



Bakalářská práce

Rozbor možností detekce mozkových nádorů na snímcích získaných metodou magnetické rezonance

Studijní program:

B0914P360007 Biomedicínská technika

Autor práce:

Kamil Mukminov

Vedoucí práce:

Ing. Karel Paleček, Ph.D.

Ústav informačních technologií a elektroniky

Liberec 2023



Zadání bakalářské práce

Rozbor možností detekce mozkových nádorů na snímcích získaných metodou magnetické rezonance

<i>Jméno a příjmení:</i>	Kamil Mukminov
<i>Osobní číslo:</i>	D20000019
<i>Studijní program:</i>	B0914P360007 Biomedicínská technika
<i>Zadávací katedra:</i>	Fakulta zdravotnických studií
<i>Akademický rok:</i>	2022/2023

Zásady pro vypracování:

Cíle práce:

Cílem této práce je využít neuronové sítě pro vyhledávání mozkových nádorů na snímcích magnetické rezonance a určit přesnost detekce těchto nádorů.

Teoretická východiska (včetně výstupu z kvalifikační práce):

Analýza snímků magnetické rezonance a následná diagnostika mozkových nádorů má rozhodující vliv na správnou diagnózu a volbu léčby pacienta, a z toho důvodu roste snaha nalézt metody, snažící se minimalizovat lidský faktor. Jako slibné se jeví použití neuronových sítí. Daná úloha je složitá vzhledem k podobnosti zdravých a patologických tkání na získaných snímcích a také vzhledem k velkému objemu dat, která je třeba zpracovat. Výstupem práce je naznačení možnosti strojového zpracování medicínského obrazu.

Výzkumné předpoklady / výzkumné otázky:

Kvůli lidské chybě se může stát, že radiolog neodhalí ty nejmenší patologické změny, což prokazuje, že je třeba vyvinout další nástroje pro diagnostiku a analýzu snímků magnetické rezonance.

Metoda:

Kvantitativní.

Technika práce, vyhodnocení dat:

Popis základních principů neuronových sítí, analýza současného stavu problematiky, implementace neuronových sítí na snímky magnetické rezonance a následné určení přesnosti získaných výsledků při detekci mozkových nádorů.

Místo a čas realizace výzkumu:

Prostory TUL, budova F, zimní semestr akademického roku 2023/24.

Vzorek:

BraTS Dataset (Brain Tumor Segmentation Dataset) 2018, 2019, 2020.

Rozsah práce:

Rozsah bakalářské práce činí 50 stran (tzn. 1/3 teoretická část, 2/3 praktická část).

Rozsah grafických prací:

Rozsah pracovní zprávy:

Forma zpracování práce:

Jazyk práce:

tištěná/elektronická

čeština

Seznam odborné literatury:

- ABD EL KADER, Isselmou et al. 2021. Differential Deep Convolutional Neural Network Model for Brain Tumor Classification. *Brain sciences*. **11**(3), 352. DOI 10.3390/brainsci11030352. Dostupné také z: <https://www.mdpi.com/2076-3425/11/3/352>
- BHANDARI, A., J. KOPPEN a M. AGZARIAN. 2020. Convolutional neural networks for brain tumour segmentation. *Insights Imaging*. **11**(77). DOI 10.1186/s13244-020-00869-4. Dostupné také z: <https://insightsimaging.springeropen.com/articles/10.1186/s13244-020-00869-4>
- CRIMI, Alessandro et al., eds. 2018. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer. ISBN 978-3-319-75238-9.
- GOODFELLOW, I., Y. BENGIO a A. COURVILLE. 2016. *Deep Learning*. Cambridge: MIT Press. ISBN 978-0-262-03561-3.
- KHAN, Hassan Ali et al. 2020. Brain tumor classification in MRI image using convolutional neural network. *Mathematical biosciences and engineering*. **17**(5), 6203–6216. DOI 10.3934/mbe.2020328. Dostupné také z: <https://www.aimspress.com/article/10.3934/mbe.2020328>
- LAKOMÝ, Radek et al. 2018. *Gliomy: současná diagnostika a léčba*. 2. vyd. Praha: Maxdorf. ISBN 978-80-7345-561-3.
- MAČÁK, J., J. MAČÁKOVÁ a J. DVORÁČKOVÁ. 2012. *Patologie*. 2. vyd. Praha: Grada. ISBN 978-80-247-3530-6.
- THAHA, M. Mohammed et al. 2019. Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. *Journal of Medical Systems*. **43**(9), 294. DOI 10.1007/s10916-019-1416-0. Dostupné také z: <https://link.springer.com/article/10.1007%2Fs10916-019-1416-0>
- ROKYTA, Richard et al. 2015. *Fyziologie a patologická fyziologie: pro klinickou praxi*. Praha: Grada. ISBN 978-80-247-4867-2.
- TOMÁŠEK, Jiří et al. 2015. *Onkologie: minimum pro praxi*. Praha: Axonite. ISBN 978-80-88046-01-1.
- TOĞAÇAR, M., B. ERGEN a Z. CÖMERT. 2020. BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model. *Medical hypotheses*. **2020** (134), 109531. DOI 10.1016/j.mehy.2019.109531. Dostupné také z: <https://www.sciencedirect.com/science/article/pii/S0306987719313416?via%3Dihub>
- STANFORD UNIVERSITY. 2021. CS231n Convolutional Neural Networks for Visual Recognition. STANFORD UNIVERSITY. *Stanford University CS231n: Convolutional Neural Networks for Visual Recognition* [online]. Stanford, [cit. 2022-01-23]. Dostupné z: <https://cs231n.github.io/>

Vedoucí práce:

Ing. Karel Paleček, Ph.D.

Ústav informačních technologií a elektroniky

Datum zadání práce:

26. října 2022

Předpokládaný termín odevzdání: 5. května 2023

L.S.

prof. MUDr. Karel Cvachovec, CSc.,
MBA
děkan

Rozhodnutí o žádosti studenta

Jiný typ žádosti, uveďte se cíl žádosti ručně

Jméno a příjmení: **Kamil Mukminov**

Osobní číslo: **D20000019**

Datum podání žádosti **19.06.2023**

Rozhodnutí děkana ze dne 21.06.2023 :

VYHOVĚL

Odůvodnění

Poučení

Rozhodnutí nemá odvolání.

Rozhodnutí rektora ze dne

NEUVEDENO

Odůvodnění:

Prohlášení

Prohlašuji, že svou bakalářskou práci jsem vypracoval samostatně jako původní dílo s použitím uvedené literatury a na základě konzultací s vedoucím mé bakalářské práce a konzultantem.

Jsem si vědom toho, že na mou bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci nezasahuje do mých autorských práv užitím mé bakalářské práce pro vnitřní potřebu Technické univerzity v Liberci.

Užiji-li bakalářskou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědom povinnosti informovat o této skutečnosti Technickou univerzitu v Liberci; v tomto případě má Technická univerzita v Liberci právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Současně čestně prohlašuji, že text elektronické podoby práce vložený do IS/STAG se shoduje s textem tištěné podoby práce.

Beru na vědomí, že má bakalářská práce bude zveřejněna Technickou univerzitou v Liberci v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů.

Jsem si vědom následků, které podle zákona o vysokých školách mohou vyplývat z porušení tohoto prohlášení.

7. prosince 2023

Kamil Mukminov

Poděkování

Děkuji panu Ing. Karlu Palečkovi, Ph.D. za vedení mé bakalářské práce. Děkuji také své rodině za jejich podporu.

ANOTACE

Rozbor možností detekce mozkových nádorů na snímcích získaných metodou magnetické rezonance

V této práci bylo zkoumáno 7 architektur konvolučních neuronových sítí v kontextu klasifikace tří typů mozkových nádorů na snímcích MR. Byly shrnuty základy neuronových sítí a provedena rešerše příslušné literatury. Byly připraveny vlastní skripty pro manipulaci s datasetem, trénování a validaci neuronových sítí. Výsledkem bylo získání dat potřebných pro vyhodnocení. Nejlepší přesnosti dosáhl model EfficientNetV2-L s přesností 99,5 %. Model MobileNetV2-S byl výpočetně nejefektivnější.

Klíčová slova

Hluboké učení, klasifikace medicinských obrazových dat, mozkový nádor, neuronové sítě

ANNOTATION

Exploring the possibilities of brain tumor detection on images obtained by the magnetic resonance imaging

In this paper, 7 convolutional neural network architectures were reviewed in the context of classifying three types of brain tumors on MRI images. The fundamentals of neural networks were summarized and relevant literature was reviewed. In-house scripts were prepared for dataset manipulation, training and validation of neural networks. As a result, the data required for the evaluation was obtained. The EfficientNetV2-L model achieved the best accuracy, showing an accuracy of 99,5 %. MobileNetV2-S turned out to be the most efficient in terms of computational cost.

Keywords

Deep learning, medical image data classification, brain tumor, neural networks

Obsah

Seznam symbolů a zkratek	9
1 Úvod	10
2 Tradiční metody	12
2.1 Manuální interpretace	12
2.2 Techniky vylepšení obrazu	12
2.3 Základní metody segmentace	12
2.4 Detekce hran	13
3 Úvod do neuronových sítí	14
3.1 Trénování neuronových sítí	15
3.2 Hodnocení úspěšnosti	15
4 Analýza současného stavu problematiky	18
5 Metody pro klasifikaci	20
5.1 Předzpracování datasetů	22
5.2 Příprava trénovacího a pomocných skriptů	23
5.3 Popis klíčových vlastností použitých architektur	25
6 Diskuze	27
7 Závěr	28
8 Seznam použité literatury	29
Příloha A Výsledky použitých modelů	32

Seznam symbolů a zkratk

cit – citováno

CNN – konvoluční neuronová síť (angl. convolutional neural network)

CPU – procesor

č – číslo

ET – zvýrazněny tumor (angl. enhanced tumor)

FN – falešně negativní

FP – falešně pozitivní

HDF – hierarchical data format

MR – magnetická rezonance

NS – neuronová síť

s – strana

TC – jádro tumoru (angl. tumor core)

tj. – to jest

TN – skutečně negativní

TP – skutečně pozitivní

WT – celý tumor (angl. whole tumor)

1 Úvod

Lidský mozek je komplexní orgán, který je náchylný k různým nemocem včetně nádorů. Nádory mozku, jak nezhoubné, tak zhoubné, mohou mít ničivé následky na zdraví, kognitivní schopnosti a celkovou kvalitu života jedince. Včasné odhalení těchto nádorů má zásadní význam nejen pro účinnou léčbu, ale také pro zlepšení prognózy a zvýšení míry přežití postižených.

V oblasti lékařského zobrazování se jako jedna ze základních technik prosadila magnetická rezonance. MR nabízí detailní pohled do měkkých tkání mozku, což z ní dělá neocenitelný nástroj pro lékaře a radiology v kontextu diagnostiky a sledování mozkových nádorů. Neinvazivní charakter MR v kombinaci s její schopností vytvářet snímky s vysokým rozlišením bez použití ionizujícího záření způsobila revoluci v oblasti neurologického zobrazování. MR poskytuje podrobné anatomické a fyziologické informace a umožňuje zobrazit i ty nejmenší abnormality ve struktuře mozkových tkání. V průběhu let sehrála MR klíčovou roli při včasné odhalování mozkových nádorů, vedení chirurgických zákroků a sledování pooperačního zotavení.

Navzdory pokrokům v technologii MR zůstává úkol přesné detekce a klasifikace mozkových nádorů obrovskou výzvou. Heterogenita mozkových nádorů, pokud jde o jejich velikost, tvar a umístění, činí z jejich identifikace náročný úkol. Kromě toho může přítomnost jiných mozkových patologií, artefaktů a složitá anatomie mozku často vést k nejednoznačnosti při rozhodování. Manuální interpretace těchto snímků je nejen časově náročná, ale je také náchylná k lidské chybě vzhledem k menším rozdílům, které odlišují benigní nádory od maligních nebo odlišují jeden podtyp nádoru od druhého.

Problémy jsou dále umocněny obrovským množstvím dat generovaných při vyšetřeních magnetickou rezonancí. Jedna sada snímků může obsahovat desítky řezů, z nichž každý vyžaduje pečlivou kontrolu. Obrovský objem dat spolu se složitostí anatomie mozku a variabilitou podob nádorů podtrhuje potřebu sofistikovanějších a automatizovaných metod detekce.

S ohledem na výše uvedené problémy je cílem této práce prozkoumat možnosti využití umělých neuronových sítí pro detekci mozkových nádorů na snímcích MR. Neuronové sítě, inspirované neuronovými strukturami lidského mozku, prokázaly významné schopnosti v oblasti rozpoznávání obrazů. Jejich schopnost učit se z rozsáhlých souborů dat a identifikovat složité znaky z nich dělá slibného kandidáta na zvýšení přesnosti a účinnosti detekce mozkových nádorů na snímcích MR.

Využitím schopností NS se tato práce snaží naznačit robustní a spolehlivý systém, který může pomoci radiologům v jejich diagnostice, snížit chybovost a zkrátit dobu potřebnou k diagnostice. Prostřednictvím tohoto výzkumu usilujeme o překlenutí propasti mezi pokročilými lékařskými zobrazovacími technikami a špičkovými metodikami umělé inteligence, čímž připravujeme půdu pro novou éru diagnostiky mozkových nádorů.

Chceme prozkoumat stávající architektury neuronových sítí, které se ukázaly jako slibné v oblasti klasifikace obrazů. Ve světě hlubokého učení se objevila spousta architektur, z nichž každá má své silné stránky. Využitím těchto již existujících modelů se snažíme vyhnout náročnému procesu návrhu neuronových sítí od začátku. Místo toho se zaměříme na vyladění a přizpůsobení těchto architektur specifickým, které představují snímky mozkových nádorů pořízené pomocí magnetické rezonance.

Hlavní úkol, které chceme pomocí těchto architektur řešit, je klasifikace nádorů. Jedná se o určení, zda daný řez obsahuje nádor a kterého je typu. Jedná se o úlohu více tříd, kdy síť na základě vlastností, které se naučí během fáze učení, klasifikuje snímky podle jednotlivých typu nádorů. Dataset, který je použit v této práci, obsahuje třídy "meningiom", "gliom", "nádor hypofýzy" a "absence nádoru".

Jakmile budou neuronové sítě natrénovány, bude další klíčovou fází tohoto výzkumu vyhodnocení jejich výkonnosti. Přesnost, ačkoli je hlavním ukazatelem, nebude jediným faktorem určujícím účinnost modelu. Budeme brát v úvahu i další metriky, jako je „precision“, „recall“ a „F1 score“. Tyto metriky poskytnou ucelený pohled na výkonnost modelů a ukážou nejen správné předpovědi, ale také i chyby, ať už se jedná o falešně pozitivní nebo falešně negativní výsledky.

Nakonec bude provedeno porovnání různých použitých architektur neuronových sítí. Tato část bude zahrnovat nejen porovnání jejich metrik, ale také hlubší zkoumání aspektů, jako je výpočetní náročnost a doba trénování. Takové srovnání pomůže určit nejslibnější architektury pro detekci mozkových nádorů na snímcích MR.

2 Tradiční metody

Před integrací pokročilých výpočetních technik a umělé inteligence do lékařského zobrazování byla detekce mozkových nádorů pomocí magnetické rezonance založena převážně na tradičních metodách.

2.1 Manuální interpretace

Základem tradičních metod je manuální interpretace zkušenými radiology. Radiologové pečlivě zkoumali řezy magnetické rezonance a identifikovali všechny anomálie, které by mohly naznačovat přítomnost nádoru. Výhodou těchto metod je individuální posouzení, které vychází z rozsáhlých zkušeností radiologa a jeho schopnosti zahrnout do diagnostického procesu klinický kontext a anamnézu pacienta. Na druhou stranu jsou velmi časově náročné, zejména pokud se jedná o snímky MR s vysokým rozlišením, existuje zde náchylnost k lidským chybám a únavě a možnost variability interpretací u různých radiologů.

2.2 Techniky vylepšení obrazu

- Vyrovnání histogramu: tato metoda rovnoměrně vyrovná intenzity napříč obrazem výrazně zvyšuje kontrast snímků MRI (Leena a Jayanthi, 2022).
- Adaptivní filtrování: pomocí filtrů se snímky MR očistí od šumu, zvýší se jejich jasnost a následně se zviditelní nádory (Leena a Jayanthi, 2022; Kurian a Juliet, 2023).
- Morfologické operace: tyto operace, včetně dilatace, eroze, otevření a uzavření zpřesňují tvar a strukturu potenciálních oblastí nádoru. Hrají klíčovou roli při odstraňování šumu, vyplňování mezer a celkovém zvyšování kvality obrazů (Jensen a Schmainda, 2009; Leena a Jayanthi, 2022).

2.3 Základní metody segmentace

Segmentací MR obrazu na odlišné oblasti na základě hodnot intenzity tyto metody izolují oblasti, které se odchyľují od normy, a označují je jako potenciální místa nádorů.

- Práhování je základní technikou, která segmentuje obraz na základě předem definovaných prahových hodnot intenzity. Každá oblast s intenzitou, která tyto prahy překročí, je určena k dalšímu zkoumání (Parthasarathy et al., 2019).
- Regionální metody: jsou metody, které jsou založeny na zjišťování podobnosti pixelů v nějaké vlastnosti, touto vlastností může být například jas nebo statistické vlastnosti okolí pixelu. Podstatou metod je, že konstrukce segmentu postupuje zdola nahoru, od jednoho pixelu po celý segment. Nejprve jsou nějakým algoritmem v obraze

rozmístěny iniciální pixely, obvykle rovnoměrně nebo náhodně, segment pak vzniká iterativním rozrůstáním se okolí iniciálního pixelu (Jensen a Schmainda, 2009).

2.4 Detekce hran

Vzhledem k odlišné povaze nádorů jsou často v mozku jasně ohraničeny od okolní zdravé tkáně. Techniky hranové detekce mají zásadní význam pro identifikaci těchto hranic a poskytují jasnější představu o velikosti a umístění nádoru.

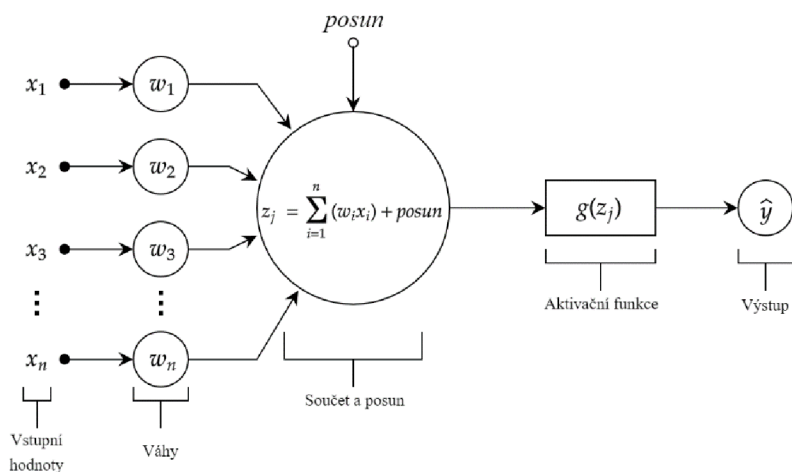
K detekci hran se obvykle používají gradientní operátory, např. Cannyho hranový detektor. Protože výstupem gradientního operátoru je obraz, kde jsou sice hrany zvýrazněny, ale může obsahovat další artefakty odpovídající lokálním nehomogenitám v obraze, je třeba obraz dále upravit. Vzhledem ke svým vlastnostem mohou detektory hran vytvářet přerušované hranice i falešné hranice, obraz hranic je tedy třeba dále zpracovat (Parthasarathy et al., 2019).

3 Úvod do neuronových sítí

Neuronové sítě představují spojení biologie a výpočetní vědy a čerpají hlubokou inspiraci ze složité sítě neuronů v lidském mozku. Podstatou neuronových sítí jsou výpočetní modely určené ke zpracování informací způsobem, který připomíná fungování našeho mozku. Jsou postaveny na principu učení se z dat, podobně jako se lidé učí ze zkušeností. Postupem času, jak jsou vystaveny většímu množství dat, upravují a zpřesňují své vnitřní parametry, aby zlepšily své předpovědi nebo rozhodnutí (Goodfellow et al., 2016).

Základní mechanismus neuronové sítě spočívá ve schopnosti přijímat vstupy, zpracovávat je prostřednictvím řady propojených neuronů a vytvářet výstup. Tento proces, známý jako dopředná propagace (angl. forward propagation), zahrnuje přenos dat sítí, přičemž každý neuron provádí specifické transformace dat. Neurony v těchto sítích jsou uspořádány do vrstev: vstupní vrstva, jedna nebo více skrytých vrstev a výstupní vrstva. Jak data procházejí těmito vrstvami, procházejí transformacemi diktovanými váhami spojů mezi neurony (Goodfellow et al., 2016).

Při první inicializaci však neuronová síť neposkytuje přesné předpovědi, protože její váhy jsou nastaveny téměř náhodně. Síť se musí naučit optimální váhy z dat, na kterých je učená. Toto učení se provádí během takzvané zpětné propagace (angl. back propagation). Poté, co dopředná propagace vytvoří výstup, síť vypočítá svou chybu (rozdíl mezi předpovídaným a skutečným výstupem). Pomocí zpětné propagace se pak tyto váhy upraví tak, aby se chyba minimalizovala. Během dalších iterací neuronová síť konverguje ke stavu, kdy jsou její předpovědi tak přesné, jak mohou být vzhledem k její architektuře a datům, na kterých byla naučená (Goodfellow et al., 2016).



Obrázek 1: umělý neuron

3.1 Trénování neuronových sítí

Hlavním cílem při trénování neuronové sítě je dosáhnout co nejnižšího součtu hodnot variance a biasu (angl. bias of an estimator). Zpočátku je variance nízká a cílem je udržet jej nebo dále snižovat v průběhu trénování. Naopak bias je na začátku velký a cílem je jej v průběhu učení snižovat (Goodfellow et al., 2016).

Trénování si lze představit jako šíření signálů neuronovou sítí a následnou úpravou matic vah jednotlivých vrstev pomocí algoritmu zpětné propagace. Tento proces úpravy se opakuje, dokud se nezdá, že variance a bias jsou minimální (Goodfellow et al., 2016).

Obvykle se dostupná data rozdělí na trénovací a validační sady. Toto rozdělení pomáhá sledovat přetrénování. Pokud se chyba na validační sadě přestane snižovat, znamená to, že nastal vhodný čas trénování ukončit. Dále jsou tyto sady dat rozděleny do "dávek". Tento přístup zajišťuje, že k úpravám vah dochází po zpracování celé dávky, a nikoli každého jednotlivého vstupu nebo celé sady dat. Tato metoda nejen zabraňuje brzkému přetrénování, ale také urychluje učení sítě, protože vstupy v rámci dávky mohou být zpracovávány současně. Před rozdělením do dávek se celá trénovací sada dat náhodně promíchá. Velikost dávek se určuje na základě celkové velikosti trénovací sady dat a možností hardwaru (Goodfellow et al., 2016).

Algoritmus zpětné propagace

Algoritmus zpětné propagace zahrnuje porovnání výstupu neuronové sítě s výsledkem žadáním, aby se určil gradient chyby. Tento gradient se vypočítá jako parciální derivace funkce tvořené jednotlivými váhami každého neuronu. Tento výpočet se provádí pro každou vrstvu neuronové sítě. Konceptně gradient chyby udává směr pro úpravu vah tak, aby se minimalizovala chyba. Velikost těchto úprav se řídí hyperparametrem „learning rate“ (Goodfellow et al., 2016).

3.2 Hodnocení úspěšnosti

Efektivitu sítě hodnotí různé ukazatele. V závislosti na úloze mohou být vhodnější specifické metriky, které přesně odrážejí schopnost sítě řešit problémy. Pro úlohy klasifikace se používá několik klíčových metrik, o kterých bude řečeno v další části textu.

Důležité pojmy

V případě kategorizace ano/ne v problému můžeme kategorii "ano" prezentovat jako pozitivní a kategorii "ne" jako negativní.

- Skutečně pozitivní (TP) je počet obrázků, které patří do pozitivní kategorie a které síť rovněž klasifikuje jako pozitivní.
- Skutečně negativní (TN) je počet obrázků, které patří do negativní kategorie a zároveň je síť klasifikovala jako negativní.
- Falešně pozitivní (FP) je počet obrázků, které patří do negativní kategorie, zatímco síť je klasifikovala jako pozitivní.
- Falešně negativní (FN) je počet obrázků, které patří do pozitivní kategorie, zatímco síť je klasifikovala jako negativní.

Accuracy

Accuracy je to, co obvykle máme na mysli, když používáme termín „přesnost“. Je to poměr počtu správných předpovědí k celkovému počtu vstupních vzorků. Accuracy lze vypočítat jako:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision

Precision je počet skutečně pozitivních výsledků dělený počtem pozitivních výsledků předpovězených klasifikátorem. Precision lze vypočítat jako:

$$Precision = \frac{TP}{TP + FP}$$

Recall

Recall je počet skutečně pozitivních výsledků vydělený počtem všech relevantních vzorků (všechny vzorky, které měly být identifikovány jako pozitivní). Recall lze vypočítat jako:

$$Recall = \frac{TP}{TP + FN}$$

F1 score

F1 score je harmonický průměr precision a recall. Rozsah F1 score je [0, 1]. Ukazuje, jak je klasifikátor přesný (kolik případů klasifikuje správně), a také jak je robustní (nevynechá významný počet případů).

Vysoký precision, ale nižší recall, dává extrémně přesný výsledek, ale pak vynechává velké množství případů, které je obtížné klasifikovat. Čím vyšší je F1 score, tím lepší je výkon modelu. Matematicky jej lze vypočítat takto:

$$F1 = 2 * \frac{1}{\frac{1}{Precision} + \frac{1}{Recall}}$$

4 Analýza současného stavu problematiky

Téma detekce mozkových nádorů pomocí neuronových sítí se rychle rozvíjí a objevuje se několik moderních výzkumných trendů. Tyto trendy jsou důsledkem pokroků v architekturách neuronových sítí a technikách zpracování dat.

Pokročilé architektury konvolučních neuronových sítí

Modely hlubokého učení: vědci stále častěji zkoumají modely hlubokého učení, jako jsou U-Net, V-Net a jejich varianty, pro lepší segmentaci a klasifikaci obrazů. Tyto modely jsou známé svou schopností zachytit složité detaily a prostorové hierarchie na snímcích MR.

Transfer Learning

Využití předtrénovaných modelů na velkých souborech dat a jejich přizpůsobení úlohám detekce mozkových nádorů ukázalo perspektivní výsledky. Tento přístup využívá znalosti získané z rozsáhlých, různorodých souborů dat, čímž zvyšuje přesnost a snižuje potřebu rozsáhlých trénovacích dat specifických pro mozkové nádory.

Integrace multimodálních dat

Vědci kombinují různé modalitty MR, například sekvence T1-vážené, T2-vážené a FLAIR, aby poskytli detailnější pohled na mozkové nádory. Taková integrace zvyšuje kontrast a detaily využitelné pro analýzu neuronovými sítěmi, což vede k přesnější detekci a segmentaci.

Automatické a polo-automatické detekční systémy

Cílem vývoje automatických a polo-automatických systémů využívajících neuronové sítě je snížit pracovní zatížení radiologů. Tyto systémy mohou rychle analyzovat snímky MR, označovat potenciální nádory a pomáhat při předběžné diagnostice.

Literární rešerše

Zexun et al. (2020) navrhli model založený na CNN pro segmentaci, který řeší dva hlavní problémy: prvním problémem je nedostatek prostorových informací a druhým

problémem je nedostatečná schopnost vícestupňového procesu. Pro řešení prvního problému byla použita implementace 3D Atrous konvoluce, zatímco ke zvýšení schopnosti modelu zpracovávat informace ve více měřících byl integrován modul pyramid pooling. Výkonnost tohoto modelu byla posouzena na různých souborech dat BRATS a prokázala značnou přesnost segmentace. Na datasetu BRATS2018 dosáhl Diceův koeficient WT 0.8658, TC 0.7688 a EC 0.74434.

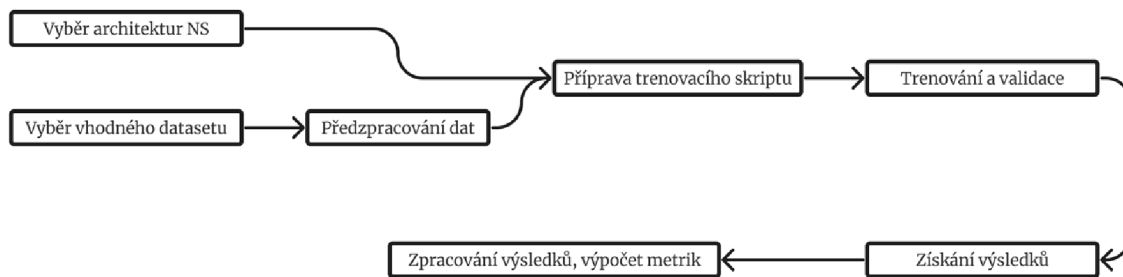
Sharma et al. (2021) vyvinuli klasifikační model využívající principy transfer learning. Tento model byl navržen jako binární klasifikátor. Při použití modelu VGG16 v rámci jimi navržené architektury dosáhli 96,5% přesnosti při trénování a 90% přesnosti při testování na veřejně dostupném datasetu.

Chandan Ganesh et al. (2020) navrhli model pro segmentaci mozkových nádorů, který využívá architekturu 3D-Dense U-Net pro zjednodušení vícestupňového procesu segmentace. Jejich výsledky na různých datových sadách BRATS naznačily značnou přesnost při segmentaci nádorů. V případě datasetu BRATS2018 byl Diceův koeficient WT 0.90, TC 0.82 a EC 0.80.

M. Mohammed Thaha et al. (2019) vyvinuli model založený na CNN využívající pro segmentaci algoritmus BAT, kde byla menším jádrům v modelu přiřazena menší váha, což zvýšilo účinnost modelu. Model prošel kroky předzpracování, jako je odstranění lebky z obrazů a potlačení šumu. Výsledky ukázaly, že accuracy navrženého modelu byla 92 %, precision 87 % a recall 90 % pro segmentaci na datasetu BRATS2015.

Talo et al. (2019) vytvořili metodu využívající různé architektury hlubokého učení, včetně VGG-16, AlexNet a ResNet, pro klasifikaci snímků MR. Tento automatizovaný postup byl testován na velkém souboru dat z Harvard Medical School a prokázal vysokou přesnost při klasifikaci mozkových nádorů. Výsledky navrženého řešení ukázaly, že nejvyšší přesnost 95.23 % byla dosáhnuta pomocí modelu ResNet50.


5 Metody pro klasifikaci



Obrázek 2: schéma pracovního postupu

Na začátku bylo vybráno 7 populárních architektur konvolučních neuronových sítí, které jsou určeny pro klasifikaci obrazů. Jejich popularita je dána jejich významným přínosem k vývoji neuronových sítí jako takových, tj. použité modely byly v té či oné části inovativní pro období, kdy byly vyvinuty.

Jako zdroj obrazových dat pro úlohu klasifikace byl zvolen dataset z volně přístupného zdroje, který byl zase shromážděn ze tří dalších zdrojů. Dataset se skládá ze 7221 obrázků a 4 tříd. Třídy představují typy nádorů nebo absenci nádoru ("meningiom", "gliom", "nádor hypofýzy" a "bez nádoru"). Nevýhodou zvoleného souboru dat je, že není zaručeno, že všechny snímky jsou klasifikovány správně. Je třeba také zmínit, že data ve třídě "absence nádoru" jsou velmi různorodá, tj. skládají se ze snímků pořízených různými režimy magnetické rezonance a mají nízkou kvalitu (příliš nízký nebo vysoký kontrast; příliš nízká nebo vysoká ostrost; nekvalitní ořez; přítomnost cizích informací, které nesouvisejí se samotnými daty ze snímku magnetické rezonance) (Nickparvar, 2021).



Obrázek 3: příklady snímků z datasetu

Spolu s výběrem datasetů bylo nutné připravit pomocné skripty pro jejich zpracování a také skripty pro trénování a validaci modelů neuronových sítí, export získaných výsledků a výpočet příslušných metrik.

Důležitým bodem, který stojí za zmínku, je použití techniky transfer learning, která využívá hotové modely neuronových sítí s upravenými vlastnostmi výstupní vrstvy. Původně byly modely předtrénovány na datasetu ImageNet, který obsahuje 1000 tříd obrázků, zatímco soubor dat použitý v této práci obsahuje pouze 4 třídy. Pro urychlení trénování byly použity váhy získané z trénování sítě na datech ImageNet.

Jako programovací jazyk byl zvolen Python vzhledem k jeho jednoduchosti a dostupnosti hotových veřejných knihoven pro práci s neuronovými sítěmi. Volba mezi knihovnami pro práci s neuronovými sítěmi byla provedena ve prospěch PyTorch kvůli jeho většímu zaměření na objektově orientovaný styl psaní kódu. Jako prostředí pro psaní kódu byl zvolen Jupyter Notebook, který umožňuje spouštět kód po částech, čímž se zjednodušuje proces odladění.

Vzhledem k velkým nárokům neuronových sítí na výpočetní výkon bylo rozhodnuto použít cloudovou platformu Colaboratory společnosti Google, se kterou

se pracuje prostřednictvím webového prohlížeče. Platforma poskytuje zdarma výpočetní akceleraci pomocí grafické karty NVIDIA Tesla T4, což mnohonásobně zkracuje dobu trénování neuronových sítí ve srovnání s CPU.

5.1 Předzpracování datasetů

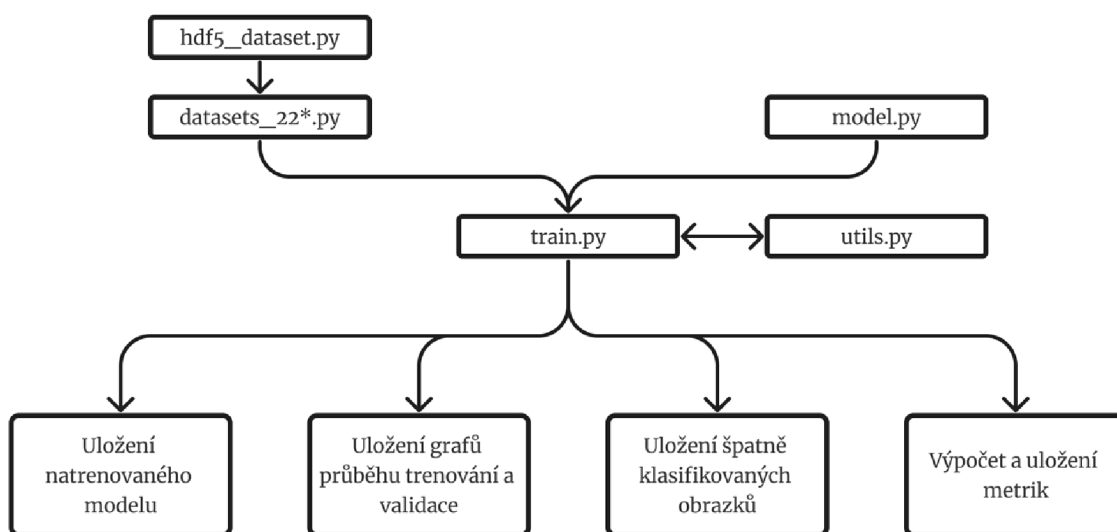
Pro další práci s datasetem bylo nutné jej zpracovat, a to:

- 1) Upravit rozlišení všech snímků na stejnou hodnotu.
- 2) Sestavit datasety pro trénování a validaci náhodně při zachování původních poměrů tříd. Trénovací soubor by měl obsahovat 80 % všech snímků.
- 3) Normalizovat data podle průměru a směrodatné odchylky datasetu ImageNet.
- 4) Uložit sady jako soubory HDF, aby se zkrátila doba přístupu k datům a následně i doba trénování a validace.

Pro automatizaci zpracování a interakce s datasety byly připraveny skripty *jpg2hdf5.py*, *datasets_224.py*, *datasets_227.py* a *hdf5_dataset.py*. První skript změni rozlišení obrázků JPEG na danou hodnotu, rozdělí je do sad pro trénování a validaci při zachování poměrů tříd v každé sadě a poté vytvoří soubor HDF5, který ve své struktuře obsahuje 2 datasety. První dataset "images" je čtyřrozměrná matice o velikosti *počet obrázků * délka * šířka * počet kanálů* a obsahuje obrázky dané sady. Druhý dataset "labels" je vektor o délce počtu obrázků a obsahuje čísla tříd pro každý obrázek z datasetu "images".

Zbývající skripty jsou určeny k interakci s datasety během trénování a validace neuronové sítě. Princip jejich fungování bude popsán v následující podkapitole.

5.2 Příprava trénovacího a pomocných skriptů



Obrázek 4: schéma interakce skriptů

Úloha přípravy skriptu pro trénování a validaci byla rozdělena na dílčí části, aby se zjednodušila interakce a odladění celého algoritmu. Schematické znázornění řešení této úlohy je uvedeno na obrázku níže.


Skript *hdf5_dataset.py* obsahuje popis třídy "HDF5Dataset" a její metody. Metodami této třídy jsou "len", která vrací počet obrázků v datové sadě, a "getitem", která vrací obrázek typu "PIL Image" pro další práci s ním při trénování a validaci neuronové sítě.

Skripty *datasets_224.py* a *datasets_227.py* popisují funkce transformace obrázků pro trénování a validaci, přípravu datasetů ve formě vhodné pro neuronovou síť a přípravu dávek pro rychlejší a optimálnější proces trénování a validace.

Skript *train.py* je hlavním skriptem tohoto řetězu. Skript přijímá jako vstupní argumenty "-e", který definuje počet epoch pro trénování, a "-lr" pro změnu parametru "learning rate". Skript pak popisuje dvě funkce pro trénování a validaci. Funkce pro trénování přijímá jako vstup model neuronové sítě, "dávkače" dat z datasetu, typ optimalizátoru a kritérium, podle kterého má být síť trénována, a po každé natrénované epoše vrací hodnoty "loss" a "accuracy". Validací funkce je v podstatě totéž, ale kromě samotného procesu validace ukládá chybně klasifikované obrázky podle nejlepší iterace modelu. Ve své hlavní části skript vypisuje do konzole informace o datasetu, zařízení, na kterém budou výpočty prováděny, hodnotu parametru „learning rate“, počet epoch pro trénování, počet všech parametrů modelu neuronové sítě a počet trénovaných

parametrů. Dále se definuje typ optimalizátoru a kritérium učení a přímo se zavolá cyklus pro trénování. Po provedení cyklu jsou volány funkce pro uložení natrénovaného modelu, grafů průběhu trénování, matice chyb a chybně klasifikovaných obrázků. Tyto funkce jsou popsány ve skriptu *utils.py*.

Pro vyzkoušení natrénovaného modelu byl vytvořen skript *inference.py*, který načte uložený model, načte obrázky pro klasifikaci a exportuje výsledky v podobě stejných obrázků doplněných textem se skutečnou a předpovězenou hodnotami.



Obrázek 5: příklad výsledku skriptu *inference.py*

Dosáhnuté hodnoty accuracy, loss a dalších metrik jsou dostupné v [příloze A](#).

5.3 Popis klíčových vlastností použitých architektur

Název	Počet parametru	Rok vydání
VGG16	134 276 932	2014
EfficientNetV2-L	118 520 396	2021
AlexNet	57 020 228	2012
ResNet50	23 516 228	2015
EfficientNet_B4	19 348 788	2019
GoogLeNet	11 983 988	2014
MobileNetV3-Small	1 521 956	2019

Tabulka 1: použité architektury neuronových sítí pro klasifikaci

AlexNet byla představena v roce 2012 a jedná se o revoluční konvoluční neuronovou síť, která zvítězila v soutěži ImageNet Large Scale Visual Recognition Challenge. Skládá se z pěti konvolučních vrstev a tří plně propojených vrstev. Zpopularizovala použití ReLU a dropout (Krizhevsky et al., 2014).

VGG16 má jednoduchou a jednotnou architekturu s 16 váhovými vrstvami, které používají malé konvoluční filtry 3x3. Je známá svou hloubkou a homogenní strukturou, díky čemuž je snadno pochopitelná a implementovatelná (Simonyan a Zisserman, 2015).

GoogLeNet je známý svým modulem inception, který používá více paralelních konvolučních filtrů různých velikostí v jedné vrstvě. Cílem této architektury je zachytit rysy v různých měřítkách a dosáhnout dobré přesnosti při zmenšení počtu parametrů. Zavedla koncept "inception" sítě (Szegedy et al., 2014).

ResNet řeší problém mizejícího gradientu zavedením reziduálních spojů. Konkrétně síť ResNet50 má 50 vrstev a využívá reziduální bloky, což usnadňuje trénování velmi hlubokých sítí. Díky reziduálním spojům umožňuje snadnější "tok" gradientu během zpětného šíření (Kaiming et al., 2015).

EfficientNet se zaměřuje na vyvážení přesnosti modelu a výpočetní efektivity. Používá metodu "compound scaling" a zahrnuje optimalizaci squeeze-and-excitation v rámci bloků (Mingxing a Quoc V., 2020).

MobileNetV3-Small je optimalizovanou verzí MobileNetů pro mobilní a okrajová zařízení se zaměřením na snížení výpočetní náročnosti. Používá odlehčené hloubkově separovatelné konvoluce, optimalizovanou verzi struktury invertovaných reziduí a zapojuje aktivační funkci h-swish (Howard et al., 2019).

EfficientNetV2 představuje vylepšení rodiny EfficientNet se zaměřením na rychlost trénování a efektivitu parametrů. Zahrnuje techniku progresivního učení, vrstvy Fused-MBConv pro rychlejší trénování a vylepšené metody stupňování pro lepší efektivitu (Mingxing a Quoc V., 2021).

6 Diskuze

Výsledkem získaných experimentů je, že mezi všemi použitými architekturami nelze provést jednoznačnou volbu. Všechny modely vykazovaly vysokou přesnost v kontextu problému klasifikace mozkových nádorů na snímcích MR. Nejnižší přesnost byla 98,6 % a nejvyšší 99,5 %. Modely EfficientNetV2-L a ResNet50 si vedly nejlépe, pokud jde o jejich kombinovaný výkon.

Dále lze diskutovat o souvisejících charakteristikách modelů, konkrétně o výpočetní náročnosti trénování těchto modelů. Obecně lze konstatovat, že počet parametrů koreluje s množstvím paměti potřebné k výpočtu a také s časem stráveným trénováním. Tento úsudek však ne vždy funguje, zejména v souvislosti s nejnovějšími modely, které kladou důraz i na efektivitu trénování. V tomto aspektu se nejlépe osvědčil model MobileNetV3-S, který je koncepčně určen pro mobilní zařízení. Trénování modelu VGG16 trvalo nejdéle kvůli velkému počtu parametrů a absenci moderních optimalizačních metod.

7 Závěr

Cílem této práce bylo prozkoumat možnosti moderních architektur neuronových sítí v kontextu detekce mozkových nádorů na snímcích magnetické rezonance. Nejprve byl čtenář seznámen s obecnými pojmy používanými v oblasti hlubokého učení, následoval stručný přehled existujících řešení. V praktické části práce byly rozebrány principy fungování vytvořených skriptů. Nedílnou součástí bylo předzpracování datové sady pro možnost jejího využití s vybranými modely. Důležitým detailem bylo získání potřebných metrik a chybně klasifikovaných snímků pro vyhodnocení výkonnosti vybraných modelů neuronových sítí. Jako nejpřesnější se ukázal model EfficientNetV2-L, což však neznamená, že je nejlepší. Byl učiněn závěr, že výběr by měl být proveden komplexně a měl by zahrnovat všechny aspekty modelů, včetně jejich závislosti na výpočetním výkonu.

8 Seznam použité literatury

1. GOODFELLOW, Ian; BENGIO, Yoshua a COURVILLE, Aaron. *Deep Learning*. online. MIT Press, 2016. ISBN 978-0262035613. Dostupné z: <http://www.deeplearningbook.org>.
2. HOWARD, Andrew; SANDLER, Mark; CHU, Grace; LIANG-CHIEH, Chen; BO, Chen et al. Searching for MobileNetV3. online. *ArXiv*. (2019). Dostupné z: <https://doi.org/10.48550/arXiv.1905.02244>.
3. CHANDAN GANESH, Bangalore Yogananda; BHAVYA R., Shah; VEJDANI-JAHROMI, Maryam; SAHIL S., Nalawade; GOWTHAM K., Murugesan et al. A Fully Automated Deep Learning Network for Brain Tumor Segmentation. Online. *Tomography*, roč. 6 (2020), s. 186-193. Dostupné z: <https://doi.org/10.18383/j.tom.2019.00026>.
4. JENSEN, Todd a SCHMAINDA, Kathleen. Computer-aided detection of brain tumor invasion using multiparametric MRI. online. *Journal of Magnetic Resonance Imaging*., roč. 30 (2009), č. 3, s. 481-489. Dostupné z: <https://doi.org/10.1002/jmri.21878>.
5. KAIMING, He; XIANGYU, Zhang; SHAOQING, Ren a JIAN, Sun. Deep Residual Learning for Image Recognition. online. *ArXiv*. (2019). Dostupné z: <https://doi.org/10.48550/arXiv.1512.03385>.
6. KRIZHEVSKY, Alex; SUTSKEVER, Ilya a HINTON, Geoffrey E. ImageNet classification with deep convolutional neural networks. online. *Communications of the ACM*, roč. 60 (2014), s. 84–90. Dostupné z: <https://doi.org/10.1145/3065386>.
7. KURIAN, Simy Mary a JULIET, Sujitha. An automatic and intelligent brain tumor detection using Lee sigma filtered histogram segmentation model. online. *Soft Comput*, (2023), č. 27, s. 13305–13319. Dostupné z: <https://doi.org/10.1007/s00500-022-07457-2>.
8. LEENA, B. a JAYANTHI, A.N. Automatic Brain Tumor Classification via Lion Plus Dragonfly Algorithm. online. *Journal of Digital Imaging*, roč. 35 (2022), č. 1, s. 1382–1408. Dostupné z: <https://doi.org/10.1007/s10278-022-00635-6>.
9. MINGXING, Tan a QUOC V., Le. EfficientNetV2: Smaller Models and Faster Training. online. *ArXiv*. (2021). Dostupné z: <https://doi.org/10.48550/arXiv.2104.00298>.

10. MINGXING, Tan a QUOC V., Le. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. online. *ArXiv*. (2020). Dostupné z: <https://arxiv.org/abs/1905.11946>. [cit. 2023-12-07].
11. M., Mohammed Thaha; K. PRADEEP, Mohan Kumar; B. S., Murugan; S., Dhanasekeran; P., Vijayakarhick et al. Brain Tumor Segmentation Using Convolutional Neural Networks in MRI Images. online. *Image & Signal Processing*, roč. 43 (2019). Dostupné z: <https://doi.org/10.1007/s10916-019-1416-0>.
12. NEHA, Sharma; MRADUL, Kumar Jain; NIRVIKAR a AMIT, Kumar Agarwal. BRAIN TUMOR CLASSIFICATION USING CNN. online. *Advances and Applications in Mathematical Sciences*, (2021), č. 20, s. 397-407. ISSN 0974-6803. Dostupné z: https://www.mililink.com/upload/article/1048930935aams_vol_203_january_2020_a8_p397-407_neha_sharma_and_amit_kumar_agarwal.pdf.
13. NICKPARVAR, Masoud. *Brain Tumor MRI Dataset*. JPEG obrázky; online. In: Kaggle. Aktualizace 24. září 2021 [2021-09-24]. Dostupné z: <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>. [152,1 MB]
14. OPENAI. ChatGPT. Webové sídlo. 2022. Archivní kopie dostupná z: Internet Archive (distributor), <https://web.archive.org/web/20231206220847/https://chat.openai.com/web/20231206220847/https://chat.openai.com/>. [archivováno 2023-06-12]. [citováno 2023-10-30].
15. PARTHASARATHY, G.; RAMANATHAN, L.; ANITHA, K. a JUSTINDHAS, Y. Predicting Source and Age of Brain Tumor Using Canny Edge Detection Algorithm and Threshold Technique. online. *Asian Pacific Journal of Cancer Prevention*, roč. 20 (2019), č. 5, s. 1409-1414. Dostupné z: <https://doi.org/10.31557/APJCP.2019.20.5.1409>.
16. SIMONYAN, Karen a ZISSERMAN, Andrew. Very Deep Convolutional Networks for Large-Scale Image Recognition. online. *ArXiv*. (2015). Dostupné z: <https://doi.org/10.48550/arXiv.1409.1556>.
17. SZEGEDY, Christian; WEI, Liu; YANGQING, Jia; SERMANET, Pierre; REED, Scott et al. Going Deeper with Convolutions. online. *ArXiv*. (2014). Dostupné z: <https://doi.org/10.48550/arXiv.1409.4842>.
18. TALO, Muhammed; YILDIRIM, Ozal; BAGOGLU, Ulas Baran; AYDIN, Galip a RAJENDRA ACHARYA, U. Convolutional neural networks for multi-class brain disease detection using MRI images. online. *Computerized Medical Imaging*

and Graphics, roč. 78 (2019). ISSN 0895-6111.

Dostupné z: <https://doi.org/10.1016/j.compmedimag.2019.101673>.

19. ZEXUN, Zhou; ZHONGSHI, He a YUANYUAN, Jia. AFPNet: A 3D fully convolutional neural network with atrous-convolution feature pyramid for brain tumor segmentation via MRI images. online. *Neurocomputing*, (2020), č. 402, s. 235-244.

Dostupné z: <https://doi.org/10.1016/j.neucom.2020.03.097>.



Příloha A

Výsledky použitých modelů



Dosáhnuté hodnoty metrik:

Název	Třída	Meningeom	Gliom	Nádor hypofýzy	Absence nádoru
	VGG16	Precision	0.985	0.979	0.994
	Recall	0.985	0.994	0.989	0.993
	F1 Score	0.985	0.986	0.992	0.997
EfficientNetV2-L	Precision	0.988	1	1	0.993
	Recall	0.994	0.991	0.994	1
	F1 Score	0.991	0.995	0.997	0.997
AlexNet	Precision	0.956	1	0.997	0.993
	Recall	0.988	0.972	0.989	0.996
	F1 Score	0.972	0.986	0.993	0.994
ResNet50	Precision	0.973	1	1	1
	Recall	1	0.994	0.992	0.991
	F1 Score	0.987	0.997	0.996	0.996
EfficientNet-B4	Precision	0.968	0.997	1	1
	Recall	0.997	0.978	0.989	1
	F1 Score	0.982	0.988	0.994	1
GoogLeNet	Precision	0.982	0.985	1	0.998
	Recall	0.985	0.991	0.989	1
	F1 Score	0.983	0.988	0.994	0.999
MobileNetV3-Small	Precision	0.953	1	0.994	0.996
	Recall	0.994	0.960	0.992	0.996
	F1 Score	0.973	0.980	0.993	0.996



Grafy průběhů hodnot accuracy a loss během fází trénování a validace:



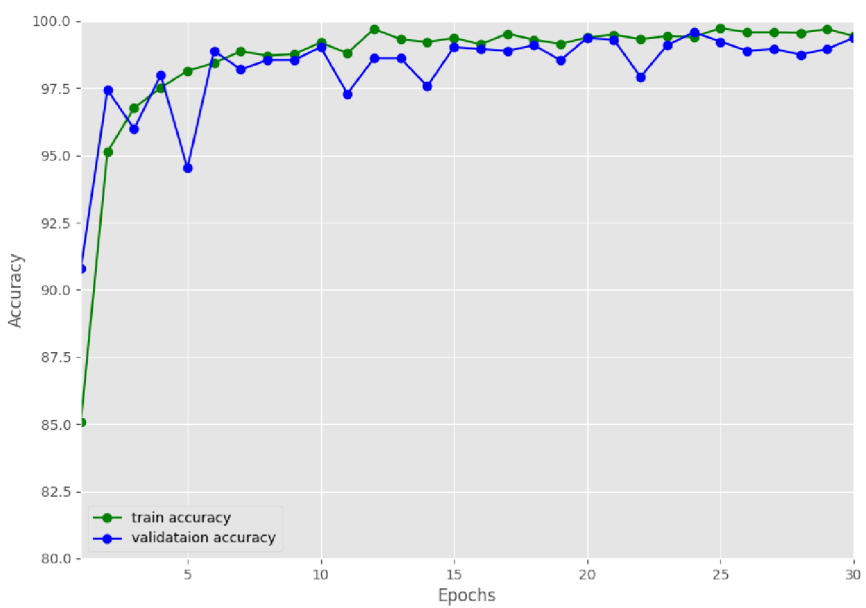

VGG16





EfficientNetV2-L



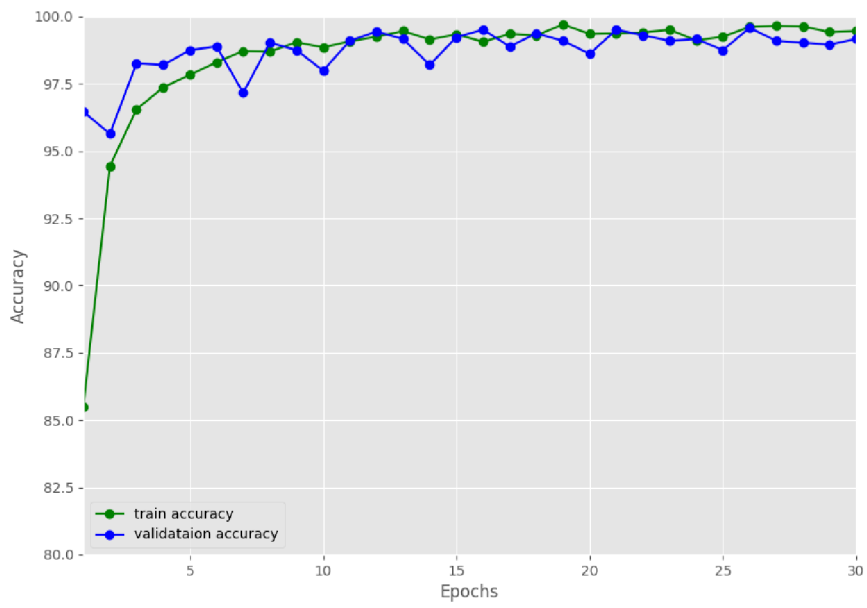

AlexNet





ResNet50



EfficientNet-B4



GoogLeNet



MobileNetV3-S