrstva [34], ktorá slúži k normalizácii vstupov do ďalšej vrstvy, pričom normalizácia je robená pre každý „mini-batch“, teda časť tréningovej databázy. Tento úkon slúži tiež ako regularizácia.

Vstupom „Batch“-normalizačnej vrstvy sú výstupy predošlých vrstiev teda príznaky resp. aktívacie v rámci daného „mini-batchu“, pričom pre každú aktiváciu resp. príznak je normalizácia robená samostatne. Pre jednu aktiváciu máme m hodnôt, čo predstavuje veľkosť daného „mini-batchu“: $B = \{x_1, \dots, x_m\}$. Pre daný „mini-batch“ vypočítame strednú hodnotu:

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i, \quad (2.18)$$

a rozptyl:

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2. \quad (2.19)$$

Následne je urobená normalizácia:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}, \quad (2.20)$$

kde ϵ je konštanta pridaná kvôli stabilite. Stredná hodnota a rozptyl sú uložené do pamäte stredných hodnôt pre celú databázu: $E(x)$ resp. do pamäte rozptylov pre

celú databázu $Var(x)$ Normalizované dáta sú následne transformované pomocou škálovacieho parametra γ a parametra posunu: β :

$$y_i = \gamma \hat{x}_i + \beta. \quad (2.21)$$

Parametre γ a β sú učené v priebehu učenia siete a pre každú aktiváciu sú odlišné. Celý tento proces je počas tréningu opakovaný a vykonaný pre všetky aktivácie. Výsledná transformácia po tréningu pre danú aktiváciu je potom:

$$y = \frac{\gamma}{\sqrt{Var(x) + \epsilon}}x + \left(\beta - \frac{\gamma E(x)}{\sqrt{Var(x) + \epsilon}}\right). \quad (2.22)$$

[34]

2.2.2 Výhody, nevýhody a využitie

CNN sú používané pre riešenie rôznych úloh. Zvyčajne sa jedná o snahu o porozumenie obrazu, pričom riešia klasifikačné, segmentačné alebo detekčné úlohy. Ďalšími možnými aplikáciami sú porozumenie reči, či prirodzenému jazyku. [31]

Jednou z najväčších výhod použitia CNN v porovnaní s inými algoritmami strojového učenia je strata nutnosti extrakcie príznakov, keďže tento proces je zahrnutý prechodom cez sekvenciu konvolučných a podvzorkovacích vrstiev. Ďalšou výhodou je vysoká úspešnosť CNN v porovnaní s inými metódami strojového učenia. [36]

Nevýhodou je požiadavka na pomerne veľký trénovací dataset. Tento problém môže byť riešený využitím predtrénovaných modelov (v angl. „Transfer Learning“). Učenie siete úplne od základu je pre dostatočné natrénovanie časovo náročné a vyžaduje veľké množstvo dát. Existujú rozsiahle databázy obrazov s anotáciami, ako je ImageNet, [35] na ktorých sa siete naučia extrahovať účinné príznaky. Takto naučená sieť je potom preučená na databáze našich dát, pričom upravované sú buď váhy všetkých vrstiev alebo iba niektorých. [36]

3 Klasifikácia a detekcia pomocou CNN

Určitá charakteristika problému klasifikácie už bola zmienená v sekcii 2.1.2. Môžeme ho charakterizovať ako predikciu tried, teda diskrétnych hodnôt. [17] Využitie konvolučných neurónových sietí pre klasifikáciu je podrobne popísané v kapitole 3.1.

Objekt je v obrazovej analýze a strojovom učení fyzikálnou jednotkou reprezentovanou určitou oblasťou v obraze tak, že množina objektov v danom obraze tvorí množinu neprekrývajúcich sa oblastí. [16] Problém detekcie objektov v obraze obyčajne zahŕňa dve štádia: lokalizáciu daného objektu a klasifikáciu, do ktorej triedy daný objekt spadá. Nie je teda stanovovaná iba trieda, ale i pozície ohraničujúce daný objekt. [42]

Konvolučné neurónové siete prinášajú do oblasti detekcie prelomové modely dosahujúce dobré výsledky, v novších prípadoch získavané v reálnom čase. Častým postupom detekcie je stanovenie regiónu, extrakcia príznakov a klasifikácia (napr. R-CNN [45], fast R-CNN [46], faster R-CNN [47]). Niektoré algoritmy pokladajú detekciu objektov za regresný a klasifikačný problém. Medzi tieto algoritmy patrí napr. YOLO (z angl. „You Only Look Once“) [48] alebo SSD (z angl. „Single Shot multibox Detector“) [49]. [42]

3.1 Klasifikácia pomocou CNN

Konvolučné neurónové siete sú v poslednej dobe štandardom riešenia klasifikačných úloh. [43] Výsledky klasifikácie silno závisia na extrahovaných príznakoch, pričom CNN dokážu z obrazu vytvoriť komplexné sémantické príznaky, čím sa stávajú dominantou spomedzi metód extrakcie príznakov. Typicky sa architektúra skladá z CNN extraktora príznakov a úplne prepojenej vrstvy so „softmax“ aktivačnou vrstvou, ktorá na výstup vyše vektor pravdepodobností jednotlivých tried. Počet neurónov v úplne prepojenej vrstve je rovný počtu tried. Výsledná trieda je tá s najvyššou pravdepodobnosťou. [37, 41, 44]

Pre učenie klasifikačnej siete sa využíva ako chybová funkcia (viď sekcia 2.1.3) tzv. vzájomná entropia:

$$E(\mathbf{w}) = - \sum_{n=1}^N \sum_{k=1}^K t_{nk} \ln(y_{nk}), \quad (3.1)$$

kde N je počet vzoriek, K je počet tried, t_{nk} je indikátor, že n -tá vzorka patrí do k -tej triedy, y_{nk} je výstupná pravdepodobnosť (výstup zo „softmax“ funkcie), že n -tá vzorka patrí do k -tej triedy. [18]

3.1.1 Publikované architektúry klasifikačných CNN

Existuje množstvo publikovaných architektúr CNN, ktoré boli vytvorené pre riešenie klasifikačného problému. Prelomovou architektúrou je tzv. AlexNet [37], ktorá vyhrala ImageNet 2012 Challenge. Je to prvá architektúra CNN, ktorá dokázala dosiahnuť pomerne dobré výsledky. Architektúra tejto siete je pomerne jednoduchá. Ide o sériové zapojenie 25 vrstiev, pričom 5 je konvolučných a 3 úplne prepojené. Klasifikuje do 1000 kategórií. [37] Hlbšiu architektúru, ktorá je taktiež sériová, predstavuje VGG-19, zložená z 16 konvolučných vrstiev a 3 úplne prepojených vrstiev. [38] Víťazom ImageNet 2014 Challenge (ILSVRC14) je tzv. GoogLeNet [39], ktorá zavádza paralelizáciu a predstavuje tzv. inepčné bloky, ktorých vstupom je jedna vstupná mapa, ktorá je filtrovaná paralelne niekoľkými typmi filtrov (viď nižšie). Architektúra je charakteristická tiež dvomi pomocnými klasifikátormi. [39] Medzi novšie architektúry potom patrí Inception-v4 [40] vychádzajúca z architektúry GoogLeNet v zmysle využívania inepčných blokov, avšak s viac uniformovanou zjednodušenou architektúrou a väčším množstvom inepčných modulov ako predošlé verzie.

Reziduálne siete

Víťazom ILSVRC 2015 sa stávajú tzv. reziduálne siete s dosiahnutím klasifikačnej chyby 3,57 %. [41] Tieto siete majú hĺbku až do 152 vrstiev, čo je až 8-krát viac ako VGG siete, avšak stále majú nižšiu komplexnosť. U veľmi hlbokých sietí dochádza k problému miznúceho gradientu v procese učenia pri spätnom šírení gradientu. Reziduálna sieť rieši tento problém pomocou skratiek, tzv. vetiev identity medzi vrstvami.

Zavádzajú sa tzv. reziduálne bloky, kedy v jednej vetve bloku je vstupná mapa spracovaná konvolučnými vrstvami, pričom paralelne je vedená vetva identity, tiež označovaná ako skratka, ktorou prechádza samotný vstup. Na konci reziduálneho bloku sú informácie z oboch vetiev sčítané. Vo vetve predstavujúcej skratku môže byť tiež zaradená 1×1 konvolúcia. ResNet architektúry môžu mať 18, 34, 50, 101 alebo 152 vrstiev. U 18 a 34 vrstiev sú vo vetve konvolúcie zaradené dve konvolučné vrstvy s veľkosťou filtru 3×3 . U 50 vrstiev a viac sa využíva tzv. „bottleneck“, kedy sú za sebou zaradené tri konvolučné vrstvy: 1×1 , 3×3 a 1×1 , pričom 1×1 vrstva je zodpovedná najskôr za zmenšenie a potom za zvýšenie dimenzionality príznakov. Konvolučná vrstva s veľkosťou filtru 3×3 potom predstavuje „bottleneck“, teda spracovanie menšej vstupnej i výstupnej dimenzie. Výstupy reziduálnych blokov sú transformované ReLU aktivačnou funkciou. [41]

Architektúra typu Inception-ResNet-v2

Sieť Inception-ResNet-v2 [40] (2016) kombinuje inepčnú architektúru a reziduálne prepojenia. Autori poukazujú na výrazné urýchlenie tréningovania inepčných sietí použitím reziduálnych blokov, a taktiež na fakt, že reziduálne inepčné siete dosahujú mierne lepšie výsledky ako podobne zložité inepčné siete bez reziduálnych spojov. S kombináciou troch reziduálnych a jednej Inception-v4 architektúr je uvádzaná „top-5“ chyba¹ 3,08 % na ImageNet Classification Challenge. [40]

Inepčné bloky v pôvodnej podobe predstavujú paralelné spracovanie jednej vstupnej mapy prostredníctvom niekoľkých vrstiev a následnú konkaténáciu výstupov vrstiev do jedného výstupu. Jednotlivé paralelné vrstvy sú zvyčajne konvolučné s rôznou veľkosťou filtru (3×3 alebo 5×5), ale i podvzorkovacie. Pred týmito filtermi sa využíva i 1×1 konvolúcia, ktorá predstavuje redukciu dimenzionality pred samotnou filtráciou. [39] U architektúry Inception-ResNet-v2 sa v prípade niektorých konvolučných vrstiev pre zrýchlenie využíva separabilná konvolúcia (dve vrstvy $1 \times n$ a $n \times 1$ za sebou, kde n je 3 alebo 7). Neseparabilné konvolučné vrstvy majú veľkosť filtrov 3×3 alebo 1×1 . [40]

U reziduálnych verzií inepčných blokov je v každom bloku paralelne vedená vetva identity a po každom bloku nasleduje sčítanie výsledných máp (na rozdiel od konkaténácie), ktorému predchádza 1×1 konvolučná vrstva pre zvýšenie dimenzionality, aby hĺbka bola zhodná s hĺbkou vstupnej mapy. Výstupná mapa po sčítaní je spracovaná ReLU aktivačnou funkciou. Architektúra Inception-ResNet-v2 je vytvorená sériami reziduálnych inepčných blokov, medzi ktorými sú zaradené dva čisto inepčné bloky (tzv. redukčné bloky), ktorých výstupná aktivačná mapa má redukovanú výšku a šírku oproti vstupnej. [40]

¹„Top-5“ chyba je percentuálny počet testovacích obrazov, pri ktorých správna trieda nepatrí medzi prvých päť tried s najvyššou pravdepodobnosťou predikovanou modelom. [37]

4 Databáza CQ500

Autori publikácie [50] (2018) zozbierali a zverejnili databázu CT snímok hlavy, ktorú nazvali CQ500. Tento dataset obsahuje 491 skenov s 193 317 2D rezmi. Skeny sú zozbierané z rozličných rádiologických center a získané rozličnými CT zariadeniami. Všetky dáta sú anonymizované. Dáta boli získané v dvoch várkach. Prvá obsahuje všetky CT skeny daných centier v rozmedzí 30 dní počnúc dňom 20.11.2017. Druhá várka je získaná algoritmom spracovania reči z klinických správ, pričom detekované boli kalvariálne fraktúry a päť typov hemoragií (IPH, IVH, EDH, SAH, SDH). Správy boli následne náhodne vybrané tak, že ostáva približne 80 skenov s IPH, EDH, SAH, SDH. Zvolené skeny sú ďalej kontrolované vylučovacími kritériami, pričom pacienti by nemali mať postoperačné defekty, v každej sérii CT skenov by mal byť aspoň jeden bezkontrastný sken zahrňajúci celý mozog s rekonštrukčným algoritmom pre mäkké tkanivo, a okrem toho by mali byť pacienti starší ako 7 rokov (pokiaľ informácia o veku nie je dostupná, vek je určený stupňom osifikácie lebečných štruktúr).

Tab. 4.1: Tabuľka počtov skenov s danými patológiami v datasete CQ500

Patológia	Počet skenov
Intrakraniálna hemoragia	205
Intraparenchymálna hemoragia	134
Intraventrikulárna hemoragia	28
Subdurálna hemoragia	53
Epidurálna hemoragia	13
Subarachnoidálna hemoragia	60
Fraktúra	39
Kalvárna fraktúra	34
Posun stredovej línie	65
Mass Effect	127

Dostupné sú i anotácie daných skenov, ktoré sú získané hodnotením troch nezávislých rádiológov, ktorí nie sú zahrnutí do diagnostického procesu daných pacientov a nepoznajú ich klinickú históriu. Hodnotenú sú prítomnosť resp. neprítomnosť intrakraniálnej hemoragie, typ hemoragie (IPH, IVH, EDH, SAH, SDH), postihnutá hemisféra a poznačené je taktiež, či sa jedná o chronickú hemoragiu, alebo nie. Ďalej je hodnotená prítomnosť resp. neprítomnosť posunu stredovej línie a presunu mozgového tkaniva (v angl. „Mass Effect“). Anotovaná je i prítomnosť resp. absencia fraktúry spolu s informáciou, či sa jedná (aspoň čiastočne) o kalvariálnu fraktúru. Posun stredovej línie je charakterizovaný ako pozitívny, pokiaľ je väčší ako 5 mm.

Ako presun mozgového tkaniva sú charakterizované lokálne presuny, utlačenie komôr, posun stredovej línie a herniácia mozgu. V prípade nezhody troch rádiológov sa ako definitívna anotácia považuje väčšinový názor. Počty skenov datasetu CQ500 s jednotlivými patológiami sú uvedené v Tab. 4.1. Možno poznamenať, že niektoré CT skeny obsahujú väčšie množstvo patológií a preto sú v tabuľke počtov skenov zahrnuté viackrát. [50]

5 Súvisiace práce

Za posledné roky je publikovaných mnoho prác zaoberajúcich sa detekciou hemoragií, ktoré popisujú riešenie danej problematiky často pomocou metód strojového učenia.

Autori Chilamkurthy a kol. (2018) [50] vo svojej publikácii popisujú detekciu piatich typov hemoragií a fraktúr lebky. K detekcii hemoragií využívajú modifikovanú architektúru CNN ResNet18, ktorá v každom 2D reze predikuje pravdepodobnosti prítomnosti každého typu hemoragie, tak, že namiesto jednej úplne prepojenej vrstvy je použitých 5 paralelných. Na úrovni celého skenu je potom predikovaná prítomnosť hemoragií pomocou metódy náhodných lesov. Následne využívajú model založený na U-Net architektúre na segmentáciu hemoragie. Autori zostavili dve databázy: Qure25k obsahujúcu 21 tisíc skenov a verejnú databázu CQ500 (viď kapitola 4). Na tejto databáze je detekciou hemoragie dosiahnutá plocha pod ROC krivkou (tzv. AUC) 0,94. Pre detekciu jednotlivých typov IPH, IVH, SDH, EDH resp. SAH autori dosahujú AUC 0,95, 0,93, 0,97 resp. 0,96. [50]

Monika Grewal a kol. [51] v roku 2018 publikujú prístup k detekcii hemoragií v CT skenoch pomocou architektúry CNN DenseNet, ktorú využívajú v kombinácii s rekurentnou neurónovou sieťou LSTM (angl. long short-term memory), ktorá informáciu začleňuje do 3D kontextu. Na úrovni 3D skenov je dosiahnutá úspešnosť predikcie hemoragií 81,82 %, pričom tréningový resp. testovací dataset pozostávajú z 185 resp. 77 CT skenov získaných z dvoch nemocníc.

Detekciu prítomnosti a typu hemoragie pomocou konceptu kombinácie CNN pre extrakciu príznakov a rekurentnej neurónovej siete (RNN, z angl. recurrent neural network) pre zachytenie sekvenčnej informácie z rezov jedného skenu využívajú i Ye a kol. (2019) [52]. Autori popisujú využitie sústavu CNN-RNN najskôr pre detekciu prítomnosti hemoragií a následne, v prípade pozitívneho výsledku, i klasifikáciu hemoragií do piatich typov. Popísaná je databáza s 2 800 CT skenmi, z ktorých 80 % je využitých na tréningovanie a po 10 % na validáciu a testovanie. V prípade klasifikácie prítomnosti hemoragie je uvádzaná úspešnosť 99 %, senzitivita 98 % a špecificita 99 %. U klasifikácie typu je pre každú triedu dosiahnutá AUC väčšia ako 0,8.

Cho a kol. (2019) [53] využívajú na detekciu hemoragie resp. jej piatich typov kaskádovitý model založený na hlbokom učení. Model sa skladá z dvoch konvolučných neurónových sietí, ktoré identifikujú krvácanie, pričom každý klasifikátor pracuje so vstupným obrazom transformovaným rôznym rádiologickým oknom. V kaskáde nasleduje duálna úplne prepojená sieť, ktorá identifikuje typ hemoragie a ohraničuje nález. Autori uvádzajú, že majú k dispozícii databázu s viac ako 130 tis. CT rezmi. Pri určovaní, či sa jedná o krvácanie, dosahujú senzitivitu 97,91 % a špecificitu 98,76 %. Pri rozlišovaní hraníc a typov autori dosahujú presnosť (v angl.

„precision“) 80,19 % a senzitivitu 82,15 %.

Klasifikácia prítomnosti a typu hemoragie pomocou CNN je popísaná i v [54] (2019), pričom autori uvádzajú využitie kombinácie doučených modelov VGG16, ResNet50, Inception-v3 a Inception-ResNet-v2. Systém zahŕňa iteratívny proces, ktorý imituje prácu rádiológa v zmysle pozorovania i susedných rezov pri klasifikácii daného rezu, pričom je využívaný vstupný rez spolu s dátami získanými interpoláciou s priliehajúcimi rezmi. Popísaná je trénovacia databáza s 904 CT skenmi a dve testovacie databázy o veľkosti 200 skenov. Senzitivita resp. špecificita klasifikácie prítomnosti hemoragie pre testovacie datasety sú: 98,0 % resp. 95,0 % a 92,4 % resp. 94,9 %. AUC u klasifikácie typu hemoragie u datasetov sa pohybuje medzi 0,92 (EDH) a 0,98 (IPH), a potom medzi 0,88 (SDH) a 0,97 (IVH).

6 Návrh detekcie hemoragií

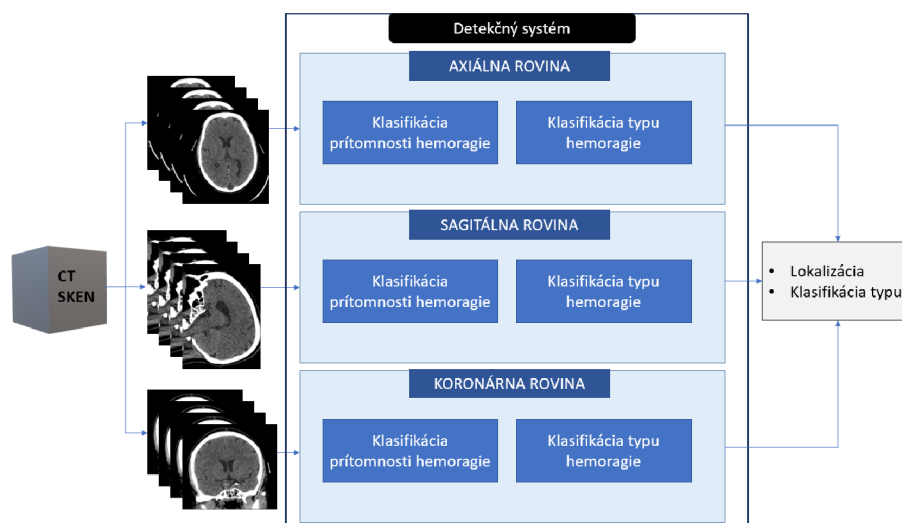
V tejto kapitole je popísaný návrh prístupu ku detekcii intrakraniálnych hemoragií v CT snímkach. Kapitola uvádza formuláciu problému a návrh riešenia v podobe popisu jednotlivých krokov algoritmu.

6.1 Všeobecný návrh riešenia

Základným problémom je nájdenie ložisiek hemoragií v 3D skene a určenie ich typov z 5 možných (IPH, IVH, SDH, EDH a SAH). Navrhnutým riešením je vytvoriť algoritmus, ktorý možno popísať v troch krokoch:

1. predspracovanie dát,
2. lokalizácia hemoragie,
3. klasifikácia typu hemoragie.

CT sken je v prvom kroku predspracovaný tak, aby spĺňal určité požiadavky. Následne sú nájdené a ohraničené hemoragické ložiská, a posledným krokom je určenie typu týchto hemoragií.




Obr. 6.1: Bloková schéma navrhnutého detekčného systému pozostávajúceho z klasifikačných podsystemov pre tri anatomické roviny.

Navrhnutá metóda detekcie intrakraniálnych hemoragií je založená na spracovaní CT skenu hlavy systémom pozostávajúcim z troch podsystemov, ktoré realizujú zmienený druhý a tretí krok v troch kolmých anatomických rovinách: axiálnej, sagitálnej a koronárnej. Na obe úlohy sa pri tom pozerá ako na klasifikačný problém. Základnou myšlienkou je teda vytvoriť tri klasifikačné podsystemy, ktoré spracujú jednotlivé 2D rezy daného CT skenu v axiálnom, sagitálnom resp. koronárnom smere.

Každý podsystém najskôr určí, či sa jedná o hemoragický rez. V prípade pozitívneho výsledku prebieha klasifikácia typu hemoragií, ktoré sa v danom reze nachádzajú. Systémom postupnej klasifikácie rezov troch anatomických rovín možno vytvoriť finálnu pravouhlú trojrozmernú ohraničujúcu oblasť. Celý navrhnutý detekčný systém je ilustrovaný na Obr. 6.1. Návrh riešenia problému lokalizácie resp. klasifikácie typu hemoragie v jednotlivých anatomických rovinách je popísaný v kap. 6.3 resp. 6.4.

6.2 Predspracovanie dát

Na základe empirických poznatkov a doteraz publikovaných článkov [50, 53, 54] je CT sken pred vstupom do navrhnutého systému podrobený predspracovaniu. Trojrozmerné CT dáta sú rotačne zarovnané. Axiálny pohľad na príklad výsledku zarovnania je zobrazený na Obr. 6.2.



Obr. 6.2: Výsledok rotačného zarovnania CT obrazu (vľavo originál, vpravo zarovnaný).




Obr. 6.3: Ukážka axiálneho rezu s transformovaným kontrastom zľava podľa mozgového, subdurálneho a kostného rádiologického okna.

Jednotlivé 2D rezy CT skenu, ktoré sú spracované klasifikačnými podsystémami, sú predspracované vo forme prevzorkovania na veľkosť 299×299 pixelov a úpravy hrúbky rezu na približne 5 mm podľa [50]. Na základe tejto publikácie sú okrem toho z každého takéhoto 2D šedotónového obrazu vytvorené vektorové obrazy s tromi kanálmi. Jednotlivé kanály predstavujú výsledky transformácie kontrastu podľa tzv. mozgového, subdurálneho a kostného rádiologického okna. Kanál podľa kostného okna má širokú škálu hodnôt medzi prahmi a zachováva tak obraz takmer nezmenený (vysoký horný prah môže viesť k prípadnému vyprahovaniu artefaktov s vysokými hodnotami HU). Fraktúra viditeľná v kostnom okne môže indikovať extracerebrálne krvácanie, a subdurálne okno môže pomôcť odlišiť extracerebrálne krvácanie, ktoré nemusí byť viditeľné v mozgovom okne, od lebky. [50] Tento postup sa osvedčil v rámci testovania navrhnutých prístupov v tejto práci. Ukážka rezu s transformovaným kontrastom podľa jednotlivých okien je na Obr. 6.3. Takáto forma predspracovania je aplikovaná na rezy z každej anatomickej roviny.

6.3 Návrh metódy pre lokalizáciu hemoragií

Po predspracovaní je druhým krokom lokalizovať hemoragiu v 3D CT skene. Úlohou je teda nájsť hranice ložiska z každej strany, čoho výsledkom je trojrozmerná pravouhlá ohraničujúca oblasť. Túto úlohu možno formulovať ako klasifikačný problém tak, že v troch navzájom kolmých rovinách sú jednotlivé rezy CT skenu klasifikované do jednej z dvoch kategórií: *Patologický* alebo *Zdravý*.




Obr. 6.4: Ukážka Axiálneho a sagitálneho rezu s pravouhlou vyznačenou oblasťou hemoragie.

V navrhnutej metóde je klasifikátor prítomnosti resp. neprítomnosti hemoragie prvou zložkou klasifikačných systémov pracujúcich v axiálnej, sagitálnej resp. koronárnej rovine. Jeho vstupom sú rezy CT skenu v danom smere. Vďaka klasifikácii 2D rezov z jednej roviny je možné určiť pozície a hranice ložísk v danom smere. Pokiaľ sú takto spracované všetky rezy 3D skenu z troch navzájom kolmých smerov,

vo výsledku je známa postihnutá oblasť s kvádrovým ohraničením zo všetkých troch smerov (viď Obr. 6.4). Preto sú pre lokalizáciu hemoragie navrhnuté tri binárne klasifikátory 2D rezov pre axiálnu, sagitálnu resp. koronárnu rovinu, ktorých úlohou je určiť prítomnosť alebo absenciu krvácania v reze.

6.4 Návrh metódy pre klasifikáciu hemoragií

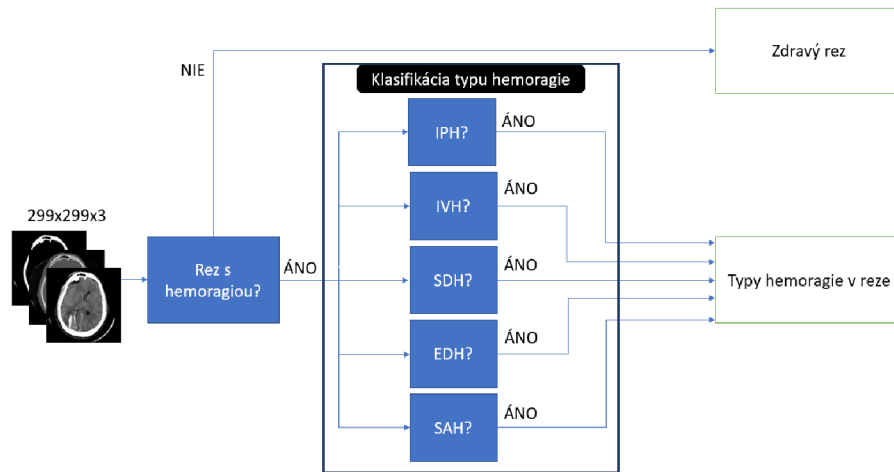
Keď sú ložiská v rámci 3D skenu lokalizované, ďalším problémom je určenie, o aký typ hemoragie sa v danej oblasti jedná. Podobne, ako lokalizáciu hemoragie, možno tento problém vyriešiť klasifikáciou typov hemoragie na úrovni 2D rezov v troch vzájomne kolmých smeroch. Pokiaľ je následne známe, ktorý typ hemoragie sa nachádza v ktorých rezoch pre každý smer, opäť je možné stanoviť lokalitu a hranice, teraz už pre jednotlivé typy hemoragií. Vo výsledku detekcia môže vyzerať ako na Obr. 6.5



Obr. 6.5: Ukážka axiálneho a sagitálneho rezu CT skenu s pravouhlou vyznačenou oblasťou hemoragií a určením ich typov.

Prakticky je v navrhovanej metóde tento problém riešený zaradením klasifikácie typu hemoragie za klasifikáciu prítomnosti hemoragie v systéme každej z troch pra-

covných anatomických rovín (viď Obr. 6.1). Pokiaľ je 2D rez v prvej časti systému pre danú rovinu označený ako patologický, vstupuje do bloku klasifikácie typu hemoragií, ktoré sa v danom reze nachádzajú. Keďže poznáme päť typov hemoragií, blok určenia typov pozostáva zo série piatich binárnych klasifikátorov rozhodujúcich o prítomnosti resp. neprítomnosti daného typu hemoragie v danom reze. Po spracovaní piatimi klasifikátormi na výstupe je tak pre daný patologický rez známe, aké hemoragie sú v ňom zobrazené. Pokiaľ daný 2D rez prvým klasifikátorom nie je označený ako patologický, nevstupuje do bloku určenia typu hemoragie. Princíp klasifikácie hemoragií sériou klasifikátorov pre jednu anatomickú rovinu je ilustrovaný na Obr. 6.6 Keďže blok piatich binárnych klasifikátorov typu nadväzuje na klasifikátor prítomnosti patológie v axiálnom, sagitálnom i koronárnom smere, typ ložiska je postupne určovaný označovaním 2D rezov súčasne s lokalizáciou hemoragie.



Obr. 6.6: Bloková schéma podsystemu klasifikácie hemoragií v jednej anatomickej rovine.

7 Realizácia detekcie hemoragií

Navrhnutým riešením detekcie hemoragií je vytvorenie systému binárnych klasifikátorov CT rezov v troch anatomických rovinách, ktoré sú založené na metódach strojového učenia s využitím CNN. Táto kapitola popisuje konkrétnu realizáciu jednotlivých blokov navrhutej metódy. Uvedená je realizácia klasifikátorov prítomnosti hemoragie pre lokalizáciu (viď sekcia 7.4), a ďalej klasifikátorov typov hemoragií (viď sekcia 7.5) v axiálnej, sagitálnej a koronárnej rovine. Algoritmy sú implementované v programovacom prostredí Matlab R2019b. Výpočty sú realizované na grafickej karte NVIDIA GeForce GTX1060 (6 GB). Program detekcie vyžaduje 3,5 GB RAM a výpočty trvajú rádovo v jednotkách minút. Všetky natrénované klasifikačné siete a ukázková verzia programu¹ sú voľne dostupné na stiahnutie².

7.1 Experimentálne dáta

Pre účely práce je využitá verejne dostupná databáza CT snímok hlavy CQ500 (viď kap. 4), ktorá zahŕňa i anotácie vo forme patientskej diagnózy. Použité sú iba bezkontrastné CT skeny [50, 52, 53, 54], ktoré buď zobrazujú hemoragiu (môže byť v kombinácii s inou diagnózou), alebo danému jedincovi nie je diagnostikovaná žiadna patológia. Keďže pôvodná databáza obsahuje anotácie od troch nezávislých rádiológov, v prípade nezhody na diagnóze je vždy pre daný sken uvažovaná väčšinová voľba podľa autorov [50].


7.1.1 Manuálna anotácia dát

Súčasťou dostupnej databázy sú iba anotácie vo forme patientskej diagnózy pre CT skeny, a preto bolo nutné urobiť manuálne expertné označenie prítomnosti i typu hemoragie v jednotlivých rezoch pre všetky tri roviny (axiálnu, sagitálnu a koronárnu). Pre zobrazovanie CT skenov za účelom následného označenia rezov je použitý softvér ImageJ [56].

Forma vlastnej anotácie pre daný 3D sken pre každú rovinu pozorovania je daná počiatočným a koncovým indexom rezu, medzi ktorými leží daná hemoragia. Z 3D kontextu je vlastná anotácia 3D pravouhlou ohraničujúcou oblasťou začínajúcou a končiacou vo vyznačených hraničných indexoch pre každý smer (viď Obr. 7.1). V danom smere sú tieto indexy hraníc určené pre všetky typy hemoragií. Treba

¹Jedná sa o skript s názvom demo.m

²<https://drive.google.com/file/d/1GX26DTCNxffghkkzup8Wr4D1qMe1V1am/view?usp=sharing>




Obr. 7.1: Zobrazenie patologických rezov a príslušných anotovaných ohraničujúcich oblastí umiestnenia hemoragie.

poznamenať, že niektoré rezy zobrazujú niekoľko typov hemoragií súčasne. V niektorých prípadoch hranice hemoragií nie sú jednoznačné. Počiatočný a koncový rez typu hemoragie je v danej rovine určený tak, že patológia je ešte zreteľná i pre nelekárskeho experta. Príklad hraničného axiálneho rezu je zobrazený na Obr. 7.2. Celkovo je pre axiálnu, sagitálnu resp. koronárnu rovinu označených viac ako 9 tis., 15 tis., resp. 22 tis. rezov.

7.2 Realizácia predspracovania

Rotačné zarovnanie 3D CT snímky hlavy je realizované iteratívnym algoritmom publikovaným v [55]. Uhly optimálnej axiálnej a koronárnej rotácie sú hľadané na základe detekcie a párovania mediánne symetrických príznakových bodov. Sagitálny uhol je určený regresnou konvolučnou neurónovou sieťou. [55]

Z jednotlivých 2D rezov sú vytvorené vektorové obrazy s tromi kanálmi vyprahovaním hodnôt pod spodným resp. nad vrchným prahom podľa jednotlivých



Obr. 7.2: Ukážka 3 rezov CT snímky pacienta. Naľavo: volený hraničný rez; v strede: rez bez určenia prítomnosti hemoragie; napravo: hemorragický rez medzi hranicami.

rádiologických okien. Prahy pre jednotlivé okná sú:

- 0 HU resp. 80 HU pre mozgové okno,
- 150 HU resp. 200 HU pre subdurálne okno,
- -1000 HU resp. 2000 HU pre kostné okno,

podľa [50]. Zvyšné hodnoty sú transformované na celú škálu šedotónových hodnôt (od -1024 HU po 3072 HU) podľa [53].

7.3 Použitá architektúra

Základom jednotlivých klasifikátorov navrhnutého systému je CNN architektúra Inception-ResNet-v2 [40] (viď sekcia 3.1.1). Architektúra je zvolená empiricky a na základe kvalitných klasifikačných výsledkov podľa jej tvorcov. Sieť podľa [57] patrí medzi najlepšie spomedzi sietí s pamäťovou náročnosťou do 1 GB pre klasifikáciu obrazov v reálnom čase. Jedná sa o 164 vrstiev hlbokú sieť, ktorá má na výstupe úplne prepojenú vrstvu s jedným tisícom neurónov a je teda schopná klasifikovať do 1 000 kategórií. Vstupom je obraz o veľkosti $299 \times 299 \times 3$. Vstupný obraz je spracovaný sériou inceptných a reziduálnych blokov. Príznaková mapa z posledného reziduálneho inceptného bloku je upravená v priemerovacej podvzorkovacej vrstve. Do úplne prepojenej vrstvy vstupuje príznaková mapa o rozmere $1 \times 1 \times 1536$. [40] [58]

Pre našu metódu je použitá predtrénovaná sieť naučená na databáze ImageNet (viď sekcia 2.2.2). Keďže všetky navrhnuté klasifikátory rozlišujú iba dve triedy, posledná úplne prepojená vrstva pôvodnej architektúry je nahradená dvojneurónovou úplne prepojenou vrstvou so „softmax“ aktivačnou funkciou. Váhy neurónov sú inicializované Glorotovou metódou [59] a prahey sú nulové.

7.4 Klasifikácia prítomnosti hemoragie

Riešením problému lokalizácie hemoragie je vytvorenie troch binárnych klasifikátorov prítomnosti resp. neprítomnosti hemoragie v 2D reze v axiálnej, sagitálnej a koronárnej rovine. Klasifikácia rezov v každom smere je realizovaná klasifikačnými CNN s architektúrou popísanou v predchádzajúcej sekcii, ktoré sú pre naše účely dotréňované na vytvorenej trénovacej databáze. Je teda nutné doučiť tri klasifikačné siete, každú pre klasifikáciu rezov z jednej anatomickej roviny.

Vstupom naučenej klasifikačnej siete pre danú rovinu je predspracovaný rez CT skenu v danom smere. Vďaka „softmax“ aktivačnej funkcii poslednej úplne prepojenej vrstvy je výstupom siete pravdepodobnosť príslušnosti obrazu do kategórie *Patologický* a *Zdravý*, pričom pri klasifikácii je využitá i informácia o susedných rezoch.

7.4.1 Vytvorenie trénovacej a testovacej databázy

Pre učenie a validáciu troch klasifikačných sietí sú vytvorené vzájomne disjunktné množiny CT skenov jedincov. Zo všetkých 3D skenov obsahujúcich aspoň jeden typ hemoragie je náhodne zvolených 70 % (teda celkom 135 CT obrazov), ktoré sú určené na tréňovanie. Zvyšné skeny (59 CT obrazov) sú určené na testovanie. Z rozdelených 3D obrazov sú vytvárané pozitívne trénovacie a testovacie databázy 2D rezov pre axiálny, sagitálny a koronárny smer tak, že sú vybrané všetky rezy v danom smere, ktoré sú označené ako patologické. Používané dáta sú podrobené predspracovaniu. Tie rezy, ktoré nie sú označené ako patologické, v ďalších krokoch metódy využívané nie sú, keďže je pripustená možnosť falošne negatívneho označenia daného rezu nelekárskym expertom.

Tab. 7.1: Tabuľka celkového počtu 2D rezov v databázach a relatívneho zastúpenia pozitívnych (s hemoragiou) a negatívnych (bez hemoragie) CT rezov v trénovacej a testovacej databáze v troch rovinách.

	Trénovacie		Testovacie		Celkovo
	Pozitívne	Negatívne	Pozitívne	Negatívne	
Axiálne	13 %	57 %	5 %	25 %	7 788
Sagitálne	10 %	61 %	3 %	26 %	9 893
Koronárne	13 %	57 %	5 %	25 %	10 550

Negatívne databázy, teda databázy skenov bez hemoragického nálezu, sú vytvárané obdobne vyčlenením 70 % dostupných CT skenov bez diagnózy na tréňovanie (teda 154), a zvyšných 30 % na testovanie (teda 67). Do jednotlivých trénovacích

a testovacích databáz 2D rezov pre axiálny, sagitálny a koronárny smer sú v tomto prípade volené všetky rezy CT skenu v danom smere. Tie sú následne predspracované. Celkové počty pozitívnych a negatívnych tréningových resp. testovacích 2D obrazov pre jednotlivé roviny spolu s relatívnym zastúpením pozitívnych a negatívnych dát sú uvedené v Tab. 7.1.

7.4.2 Učenie sietí

V rámci tréningovania sietí je pre každú rovinu vytvorená tréningová databáza pozostávajúca z predspracovaných rezov. Keďže pre všetky tri klasifikátory je použitá predučená sieť, je nutné natréňovať predovšetkým novo inicializovanú úplne prepojenú vrstvu. Z toho dôvodu je zvýšená rýchlosť učenia parametrov tejto vrstvy na desaťnásobok oproti ďalším vrstvám. Zvolenou chybovou funkciou (viď sekcia 2.1.3) je váhovaná vzájomná entropia:

$$E(\mathbf{w}) = -\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K w_k t_{nk} \ln(y_{nk}), \quad (7.1)$$

kde N je počet vzoriek, K je počet tried, t_{nk} je indikátor, že n -tá vzorka patrí do k -tej triedy, y_{nk} je výstupná pravdepodobnosť príslušnosti n -tej vzorky do k -tej triedy a w_k je váha k -tej triedy. [60] Pokiaľ je v tréningovej databáze N_{pos} pozitívnych obrazov a N_{neg} negatívnych obrazov, váha triedy *Patologický* resp. *Zdravý* je daná ako $\frac{N_{neg}}{N_{pos}+N_{neg}}$ resp. $\frac{N_{pos}}{N_{pos}+N_{neg}}$. Ako algoritmus učenia je použitá metóda ADAM (viď sekcia 2.1.3) s variantou pre „mini-batch“. Podľa odporúčaní v [29] volíme hyperparameter exponenciálneho zabúdania starých momentov prvého rádu resp. druhého rádu ako $\beta_1 = 0,9$ resp. $\beta_2 = 0,999$. Inicializačná rýchlosť učenia α je nastavená na $0,0001$, a ďalej $\epsilon = 10^{-8}$. Aby sa zredukovalo preučovanie sietí pri tréningovaní, využité je L_2 regularizácia. Regularizovaná chybová funkcia je potom:

$$E_R(\mathbf{w}) = E(\mathbf{w}) + \lambda \left(\frac{1}{2} \mathbf{w}^T \mathbf{w} \right), \quad (7.2)$$

kde $E(\mathbf{w})$ je chybová funkcia, \mathbf{w} je vektor váh a λ je tzv. regularizačný faktor. [18] [61] Nastavenie regularizačného faktora a ďalších tréningových parametrov pre dotréningovanie sietí pre axiálnu, sagitálnu a koronárnu rovinu je uvedené v Tab. 7.2.

Dáta z tréningových databáz sú náhodne premiešané pred každou epochou a využívaná je tiež „online“ augmentácia. V každej epoche môže prebehnúť náhodná translácia, rotácia a škálovanie. Obrazy môžu byť posunuté v oboch smeroch maximálne o -12 až 12 pixelov, pričom pre každý smer je posun volený náhodne. Hranice náhodnej rotácie sú -10° až 10° a hranice škálovania sú $0,8 - 1,2$, pričom pre oba smery je vždy škálovací faktor rovnaký. V prípade axiálneho a koronárneho smeru môžu byť dáta v každej epoche upravené i náhodnou horizontálnou reflexiou s pravdepodobnosťou 50% .

Tab. 7.2: Tabuľka tréningových parametrov klasifikátorov prítomnosti hemoragie v troch rovinách CT obrazu.

	Axiálna	Sagitálna	Koronárna
Mini-Batch	20	24	27
Epochy	7	8	8
L2 reg. faktor	0,001	0,0005	0,0005

7.4.3 Klasifikácia CT rezu

Klasifikačné siete sú tréňované tak, aby boli schopné určiť pravdepodobnosti príslušnosti 2D rezov CT skenu ku daným triedam. Namiesto jednoduchého určenia triedy iba na základe predikcie siete je zvolený prístup, ktorý do určitej miery uvažuje 3D kontext a redukuje tým falošné výsledky. V [54] autori publikujú metódu interpolácie rezov, vďaka ktorej integrujú informáciu z po sebe idúcich rezov CT objemu. Tým je napodobnené hodnotenie rádiológa, ktorý nehodnotí izolované 2D rezy ale uvažuje objemovú informáciu. Interpolované obrazy zo susedných rezov sú spracované sieťou už počas učenia vďaka modifikovanej chybovej funkcii. Realizácia klasifikácie 2D rezov v našom algoritme je do určitej miery inšpirovaná touto publikáciou, avšak informácia zo susedných rezov je zakomponovaná až na úrovni vybavovania sietí.

Pri spracovaní rezu v danom smere je volených N susedných rezov z oboch strán. V rámci optimalizácie sú testované varianty $N \in \{1, 2, 3, 4\}$. Pravdepodobnosť príslušnosti aktuálne spracovaného rezu do kategórie *Patologický* je daná výstupnou pravdepodobnosťou klasifikačnej neurónovej siete. Danou sieťou sú určené i pravdepodobnosti pre N susedných rezov z každej strany, avšak tie sú upravené na skóre n -tého susedného rezu S_n podľa:

$$S_n = \beta_n P^a + (1 - \beta_n) P_n^s, \quad (7.3)$$

kde P^a resp. P_n^s je pravdepodobnosť príslušnosti aktuálneho resp. n -tého susedného rezu do kategórie *Patologický* podľa klasifikačnej siete a β_n je váha určujúca vplyv aktuálneho rezu. Takýmto spôsobom je vypočítané skóre pre všetkých N susedných rezov. Čiastkovým skóre S_0 pre aktuálny rez je pravdepodobnosť P^a . Výsledné skóre S pre aktuálny rez, ktoré určuje finálny výsledok klasifikácie, je určené spriemerovaním všetkých skóre susedných rezov spolu s čiastkovým skóre aktuálneho rezu, teda:

$$S = \frac{1}{2N + 1} \sum_{n=-N}^N S_n. \quad (7.4)$$

Toto skóre určuje finálnu klasifikáciu tak, že pokiaľ platí $S \geq T$, tak výsledná trieda pre daný rez je *Patologický*, inak je rez určený ako *Zdravý*, pričom parameter T je

prah. Váhy vplyvu pravdepodobnosti aktuálneho rezu β_n sú určené pre $N = 1, \dots, 4$ postupne pre susedné rezy od najbližšieho po najvzdialenejší ako:

- $\beta_n \in \{0, 67\}$,
- $\beta_n \in \{0, 80; 0, 60\}$,
- $\beta_n \in \{0, 86; 0, 72; 0, 58\}$,
- $\beta_n \in \{0, 89; 0, 78; 0, 6; 0, 56\}$,

podľa [54]. V prípade, že sú spracované okrajové rezy CT skenu, priemerované sú iba tie skóre, ktoré je možné určiť predikciou pravdepodobnosti susedných rezov. Takýmto spôsobom sú klasifikované rezy v axiálnom, sagitálnom a koronárnom smere, pričom v každom smere je využitá príslušná klasifikačná sieť.

7.5 Klasifikácia typu hemoragie

Navrhnutým riešením určenia typu hemoragického ložiska je zaradenie série piatich binárnych klasifikátorov založených na CNN zvlášť pre každú pracovnú anatomickú rovinu, ktoré identifikujú prítomnosť jednotlivých typov v danom CT reze. Klasifikácia typov hemoragie prebehne iba v prípade, že daný rez je zaradený ako hemoragický. Každý klasifikátor jednotlivých typov je realizovaný ako predučená CNN s architektúrou popísanou v kapitole 7.3.

Vstupom každej klasifikačnej siete je predspracovaný CT rez v danej rovine, ktorý je zaradený ako hemoragický. Vďaka „softmax“ aktivačnej funkcii úplne prepojenej vrstvy je výstupom pravdepodobnosť príslušnosti rezu do dvoch tried: prítomnosť resp. neprítomnosť daného typu, teda napríklad v prípade klasifikátora typu IPH sa jedná o pravdepodobnosť prítomnosti resp. neprítomnosti intraparenchymálnej hemoragie v danom reze. Keďže pre každú anatomickú rovinu je potreba piatich klasifikačných sietí, celkovo je nutné natréňovať pätnásť modelov. Definitívne výstupné rozhodnutie jedného klasifikátora prítomnosti daného typu hemoragie v CT reze je potom výsledkom integrácie výstupnej informácie z CNN pre niekoľko susedných rezov, podobne ako pri určovaní prítomnosti hemoragie.

Pri navrhnutom prístupe dotréňovania CNN pre klasifikáciu jednotlivých typov hemoragií nie je postupované učením resp. testovaním na tréningovej resp. testovacej databáze ako v prípade určovania typu hemoragie. Dôvodom je skutočnosť, že počty patientskych skenov s jedným typom sú oveľa menšie ako v prípade kombinácie akýchkoľvek typov hemoragie (viď Tab. 4.1). Využitá je preto k-násobná krížová validácia, ktorá dokáže lepšie validovať schopnosť siete klasifikovať jednotlivé rezy.

7.5.1 Príprava dát

V prípade klasifikácie typu hemoragie sú využívané iba CT skeny jedincov s intrakraniálnou hemoragiou, z ktorých sú po predspracovaní vytvorené datasety 2D rezov. Pre každú z anatomických rovín je vytvorených desať databáz, z ktorých päť je pozitívnych v zmysle obsahu rezov s daným typom hemoragie (IPH, IVH, SDH, EDH a SAH) a zvyšných päť je negatívnych v zmysle obsahu rezov s akýmkoľvek iným typom okrem daného jedného (napr. dataset bez IPH obsahuje rezy s IVH, SDH, EDH a SAH). Pozitívne databázy obsahujú všetky rezy s daným typom, avšak môžu zobrazovať kombináciu s ďalšími typmi. Rovnako v negatívnych databázach nie sú výlučne rezy s jedným typom hemoragie. Pozitívna a negatívna databáza pre daný typ hemoragie sú vzájomne disjunktné už na úrovni CT skenov jedincov. Takto je vytvorených desať databáz 2D rezov axiálnej, sagitálnej a koronárnej roviny. Počty obrazov v jednotlivých databázach sú uvedené prílohe A v Tab. A.2

7.5.2 Krížová validácia

Pre určenie typu hemoragie v reze danej anatomickej roviny je potrebné naučiť päť klasifikačných sietí tak, aby každá bola schopná predikovať pravdepodobnosť prítomnosti resp. neprítomnosti daného typu hemoragie v hemoragickom reze. Pre tri anatomické roviny je celkovo dotrénovaných pätnásť modelov. Keďže súčasťou práce je i validácia navrhutej metódy, z dôvodu menšieho počtu pozitívnych dát pre binárne klasifikátory je zvolená metóda k -násobnej krížovej validácie, pričom volíme $k = 5$.

Pre účely krížovej validácie jednej klasifikačnej siete (napr. typu IPH) pracujeme s príslušným pozitívnym datasetom s CT rezmi zobrazujúcimi daný typ a odpovedajúcim negatívnym datasetom, ktorý zobrazuje všetky obrazy s ostatnými typmi (teda v tomto prípade IVH, SDH, EDH a SAH). V predošlej sekcii je popísané vytvorenie datasetov s 2D rezmi. Aby siete pri validácii neboli trénované a testované na rôznych rezoch od rovnakého pacienta, náhodné rozdelenie datasetov je potrebné urobiť na úrovni patientskych skenov. Po rozdelení 2D obrazov podľa pred tým urobeného rozdelenia CT skenov prebieha samotný proces krížovej validácie, a to pre všetky klasifikačné siete typu hemoragie v každom smere. Finálna klasifikácia typu hemoragie v reze danými klasifikátormi je realizovaná integráciou informácie o výstupnej pravdepodobnosti výskytu daného typu v aktuálnom, i susedných rezoch podobne ako u klasifikácie prítomnosti hemoragie (viď sekcia 7.4.3).

7.5.3 Učenie sietí

V jednotlivých redučených sieťach je potrebné natréňovať klasifikačnú úplne prepojenú vrstvu a preto je rýchlosť jej učenia zvýšená na desiatnásobok. Výrazne nevyrovnané pozitívne a negatívne datasety (viď Tab. A.2) vedú k použitiu váhovanej vzájomnej entropii (rovnica 7.1) ako chybovej funkcie. Podobne, ako v prípade klasifikácie prítomnosti hemoragie, je použitá metóda ADAM ako algoritmus učenia, pričom je zvolené rovnaké nastavenie parametrov (viď sekcia 7.4.2), a ďalej je využitá i L2 regularizácia (viď rovnica 7.2).

Váhy tried daného typu resp. iného typu hemoragie u váhovanej krížovej entropii sú vo väčšine prípadov určené ako $\frac{N_{neg}}{N_{pos}+N_{neg}}$ resp. $\frac{N_{pos}}{N_{pos}+N_{neg}}$. V niektorých prípadoch v axiálnom smere je váha daného typu hemoragie zvýšená. U klasifikátora IPH, IVH resp. EDH sú váhy triedy daného typu 0,91, 0,95 resp. 0,93. Váha triedy iného typu u týchto binárnych klasifikačných sietí je vždy doplnok do 1. Pri tréňovaní je veľkosť „mini-batchu“ nastavená na 24, počet epôch je 8 a L2-regularizačný faktor $\lambda = 0,0005$.

Pri tréňovaní sú 2D obrázky v tréňovacej databáze náhodne premiešané pred každou epochou a používaná je „online“ augmentácia. Obrázky sú augmentované rovnakým spôsobom, ako v prípade klasifikácie prítomnosti hemoragie (viď sekcia 7.4.2).

8 Výsledky a diskusia

Validácia kvality funkčnosti algoritmu je založená na ohodnotení výsledkov testovania klasifikátorov prítomnosti a typu hemoragie v jednotlivých anatomických rovinách.

8.1 Miery kvantitatívneho vyhodnotenia výsledkov

Pre objektívne kvantitatívne ohodnotenie výsledkov série binárnych klasifikátorov 2D rezov sú použité tri miery: senzitivita, špecificita a Dice koeficient. Pri testovaní klasifikátora sú zaznamenané počty správne pozitívnych (TP, z angl. „true positive”), falošne pozitívnych (FP, z angl. „false positive”), správne negatívnych (TN, „true negative”) a falošne negatívnych (FN, „false negative”) výsledkov klasifikácie.

Senzitivita je definovaná ako:

$$Se = \frac{TP}{TP + FN} \times 100\% \quad (8.1)$$

a vypovedá o schopnosti klasifikátora správne zaradiť daný rez ako hemoragický. Inými slovami sa jedná o pravdepodobnosť pozitívneho výsledku, pokiaľ je rez patologický. Špecificita je potom určená ako:

$$Sp = \frac{TN}{TN + FP} \times 100\% \quad (8.2)$$

a poukazuje na schopnosť klasifikátora správne rozoznať negatívny rez. Vypovedá o pravdepodobnosti negatívneho výsledku v prípade absencie patológie v reze. [62] Dice koeficient [63] (niekedy uvádzaný i ako F1 skóre) môže byť vypočítaný ako:

$$DC = \frac{2TP}{2TP + FP + FN} \times 100\%. \quad (8.3)$$

[64]

8.2 Výsledky klasifikácie prítomnosti hemoragie


Testovanie troch klasifikátorov prítomnosti hemoragií, ktoré sú popísané v kapitole 7.4, prebieha na axiálnych, sagitálnych a koronárnych rezoch zo 67 zdravých a 59 patologických CT skenov. Príprava testovacej databázy, ktorá je disjunktná s tréningovou databázou už na úrovni patientskych skenov, je podrobne popísaná v sekcii 7.4.1.

Prah skóre pri testovaní je zvolený ako $T = 0,5$. Pre každú anatomickú rovinu je zvolené iné optimálne nastavenie počtu uvažovaných susedných rezov z oboch strán

N . Pre klasifikátor prítomnosti hemoragie v axiálnej a sagitálnej rovine je nastavené: $N = 2$. Pre koronárnu rovinu je tento parameter nastavený ako $N = 1$. Kvantitatívne ohodnotenie výsledkov testovania na testovacej databáze v podobe uvedenia senzitivity, špecificity a Dice koeficientu pre všetky tri klasifikátory založené na do-trénovaných CNN je uvedené v Tab. 8.1.

Tab. 8.1: Tabuľka výsledkov testovania klasifikátorov prítomnosti hemoragie v CT rezoch v troch rovinách a priemerné hodnoty výsledkov cez všetky roviny.

	Axiálna	Sagitálna	Koronárna	Priemerne
Se [%]	87,4	86,6	83,5	85,8
Sp [%]	97,8	96,8	95,3	96,6
DC [%]	88,1	80,9	80,5	83,2




Obr. 8.1: Ukážka axiálnych rezov správne klasifikovaných ako patologické. a) Okraj IPH s drobným, ťažko rozpoznateľným ložiskom; b) SAH; c) kombinácia SAH a SDH; d) kombinácia IPH, IVH, SAH; e) okraj SDH, ktorý je ťažko rozpoznateľný človekom; f) IPH; g) SAH; h) chronická SDH. Pozn.: Šípka ukazuje ložisko v prípade ťažšie viditeľných hemoragií.

8.2.1 Diskusia výsledkov

Testovanie troch klasifikátorov prítomnosti hemoragie pre jednotlivé anatomické roviny prebieha na nevyrovnaných datasetoch, čo sa týka pomeru počtu pozitívnych a negatívnych rezov (viď Tab. 7.1). Dôvodom je že hemoragia sa rozprestiera iba na

časti rezov patologického CT skenu, zatiaľ čo do negatívnych datasetov sú zaradené všetky rezy nepatologických 3D obrazov. Počet pozitívnych rezov, ktorý z hľadiska výsledkov odpovedá súčtu TP + FN je oveľa nižší, ako súčet TN + FP (teda počet negatívnych rezov), z čoho vyplýva, že falošne negatívny výsledok sa odzrkadlí na poklese senzitivity omnoho viac, ako falošne pozitívny výsledok na špecificite. Hodnoty Se a Dice koeficient nie sú skreslené vysokým počtom správne negatívnych výsledkov.




Obr. 8.2: Ukážka správne klasifikovaných sagitálnych a koronárnych patologických rezov, ktoré môžu byť ťažko rozpoznateľné človekom kvôli zobrazeniu okraju hemoragie alebo malého ložiska. a) Sagitálny rez okraju hlavy so SDH, ktorá zaberá v obraze celú oblasť ohraničenú lebkou; b) sagitálny rez zobrazujúci ťažko rozlíšiteľný okraj SDH; c) sagitálny rez zobrazujúci okraj SAH; d) koronárny rez zobrazujúci SDH pozdĺž veľkej srpovitej riasy a listu tvrdej plény; e) koronárny rez zobrazujúci okraj SDH. Pozn.: Šípka ukazuje ložisko hemoragie.

Najlepšie výsledky dosahuje klasifikátor prítomnosti hemoragie v axiálnych CT rezoch, kde je hemoragia najjednoduchšie rozpoznateľná i pre ľudského pozorovateľa. Pre všetky tri roviny platí, že špecificita je značne vyššia ako senzitivita. Pomerne vysoké hodnoty senzitivity a Dice koeficientu však vypovedajú o schopnosti algoritmu vo väčšine prípadov spoľahlivo rozpoznať hemoragické ložisko v reze. Na Obr. 8.1 možno demonštrovať schopnosť klasifikátora rozpoznať hemoragický rez i napriek veľkej rozmanitosti veľkostí a tvarov ložisiek.

Na Obr. 8.1 *a* a *e* možno poukázať na schopnosť klasifikátora zaradiť patologický rez do správnej kategórie i napriek nie ľahko rozpoznateľným ložiskám. Na Obr. 8.2 možno poukázať na dobrú rozlišovaciu schopnosť klasifikátorov v sagitálnej resp. koronárnej rovine.


V prípade niektorých rezov dochádzalo k falošne negatívnym výsledkom klasifikácie prítomnosti hemoragie. Veľkú časť tvorili rezy zobrazujúce drobnú hemoragiu,



Obr. 8.3: Ukážka falošne negatívne klasifikovaných rezov v axiálnej, sagitálnej a koronárnej rovine. a) Axiálny rez s okrajom SDH ťažko rozpoznateľnej od lebky; b) axiálny rez s okrajom IPH; c) axiálny rez so SDH; d) sagitálny rez so SDH ťažko rozpoznateľnej od lebky; e) SAH; f) koronárny rez zobrazujúci okraj IPH; g) koronárny rez so SAH. Pozn.: Šípka ukazuje ložisko.

alebo okraj ložiska (viď Obr. 8.3). U okrajových rezov môže byť jednou z príčin vplyv okolitých nepatologických rezov na výsledné skóre. Niektoré z drobných hemoragií je však problematické rozpoznať i človekom a nejasnosť môže mať vplyv na nižšiu výstupnú pravdepodobnosť príslušnosti do patologickej triedy po klasifikácii pomocou CNN. U niektorých CT skenov dochádza k falošne negatívnym klasifikáciám rezov vo všetkých troch rovinách čoho príčinou môže byť odlišnosť dát od obrazov v tréningovej databáze. Ojedinelé nesprávne klasifikácie vznikajú u rezov so SAH v sagitálnej a koronárnej rovine, kde je tento typ hemoragie náročne rozpoznateľný (viď 8.3 *e, g*).

U klasifikátorov vo všetkých troch rovinách môže dôjsť k falošne pozitívnym výsledkom klasifikácie u rezov, ktoré sa môžu javiť ako hemoragické i ľudskému pozorovateľovi (viď Obr. 8.4 *c, d, f*). Klasifikátor v axiálnej a sagitálnej rovine v ojedinelých prípadoch určuje ako patologické také rezy, ktoré zobrazujú okraj hlavy



Obr. 8.4: Ukážka falošne pozitívne klasifikovaných nepatologických rezov v axiálnej, sagitálnej a koronárnej rovine. a) Axiálny rez zobrazujúci okraj hlavy; b) skreslený axiálny rez; c) axiálny rez, v ktorom oblasti s vyšším jasom môžu pripomínať SAH alebo drobnú IPH; d) koronárny rez, v ktorom oblasť s vyšším jasom pripomína IPH; e) koronárny rez s výrazne pozorovateľnou veľkou srpovitou riasou a listom tvrdej plény; f) sagitálny rez ktorý sa môže javiť ako patologický s tenkou SDH pod lebečnou klenbou; g) sagitálny rez zobrazujúci okraj hlavy.

(viď Obr. 8.4 a, g). Tento jav pravdepodobne nastáva z dôvodu, že sieť môže na výstupe predikovať vyššiu pravdepodobnosť príslušnosti do patologickej triedy kvôli častej prítomnosti SDH a EDH pri lebke v takýchto okrajových rezoch v trénovacej databáze. Klasifikátor v koronárnej rovine v určitých prípadoch klasifikuje ako patologické rezy s výrazne pozorovateľnými štruktúrami veľká srpovitá riasa („*falx cerebri*“) a list tvrdej plény („*tentorium cerebelli*“) (viď Obr. 8.4 e). Príčinou môže byť charakteristické zobrazenie s vyšším jasom oproti okolitým štruktúram, ktoré sa môže podobáť na výskyt SDH v týchto miestach. Ako však vypovedajú hodnoty špecificity pre všetky tri klasifikátory, falošne pozitívne klasifikácie sú menšinové oproti správnym určeniam triedy.

8.3 Výsledky klasifikácie typu hemoragie

Testovanie pätnástich klasifikátorov typu hemoragie (päť pre každú anatomickú rovinu) je nezávislé na testovaní prítomnosti hemoragie, i keď tento krok v navrhnutom algoritme nasleduje po označení rezu ako hemoragického. Cieľom je zistiť kvalitu funkčnosti jednotlivých klasifikátorov bez toho, aby bola skreslená prípadnou chybou v predchádzajúcom kroku. Pre krížovú validáciu klasifikátora každého typu v jednotlivých anatomických rovinách sú vytvorené samostatné databázy 2D rezov (viď sekcia 7.5.1).

Pre samotný proces krížovej validácie (viď sekcia 7.5.2) je použité nastavenie prahu skóre príslušnosti do pozitívnej triedy $T = 0,5$. Optimálny počet susedných rezov, ktoré sú brané do úvahy je $N = 1$ v axiálnom smere pre klasifikátor IPH a IVH, a potom v sagitálnom smere pre klasifikátory IPH, SDH, EDH a SAH. Pre zvyšné klasifikátory v týchto rovinách, a ďalej pre všetky v koronárnej rovine je zvolené nastavenie $N = 2$.


Trénovanie a testovanie klasifikátorov v jednotlivých iteráciách krížovej validácie prebieha na nevyrovnanom pomere počtu pozitívnych a negatívnych rezov, čo môže byť zrejmé z počtu dát v jednotlivých databázach (viď príloha A, Tab. A.2). Je však nutné podotknúť, že počty dát v použítom datasete s jednotlivými typmi hemoragií sa výrazne líšia (viď Tab. 4.1). Keby je pri hodnotení postupované ako u klasifikácie prítomnosti hemoragie (vytvorenie jedného trénovacieho a testovacieho datasetu), veľký vplyv na výsledky by malo samotné rozdelenie dát z dôvodu výrazne nižšieho počtu dostupných CT skenov pre jednotlivé klasifikátory. Tento problém je riešený použitím krížovej validácie. Je však potrebné poznamenať, že samotné náhodné rozdelenie dát do častí pre krížovú validáciu, ktoré prebieha na úrovni patientskych skenov, môže viesť k nevyrovnanému rozloženiu dát v trénovacích a testovacích databázach v jednotlivých iteráciách krížovej validácie. Tieto odlišnosti sú zapríčinené rozličným počtom 2D rezov zobrazujúcich danú hemoragiu u rôznych pacientov a prejaviť sa môžu predovšetkým v častiach pozitívnych datasetov u typov hemoragií, ktorých zastúpenie je nízke (napr. 13 CT skenov s EDH). Snaha do istej miery preklenúť tento problém spočíva v kumulácii počtov TP, FP, TN a FN počas jednotlivých iterácií krížovej validácie klasifikátora, a následnom výpočte mier kvantitatívneho ohodnotenia z kumulovaných počtov, namiesto priemerovania mier z jednotlivých iterácií. Priemerné hodnoty Se, Sp a DC pre klasifikáciu jednotlivých typov resp. pre tri roviny sú vypísané v Tab. 8.2 resp. Tab. 8.3. Hodnoty senzitivity, špecificity a Dice koeficientu pre klasifikátory jednotlivých typov hemoragie v každej rovine sú potom uvedené v prílohe A (viď Tab. A.3).

Tab. 8.2: Tabuľka priemerných hodnôt Se, Sp a DC pre klasifikácie jednotlivých typov hemoragie. Pozn.: Priemer je počítaný z výsledkov v troch rovinách.

	IPH	IVH	SDH	EDH	SAH
Se [%]	76,4	76,8	63,6	43,8	72,0
Sp [%]	86,7	94,5	87,2	94,2	90,0
DC [%]	77,8	72,8	64,6	38,0	75,7

Tab. 8.3: Tabuľka priemerných hodnôt Se, Sp a DC pre klasifikáciu typu hemoragie v jednotlivých rovinách. Pozn.: Priemer je počítaný z výsledkov klasifikácie jednotlivých typov v danej rovine.

	Axiálna	Sagitálna	Koronárna
Se [%]	67,4	66,6	65,6
Sp [%]	92,5	88,1	91,1
DC [%]	68,2	62,6	66,5




Obr. 8.5: Ukážka falošne negatívnych výsledkov u klasifikácie typu hemoragie. a) Klasifikácia typu SAH; v axiálnom reze sa nachádza kombinácia IPH, SDH, SAH; b) Klasifikácia typu SAH; v axiálnom reze sa nachádza slabo viditeľná SAH v kombinácii s výraznejšou SDH; c) Klasifikácia typu IVH; rez zobrazuje kombináciu IVH a masívnej IPH; d) Klasifikácia typu SDH; sagitálny rez s tenkou SDH pri lebke; e) Klasifikácia typu SDH; sagitálny rez s hemoragiou SDH pozdĺž listu tvrdej plény.

8.3.1 Diskusia výsledkov

Pre správnu interpretáciu výsledkov sú hodnoty senzitivity ovplyvnené výskytom falošne negatívneho výsledku viac ako hodnoty špecificity v prípade falošne pozitívneho výsledku z dôvodu nevyrovnaných pomerov počtov pozitívnych a negatívnych

dát. Okrem toho, výsledky klasifikátorov rôznych typov hemoragií nie sú navzájom porovnateľné medzi sebou z dôvodu nevyrovnaného počtu dát s jednotlivými typmi hemoragie (napr. 134 CT skenov s IPH a 13 s EDH). Jeden zle klasifikovaný rez spôsobí podstatne výraznejší pokles miery ohodnotenia (predovšetkým Se a DC) u typov hemoragie s menším zastúpením v porovnaní s typmi s vysokým zastúpením. Špecifická nie je ovplyvnená až do tak vysokej miery z dôvodu vyššieho počtu negatívnych rezov.



Obr. 8.6: Ukážka falošne pozitívnych výsledkov u klasifikácie typu hemoragie. a) Klasifikácia typu IVH; axiálny rez so SAH; b) Klasifikácia typu SAH; axiálny rez s IPH; c) Klasifikácia typu IVH; axiálny rez s IPH na obvyklom mieste mozgových komôr; d) klasifikácia typu IPH; koronárny rez so SDH, ktorá má podobný tvar ako IPH; e) Klasifikácia typu SDH; axiálny rez s EDH; f) Klasifikácia typu SAH; sagitálny rez s drobnými IPH, ktoré sa podobajú na SAH.

Vo všeobecnosti možno konštatovať, že klasifikátory i napriek menším datasetom nadobúdajú pri učení pomerne dobrú generalizačnú schopnosť a dokážu vo väčšine prípadov správne rozpoznať daný typ hemoragie (a to i v prípadoch, keď sa v danom reze nachádza kombinácia hemoragií). Problematické sú klasifikátory EDH vo všetkých troch rovinách, ktoré majú problém spoľahlivo rozpoznať rezy s týmto typom hemoragie. Dôvodom je pravdepodobne skutočnosť, že v celej dostupnej databáze je iba 13 skenov s EDH, navyše často v kombinácii z ďalšími typmi. Klasifikačné siete majú problém zovšeobecniť klasifikačnú schopnosť na neznáme dáta kvôli vysokej variabilite možných pozícií a tvarov tohto typu hemoragie v reze.

Falošne negatívne výsledky (viď Obr. 8.5) sa vyskytujú v prípade drobných málo nápadných hemoragií alebo u rezov zobrazujúcich okraj hemoragie. Ďalšou z príčin vzniku falošne negatívneho výsledku je spoločný výskyt menšej hemoragie daného

typu s odlišnou masívnou hemoragiou v reze, ktorá pravdepodobne zapríčiňuje nižšiu výstupnú pravdepodobnosť príslušnosti k danému typu (viď Obr. 8.5 *a, b, c*). Táto skutočnosť vo veľkej miere vplýva na nízku senzitivitu a Dice koeficient u klasifikátorov SDH v sagitálnej a koronárnej rovine. Tento typ je v niektorých prípadoch problematické rozlíšiť i v okrajových rezoch hlavy (viď Obr. 8.5 *d*).

Falošne pozitívne výsledky sú pozorované u rezov zobrazujúcich hemoragie, ktoré sa často vyskytujú spoločne s hľadaným typom, čo je zapríčinené učením sietí na datasetoch rezov s kombináciami hemoragií (viď Obr. 8.6 *a, b*). Falošne pozitívne sú klasifikované taktiež také rezy, v ktorých sú tvar a pozícia hemoragie podobné tým, ktoré nadobúda hľadaný typ (viď Obr. 8.6 *c, d, e, f*). U typov SDH a EDH dochádza k vzájomným zámenám pri klasifikácii, čo môže byť odôvodnené skutočnosťou, že i pre ľudského pozorovateľa majú tieto typy podobné tvary a lokality, a to predovšetkým v rezoch sagitálnej a koronárnej roviny.

8.4 Diskusia nastavenia algoritmu

Pre správnu funkčnosť detekcie je hľadané optimálne nastavenie niekoľkých parametrov, ale i vhodná voľba krokov v algoritme. V tejto sekcii je diskutovaný vplyv rôznych premenných a krokov na funkčnosť algoritmu.

8.4.1 Predspracovanie dát

Rotačné zarovnanie 3D dát môže dopomôcť k dobrému natrénovaniu klasifikačných sietí. Zarovnanie zabezpečí, že rezy v axiálnej, sagitálnej a koronárnej rovine zobrazujú u rôznych pacientov v danej pozícii rovnaké štruktúry (s ohľadom na individuálnu odlišnosť pacientov), čo dopomôže sieti naučiť sa na abnormality v podobe hemoragie. Výhodou zarovnania je i strata nutnosti augmentácie trénovacej databázy v podobe rotácií 2D rezov o veľké uhly.

CT skeny v dostupnej databáze majú rozličné rozlíšenie. Úprava hrúbky rezov na približne 5 mm [50] vedie k zjednoteniu a dopomáha sieti k správne natrénovaniu. Tento krok tiež zabraňuje preučovaniu, ku ktorému dochádzalo pri použití rezov bez úpravy hrúbky pravdepodobne kvôli veľkej podobnosti susedných rezov pri vysokom rozlíšení. Použitie rôznych rádiologických okien pre jednotlivé vstupné kanály siete a transformácia kontrastu na celú škálu šedotónových hodnôt vychádzajú z publikovaných článkov [50, 53, 54] a viedli k zlepšeniu klasifikačných výsledkov dosahovaných sietami.

8.4.2 Voľba architektúry CNN

V rámci práce boli testované štyri klasifikačné architektúry CNN predtrénované na databáze ImageNet [35]: AlexNet, GoogLeNet, ResNet50 a Inception-ResNet-v2 (viď sekcia 3.1.1). Na základe dosahovaných výsledkov sa ukázalo, že optimálnou architektúrou pre riešenie našej problematiky je Inception-ResNet-v2, čo dokazuje i publikácia [40], v ktorej autori zmieňujú kvalitné výsledky pri klasifikačných úlohách.

8.4.3 Parametre tréovania sietí

Tradičná vzájomná entropia (viď rovnica 3.1) nie je vhodná chybová funkcia pre naše účely z dôvodu nevyrovnaných tréovacích databáz v zmysle rozličného počtu pozitívnych a negatívnych dát. Z tohto dôvodu je používaná váhovaná vzájomná entropia (viď rovnica 7.1), kde váha pozitívnych dát je navýšená zvyčajne úmerne pomeru pozitívnych a negatívnych dát (viď sekcia 7.4.2 a 7.5.2).

Optimalizačná metóda ADAM je zvolená na základe schopnosti preklenúť niektoré problémy vznikajúce pri optimalizácii (ako napr. únik z lokálneho minima, problém nastavenia kroku učenia), a ďalej dobrých výsledkov v porovnaní s inými optimalizačnými algoritmi. [29] Parametre optimalizačnej metódy sú zvolené podľa publikácie a osvedčili sa aj na základe urobených experimentov. Možné transformácie u „online“ augmentácie boli nastavené empiricky na základe dosahovaných výsledkov klasifikačných sietí rovnako ako parametre tréovania sietí. Kvôli predchádzaniu preučenia je použitá L_2 regularizácia a „batch“ normalizácia. Veľkosť použitého „mini-batchu“ je ohraničená zhora dostupnou pamäťou na grafickom procesore.

Parameter počtu častí databázy u krížovej validácie pri klasifikácii typu hemoragie k bol nastavený na hodnotu $k = 5$ po zvážení publikovanej literatúry [53] a kompromisu medzi robustnosťou výsledkov krížovej validácie a časovou náročnosťou procesu tréovania.

8.4.4 Parametre klasifikácie CT rezu

Klasifikácia CT rezu podľa skóre, ktoré je počítané z výstupných pravdepodobností príslušnosti spracovaného rezu a jeho susedov do danej kategórie, sa javí ako dobrý prístup z pohľadu dosahovaných výsledkov. V prípade určovania kategórie rezu iba podľa výstupnej pravdepodobnosti z klasifikačnej siete dochádzalo v niektorých prípadoch k menšinovým falošným výsledkom uprostred množstva správne klasifikovaných rezov. Problematické môžu byť hraničné rezy zobrazujúce napr. okraj hemoragie alebo drobnú hemoragiu nachádzajúcu sa iba v jednom reze, keďže rezy


odlišnej kategórie z ich susedstva znižujú výsledné skóre. Preto je veľkosť susedstva pre jednotlivé klasifikátory optimalizovaná vzhľadom na dosahované výsledky.

V rámci optimalizácie sú testované susedstvá o veľkosti jedného až štyroch rezov z oboch strán podľa [54]. Optimálna veľkosť susedstva pre klasifikáciu prítomnosti i typu hemoragie nie je väčšia ako dva rezy z každej strany (viď kapitola 8.2 resp. kapitola 8.3). Pri väčšom okolí zvyčajne počty falošne negatívnych výsledkov začali narastať (z dôvodu zníženia skóre na hraničných rezoch).

Nastavenie klasifikačného prahu skóre

Je zjavné, že výsledky binárnych klasifikátorov závisia na zvolenom klasifikačnom prahu skóre T . Pri znižovaní prahu narastá senzitivita kvôli znižovaniu počtu falošne negatívnych výsledkov, avšak klesá špecificita z dôvodu zvyšovania falošne pozitívnych klasifikácií. V algoritme je u všetkých klasifikátorov nastavený prah $T = 0,5$. Dôvodom je skutočnosť, že u dobre naučenej siete by takýto prah pre predikované pravdepodobnosti mal zabezpečiť dobré výsledky, a klasifikačné skóre vychádza z výstupných pravdepodobností.

Keďže sa jedná o kompromis medzi Se a Sp , vhodnosť nastaveného prahu závisí predovšetkým na preferenciách užívateľa. Pre klinické účely by mohol byť prah nastaviteľný manuálne hodnotiacim personálom (napr. posuvníkom v grafickom užívateľskom rozhraní). Ďalšia možnosť hľadania vhodného prahu môže vychádzať z analýzy ROC krivky (z angl. Receiver Operating Characteristic), teda z grafu závislosti senzitivity na hodnotách $1 - Sp$ pri rôzne nastavených prahoch. [65] Vhodný prah môže byť nastavený ako ten, pre ktorý je bod na ROC krivke najbližšie bodu $[0, 1]$. Príklad výsledkov dosiahnutých nastaveným prahom skóre podľa zmieneného postupu, a porovnanie s používaným prahom pre klasifikátor prítomnosti hemoragie v axiálnej rovine je zobrazený na Obr. 8.7. Prah skóre získaný takouto analýzou je podstatne nižší od používaného prahu $T = 0,5$. Je vidieť, že hodnota senzitivity narástla pri použití prahu získaného z analýzy ROC krivky, avšak špecificita klesla. Hodnoty Se , Sp a DC po použití prahu vychádzajúceho z ROC analýzy pre klasifikátory prítomnosti hemoragie v troch rovinách sú zobrazené v prílohe A (viď Tab. A.4). Takýto postup by mohol byť vhodný pre klinickú implementáciu algoritmu, keďže hlavnou motiváciou vývoja detekčného algoritmu pre klinickú prax je jeho senzitivita. [54]



Obr. 8.7: Ukážka ROC krivky klasifikátora prítomnosti hemoragie v axiálnych rezoch. Červený bod značí najbližší bod krivky k bodu $[0,1]$ a odpovedá prahu $T = 0,242$. Čierny bod odpovedá hodnotám Se a Sp pre používaný prah $T = 0,5$.

8.5 Diskusia možného využitia algoritmu v lekárskej diagnostike

Podporné diagnostické systémy (CAD systémy, z angl. „computer-aided diagnosis“) predstavujú aktuálnu oblasť záujmu výskumu v oblasti diagnostickej rádiológie a spracovania medicínskych obrazov. Tieto systémy slúžia ako zdroj komplementárnej informácie k uváženiu rádiológa. Rádiológ rozhoduje o diagnóze, ale pri utvorení finálneho úsudku mu môže dopomôcť výstup CAD systému. [66]

Ako je uvedené v Úvode, intrakraniálne hemoragie sú nebezpečným ochorením a vysoká dôležitosť sa pripisuje ich skorému odhaleniu. Algoritmus popísaný v tejto práci má vysoký potenciál pre podporné softvérové systémy vďaka pomerne dobrým výsledkom klasifikácie rezov a jeho rýchlosti vďaka použitiu CNN. Jeho prínosom môže byť detekcia hemoragie v troch navzájom kolmých rovinách, pričom v publikovanej literatúre sa detekcia hemoragií zvyčajne realizuje iba v axiálnom smere. Výhodou je detekcia ložisiek bez nutnosti aplikácie kontrastnej látky. CAD systém so zakomponovaným algoritmom môže upozorniť rádiológa na prítomnosť hemoragie, a ďalej vo vstupnom 3D CT skene detekuje jednotlivé hemoragické ložiská, klasifikuje ich typy a vyznačí ich 3D ohraničujúcimi oblasťami. Výstup v takejto forme môže zabrániť prehliadnutiu patológie vplyvom únavy rádiológa, zamerania

na iné patológie alebo ďalším ľudským faktorom. Lokalizácia a určenie typov hemoragií môžu urýchliť proces diagnostiky, čím môže systém dopomôcť k zamedzeniu trvalých následkov až smrti pacienta.

Záver

Cielom tejto práce bolo naštudovať základné anatomické, patologické a rádiologické poznatky, ďalej teóriu metód spracovania obrazov pre detekciu a klasifikáciu s využitím strojového učenia, a vypracovanie rešerše metód pre detekciu hemoragií v CT snímkach hlavy vrátane popisu voľne dostupnej databázy. Úlohou bolo navrhnúť, realizovať, testovať a vyhodnotiť postup detekcie hemoragií s využitím strojového učenia vrátane optimalizácie parametrov, a diskutovať jeho využitie v lekárskej diagnostike.

Práca popisuje základné teoretické lekárske a technické východiská nevyhnutné pre orientáciu v oblasti záujmu. Vypracovaná je literárna rešerš zameraná na aktuálne publikácie zaoberajúce sa problematikou detekcie hemoragií v CT snímkach. V práci je popísaná verejne dostupná databáza CT snímkov hlavy CQ500 s lekáorskými anotáciami vo forme patientskych diagnóz. Súčasťou práce je manuálna anotácia dát z dostupnej databázy označovaním prítomnosti a typov hemoragií (IPH, IVH, SDH, EDH, SAH) na úrovni jednotlivých rezov. Návrh metódy pre detekciu hemoragií spočíva v spracovaní CT dát systémom pozostávajúcim z troch klasifikačných podsystémov, ktoré spracujú jednotlivé 2D rezy CT skenu v axiálnom, sagitálnom a koronárnom smere. Klasifikačné podsystémy sú zložené zo série binárnych klasifikátorov založených na architektúre CNN Inception-ResNet-v2. V každej rovine v danom reze prvý klasifikátor určí prítomnosť alebo neprítomnosť hemoragie a v prípade pozitívneho výsledku je následne rez spracovaný sériou klasifikátorov určujúcich typy hemoragie v danom reze. Postupnou klasifikáciou rezov v troch rovinách možno vytvoriť ohraničujúcu oblasť okolo hemoragií v CT skene a určiť typy ložisiek.

Jednotlivé klasifikátory sú testované a parametre algoritmu sú optimalizované vzhľadom na dosahované výsledky. Klasifikátory prítomnosti hemoragie dosahujú v každej rovine senzitivitu väčšiu ako 83 % a špecificitu väčšiu ako 95 %, čo vypovedá o dobrej schopnosti rozpoznať patologický a nepatologický rez. V prípade klasifikátorov typu hemoragie je dosahovaná priemerná hodnota senzitivity pre IPH, IVH a SAH väčšia ako 72 %, pre SDH je dosiahnutých 63 %. Väčšina klasifikátorov dokáže pomerne spoľahlivo rozpoznať daný typ. Klasifikácia typu EDH dosahuje horšiu senzitivitu 44 % z dôvodu nie príliš rozsiahlej databázy skenov. Priemerná špecificita je u všetkých typov väčšia ako 86 %, z čoho vyplýva vysoký počet správne negatívnych klasifikácií.

Klasifikácia prítomnosti a väčšiny typov hemoragie je spoľahlivá a navrhovaný detekčný algoritmus má vysoký potenciál pre podporné diagnostické systémy. Prínosom práce je vytvorenie anotácii 2D rezov voľne dostupného datasetu CT snímkov, návrh a realizácia detekčnej metódy založenej na klasifikácii 2D obrazov, ktorá lo-

kalizuje hemoragické ložiská v troch smeroch a klasifikuje ich typy, pričom v publikovanej literatúre je detekcia zvyčajne realizovaná iba v axiálnom smere.

Literatúra

- [1] CACERES, J. Alfredo a Joshua N. GOLDSTEIN. Intracranial Hemorrhage. *Emergency Medicine Clinics of North America* [online]. 2012, **30**(3), 771-794 [cit. 2020-05-29]. DOI: 10.1016/j.emc.2012.06.003. ISSN 07338627. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0733862712000272>
- [2] WEAKER, Frank J. *Structures of the head and neck*. Philadelphia, PA: F.A. Davis, c2014. ISBN 978-0-8036-2958-5.
- [3] DYLEVSKÝ, Ivan. *Funkční anatomie*. Praha: Grada, 2009. ISBN 978-80-247-3240-4.
- [4] NAŇKA, Ondřej a Miloslava ELIŠKOVÁ. *Přehled anatomie*. Třetí, doplněné a přepracované vydání. Praha: Galén, [2015]. ISBN 978-80-7492-206-0.
- [5] ČIHÁK, Radomír. *Anatomie*. Třetí, upravené a doplněné vydání. Ilustroval Ivan HELEKAL, ilustroval Jan KACVINSKÝ, ilustroval Stanislav MACHÁČEK. Praha: Grada, 2016. ISBN 978-80-247-5636-3.
- [6] HULÍN, Ivan. *Patofyziologie*. 5., aktualiz. a rozš. vyd. Bratislava: Slovak Academic Press, 1998. ISBN 80-88908-07-8.
- [7] POVÝŠIL, Ctibor a Ivo ŠTEINER. *Speciální patologie*. 2., dopl. a přeprac. vyd. Praha: Galén, c2007. ISBN 978-80-7262-494-2.
- [8] SILBERNAGL, Stefan a Florian LANG. *Atlas patofyziologie*. 2. české vyd. Praha: Grada, 2012. ISBN 978-80-247-3555-9.
- [9] HEŘMAN, Miroslav. *Základy radiologie*. V Olomouci: Univerzita Palackého, 2014. ISBN 978-80-244-2901-4.
- [10] *CT head (an approach) - Radiopaedia*. [cit 2019-12-12]. Dostupné z: <https://radiopaedia.org/articles/ct-head-an-approach?lang=us>.
- [11] NEKULA, Josef. *Radiologie*. 3. vyd. V Olomouci: Univerzita Palackého, 2005. ISBN 8024410117.
- [12] NOVELLINE, Robert A. *Squire's fundamentals of radiology*. 6th ed. Cambridge: Harvard University Press, c2004. ISBN 0-674-01279-8.
- [13] SEIDL, Zdeněk. *Radiologie pro studium i praxi*. Praha: Grada, 2012. ISBN 978-80-247-4108-6.

- [14] HEIT, Jeremy J., Michael IV a Max WINTERMARK. Imaging of Intracranial Hemorrhage. *Journal of Stroke* [online]. 2017, **19**(1), 11-27 [cit. 2020-04-30]. DOI: 10.5853/jos.2016.00563. ISSN 2287-6391. Dostupné z: <http://j-stroke.org/journal/view.php?doi=10.5853/jos.2016.00563>
- [15] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL: Taylor & Francis, 2006. ISBN 978-0-8247-5849-3.
- [16] SONKA, Milan, Vaclav HLAVAC a Roger BOYLE. *Image processing, analysis, and machine vision*. 3rd ed. Toronto: Thompson Learning, c2008. ISBN 978-0-495-08252-1.
- [17] WATT, Jeremy, Reza BORHANI a Aggelos Konstantinos KATSAGGELOS. *Machine learning refined: foundations, algorithms, and applications*. New York: Cambridge University Press, 2016. ISBN 978-1-107-12352-6.
- [18] BISHOP, Christopher M. *Pattern recognition and machine learning*. New York: Springer, c2006. Information science and statistics. ISBN 978-0387-31073-2.
- [19] LITJENS, Geert, Thijs KOOI, Babak Ehteshami BEJNORDI, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis* [online]. 2017, **42**, 60-88 [cit. 2019-12-12]. DOI: 10.1016/j.media.2017.07.005. ISSN 13618415. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1361841517301135>
- [20] DUDA, Richard O., Peter E. HART a David G. STORK. *Pattern classification*. 2nd ed. New York: Wiley, c2001. ISBN 0-471-05669-3.
- [21] NIXON, Mark S. a Alberto S AGUADO. *Feature extraction and image processing*. 2nd ed. Amsterdam: Academic Press, 2008. ISBN 978-0-1237-2538-7.
- [22] TIN KAM HO. Random decision forests. In: *Proceedings of 3rd International Conference on Document Analysis and Recognition* [online]. IEEE Comput. Soc. Press, 1995, s. 278-282 [cit. 2019-12-12]. DOI: 10.1109/ICDAR.1995.598994. ISBN 0-8186-7128-9. Dostupné z: <http://ieeexplore.ieee.org/document/598994/>
- [23] JAIN, A.K., JIANCHANG MAO a K.M. MOHIUDDIN. Artificial neural networks: a tutorial. *Computer* [online]. **29**(3), 31-44 [cit. 2019-12-13]. DOI: 10.1109/2.485891. ISSN 00189162. Dostupné z: <http://ieeexplore.ieee.org/document/485891/>

- [24] ODA, Tetsuya, Ryoichiro OBUKATA, Masafumi YAMADA, Masahiro HIYAMA, Leonard BAROLLI a Makoto TAKIZAWA. A Neural Network Based User Identification for Tor Networks: Comparison Analysis of Different Activation Functions Using Friedman Test. In: *2016 19th International Conference on Network-Based Information Systems (NBiS)* [online]. IEEE, 2016, 2016, s. 480-487 [cit. 2019-12-13]. DOI: 10.1109/NBiS.2016.24. ISBN 978-1-5090-0979-4. Dostupné z: <http://ieeexplore.ieee.org/document/7789806/>
- [25] MERCIONI, Marina Adriana, Alexandru TIRON a Stefan HOLBAN. Dynamic Modification of Activation Function using the Backpropagation Algorithm in the Artificial Neural Networks. *International Journal of Advanced Computer Science and Applications* [online]. 2019, **10**(4) [cit. 2019-12-13]. DOI: 10.14569/IJACSA.2019.0100406. ISSN 21565570. Dostupné z: <http://thesai.org/Publications/ViewPaper?Volume=10&Issue=4&Code=IJACSA&SerialNo=6>
- [26] Glorot, Xavier & Bordes, Antoine & Bengio, Y.. (2011). *Deep Sparse Rectifier Neural Networks*. Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS) 2011. 15. 315-323.
- [27] NIELSEN, M.A. Neural Networks and Deep Learning. [online]. Determination Press, 2018. Dostupné z: <http://neuralnetworksanddeeplearning.com/>.
- [28] THEODORIDIS, Sergios a Konstantinos KOUTROUMBAS. *Pattern recognition*. 2nd ed. Boston: Academic Press, c2003. ISBN 0-12-685875-6.
- [29] KINGMA, Diederik & Jimmy, BA. (2014). Adam: A Method for Stochastic Optimization. International Conference on Learning Representations. ArXiv. 2017, abs/1412.6980.
- [30] GOODFELLOW, Ian, Yoshua, BENGIO, Aaron, COURVILLE. Deep Learning. [online]. MIT Press, 2016. Dostupné z: <http://www.deeplearningbook.org/.com/>.
- [31] LECUN, Yann, Yoshua BENGIO a Geoffrey HINTON. Deep learning. *Nature* [online]. 2015, **521**(7553), 436-444 [cit. 2019-12-26]. DOI: 10.1038/nature14539. ISSN 0028-0836. Dostupné z: <http://www.nature.com/articles/nature14539>
- [32] Convolutional Neural Network. UFLDL Tutorial [online]. [cit. 2019-12-26]. Dostupné z: <http://ufldl.stanford.edu/tutorial/supervised/ConvolutionalNeuralNetwork/>.

- [33] SRIVASTAVA, Nitish, Geoffrey, HINTON, Alex, KRIZHEVSKY, Ilya, SUTSKEVER, Ruslan, SALAKHUTDINOV. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 2015, 15, 1929-1958.
- [34] IOFFE, Sergej, Christian, SZEGEDY. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In *Proceedings of the 32nd International Conference on International Conference on Machine Learning - Volume 37 (ICML 15)*. ArXiv. 2015, abs/1502.03167.
- [35] DENG, Jia, Wei DONG, Richard SOCHER, Li-Jia LI, KAI LI a LI FEI-FEI. ImageNet: A large-scale hierarchical image database. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition* [online]. IEEE, 2009, 2009, s. 248-255 [cit. 2019-12-27]. DOI: 10.1109/CVPR.2009.5206848. ISBN 978-1-4244-3992-8. Dostupné z: <https://ieeexplore.ieee.org/document/5206848/>
- [36] HEDJAZI, Mohamed Abbas, Ikram KOURBANE a Yakup GENC. On identifying leaves: A comparison of CNN with classical ML methods. In: *2017 25th Signal Processing and Communications Applications Conference (SIU)* [online]. IEEE, 2017, 2017, s. 1-4 [cit. 2019-12-27]. DOI: 10.1109/SIU.2017.7960257. ISBN 978-1-5090-6494-6. Dostupné z: <http://ieeexplore.ieee.org/document/7960257/>
- [37] KRIZHEVSKY, Alex, Ilya SUTSKEVER a Geoffrey E. HINTON. ImageNet classification with deep convolutional neural networks. *Communications of the ACM* [online]. 2017, **60**(6), 84-90 [cit. 2019-12-27]. DOI: 10.1145/3065386. ISSN 00010782. Dostupné z: <http://dl.acm.org/citation.cfm?doid=3098997.3065386>
- [38] SIMONYAN, Karen, Andrew, ZISSERMAN. (2014). Very deep convolutional networks for large-scale image recognition. In *CoRR* [online]. 2014. Vol. abs/1409.1556. Dostupné na internete: <http://arxiv.org/abs/1409.1556>.
- [39] SZEGEDY, Christian, WEI LIU, YANGQING JIA, et al. Going deeper with convolutions. In: *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2015, 2015, s. 1-9 [cit. 2019-12-28]. DOI: 10.1109/CVPR.2015.7298594. ISBN 978-1-4673-6964-0. Dostupné z: <http://ieeexplore.ieee.org/document/7298594/>
- [40] SZEGEDY, Christian, Sergey, IOFFE, Vincent, VANHOUCHE, Alexander, ALEMI. (2016). Inception-v4, Inception-ResNet and the Impact of Residual

- Connections on Learning. In AAAI Conference on Artificial Intelligence [online]. 2016. Vol. abs/1602.07261. Dostupné z: <https://arxiv.org/pdf/1602.07261.pdf>.
- [41] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, 2016, s. 770-778 [cit. 2019-12-28]. DOI: 10.1109/CVPR.2016.90. ISBN 978-1-4673-8851-1. Dostupné z: <http://ieeexplore.ieee.org/document/7780459/>
- [42] ZHAO, Zhong-Qiu, Peng ZHENG, Shou-Tao XU a Xindong WU. Object Detection With Deep Learning: A Review. *IEEE Transactions on Neural Networks and Learning Systems* [online]. 2019, **30**(11), 3212-3232 [cit. 2019-12-10]. DOI: 10.1109/TNNLS.2018.2876865. ISSN 2162-237X. Dostupné z: <https://ieeexplore.ieee.org/document/8627998/>
- [43] SULTANA, Farhana, Abu SUFIAN a Paramartha DUTTA. Advancements in Image Classification using Convolutional Neural Network. In: *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)* [online]. IEEE, 2018, 2018, s. 122-129 [cit. 2019-12-28]. DOI: 10.1109/ICRCICN.2018.8718718. ISBN 978-1-5386-7638-7. Dostupné z: <https://ieeexplore.ieee.org/document/8718718/>
- [44] LI, Zhuangzi, Xiaobin ZHU, Lei WANG a Peiyu GUO. Image Classification Using Convolutional Neural Networks and Kernel Extreme Learning Machines. In: *2018 25th IEEE International Conference on Image Processing (ICIP)* [online]. IEEE, 2018, 2018, s. 3009-3013 [cit. 2019-12-28]. DOI: 10.1109/ICIP.2018.8451560. ISBN 978-1-4799-7061-2. Dostupné z: <https://ieeexplore.ieee.org/document/8451560/>
- [45] GIRSHICK, Ross, Jeff DONAHUE, Trevor DARRELL a Jitendra MALIK. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition* [online]. IEEE, 2014, 2014, s. 580-587 [cit. 2019-12-28]. DOI: 10.1109/CVPR.2014.81. ISBN 978-1-4799-5118-5. Dostupné z: <http://ieeexplore.ieee.org/document/6909475/>
- [46] GIRSHICK, Ross. Fast R-CNN. In: *2015 IEEE International Conference on Computer Vision (ICCV)* [online]. IEEE, 2015, 2015, s. 1440-1448 [cit. 2019-12-28]. DOI: 10.1109/ICCV.2015.169. ISBN 978-1-4673-8391-2. Dostupné z: <http://ieeexplore.ieee.org/document/7410526/>

- [47] REN, Shaoqing, Kaiming HE, Ross GIRSHICK a Jian SUN. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. 2017, **39**(6), 1137-1149 [cit. 2019-12-28]. DOI: 10.1109/TPAMI.2016.2577031. ISSN 0162-8828. Dostupné z: <http://ieeexplore.ieee.org/document/7485869/>
- [48] REDMON, Joseph, Santosh DIVVALA, Ross GIRSHICK a Ali FARHADI. You Only Look Once: Unified, Real-Time Object Detection. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, 2016, s. 779-788 [cit. 2019-12-28]. DOI: 10.1109/CVPR.2016.91. ISBN 978-1-4673-8851-1. Dostupné z: <http://ieeexplore.ieee.org/document/7780460/>
- [49] LIU, Wei, Dragomir ANGUELOV, Dumitru ERHAN, Christian SZEGEDY, Scott REED, Cheng-Yang FU a Alexander C. BERG. SSD: Single Shot Multi-Box Detector. LEIBE, Bastian, Jiri MATAS, Nicu SEBE a Max WELLING, ed. *Computer Vision — ECCV 2016* [online]. Cham: Springer International Publishing, 2016, 2016-09-17, s. 21-37 [cit. 2019-12-28]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-46448-0_2. ISBN 978-3-319-46447-3. Dostupné z: http://link.springer.com/10.1007/978-3-319-46448-0_2
- [50] CHILAMKURTHY, Sasank, Rohit GHOSH, Swetha TANAMALA, Mustafa BIVIJI, Norbert G CAMPEAU, Vasantha Kumar VENUGOPAL, Vidur MAHAJAN, Pooja RAO a Prashant WARIER. Development and Validation of Deep Learning Algorithms for Detection of Critical Findings in Head CT Scans. ArXiv. 2018, abs/1803.05854.
- [51] GREWAL, Monika, Muktabh Mayank SRIVASTAVA, Pulkit KUMAR a Srikrishna VARADARAJAN. RADnet: Radiologist level accuracy using deep learning for hemorrhage detection in CT scans. In: *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)* [online]. IEEE, 2018, 2018, s. 281-284 [cit. 2019-12-29]. DOI: 10.1109/ISBI.2018.8363574. ISBN 978-1-5386-3636-7. Dostupné z: <https://ieeexplore.ieee.org/document/8363574/>
- [52] YE, Hai, Feng GAO, Youbing YIN, et al. Precise diagnosis of intracranial hemorrhage and subtypes using a three-dimensional joint convolutional and recurrent neural network. *European Radiology* [online]. 2019, **29**(11), 6191-6201 [cit. 2020-04-29]. DOI: 10.1007/s00330-019-06163-2. ISSN 0938-7994. Dostupné z: <http://link.springer.com/10.1007/s00330-019-06163-2>

- [53] CHO, Junghwan, Ki-Su PARK, Manohar KARKI, et al. Improving Sensitivity on Identification and Delineation of Intracranial Hemorrhage Lesion Using Cascaded Deep Learning Models. *Journal of Digital Imaging* [online]. 2019, **32**(3), 450-461 [cit. 2019-12-29]. DOI: 10.1007/s10278-018-00172-1. ISSN 0897-1889. Dostupné z: <http://link.springer.com/10.1007/s10278-018-00172-1>
- [54] LEE, Hyunkwang, Sehyo YUNE, Mohammad MANSOURI, et al. An explainable deep-learning algorithm for the detection of acute intracranial haemorrhage from small datasets. *Nature Biomedical Engineering* [online]. 2019, **3**(3), 173-182 [cit. 2020-04-29]. DOI: 10.1038/s41551-018-0324-9. ISSN 2157-846X. Dostupné z: <http://www.nature.com/articles/s41551-018-0324-9>
- [55] CHMELIK, Jiri, Roman JAKUBICEK, Tomas VICAR, Petr WALEK, Petr OUREDNICEK a Jiri JAN. Iterative machine learning based rotational alignment of brain 3D CT data*. In: *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2019, 2019, s. 4404-4408 [cit. 2020-05-06]. DOI: 10.1109/EMBC.2019.8857858. ISBN 978-1-5386-1311-5. ISSN 1557-170X. Dostupné z: <https://ieeexplore.ieee.org/document/8857858/>
- [56] RUEDEN, Curtis T., Johannes SCHINDELIN, Mark C. HINER, Barry E. DEZONIA, Alison E. WALTER, Ellen T. ARENA a Kevin W. ELICEIRI. ImageJ2: ImageJ for the next generation of scientific image data. *BMC Bioinformatics* [online]. 2017, **18**(1) [cit. 2020-05-07]. DOI: 10.1186/s12859-017-1934-z. ISSN 1471-2105. Dostupné z: <https://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-017-1934-z>
- [57] BIANCO, Simone, Remi CADENE, Luigi CELONA a Paolo NAPOLETANO. Benchmark Analysis of Representative Deep Neural Network Architectures. *IEEE Access* [online]. 2018, **6**, 64270-64277 [cit. 2020-05-12]. DOI: 10.1109/ACCESS.2018.2877890. ISSN 2169-3536. Dostupné z: <https://ieeexplore.ieee.org/document/8506339/>
- [58] *MathWorks - Makers of MATLAB and Simulink- MATLAB & Simulink [online]. Copyright © 1994 [online].* [cit 2020-05-12]. Dostupné z: <https://www.mathworks.com/help/deeplearning/ref/inceptionresnetv2.html>.
- [59] GLOT, X., BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. In TEH, Y.W. - TITTERINGTON, D.M. AISTATS [online]. [s.l.]: JMLR.org, 2010. s. 249-256. Dostupné na internete: <http://dblp.uni-trier.de/db/journals/jmlr/jmlrp9.html#GlorotB10>.

- [60] *MathWorks - Makers of MATLAB and Simulink- MATLAB & Simulink [online]. Copyright © 1994 [online].* [cit 2020-05-13]. Dostupné z: <https://www.mathworks.com/help/deeplearning/ug/create-custom-weighted-cross-entropy-classification-layer.html>.
- [61] MURPHY, Kevin P. *Machine learning: a probabilistic perspective*. Cambridge: MIT Press, c2012. Adaptive computation and machine learning series. ISBN 978-0-262-01802-9.
- [62] PARIKH, Rajul, Annie MATHAI, Shefali PARIKH, G CHANDRA SEKHAR a Ravi THOMAS. Understanding and using sensitivity, specificity and predictive values. *Indian Journal of Ophthalmology* [online]. 2008, **56**(1) [cit. 2020-05-19]. DOI: 10.4103/0301-4738.37595. ISSN 0301-4738. Dostupné z: <http://www.ijo.in/text.asp?2008/56/1/45/37595>
- [63] DICE, Lee R. Measures of the Amount of Ecologic Association Between Species. *Ecology* [online]. 1945, **26**(3), 297-302 [cit. 2020-05-19]. DOI: 10.2307/1932409. ISSN 00129658. Dostupné z: <http://doi.wiley.com/10.2307/1932409>
- [64] TAHA AA, Hanbury A. Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC Med Imaging*. 2015, [cit. 2020-05-19]. DOI: 10.1186/s12880-015-0068-x. Dostupné z: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4533825/pdf/12880_2015_Article_68.pdf.
- [65] FAWCETT, Tom. An introduction to ROC analysis. *Pattern Recognition Letters* [online]. 2006, **27**(8), 861-874 [cit. 2020-05-26]. DOI: 10.1016/j.patrec.2005.10.010. ISSN 01678655. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S016786550500303X>
- [66] DOI, Kunio. Computer-aided diagnosis in medical imaging: Historical review, current status and future potential. *Computerized Medical Imaging and Graphics* [online]. 2007, **31**(4-5), 198-211 [cit. 2020-05-27]. DOI: 10.1016/j.compmedimag.2007.02.002. ISSN 08956111. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0895611107000262>

A Príloha

A.1 Tabuľky počtov rezov v databázach pre klasifikáciu prítomnosti a typu hemoragie

Tab. A.1: Tabuľka počtov pozitívnych (s hemoragiou) a negatívnych (bez hemoragie) CT rezov v tréningovej a testovacej databáze v troch rovinách.

	Tréningovanie		
	Axiálne	Sagitálne	Koronárne
Pozitívne	980	957	1 414
Negatívne	4 479	6 008	6 008
Celkovo	5 459	6 965	7 422
	Testovanie		
	Axiálne	Sagitálne	Koronárne
Pozitívne	380	323	523
Negatívne	1 949	2 605	2 605
Celkovo	2 329	2 928	3 128

Tab. A.2: Tabuľka počtov rezov v pozitívnych (s daným typom hemoragie) a negatívnych (kombinácia iných typov hemoragií) databázach pre jednotlivé typy hemoragií v troch anatomických rovinách.

AXIÁLNE	IPH	IVH	SDH	EDH	SAH
Pozitívne	144	148	468	104	362
Negatívne	979	1 032	820	1 208	831
SAGITÁLNE	IPH	IVH	SDH	EDH	SAH
Pozitívne	498	162	256	78	566
Negatívne	530	1 041	999	1 319	695
KORONÁRNE	IPH	IVH	SDH	EDH	SAH
Pozitívne	714	238	614	116	672
Negatívne	1 032	1 727	1 240	2 030	1 367

A.2 Tabuľky výsledkov klasifikácie

Tab. A.3: Tabuľka kvantitatívnych výsledkov klasifikácie typu hemoragie v CT rezo-
zoch v troch rovinách.

AXIÁLNA	IPH	IVH	SDH	EDH	SAH
Se [%]	63,9	74,3	86,5	42,3	70,0
Sp [%]	93,9	96,9	84,5	93,1	94,0
DC [%]	70,8	75,9	81,1	37,9	75,4
SAGITÁLNA	IPH	IVH	SDH	EDH	SAH
Se [%]	81,1	82,1	49,2	48,7	71,9
Sp [%]	81,3	88,5	88,3	94,7	87,5
DC [%]	80,7	64,1	50,5	40,9	76,8
KORONÁRNA	IPH	IVH	SDH	EDH	SAH
Se [%]	84,3	74,0	55,2	40,5	74,0
Sp [%]	85,0	98,0	88,9	94,9	88,5
DC [%]	81,9	78,4	62,1	35,3	75,0

Tab. A.4: Tabuľka výsledkov testovania klasifikátorov prítomnosti hemoragie v CT
rezoch v troch rovinách pri použití prahu skóre rezu $T = 0,5$ a prahu vychádzajúceho
z ROC analýzy klasifikátora.

	Axiálna		Sagitálna		Koronárna	
	$T_{0,5}$	T_{ROC}	$T_{0,5}$	T_{ROC}	$T_{0,5}$	T_{ROC}
Se [%]	87,4	92,7	86,6	92,8	83,5	90,7
Sp [%]	97,8	94,8	96,8	94,0	95,3	90,9
DC [%]	88,1	84,7	80,9	75,9	80,5	76,5