


UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



DETEKCIA MENINGEÓMU V CT SNÍMKACH

Diplomová práca

2022

Bc. Filip Sekerka

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



DETEKCIA MENINGEÓMU V CT SNÍMKACH

Diplomová práca

Študijný program: Aplikovaná informatika
Študijný odbor: 2511 Aplikovaná informatika
Školiace pracovisko: Katedra aplikovanej informatiky
Školiteľ: RNDr. Zuzana Černeková, PhD.

Bratislava, 2022

Bc. Filip Sekerka



ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Filip Sekerka
Študijný program: aplikovaná informatika (Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: informatika
Typ záverečnej práce: diplomová
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: Detekcia meningeómu v CT snímkach
Meningeoma detection in CT images

Anotácia: Cieľom práce je detegovať meningeom v snímkach CT mozgu s využitím neurónových sietí. Meningeóm je nezhubný nádor, ktorý vychádza z mozgových obalov a vyskytuje sa teda na periférii mozgu. Môže byť aj kalcifikovaný (vtedy je "svetlejší").
Naštudovať problematiku spracovania medicínskych dát pomocou neurónových sietí. Analyzovať existujúce riešenia publikované v dostupnej odbornej literatúre. Navrhnuť a implementovať metódu založenú na neurónových sieťach, ktorá zdeteguje a určí veľkosť meningeómu na CT snímkach mozgu. Túto metódu otestovať a vyhodnotiť výsledky.

Cieľ: Cieľom práce je detegovať meningeom v snímkach CT mozgu s využitím neurónových sietí.
Naštudovať problematiku spracovania medicínskych dát pomocou neurónových sietí. Analyzovať existujúce riešenia publikované v dostupnej odbornej literatúre. Navrhnuť a implementovať metódu založenú na neurónových sieťach, ktorá zdeteguje a určí veľkosť meningeómu na CT snímkach mozgu. Túto metódu otestovať a vyhodnotiť výsledky.

Vedúci: RNDr. Zuzana Černeková, PhD.
Katedra: FMFI.KAI - Katedra aplikovanej informatiky
Vedúci katedry: prof. Ing. Igor Farkaš, Dr.

Dátum zadania: 15.10.2021

Dátum schválenia: 23.10.2021

prof. RNDr. Roman Ďurikovič, PhD.
garant študijného programu

.....
študent

.....
vedúci práce

Čestne prehlasujem, že túto diplomovú prácu som vypracoval samostatne len s použitím uvedenej literatúry a za pomoci konzultácií u môjho školiteľa.

Bratislava, 2022

.....

Bc. Filip Sekerka

Pod'akovanie

Pod'akovanie.

Abstrakt

Abstrakt po slovensky.

Kľúčové slová: kľúčové slovo1, kľúčové slovo2

Abstract

Abstrakt po anglicky.

Keywords: key word1, key word2

Obsah

1	Úvod	1
2	Motivácia	2
3	Východiská	3
3.1	Medicínske dáta	3
3.1.1	CT skeny	3
3.1.2	Meningeómy na CT snímkach	4
3.1.3	Dicom formát	5
3.1.4	Dáta z Nemocnice sv. Cyrila a Metoda v Bratislave	6
3.2	Neurónové siete	7
3.2.1	Konvolučné neurónové siete	7
4	Predchádzajúce riešenia	10
4.1	Použitie predtrénovaných modelov na klasifikáciu	10
4.2	Lokalizácia nádorov	16
5	Návrh modelu	21
6	Implementácia	22
7	Výsledky	23

<i>OBSAH</i>	ix
7.1 Klasifikácia nádorov	23
7.2 Lokalizácia nádorov	23
8 Záver	24

Kapitola 1

Úvod

Kapitola 2

Motivácia

Kapitola 3

Východiská


3.1 Medicínske dáta

Táto časť detailne vysvetľuje, ako vyzerali dáta, ktoré sme v práci využívali. K dispozícii sme mali CT skeny mozgu z rádiológie z Nemocnice sv. Cyrila a Metoda v Bratislave.

3.1.1 CT skeny

CT skeny sú štandardným nástrojom na diagnostiku v rádiológii. Jeden CT sken obsahuje viacero snímok, ktoré môžu byť robené v 3 rôznych rovinách, viď Obrázok 3.1. Dataset, ktorý sme mali k dispozícii pre túto prácu, obsahoval snímky v axiálnej rovine (tranverse plane) a frontálnej rovine (coronal plane). Medzi snímkami v jednotlivých rovinách bývajú zvyčajne rozostupy 1 mm alebo 3 mm. Snímky v jednotlivých rovinách sa často označujú ako rezy. Jednotlivé CT snímky (rezy) sú jednokanálové šedotónové obrázky. Každý pixel má teda priradenú jednu hodnotu, tzv. denzitu. Ako jednotka sa používa Hounsfieldova jednotka (HU). Táto hodnota vyjadruje ako jednotlivé časti tela absorbujú žiarenie - vzduch má napríklad denzitu okolo -900 HU, kosti

1000 HU a vyššie. Keďže možných hodnôt denzít v CT snímkach je viac ako dokážeme zobrazit' do šedotónovej škály, pri pozeraní CT skenov si radiologickí experti môžu nastaviť takzvané hodnoty window level a window width. Pomocou týchto hodnôt sa určuje, ktoré hodnoty sa zobrazia v šedotónovej škále a ktoré budú ignorované. Hodnota window level určuje strednú hodnotu, ktorá sa zobrazí ako sivá farba (farba presne v strede medzi bielou a čiernou) a hodnota window width určuje rozsah hodnôt, ktoré sa zobrazia do šedotónovej škály. Hodnoty, ktoré sú väčšie ako $\text{window level} + \frac{\text{window width}}{2}$ sa zobrazia ako biela farba. Hodnoty, ktoré sú menšie ako $\text{window level} - \frac{\text{window width}}{2}$ sa zobrazia ako čierna farba.




Obr. 3.1: Jednotlivé roviny v CT skenoch.

3.1.2 Meningeómy na CT snímkach

Cieľom tejto práce bolo navrhnúť model neurónovej siete, ktorý by detekoval meningeómy na snímkach z CT skenov. Meningeóm je nezhubný mozgový nádor. Vždy vychádza z mozgových obalov, t.j. vždy sa nachádza pri okraji lebky. Meningeómy sa v mozgu môžu vyskytovať v dvoch rôznych for-

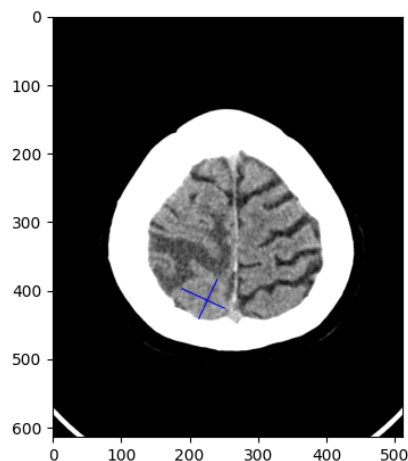
mách - nekalcifikované alebo kalcifikované. Nekalcifikované meningeómy sú zo začiatku, vtedy sa ich denzity podobajú denzitám zdravého mozgového tkaniva. Po čase môžu meningeómy skalcifikovať. Potom sa ich denzity podobajú denzitám kostí. Na Obr. 3.2 je modrými úsečkami označený kalcifikovaný meningeóm, na Obr. 3.3 je modrými úsečkami označený nekalcifikovaný meningeóm.



Obr. 3.2: Kalcifikovaný meningeóm.

3.1.3 Dicom formát

Najpoužívanejší formát CT snímok je DICOM, jednotlivé súbory majú príponu .DCM. Súbory tohto formátu obsahujú jednak samotnú snímku a tak tiež dodatočné informácie, ktoré sú v súbore označované ako Tagy. Pomocou Tagov je možné zistiť poradové číslo aktuálnej snímky, unikátny identifikátor snímky, unikátny identifikátor série, v ktorej bola snímka vytvorená, či napríklad hrúbku aktuálnej snímky (rezu).



Obr. 3.3: Nekalcifikovaný meningeóm.

3.1.4 Dáta z Nemocnice sv. Cyrila a Metoda v Bratislave

Ako už bolo spomenuté, dáta do diplomovej práce sme mali k dispozícii z Nemocnice sv. Cyrila a Metoda v Bratislave. K dispozícii sme mali dáta pacientov s pozitívnymi aj negatívnymi nálezmi meningeómov. Všetky osobné údaje pacientov boli nemocnicou anonymizované. Každému vyšetrovanému pacientovi bol priradený jeden priečnik. Tento priečnik obsahoval tri typy súborov - .DCM, .json a .txt. Súbor s príponou .DCM predstavujú jednotlivé CT snímky pacienta. Súbor s príponou .json obsahoval dodatočné informácie o meraniach - napríklad, či meningeóm bol kalcifikovaný, prípadne koľko ložísk meningeómov má pacient celkovo. Súbor s príponou .txt obsahoval merania meningeómov (ak pacient meningeóm mal). Meningeómy boli vždy anotované iba v axiálnej rovine (transverse plane) a vždy boli anotované iba na tom reze, kde mal meningeóm najväčšiu veľkosť. Ak teda pacient mal jeden meningeóm, tak súbor s príponou .txt obsahoval jedno meranie. Takéto

meranie obsahovalo informáciu o čísle rezu, na ktorom bolo meranie robené. Ďalej toto meranie obsahovalo krajné body dvoch úsečiek. Tieto dve úsečky určovali najväčšiu šírku a výšku meningeómu - z týchto hodnôt bolo následne jednoduché vytvoriť obdĺžnikový bounding box okolo meningeómu.

3.2 Neurónové siete

Cieľom diplomovej práce bolo využitie neurónových sietí na detekciu meningeómov v CT snímkach. Použitie hlbokých neurónových sietí (často označované ako hlboké učenie) patrí medzi moderné metódy strojového učenia. Oproti klasickým metódam strojového učenia sa neurónové siete príznaky naučia automaticky. Nie je teda potrebné ručne dizajnovať príznaky, ktoré by sa mala neurónová sieť naučiť. Na prvých vrstvách by sa neurónová sieť mala naučiť základné príznaky, ako napríklad detekciu hrán, či farieb. V neskorších vrstvách by sa neurónová sieť mala postupne naučiť čím ďalej, tým komplexnejšie príznaky.

3.2.1 Konvolučné neurónové siete

Na prácu s obrázkami sa v súčasnosti najviac využívajú konvolučné neurónové siete. Keďže jednotlivé rezy CT skenov sú dvojrozmerné snímky, konvolučné neurónové siete sú podstatné aj pre túto prácu. Hlavnou súčasťou konvolučných neurónových sietí sú konvolučné vrstvy, ktoré obsahujú filtre, tzv. kernely. Tieto filtre obsahujú parametre, ktoré sa dajú trénovať rovnako ako váhy v klasických neurónových sieťach. Tieto filtre následne vykonávajú konvolúciu vzhľadom ku vstupu (resp. výstupu z predošlej vrstvy). V prípade dvojrozmerných snímok sú aj filtre dvojrozmerné - využíva sa teda takzvaná 2D konvolúcia. Pri trojrozmerných snímkach sa môžu využiť trojrozmerné

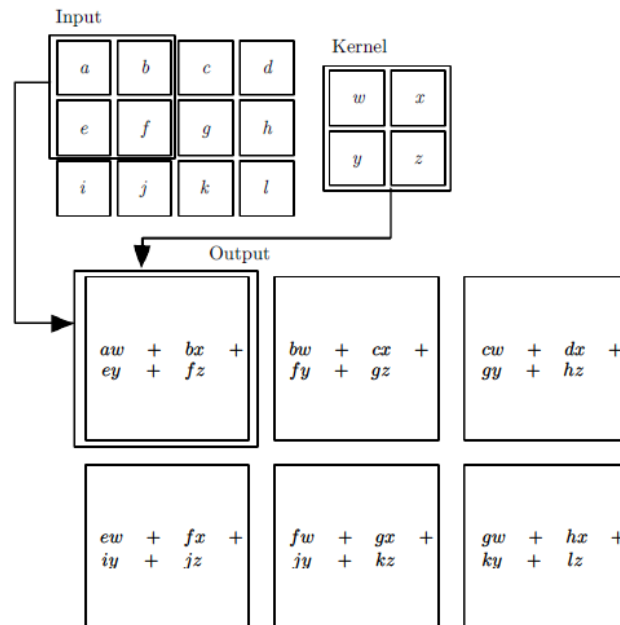
filtre, v takom prípade sa jedná o 3D konvolúciu.

Už spomínané filtre sa následne posúvajú po vstupe a počítajú skalárny súčin medzi daným filtrom a príslušnou časťou vstupu. Schematicky to je zobrazené na Obr. 3.4 z [1]. Ako je spomenuté v [4], pomocou tejto operácie sa filtre naučia reagovať na konkrétne príznaky na danej pozícii vo vstupe.

Filter sa po vstupe môže posúvať rôznym krokom - tento parameter sa v konvolučných neurónových sieťach nazýva stride.

Použitie konvolučného filtra môže zmenšiť dimenziu vstupu. Pokiaľ dimenziu zmenšiť nechceme, môžeme okolo vstupu pridať umelé hodnoty, väčšinou nuly a tým zväčšiť dimenziu vstupu. Tento parameter sa v konvolučných neurónových sieťach nazýva padding.

Najpoužívanejšou aktivačnou funkciou v konvolučných neurónových sieťach je ReLU (rectified linear unit). ReLU je daná predpisom: $f(x) = \max(0, x)$.



Obr. 3.4: Schematický príklad 2D konvolúcie z [1].

Dôležitou súčasťou konvolučných neurónových sietí sú aj takzvané pooling vrstvy. Úlohou takýchto vrstiev je znižovanie dimenzie vstupu. Pooling vrstvy musia mať definovanú veľkosť kernelu, veľkosť kroku (stride) a funkciu, pomocou ktorej sa vypočíta výsledná hodnota pre každú pozíciu na vstupe. Ako je spomenuté v [4], vo väčšine konvolučných neurónových sietí sa využívajú pooling vrstvy s MAX funkciou, veľkosťou kernelu 2x2 a hodnotou stride 2.

Kapitola 4

Predchádzajúce riešenia


V tejto časti sa zameriame na riešenia podobných problémov.

4.1 Použitie predtrénovaných modelov na klasifikáciu

Častou prekážkou pri použití hlbokých neurónových sietí pre medicínske účely je nedostatok dát na natrénovanie modelu. V takom prípade môže dôjsť k preučeniu modelu - model dosahuje výborné výsledky na tréningovej množine, ale výsledky na validačnej množine sú zlé. Riešením tohto problému môže byť silná augmentácia dát, regularizácia, či použitie modelu, ktorý bol najprv natrénovaný pre inú úlohu a následne bol dotrénovaný na menšom datasete. Pri dotrénovaní modelu sa väčšinou prvé vrstvy zamrazia a trénujú sa iba posledné vrstvy.

Autori článku [5] sa rozhodli použiť predtrénovaný model. Ich cieľom bolo navrhnúť model, ktorý by klasifikoval MR snímky mozgu s nádormi do troch rôznych typov nádorov mozgu - glióm, meningeóm a adenóm hypofýzy. K dispozícii mali dataset, ktorý obsahoval 3064 MR snímkov z celkovo 233 pa-

cientov. Každá snímka v datasete bola rozmerov 512 x 512 pixelov. Autori článku sa rozhodli nepoužiť 3D model, ale každú snímku z datasetu používali iba ako vstup do 2D modelu. Cieľom tohto prístupu bolo, aby výsledný model bol viac použiteľný v praxi, pretože vo väčšine klinických prípadov sa požívajú CT alebo MR skeny, ktoré majú veľké rozostupy medzi jednotlivými rezmi. Na normalizáciu dát autori použili min-max normalizáciu, ktorej vzorec vyzerá nasledovne: $y_i = (x_i - \min(x)) / (\max(x) - \min(x))$. Po normalizácii zmenili rozmery snímkov na 224 x 224 pixelov. Ako predtrénovaný model autori použili VGG19. Model VGG19 má 19 vrstiev, pričom väčšina z nich sú konvolučné vrstvy. Model má celkovo približne 144 miliónov trénovateľných parametrov. Model bol predtrénovaný na známom datasete ImageNet, v ktorom sa robí klasifikácia RGB obrázkov do 1000 tried. Autori článku preto upravili poslednú vrstvu, aby mala iba 3 výstupné neuróny. Následne bol model dotrénovaný na spomínanom datasete s MR snímkami. Model je schematicky zobrazený na Obrázku 4.1 z článku [5].



Obr. 4.1: Architektúra modelu VGG19 z článku [5] rozdelená do blokov.

Autori v článku [5] sa ešte zamerali na rôzne spôsoby dotrénovania modelu. Model si autori rozdelili do blokov B1 až B6 (viď Obrázok 4.1), dotrénovali ho 6 rôznymi spôsobmi a výsledky porovnali. Výsledky sú zobrazené


v Tabuľke 4.1. Názov metódy hovorí, ktoré bloky boli dotrénované a ktoré boli zmrazené. Označenie FT:B6 znamená, že dotrénované boli iba vrstvy z bloku B6, označenie FT:B5-B6 znamená, že dotrénované boli vrstvy z blokov B5 až B6. Z výsledkov vidno, že najlepšie výsledky model dosahoval, keď mal dotrénované všetky vrstvy. Autori to zdôvodnili tým, že keďže model bol predtrénovaný na úplne inej doméne dát, tak bolo potrebné dotrénovať všetky vrstvy, aby sa model naučil dôležité príznaky z MR snímok mozgu. Klasické dotrénovanie (iba posledných vrstiev) by sa dalo použiť v prípade, že by aj cieľové dáta pochádzali z podobnej domény ako dáta na predtrénovanie.

Tabuľka 4.1: Porovnanie rôznych metód dotrénovania modelu VGG19 z [5].

Metóda	Recall (%)			Specificity (%)		
	Glióm	Meningeóm	Adenóm hyp.	Glióm	Meningeóm	Adenóm hyp.
FT:B1-B6	95.97	89.98	96.81	93.79	96.42	93.93
FT:B2-B6	95.15	90.48	97.15	94.13	96.02	93.54
FT:B3-B6	94.20	91.06	96.87	94.19	95.25	93.19
FT:B4-B6	93.86	89.29	96.99	93.58	95.20	92.31
FT:B5-B6	91.70	86.71	96.09	91.97	93.53	90.04
FT:B6	90.24	67.60	96.43	83.70	92.79	82.58


V článku [7] autori taktiež využili predtrénované modely. Cieľom autorov bolo vytvoriť model, ktorý by MR snímky mozgu klasifikoval do 5 rôznych tried - degenerative disease, inflammatory disease, cerebrovascular disease, neoplastic disease and normal class. Trieda neoplastic disease zahŕňa aj meningeómy. Dataset sa skladal z 42 rôznych prípadov, všetky snímky boli rozmerov 256 x 256 pixelov. Dokopy mali k dispozícii 1074 snímok (rezov). Autori v tomto článku využili modely AlexNet, VGG16, ResNet18, ResNet34 a ResNet50. Model AlexNet[3] vyhral v roku 2012 súťaž ILSVRC, jeho top-5 testovacia chyba bola 15.3%, čo bolo takmer o 11% lepšie ako model na druhom mieste. Model sa skladal z 5 konvolučných vrstiev. Za prvou, druhou a

piatou konvolučnou vrstvou sa ešte nachádzala max-pooling vrstva. Konvolučné vrstvy používali aktivačnú funkciu ReLu. Za konvolučnými vrstvami sa ešte nachádzali plno prepojené vrstvy a na výstupe sa použila aktivačná funkcia softmax, aby bolo možné výsledné klasifikácie reprezentovať ako pravdepodobnosti. Architektúra modelu je zobrazená na Obrázku 4.2.




Obr. 4.2: Architektúra modelu AlexNet z článku [7].

Ďalším použitým modelom v článku [7] boli rôzne verzie modelu ResNet. Modely ResNet[2] patria medzi najpoužívanejšie modely súčasnosti. Kvôli ich dobrým výsledkom sú často používané ako základné (baseline) modely pre rôzne experimenty. Najdôležitejšou súčasťou ResNet modelov sú takzvané reziduálne prepojenia. Schematicky je takéto reziduálne prepojenie zobrazené na Obr. 4.3. Výhodou týchto prepojení je to, že gradient sa počas spätnej propagácie môže šíriť viacerými cestami a tým sa eliminuje problém zanikajúceho gradientu. Vďaka tomu je možné dobre natrénovať aj veľmi hlboké siete.

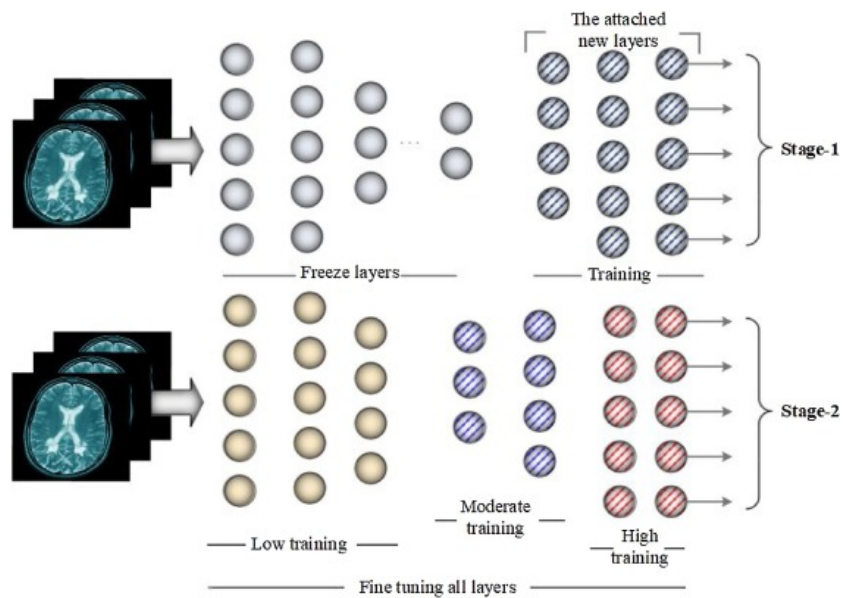


Obr. 4.3: Reziduálne prepojenie z článku [2].

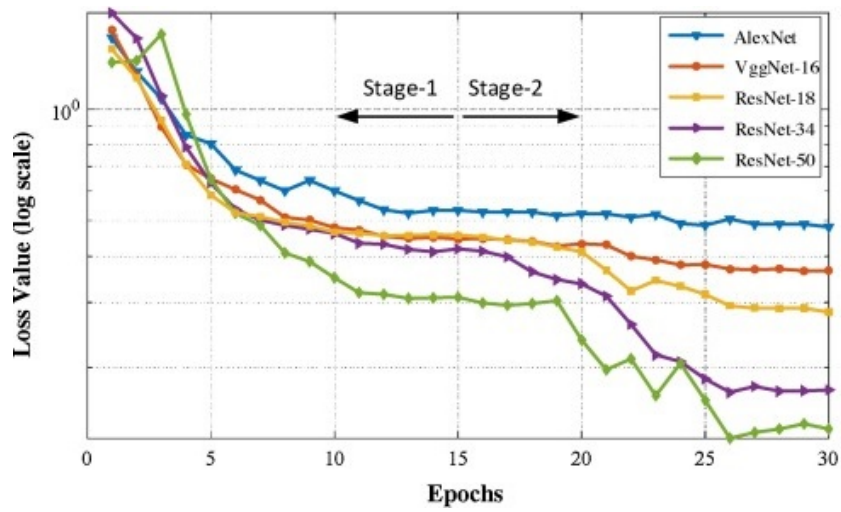


Obr. 4.4: Architektúra modelu ResNet z článku [7].

Všetky modely v článku [7] boli predtrénované opäť na datasete ImageNet. Bolo preto nutné upraviť posledné vrstvy týchto sietí tak, aby mali 5 výstupných neurónov. Autori sa rozhodli dotrénovať všetky modely v dvoch fázach. V prvej fáze dotrénovali iba nové výstupné vrstvy, v druhej fáze dotrénovali celú vždy celú sieť, pričom najväčšia rýchlosť učenia bola na posledných vrstvách a najmenšia rýchlosť učenia bola na prvých vrstvách. Schematicky to je zobrazené na Obr. 4.5. Trénovanie v oboch fázach trvalo 15 epoch. Na Obrázku 4.6 je zobrazená validačná chyba jednotlivých modelov. Z obrázku vidno, že validačná chyba modelu AlexNet sa v druhej fáze už viacmenej nemenila, pričom zložitejším modelom ako napríklad Resnet34 a Resnet50 validačná chyba ešte ďalej klesala. Najlepšie výsledky na validačnej množine dosahoval model ResNet 50, vid' Tabuľka 4.2. Najhoršie výsledky dosahoval model AlexNet, vid' Tabuľka 4.3.



Obr. 4.5: Dve fázy dotrénovania modelov z článku [7].



Obr. 4.6: Validačná chyba počas dotrénovania modelov z článku [7].

Tabuľka 4.2: Výsledky (priemer \pm štandardná odchýlka) modelu ResNet50 na validačnej množine vypočítané pomocou k-fold validácie (článok [7]).

Triedy	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)	F1-Score (%)
Degenerative	96.14 \pm 1	94.37 \pm 1.2	94.11 \pm 3.1	97.16 \pm 0.7	94.21 \pm 1.6
Inflammatory	97.89 \pm 0.9	91.16 \pm 4.4	99.59 \pm 0.9	97.47 \pm 1.3	95.13 \pm 2
Normal	97.71 \pm 0.8	97.31 \pm 4.5	85.82 \pm 5	99.56 \pm 0.7	91.08 \pm 3.2
Cerebrovascular	99.03 \pm 0.3	97.77 \pm 0.7	98.52 \pm 0.8	99.21 \pm 0.3	98.15 \pm 0.6
Neoplastic	99.51	100	94.50 \pm 0.1	100	97.17

Tabuľka 4.3: Výsledky (priemer \pm štandardná odchýlka) modelu AlexNet na validačnej množine vypočítané pomocou k-fold validácie (článok [7]).

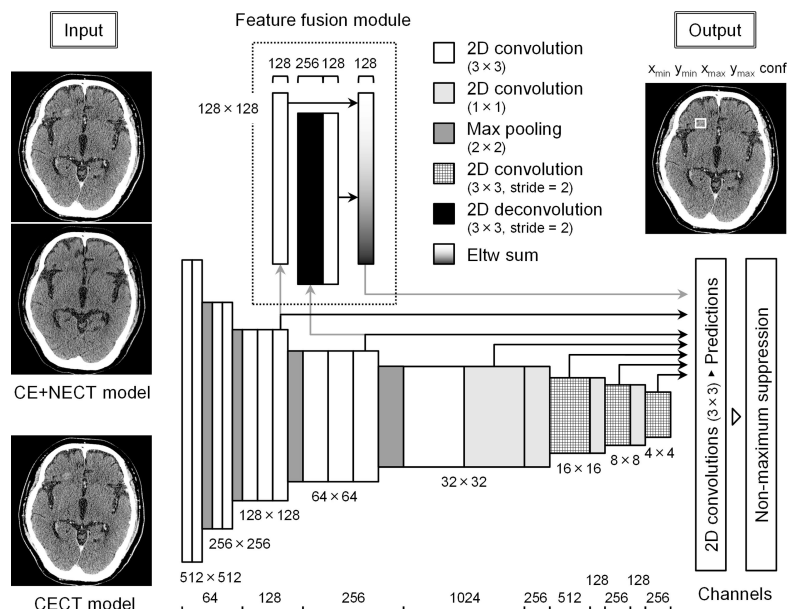
Triedy	Accuracy (%)	Precision (%)	Sensitivity (%)	Specificity (%)	F1-Score (%)
Degenerative	84.76 \pm 2.9	81.88 \pm 5	76.72 \pm 2.7	89.68 \pm 3.2	79.18 \pm 3.4
Inflammatory	90.68 \pm 3	71.73 \pm 10.1	95.59 \pm 3.5	89.29 \pm 3.3	81.64 \pm 7.5
Normal	89.27 \pm 1.6	77.19 \pm 6.7	51.21 \pm 5.3	96.91 \pm 1.3	61.23 \pm 3.4
Cerebrovascular	92.84 \pm 1	85.94 \pm 4.2	85.29 \pm 4.4	95.42 \pm 1.3	85.48 \pm 1.8
Neoplastic	98.27 \pm 0.6	87.65 \pm 4.3	96.88 \pm 2.8	98.45 \pm 0.6	91.96 \pm 2.2

4.2 Lokalizácia nádorov

V tejto časti sa zameriame na modely neurónových sietí, ktoré detekujú polohu nádoru na snímke. Výstupom z takýchto modelov sú súradnice, ktoré určujú bounding-box, resp. polohu nádoru.

Autori článku [6] sa zamerali na vytvorenie modelu, ktorý by vedel detekovať polohu metastáz v mozgu. K dispozícii mali dataset CT snímok 116 pacientov. Na tréning mali k dispozícii 2026 rezov s metastázami. Anotácie pre jednotlivé rezy vytvorili traja radiológovia s využitím ich súkromného softvéru na anotáciu. Autori mali ku každému pacientovi k dispozícii dva typy CT snímok (non-enhanced a contrast-enhanced), preto bolo možné na vstupe do modelu používať páry týchto snímok. Ako model bol použitý SSD model (single shot detector). Autori vytvorili dve verzie tohto modelu,

prvý na vstup dostal pár rezov (non-enhanced a contrast-enhanced) a druhý dostal na vstup iba jeden rez (contrast-enhance). Architektúra modelu je zobrazená na Obr. 4.7. Základom modelu je 18 konvolučných vrstiev, ktoré slúžia na extrakciu príznakov, resp. vytvorenie máp príznakov. Následne 6 z týchto máp príznakov sa spolu využívajú na predikciu. Model ešte obsahuje Feature fusion modul. Jeho architektúra je taktiež zobrazená na Obr. 4.7. Feature fusion modul na vstup dostáva dve mapy príznakov zo základnej časti SSD modelu, spracuje ich a výstupná mapa príznakov sa taktiež využije na predikciu. Na výstup z vrstvy, ktorá má za úlohu predikciu, sa aplikuje ešte operácia Non-maximum suppression. Cieľom tejto operácie vyfiltrovanie bounding boxov, ktoré by sa prekrývali, t.j. ukazovali by na rovnaký objekt. Výsledky modelu na testovacích dátach sú zobrazené v Tabuľkách 4.4 a 4.5. Ako pozitívna detekcia sa považoval prípad, keď sa výsledný bounding-box prekrýval s metastázou, ako negatívna detekcia sa považoval prípad, keď sa výsledná bounding-box neprekrýval so žiadnou metastázou.



Obr. 4.7: Architektúra SSD modelov z článku [6].

Tabuľka 4.4: Výsledky (recall) SSD modelu z článku [6] na testovacích dátach.

	CT+NECT model	CECT model
Veľkosť metastázy	Recall (%)	
Celkovo	88.7	87.6
< 3 mm	41.5	36.9
3 - 6 mm	81.6	80.3
>= 6 mm	96.5	96.0

Tabuľka 4.5: Výsledky (precision) SSD modelu z článku [6] na testovacích dátach.


	CT+NECT model	CECT model
Veľkosť metastázy	Precision (%)	
Celkovo	44.0	37.2
< 3 mm	33.9	27.9
3 - 6 mm	30.9	25.7
>= 6 mm	55.0	45.9

Článok [8] sa taktiež venoval detekcii polohy metastáz v mozgu, avšak v tomto prípade autori pracovali s MR snímkami. K dispozícii mali dataset z MR snímok 266 pacientov. Na trénovanie mali k dispozícii 6711 rezov s metastázami. Autori zostrojili vlastný SSD model, ktorý následne porovnali s inými modelmi na detekciu polohy. Architektúra navrhnutého modelu je zobrazená na Obr. 4.8. Základ modelu sa skladal zo 16 konvolučných vrstiev, ktoré slúžili na extrakciu príznakov, resp. vytvorenie máp príznakov. Následne výstupy zo 6 konvolučných vrstiev sa využili na predikciu. Rovnako ako model v predošlom článku aj tento model využíval na konci operáciu Non-maximum supression. Autori použili náhodné affínne transformácie, aby zväčšili počet trénovacích príkladov. Vďaka tomu sa im počet trénovacích príkladov zväčšil až 5-krát. Výsledky tohto modelu následne porovnali s nasledujúcimi modelmi:

- SSD model, ktorý ako základnú časť využíva ResNet50

- SSD model, ktorý ako chybu využíva focal loss
- RetinaNet

SSD model navrhnutý autormi z článku [8] využíval ako chybu váhovanú sumu klasifikačnej chyby a lokalizačnej chyby. Použitie SSD modelu, ktorý využíva focal loss autori odvodnili tým, že focal loss by mala zlepšiť výsledky tým, že kladie dôraz na zle klasifikované prípady. Porovnanie výsledkov všetkých 4 modelov sú v Tabuľkách 4.6 a 4.7.



Obr. 4.8: Architektúra základného SSD modelu z článku [8].

Tabuľka 4.6: Výsledky (recall) modelov z článku [8] na testovacích dátach.

	Základný SSD	Základný SSD + ResNet50	Základný SSD + focal loss	RetinaNet
Veľkosť metastáz	Recall (%)			
Celkovo	81	73	77	79
< 3 mm	15	10	20	40
3 - 6 mm	70	55	62	66
>= 6 mm	98	94	95	92

Tabuľka 4.7: Výsledky (precision) modelov z článku [8] na testovacích dátach.

	Základný SSD	Základný SSD + ResNet50	Základný SSD + focal loss	RetinaNet
Veľkosť metastáz	Precision (%)			
Celkovo	36	29	26	13
< 3 mm	100	100	80	2
3 - 6 mm	35	34	21	9
>= 6 mm	36	28	29	28

Kapitola 5

Návrh modelu

Kapitola 6

Implementácia

Kapitola 7

Výsledky

7.1 Klasifikácia nádorov

V tejto časti budú uvedené výsledky modelov, ktoré sme využili na binárnu klasifikáciu. Vyskúšali sme vlastný model, upravenú verziu VGG19, upravenú verziu VGG11, ResNet18, upravenú verziu ResNet18 a 3D model ResNet10. Taktiež sme skúšali rôzne typy augmentácii - preklopenie, náhodne rozostrenie, náhodný šum, náhodné prehodenie častí snímky, náhodnú rotáciu, či náhodnú elastickú deformáciu.

7.2 Lokalizácia nádorov

V tejto časti budú uvedené výsledky modelov, ktoré sme využívali na detekciu polohy meningeómov v snímke. Na túto úlohu sme využili model RetinaNet.

Kapitola 8

Záver

Literatúra

- [1] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [2] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [3] A. Krizhevsky, I. Sutskever, and G. Hinton. Imagenet classification with deep convolutional neural networks. *Neural Information Processing Systems*, 25, 01 2012.
- [4] K. O'Shea and R. Nash. An introduction to convolutional neural networks. *CoRR*, abs/1511.08458, 2015.
- [5] Z. N. K. Swati, Q. Zhao, M. Kabir, F. Ali, Z. Ali, S. Ahmed, and J. Lu. Brain tumor classification for mr images using transfer learning and fine-tuning. *Computerized Medical Imaging and Graphics*, 75:34–46, 2019.
- [6] H. Takao, S. Amemiya, S. Kato, H. Yamashita, N. Sakamoto, and O. Abe. Deep-learning single-shot detector for automatic detection of brain metastases with the combined use of contrast-enhanced and non-enhanced computed tomography images. *European Journal of Radiology*, 144:110015, 2021.

- [7] M. Talo, O. Yildirim, U. B. Baloglu, G. Aydin, and U. R. Acharya. Convolutional neural networks for multi-class brain disease detection using mri images. *Computerized Medical Imaging and Graphics*, 78:101673, 2019.
- [8] Z. Zhou, J. W. Sanders, J. M. Johnson, M. K. Gule-Monroe, M. M. Chen, T. M. Briere, Y. Wang, J. B. Son, M. D. Pagel, J. Li, and J. Ma. Computer-aided detection of brain metastases in t1-weighted mri for stereotactic radiosurgery using deep learning single-shot detectors. *Radiology*, 295(2):407–415, 2020. PMID: 32181729.

Zoznam obrázkov

3.1	Jednotlivé roviny v CT skenoch.	4
3.2	Kalcifikovaný meningeóm.	5
3.3	Nekalcifikovaný meningeóm.	6
3.4	Schematický príklad 2D konvolúcie z [1].	8
4.1	Architektúra modelu VGG19 z článku [5] rozdelená do blokov.	11
4.2	Architektúra modelu AlexNet z článku [7].	13
4.3	Reziduálne prepojenie z článku [2].	13
4.4	Architektúra modelu ResNet z článku [7].	14
4.5	Dve fázy dotrénovania modelov z článku [7].	15
4.6	Validačná chyba počas dotrénovania modelov z článku [7].	15
4.7	Architektúra SSD modelov z článku [6].	17
4.8	Architektúra základného SSD modelu z článku [8].	19