



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY

A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV TELEKOMUNIKACÍ

DEPARTMENT OF TELECOMMUNICATIONS

TRÉNOVATELNÁ SEGMENTACE OBRAZU S POUŽITÍM HLUBOKÝCH NEURONOVÝCH SÍTÍ

TRAINABLE IMAGE SEGMENTATION USING DEEP NEURAL NETWORKS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Martin Majtán

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Pavol Harár

BRNO 2016

ABSTRAKT

Diplomová práca sa zaoberá segmentáciou obrazu pomocou hlbokých neuronových sietí. V práci je popísaný princíp digitálneho spracovania obrazu a segmentácia obrazu. Je tu vysvetlený princíp umelých neuronových sietí, model umelého neurónu, spôsob ako sa neuronové siete trénujú a aktivujú. V praktickej časti je vytvorený algoritmus na generovanie podobrazov zo snímok z magnetickej rezonancie. Vygenerované podobrazy sa používajú na trénovanie, testovanie a validáciu modelu neuronovej siete. V práci je vytvorený model umelej neuronovej siete, ktorí bol použitý pri trénovateľnej segmentácii obrazu. Model neuronovej siete je vytvorený pomocou knižnice Deeplearning4j a je optimalizovaný na paralelné trénovanie pomocou knižnice Spark.

KLÚČOVÉ SLOVÁ

konvolučné neuronové siete, hlboké učenie, trénovateľná segmentácia, MRI, roztrúsená skleróza, Deeplearning4j, Spark

ABSTRACT

Diploma thesis is aimed to trainable image segmentation using deep neural networks. In the paper is explained the principle of digital image processing and image segmentation. In the paper is also explained the principle of artificial neural network, model of artificial neuron, training and activation of artificial neural network. In practical part of the paper is created an algorithm of sliding window to generate sub-images from image from magnetic resonance. Generated sub-images are used to train, test and validate of the model of neural network. In practical part of the paper si created the model of the artificial neural network, which is used to trainable image segmentation. Model of the neural network is created using the Deeplearning4j library and it is optimized to parallel training using Spark library.

KEYWORDS

convolution neural network, deep learning, trainable segmentation, MRI, multiple sclerosis, Deeplearning4j, Spark

MAJTÁN, Martin *Trénovateľná segmentace obrazu s použitím hlbokých neuronových sietí*: diplomová práca. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačných technológií, Ústav telekomunikací, 2016. 48 s. Vedúci práce bol Ing. Pavol Harár,

PREHLÁSENIE

Prehlasujem, že som svoju diplomovú prácu na tému „Trénovateľná segmentace obrazu s použitím hlubokých neuronových sítí“ vypracoval(a) samostatne pod vedením vedúceho diplomovej práce, využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor(ka) uvedenej diplomovej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušil(a) autorské práva tretích osôb, najmä som nezasiahol(-la) nedovoleným spôsobom do cudzích autorských práv osobnostných a/nebo majetkových a som si plne vedomý(-á) následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona č. 121/2000 Sb., o právu autorskom, o právach súvisejúcich s právom autorským a o zmeně niektorých zákonov (autorský zákon), vo znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákoníka č. 40/2009 Sb.

Brno

.....

podpis autora(-ky)

POĎAKOVANIE

Rád by som poďakoval mojej rodine a priateľke za podporu a rady pri vypracovávaní diplomovej práce a vedúcemu diplomovej práce pánovi Ing. Pavlovi Harárovi za odborné vedenie, konzultácie, trpezlivosť a podnetné návrhy k práci.

Brno

.....

podpis autora(-ky)



Faculty of Electrical Engineering
and Communication
Brno University of Technology
Purkynova 118, CZ-61200 Brno
Czech Republic
<http://www.six.feec.vutbr.cz>

POĎAKOVANIE

Výzkum popsaný v tejto diplomovej práci bol realizovaný v laboratóriách podporených projektom SIX; registračné číslo CZ.1.05/2.1.00/03.0072, operačný program Výzkum a vývoj pro inovace.

Brno

.....

podpis autora(-ky)



EVROPSKÁ UNIE
EVROPSKÝ FOND PRO REGIONÁLNÍ ROZVOJ
INVESTICE DO VAŠÍ BUDOUCNOSTI



OBSAH

Úvod	9
1 Neurónové siete	10
1.1 Biologické neurónové siete	10
1.2 Umelé neurónové siete	11
1.2.1 Model umelého neurónu	11
1.2.2 Topológia umelej neurónovej siete	13
1.2.3 Trénovanie umelej neurónovej siete	14
1.2.4 Aktivácie umelej neurónovej siete	15
1.3 Konvolučné siete	16
1.3.1 Prezorkovanie obrazu	17
1.3.2 Možnosti konvolučných sietí	17
2 Popis problému	18
2.1 Spracovanie digitálneho obrazu	18
2.2 Segmentácia obrazu	19
2.2.1 Trénovateľná segmentácia obrazu	20
2.3 Roztrúsená skleróza	20
2.3.1 Diagnostika roztrúsenej sklerózy	21
2.3.2 Detekcia roztrúsenej sklerózy s neurónovou sieťou	22
3 Praktická časť	24
3.1 Použitý software a hardware	24
3.1.1 Použitý software	24
3.1.2 Použitý hardware	25
3.2 Príprava dát pre neurónovú sieť	25
3.2.1 Algoritmus klzajúceho okna	25
3.2.2 Normalizácia podobrazov	27
3.3 Model umelej neurónovej siete	28
3.3.1 Hodnotenie modelu neurónovej siete	28
3.3.2 Optimalizácia tréovania modelu neurónovej siete	29
3.3.3 Realizácia modelu neurónovej siete	31
3.3.4 Trénovanie modelu neurónovej siete	32
3.4 Dosiahnuté výsledky	33
4 Záver	38
Literatúra	40

Zoznam symbolov, veličín a skratiek	44
Zoznam príloh	45
A Obsah priloženého CD	46
A.1 Použité triedy v praktickej časti	46
A.2 Postup pri použití modelu UNS	46
A.3 Adresárová štruktúra priloženého CD	47

ZOZNAM OBRÁZKOV

1.1	Biologický model neurónu. Obrázok prevzatý z [4].	10
1.2	Model umelého neurónu.	12
1.3	Lineárne neseparovateľný a lineárne separovateľný problém.	13
1.4	Obrázok znázorňuje topológiu viac-vrstvej neurónovej siete.	14
1.5	Zobrazenie iteračného aktivovania.	16
1.6	Podvzorkovanie obrazu (Maxpooling), veľkosť filtru 2×2 pixely. . . .	17
2.1	Zobrazenie snímku (vľavo) a segmentovaného snímku (vpravo).	19
2.2	Zobrazenie zdravého a poškodeného myelínového obalu neurónu.[38]	22
3.1	Snímok z magnetickej rezonancie a maska k snímku.	26
3.2	Vygenerované podobrazy, trieda true (a) a b)), trieda false (c))	27
3.3	Zobrazenie iteratívneho procesu MapReduce.	30
3.4	Zobrazenie pretrénovania neurónovej siete.	32
3.5	Originálny snímok (vľavo), segmentovaný snímok UNS (v strede, prah 0,5) a maska snímku (vpravo).	35
3.6	Originálny snímok (vľavo), segmentovaný snímok UNS (v strede, prah 0,99) a maska snímku (vpravo).	36

ÚVOD

Digitálne spracovanie obrazu je v súčasnosti dôležitou a rozvíjajúcou sa oblasťou ktorá sa využíva v automobilovom priemysle, v medicíne, v oblasti automatizácie a v ďalších odvetviach. Do oblasti digitálneho spracovania obrazu patrí aj segmentácia obrazu. Diplomová práca sa zaoberá trénovateľnou segmentáciou obrazových dát s využitím hlbokých neuronových sietí. Diplomová práca je rozdelená do troch kapitol.

Prvá kapitola diplomovej práce sa zaoberá teoretickými aspektami neuronových sietí. V prvej kapitole sú popísané biologické a umelé neuronové siete. Je tu popísaný model umelého neurónu, topológia umelej neuronovej siete a spôsob trénovania a aktivovania umelých neuronových sietí. V prvej kapitole je tiež vysvetlený princíp konvolučných sietí a ich možnosti pri klasifikovaní objektov v obraze.

Druhá kapitola sa venuje popisu problému trénovateľnej segmentácie obrazu s využitím hlbokých neuronových sietí. Je tu vysvetlený základný princíp spracovania digitálneho obrazu. Ďalej tu je popísaná segmentácia obrazu a možnosti trénovateľnej segmentácie obrazu pomocou umelých neuronových sietí. V druhej kapitole je popísaná roztrúsená skleróza a návrh modelu na detekciu roztrúsenej sklerózy zo snímok z magnetickej rezonancie pomocou trénovateľnej segmentácie obrazu.

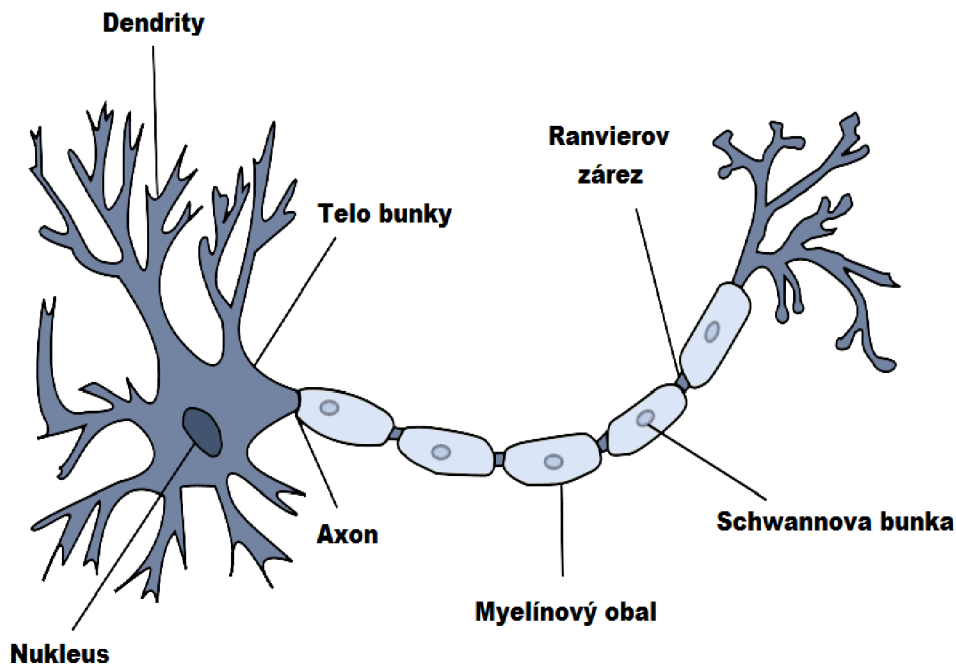
Tretia kapitola sa venuje praktickej časti diplomovej práce, je tu popísaná príprava obrazových dát, ktoré sa použili na trénovanie neuronovej siete. Je tu tiež vysvetlený algoritmus klzajúceho okna použitý na generovanie podobrazov zo snímok z magnetickej rezonancie. Pomocou tohto algoritmu boli vytvorené tri súbory dát použité na trénovanie, testovanie a validáciu modelu neuronovej siete. V praktickej časti práce bol vytvorený model umelej neuronovej siete ktorý bol natrénovaný a použitý na detekciu roztrúsenej sklerózy zo snímok z magnetickej rezonancie. Model neuronovej siete bol optimalizovaný na využitie viacerých jadier procesora pre rýchlejšie trénovanie. Model umelej neuronovej siete bol vytvorený pomocou knižnice Deep Learning for Java, Spark a programovacieho jazyku Java.

1 NEURÓNOVÉ SIETE

Táto kapitola sa venuje teoretickým aspektom umelých neurónových sietí a základnému popisu biologických neurónových sietí. V tejto kapitole je vysvetlený princíp umelého neurónu a umelých neurónových sietí so zameraním na hlboké neurónové siete s dopredným šírením signálu a konvolučnými vrstvami.

1.1 Biologické neurónové siete

Umelá neurónová sieť je výpočtový model inšpirovaný biologickými neurónovými sieťami v ľudskom nervovom systéme a podobne ako biologické neurónové siete, aj umelé neurónové siete sa skladajú z jednotlivých umelých neurónov. Umelé neuróny svojou funkciou napodobňujú biologické neuróny. Ľudský nervový systém má približne 10^{11} neurónov, typická umelá neurónová sieť má jednotky až milióny umelých neurónov. Podľa [3] existuje niekoľko druhov biologických neurónov ktoré sa od seba odlišujú rôznou štruktúrou. Všetky biologické neuróny sa skladajú z tela neurónu, ktoré sa tiež nazýva soma, z dendritov, axonu, schwannových buniek a nukleusu. Obr.1.1 zobrazuje biologický model neurónu a jeho jednotlivé časti.[3, 4]



Obr. 1.1: Biologický model neurónu. Obrázok prevzatý z [4].

Biologické neuróny prijímajú signály z ostatných neurónov pomocou dendritov cez špeciálne spojenia ktoré sa nazývajú synapsie. Toto spojenie sa najčastejšie na-

chádza na dendritoch, niekedy sa môže toto synaptické spojenie nachádzať priamo na tele neurónu. Synaptické spojenie môže byť elektrického alebo chemického druhu. Prijaté signály sú potom privedené do nucleusu, kde sú všetky signály sčítané. Keď úroveň signálu prekročí určitú hranicu, neurón sa aktivuje a vyšle elektrický impulz. Impulz je vyslaný cez axon ktorý je izolovaný pre lepší prenos elektrických impulzov. Elektrický impulz je cez axon ďalej distribuovaný do ďalších neurónov alebo buniek.[1, 2, 3, 4, 17]

1.2 Umelé neurónové siete

Umelé neurónové siete podobne ako biologické neurónové siete využívajú paralelné spracovanie informácií. Umelá neurónová sieť sa charakterizuje podľa použitého modelu neurónu, podľa topológie neurónovej siete, podľa spôsobu akým sa neurónová sieť trénuje a podľa spôsobu aktivovania.[1, 2, 17]

1.2.1 Model umelého neurónu

Formálny neurón

Základom matematického popisu neurónovej siete je formálny neurón. Obrázok 1.2 zobrazuje formálny neurón. Matematický popis formálneho neurónu

$$z = w_0 + \sum_{i=1}^N w_i x_i, \quad (1.1)$$

kde z je vnútorný potenciál neurónu, w_0 je prah neurónu nazývaný tiež bias, x_i je i -tý vstup neurónu a w_i je i -tá synaptická váha. Výstup neurónu je definovaný prenosovou funkciou neurónu


$$y = f(z), \quad (1.2)$$

kde y je výstup neurónu, z je vnútorný potenciál neurónu a $f(z)$ je prenosová funkcia neurónu. [1, 2, 17]

Obrázok 1.2 zobrazuje model umelého neurónu. Na obrázku sú zobrazené vstupy neurónu x_1 až x_n a k nim patriace váhy w_1 až w_n . Prah neurónu zobrazuje váha w_0 so vstupom 1.

Perceptrón

V roku 1943 pán McCulloch a pán Pitts [5] predstavili prvý model umelej neurónovej siete. Formálne neuróny v tejto sieti predstavovali jednoduché logické prepínače. Ich prepínanie prebiehalo asynchrónne v diskretných časových intervaloch. V tomto



Obr. 1.2: Model umelého neurónu.

modeli umelej neurónovej siete boli hodnoty všetkých váh a prahov fixné. Autori dokázali že ich model umelej neurónovej siete dokáže realizovať rôzne procesy popísané konečným počtom symbolických výrazov.[17]

V roku 1958 Frank Rosenblatt dokázal že McCullochova-Pittsova umelá neurónová sieť s modifikovateľnými váhami sa dá natrénovať tak, aby vedela klasifikovať rôzne objekty. Frank Rosenblatt pomenoval tieto neurónové siete s modifikovateľnými váhami perceptróny. Perceptrón obsahuje modifikovateľné váhy, ktoré pri procese učenia menia svoje hodnoty. Pri procese učenia perceptrónu sa najskôr zaznamená jeho odpoveď na podnet. Ak je odpoveď správna, váhy sa nemodifikujú. Ak nie je odpoveď správna, váhy perceptrónu sa modifikujú dvomi spôsobmi:

1. Ak má byť perceptrón aktívny a nie je, váhy sa zväčšujú.
2. Ak nemá byť perceptrón aktívny a je, váhy sa znižujú.

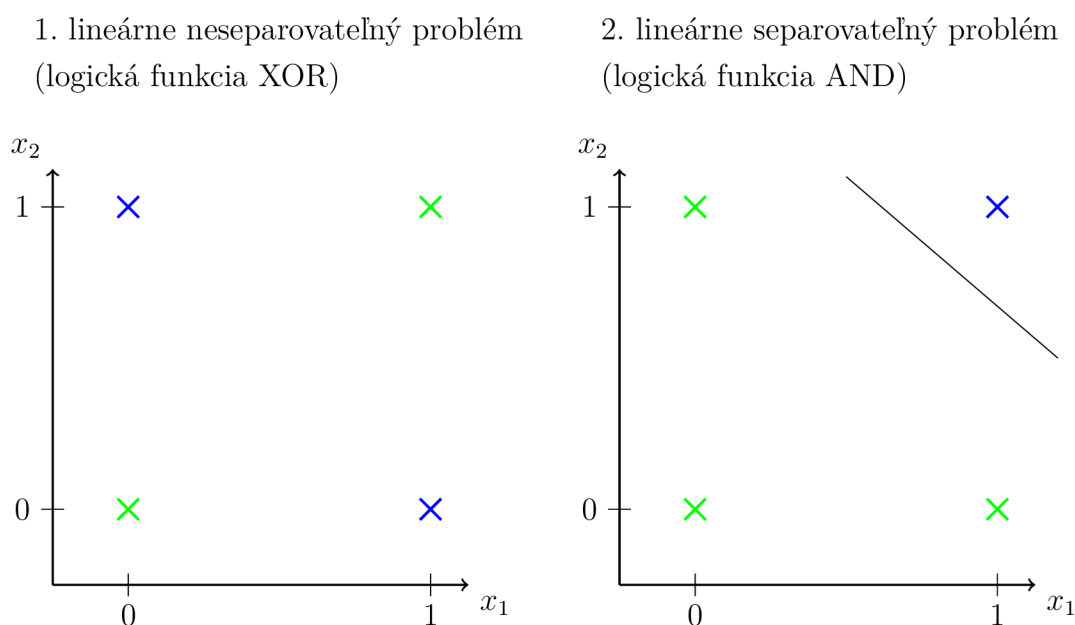
Algoritmus učenia perceptrónu, ktorý modifikuje váhy podľa výstupu perceptrónu a koriguje chyby sa často v upravenej verzii používa dodnes. V roku 1960 [18] bol predstavený model neurónového klasifikátora nazvaný ADALINE¹. Autori tohoto modelu ukázali, že pri učení sa minimalizuje globálna funkcia systému neurónového klasifikátora.[17]

Pán Minsky a Papert v roku 1969 kritizovali perceptróny za to, že perceptróny

¹Adaptive Linear Neuron - Adaptívny lineárny neurón

nedokážu riešiť lineárne neseparovateľné problémy (napríklad logická funkcia XOR). Tento problém sa podarilo vyriešiť až zavedením algoritmu spätného šírenia chýb pri učení neurónovej siete.[1, 2, 17]

Obrázok 1.3 zobrazuje lineárne neseparovateľný a lineárne separovateľný problém. Obrázok zobrazuje graf logickej funkcie XOR, táto funkcia patrí do skupiny lineárne neseparovateľných problémov. Ako je vidieť z obrázku, vyznačené body sa nedajú rozdeliť do dvoch tried (zelená a modrá) pomocou lineárnej funkcie. Druhá časť obrázku zobrazuje lineárne separovateľný problém, jedná sa o logickú funkcie AND. V tomto grafe je zobrazená lineárna funkcia ktorá rozdeľuje zobrazené body na dve triedy.[17]



Obr. 1.3: Lineárne neseparovateľný a lineárne separovateľný problém.


1.2.2 Topológia umelej neurónovej siete

Topológia neurónovej siete určuje usporiadanie neurónov, vrstiev a spôsob prepojenia jednotlivých neurónov ako aj prepojenie jednotlivých vrstiev. Neurónová sieť môže mať dva druhy prepojenia medzi rôznymi vrstvami:

- Priamoväzobné , prepojenie medzi dvomi vrstvami neurónovej siete je iba medzi vrstvami ktoré spolu susedia a prepojenie je priame z vyššej vrstvy do nižšej vrstvy.
- Spätňoväzobné v prepojení jednotlivých vrstiev neurónovej siete sú spätne väzby medzi vrstvami.

Niektoré neurónové siete využívajú laterálne prepojenia neurónov, je to prepojenie medzi neurónmi v rovnakej vrstve. Použité väzby medzi vrstvami neurónovej siete určujú smer šírenia vstupného signálu:

- Dopredné, vstupný signál sa šíri smerom od vstupnej k výstupnej vrstve, prepojenie medzi vrstvami je priamoväzobné.
- Spätné, signál sa šíri dvomi smermi, od vstupnej vrstvy do výstupnej a naopak, toto šírenie signálu je charakteristické pre spätnoväzobné prepojenie vrstiev v neurónovej sieti.[1, 2, 17]



Obr. 1.4: Obrázok znázorňuje topológiu viac-vrstvej neurónovej siete.

1.2.3 Trénovanie umelej neurónovej siete

Pojem tréovanie v súvislosti s neurónovými sieťami znamená proces pri ktorom sa menia hodnoty jednotlivých váh v neurónovej sieti podľa daného učiaceho algoritmu. Cieľom tréovania je nájsť také hodnoty váh, pri ktorých budú na výstupe siete požadované výstupné hodnoty podľa zadaných vstupných hodnôt. V oblasti umelých neurónových sietí existuje veľa rôznych algoritmov akými sa neurónové siete tréujú, všetky algoritmy tréovania sa rozdeľujú na tri skupiny:

1. Tréovanie s učiteľom, pri tomto spôsobe tréovania sa používa súbor dát zložený zo vstupných a požadovaných výstupných hodnôt. Vstupné hodnoty sa pri tréovaní predkladajú neurónovej sieti a na výstupe sa očakáva výstupná hodnota priradená k vstupnej hodnote. Rozdiel medzi reálnou a očakávanou

výstupnou hodnotou je chyba neurónovej siete podľa ktorej sa robí korekcia jednotlivých váh neurónovej siete.

2. Trénovanie bez učiteľa, tento spôsob učenia neurónovej siete využíva súbor dát bez očakávaných výstupných hodnôt. Neurónová sieť hľadá vzory vo vstupných dátach, tento spôsob sa využíva napríklad pri dolovaní dát z báze dát.
3. Posilňované trénovanie, tento spôsob trénovania je podobný ako trénovanie s učiteľom, pri tomto spôsobe nie je použitý súbor dát s požadovanými výstupnými hodnotami ale neurónová sieť sa pri trénovaní snaží maximalizovať úspešnosť pokusmi a omylmi.[1, 2, 17]

Algoritmus Error Backpropagation


Tento algoritmus je určený pre viacvrstvé neurónové siete s dopredným šírením signálu bez laterálnych spojov medzi neurónmi. Algoritmus Error Backpropagation (spätné šírenie chyby) slúži na výpočet gradientu pri trénovaní neurónovej siete. Algoritmus Error Backpropagation bol prvýkrát predstavený v roku 1970, dnes predstavuje dôležitú súčasť neuronálnych sietí pri trénovaní. Cieľom algoritmu Backpropagation je optimalizovať váhy neurónovej siete pri trénovaní tak, aby na výstupe neurónovej siete bola požadovaná výstupná hodnota. Algoritmus na optimalizáciu váh neurónovej siete využíva spätné šírenie chýb. Výpočet chyby neurónovej siete sa počíta od výstupnej vrstvy smerom k vstupným vrstvám.[28, 17]

1.2.4 Aktivácie umelej neurónovej siete

Aktivácia neurónovej siete je proces pri ktorom neurónovej sieti predložíme vstupné hodnoty, ktoré neboli použité pri trénovaní neurónovej siete a neurónová sieť podľa nastavených váh vypočíta výstupné hodnoty.

Podľa druhu neurónovej siete sa aktivácia neurónovej siete delí na dva druhy:

1. Jednorázová aktivácia, pri jednorázovej aktivácii sa neurónovej sieti predložia vstupné hodnoty a výstupné hodnoty sú vypočítané pri jednom priechode vstupných hodnôt cez neurónovú sieť. Jednorázový proces aktivovania využíva napríklad viac-vrstvová perceptronová sieť.
2. Iteračné aktivovanie, pri iteračnom aktivovaní sa výstupné hodnoty počítajú postupne pri jednotlivých iteráciách, pri úspešnom iteračnom aktivovaní pri každej ďalšej iterácii výstupné hodnoty konvergujú k požadovanému výstupu. Iteračný proces vybavovania využíva napríklad Hopfieldova sieť.[1, 2, 17]



Obr. 1.5: Zobrazenie iteračného aktivovania.

1.3 Konvolučné siete


Konvolučné siete sú špeciálnym prípadom umelých neurónových sietí ktoré využívajú konvolúciu na spracovanie signálu v neurónovej sieti. Konvolučné siete sa využívajú pri spracovaní obrazov, zvuku a textu pomocou neurónových sietí. Konvolučné siete sú schopné rozpoznávať tváre v obraze, dopravné značky a ďalšie objekty. [15, 19, 20]

Konvolučné siete spracúvajú vstupný obraz ako troj-rozmerné objekty, kde výška a šírka je daná výškou a šírkou vstupného obrazu a tretí rozmer je daný spôsobom akým počítače pracujú s farbou. Farebné obrazy sa vytvárajú kombináciou niekoľkých základných farieb. Tretí rozmer je daný počtom základných farieb a použitom farebnom modeli. Počet kanálov je daný tretím rozmerom a každý kanál reprezentuje jednu zo základných farieb obrazu. Konvolučné siete spracovávajú signál rovnako ako prebieha samotná konvolúcia signálu a filtru. V konvolučných sieťach je rozmer filtru rovnaký ako rozmery dát ktoré sa aktuálne spracovávajú a zároveň je veľkosť filtru menšia ako sú rozmery vstupného obrazu. [15, 19, 20]

Okno ktoré sa pohybuje cez vstupný obraz a po konvolúcii s filtrom vytvára skalárny súčin sa zapisuje do aktivačnej mapy. Veľkosť aktivačnej mapy sa rovná počtu krokov ktoré okno spraví pri prechádzaní cez celý obraz. Filtre ktoré sa používajú pri konvolúcii reprezentujú rôzne vzory, ktoré má konvolučná sieť rozpoznať. Najväčším problémom pri spracovaní obrazov pomocou neurónovej siete je, že majú veľké rozmery a sú pamäťovo aj výkonovo náročné na spracovanie. Konvolučné siete sú navrhnuté na zmenšenie rozmerov obrazu a zachovanie relevantných informácií. Ďalšou možnosťou ako zmenšiť rozmery obrazu a zachovať relevantné informácie je prevzorkovanie. [15, 19, 20]

1.3.1 Prevzorkovanie obrazu

Prevzorkovanie obrazu je podobná operácia akú vykonáva konvolučná vrstva. Prevzorkovanie je menej náročná operácia na pamäť aj výpočtový výkon. Pri prevzorkovaní obrazu sa cez celý obraz pohybuje okno rovnako ako pri konvolúcii. Podľa použitého typu prevzorkovania sa z tohoto okna vypočíta výsledná hodnota, ktorá sa zapíše do nového obrazu. Pri výpočte výsledného obrazu sa využívajú rôzne typy prevzorkovania, napríklad maximálna a minimálna hodnota, priemerná hodnota a ďalšie. Operácia prevzorkovania obrazu sa často využíva spoločne s konvolučnou vrstvou. Obrázok 1.6 zobrazuje podvzorkovanie obrazu s filtrom o veľkosti 2×2 pixely. S filtrom sa do podvzorkovaného obrazu vyberá pixel s maximálnou hodnotou. [15]



Obr. 1.6: Podvzorkovanie obrazu (Maxpooling), veľkosť filtru 2×2 pixely.

1.3.2 Možnosti konvolučných sietí

Konvolučné siete nachádzajú široké uplatnenie v rôznych odvetviach. Najčastejšie sa využívajú pri spracovaní obrazu a klasifikácii rôznych objektov v obraze. Dôkazom toho, že konvolučné siete sú schopné naučiť sa a potom klasifikovať rôzne objekty v obraze sú súťaže, kde sa tímy alebo jednotlivci snažia dosiahnuť čo najvyššiu percentuálnu úspešnosť pri klasifikácii objektov v obraze. V roku 2014 sa uskutočnila súťaž ([35]), kde prvé miesto získal model umelej neurónovej siete s úspešnosťou 96,53% ([36]). V tejto súťaži bol na tréning a validáciu použitý súbor dát o veľkosti 60 000 farebných obrazov. Každý obraz mal veľkosť 32×32 pixelov, všetky obrazy boli rozdelené do desiatich tried. [24, 25, 34, 35, 36]

2 POPIS PROBLÉMU

Táto kapitola sa venuje popisu problému trénovateľnej segmentácie obrazu pomocou hlbokých neurónových sietí. Je tu vysvetlený princíp digitálneho spracovania obrazu, segmentácia obrazu a možnosti segmentácie obrazu pomocou umelých neurónových sietí. V tejto kapitole je tiež popísaná roztrúsená skleróza a návrh detekcie roztrúsennej sklerózy zo snímok z magnetickej rezonancie pomocou trénovateľnej segmentácie obrazu.

2.1 Spracovanie digitálneho obrazu

Podľa [13] môže byť každý obraz definovaný ako funkcia s dvomi neznámymi

$$f(x, y), \quad (2.1)$$

kde x a y sú súradnice a amplitúda f jedného páru súradníc (x, y) označuje intezitu obrazu v konkrétnom bode definovanom súradnicami. V prípade že všetky súradnice (x, y) a amplitúda f sú konečné diskkrétne veličiny, tak obraz voláme digitálny obraz. Jednotlivé body digitálneho obrazu ktoré sú definované súradnicami sa nazývajú obrazové body, alebo tiež pixely v dvoj-rozmerných obrazoch a voxely v troj-rozmerných obrazoch, troj-rozmerné digitálne obrazy sú tvorené sériou dvoj-rozmerných snímok. Viac-rozmerné digitálne obrazy sú tvorené rovnako ako troj-rozmerné, ale namiesto jedného obrazového bodu ktorý reprezentuje farbu obrazu na konkrétnom mieste, vo viac-rozmerných digitálnych obrazoch sa pri spracovaní obrazu používa vektor hodnôt (napr. RGB hodnoty obrazového bodu), výsledná farba potom reprezentuje obrazový bod.[13]

Oblasť spracovania digitálneho obrazu je široká a nachádza uplatnenie vo veľa oboroch. Spracovanie digitálneho obrazu sa vykonáva pomocou digitálnych počítačov a podľa [13] je to časť počítačovej vedy. Na rozdiel od ľudského oka, počítače (špecializované zariadenia pripojené k počítačom) sú schopné zaznamenávať a spracovať obraz aj z iných zdrojov žiarenia ako je viditeľné spektrum, napr.: röntgenové lúče, infračervené žiarenie a ďalšie. To sa využíva napríklad pri spracovaní medicínskych dát z röntgenových zariadení, CT¹ a magnetickej rezonancie. Spracovanie digitálnych obrazov vytvorených z astronomických teleskopov, z elektrónových mikroskopov, v automobilovom priemysle, v súčasnosti sa rozvíjajúca oblasť autonómnych automobilov (na určenie polohy automobilu sa spracováva obraz z klasických kamier, 3D obraz vytvorený pomocou technológie Lidar² [14]) a iné.[13]

¹Computer tomography - Počítačová tomografia


²Light Detection and Ranging - Detekcia svetla a vzdialenosti

Podľa [13] sa metódy na spracovanie digitálneho obrazu delia na dva základné druhy:

1. Metódy na ktorých vstupe sú digitálne obrazy a na výstupe sú tiež digitálne obrazy.
2. Metódy na ktorých vstupe sú digitálne obrazy a na výstupe sú atribúty vyextrahované z digitálneho obrazu.

2.2 Segmentácia obrazu

V oblasti spracovania obrazu je segmentácia obrazu proces, pri ktorom sa obraz rozdelí do viacerých častí ktoré sa nazývajú segmenty. Pri segmentácii obrazu sa jednotlivým pixelom ktoré spolu súvisia (pixely ktoré v obraze reprezentujú jeden objekt) priraduje rovnaké označenie, pixely s rovnakým označením potom tvoria jeden segment nazývaný tiež superpixel. Cieľom segmentácie je rozdeliť obraz do segmentov, pričom každý segment v obraze reprezentuje samostatnú časť. Výsledkom segmentácie obrazu je súbor segmentov ktoré pokrývajú obraz a pomocou ktorých sa dá ďalej ľahšie pracovať a identifikovať jednotlivé časti obrazu. Obrázok 2.1 zobrazuje snímok hlavy z magnetickej rezonancie, obrázok vľavo je nesegmentovaný, obrázok vpravo bol segmentovaný s použitím knižnice SRM³. [9, 10, 11, 12]



Obr. 2.1: Zobrazenie snímku (vľavo) a segmentovaného snímku (vpravo).

³Statistical region merging - Spájanie regiónov podľa štatistiky

2.2.1 Trénovateľná segmentácia obrazu

Vela segmentačných metód pri segmentácii obrazu berie do úvahy iba informácie o hodnotách farby jednotlivých pixeloch. Výsledkom takýchto segmentačných metód sú segmenty ktoré nezohľadňujú komplexnejšie chápanie obrazu tak ako ho chápu ľudia. Vytvorenie segmentačnej metódy ktorá by pracovala podobne ako dokážu ľudia chápať a segmentovať obraz je veľmi náročné. Vytvorenie takejto segmentačnej metódy by vyžadovalo veľa výpočtového času (ľudia sa učia rozoznávať obrazy niekoľko rokov) a vytvorenie veľmi veľkého súboru dát ktorý v súčasnosti nie je k dispozícii. Techniky založené na trénovateľnej segmentácii obrazu sú schopné naučiť sa segmentovať obraz podľa naučených vzorov. Na trénovateľnú segmentáciu obrazu sa využívajú konvolučné neurónové siete. Pri segmentácii pomocou konvolučnej siete je vstupom podobraz vytvorený z obrazu, ktorý chceme segmentovať. Konvolučná sieť v sebe obsahuje niekoľko konvolučných a neurónových vrstiev, ktoré spracujú vstupný podobraz. Výstupom siete je trieda do ktorej patrí vstupný podobraz. Pri trénovateľnej segmentácii obrazu sa využíva segmentačný model (napríklad neurónová sieť) ktorý sa pomocou súboru dát natrénuje tak, aby rozpoznával a klasifikoval netréňované objekty v obraze.[29, 26]

2.3 Roztrúsená skleróza

Roztrúsená skleróza je závažné ochorenie centrálného nervového systému a je to jedno z najčastejších ochorení centrálného nervového systému. Je to chronické zápalové ochorenie autoimunitného systému, ktoré postihuje zrakové nervy, miechu a mozog. Pri ochorení roztrúsenej sklerózy imunitný systém napadá myelínový obal. Myelínová vrstva obaluje nervové vlákna v mozgu a v mieche. Myelínový obal je potrebný k správnejmu fungovaniu nervových vlákien. Pri napádaní myelínového obalu imunitným systémom dochádza k jeho poškodeniu ako aj poškodeniu samotných nervových vlákien. Keď je nejaká časť myelínového obalu alebo nervového vlákna poškodená alebo zničená, nervové impulzy ktoré prechádzajú z mozgu do miechy a naopak cez poškodené nervové vlákna sú skreslené alebo prerušené. Tieto skreslené nervové impulzy vyvolávajú celý rad symptómov. Pri roztrúsenej skleróze dochádza k opakovanému napádaniu rovnakých miest imunitným systémom, preto sa myelínový obal nedokáže obnoviť a na poškodených miestach vznikajú jazvy ktoré ďalej prekážajú prenosu nervových impulzov. [6, 7, 8]

Podľa [8] sa roztrúsená skleróza vyskytuje v štyroch podobách:

1. Relapsujúca-remitujúca skleróza, hlavným príznakom sú časové intervaly, kedy sa príznaky a stav postihnutého striedavo zlepšujú a zhoršujú, nie je progresia

ochorenia.

2. Primárne progresívna skleróza, typickým príznakom je progresívne zhoršovanie príznakov a postihnutie od vypuknutia choroby.
3. Sekundárne progresívna skleróza, je kombináciou predchádzajúcich dvoch, zo začiatku od vypuknutia ochorenia prevláda relapsujúca-remitujúca skleróza a neskôr prevláda progresívna skleróza.
4. Progresívna-relapsujúca skleróza, je to kombinácia relapsujúcej-remitujúcej a progresívnej sklerózy, vyskytujú sa časové intervaly ale na rozdiel od relapsujúcej-remitujúcej sklerózy, medzi časovými intervalmi dochádza k zhoršeniu príznakov a postihnutia.

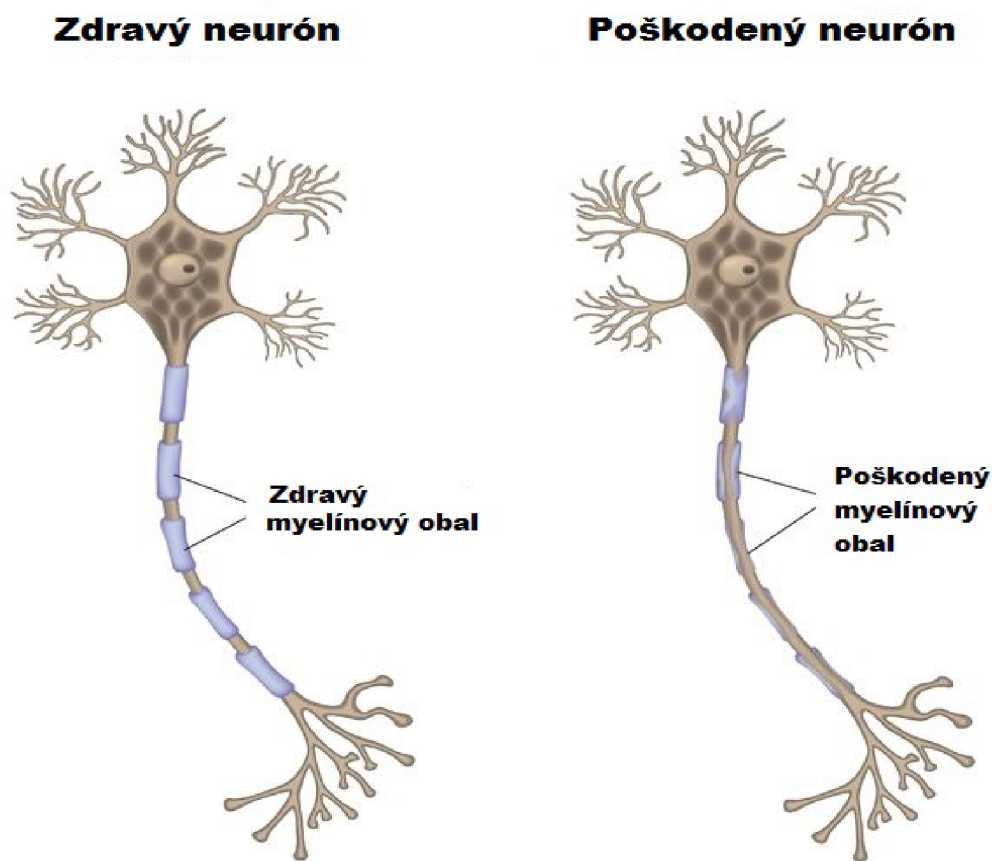
V súčasnosti nie je známy liek na toto ochorenie, ale v prípade včasnej diagnózy sa darí potláčať príznaky a šírenie roztrúsenej sklerózy. Diagnostikovať roztrúsenú sklerózu je veľmi ťažké pretože príznaky roztrúsenej sklerózy sa podobajú na iné ochorenia, z tohoto dôvodu je roztrúsená skleróza diagnostikovaná až potom ako sa vylúčia iné ochorenia s podobnými príznakmi.[6, 7]

2.3.1 Diagnostika roztrúsenej sklerózy

Pri diagnostikovaní roztrúsenej sklerózy neurológ stanoví diagnózu na základe rôznych druhov vyšetrení a príznakov:

- Celkové zhodnotenie stavu pacienta
- Príznaky ktoré sa objavujú v pravidelných intervaloch bez horúčky
- Známky poškodenia centrálného nervového systému
- Testovaním pohybových a vnemových schopností
- Vyšetrením mozgovo-miechového moku
- Magnetickou rezonanciou[6, 7, 8]

Vyšetrenie roztrúsenej sklerózy magnetickou rezonanciou je bezbolestné, neinvazívne vyšetrenie, ktoré zisťuje množstvo vody v tkanivách v rôznych častiach ľudského tela. Pri vyšetrení magnetickou rezonanciou sa využíva silné magnetické pole, výstupom magnetickej rezonancie je obraz vytvorený na základe naindukovaného napätia. Výsledný obraz je čiernobiely. Výhody vyšetrenia pomocou magnetickej rezonancie je väčšia presnosť zobrazenia oproti iným diagnostickým prístrojom, vyšetrenie nie je škodlivé a je bezbolestné. Nové metódy umožnili skrátiť čas zobrazovania na desiatky milisekúnd, čo umožňuje zobrazovať orgány takmer v reálnom čase. Medzi nevýhody magnetickej rezonancie patria veľké náklady na nákup a vyšetrenie pomocou magnetickej rezonancie. Nevýhodou sú tiež časové nároky na zhotovenie snímok. Pri vyšetrení magnetickou rezonanciou je dôležité, aby pacient nemal pri



Obr. 2.2: Zobrazenie zdravého a poškodeného myelínového obalu neurónu.[38]

sebe žiadne kovové materiály, ktoré by mohli spôsobiť zranenie v silnom magnetickom poli. Ďalšou nevýhodou magnetickej rezonancie je nemožnosť vyšetrenia pacientov ktorý používajú kardiostimulátory, kovové telesá, ušné implantáty a pacientov ktorí majú veľké tetovanie vo vyšetrovanej oblasti.[6, 7, 8]

2.3.2 Detekcia roztrúsenej sklerózy s neurónovou sieťou

Po vytvorení snímok pomocou magnetickej rezonancie lekár na základe snímok určí diagnózu manuálnym preskúmaním jednotlivých snímok. Ďalšou možnosťou je strojové určenie diagnózy, pri tomto spôsobe špecializovaný program analyzuje snímky z magnetickej rezonancie a s určitou pravdepodobnosťou označí v snímkoch miesta kde sa nachádza roztrúsená skleróza. V tejto práci sa trénovateľná segmentácia obrazu pomocou umelých neurónových sietí využíva na strojovú detekciu roztrúsenej sklerózy zo snímok z magnetickej rezonancie. [1, 15]

Detekcia roztrúsenej sklerózy pomocou umelej neurónovej siete prebieha v niekoľkých krokoch. Z originálnych snímok z magnetickej rezonancie sa vyberie prvý pixel

a vytvorí sa podobraz, vybratý pixel sa nachádza v strede podobrazu. Vytvorený podobraz má rovnaké rozmery ako podobrazy použité pri tréovaní neurónovej siete. Tento podobraz slúži ako vstupné dáta pre neurónovú sieť. Neurónová sieť obsahuje niekoľko konvolučných, podvzorkovacích a neurónových vrstiev, ktoré spracujú vstupné dáta. Výstupom siete bude pravdepodobnosť, či pixel v strede vstupného podobrazu reprezentuje alebo nereprezentuje roztrúsenú sklerózu. Tento proces sa opakuje pre všetky pixely v originálnom snímku z magnetickej rezonancie, zo získaných údajov z neurónovej siete sa ďalej vytvorí maska, ktorá určuje kde v originálnom snímku sa nachádza roztrúsená skleróza. [1, 15]

3 PRAKTICKÁ ČASŤ

Táto kapitola sa venuje praktickej časti diplomovej práce. V tejto kapitole je popísaný návrh a realizácia modelu umelej neurónovej siete ako aj časová optimalizácia trénovania tohoto modelu. V praktickej časti diplomovej práce bol vytvorený algoritmus kľúčajúceho okna na generovanie podobrazov, z ktorých sa potom vytvorili súbory dát pre neurónovú sieť. V praktickej časti bol tiež vytvorený model neurónovej siete, ktorí bol použitý na detekciu roztrúsenej sklerózy zo snímok z magnetickej rezonancie.

3.1 Použitý software a hardware

3.1.1 Použitý software

Knižnica Deeplearning4j

Deeplearning4j¹ (DL4J) je komerčná open-source knižnica určená pre programovací jazyk Java a Scala. Je vydaná pod licenciou Apache 2.0. Knižnica Deeplearning4j využíva jednovláknové a viacvláknové spracovanie dát s použitím umelých neurónových sietí. Podľa [16] knižnica DL4J podporuje tieto typy neurónových sietí:

- Boltzmannove stroje
- Konvolučné siete
- Rekurentné siete
- Rekurzívne autokodéry
- Hlboké neurónové siete
- Hlboké autokodéry
- Rekurzívne tensorové neurónové siete

Model umelej neurónovej siete použitý na trénovateľnú segmentáciu obrazu v tejto práci bol vytvorený pomocou knižnice DL4J.

Knižnica Apache Spark

Apache Spark je open-source knižnica ktorá umožňuje vytvárať paralelné a distribuované aplikácie. Apache Spark poskytuje API² pre programovacie jazyky Java, Scala, Python a ďalšie. Spark tiež obsahuje sadu nástrojov pre štrukturované spracovanie dát, strojové učenie a ďalšie. [30, 31]

¹Deeplearning for Java

²Application programming interface

Knižnica Deeplearning4j má implementované rozhranie Sparku-u a toto rozhranie využíva na paralelné učenia modelov neurónových sietí. Deeplearning4j pomocou knižnice Spark optimalizuje učenie neurónovej siete na zvolený počet jadier procesoru tak, že pre každé jadro sa vytvorí rovnaký model neurónovej siete. Trénovací súbor dát sa potom rovnomerne rozdelí na rovnaký počet ako je počet modelov neurónovej siete. Jednotlivé modely neurónovej siete sa pomocou rozdeleného súboru dát trénujú paralelne tak, že každý model využíva samostatné jadro procesoru. Parametre jednotlivých modelov sa po každej iterácii priemerujú. V nasledujúcej iterácii sa použijú spriemerované hodnoty. [30, 31]

3.1.2 Použitý hardware

V praktickej časti práce bol na trénovanie, testovanie a validáciu použitý počítač s dvomi štvorjadrovými procesormi Intel Xeon E5504@2 GHz. Veľkosť operačnej pamäte bola 32 GB. Na použítom počítači bol nainštalovaný 64-bitový operačný systém Windows 7 Professional.


3.2 Príprava dát pre neurónovú sieť

Pre úspešné naučenie neurónovej siete je potrebné pri trénovaní neurónovej siete predkladať vhodné dáta. Natrénovanie neurónovej siete na snímkoch s veľkými rozmermi by trvalo dlhý čas preto sa používajú rôzne metódy na zmenšenie rozmerov obrazu a zároveň zachovanie dôležitých informácií v obraze.

Snímky hlavy z magnetickej rezonancie desiatich pacientov a k nim patriace masky slúžili na vytvorenie súborov dát pre umelú neurónovú sieť. Snímky boli troj-rozmerné, výška a šírka snímkov bola 400 pixelov. Každý troj-rozmerný snímok sa skladal z 257-mich rezov, ktoré určujú hĺbku troj-rozmerného snímku. Všetky snímky boli 8-bitové. Masky mali rovnaké rozmery ako snímky a určovali kde v snímkoch sa nachádza roztrúsená skleróza. Masky boli vytvorené lekárom. Obrázok 3.1 zobrazuje jeden dvoj-rozmerný snímok hlavy z magnetickej rezonancie a masku snímku ktorá zobrazuje kde sa nachádza roztrúsená skleróza v snímku.

3.2.1 Algoritmus klzajúceho okna

V praktickej časti diplomovej práce bol vytvorený algoritmus klzajúceho okna. Pomocou tohto algoritmu a obrazových dát popísaných v kapitole 3.2 boli vytvorené tri súbory dát určené k trénovaniu, testovaniu a validácii umelej neurónovej siete.



a) snímok

b) maska

Obr. 3.1: Snímok z magnetickej rezonancie a maska k snímku.


Hlavnými vstupnými parametrami je veľkosť okna, hodnota prahu a krok okna. Tabuľka 3.1 zobrazuje parametre, ktoré boli použité v algoritme klzajúceho okna pri generovaní podobrazov.

Parameter	Hodnota parametru
Veľkosť okna	29×29 pixelov
Hodnota prahu	60
Krok okna	1

Tab. 3.1: Parametre použité pri generovaní podobrazov.

Algoritmus klzajúceho okna pracuje nasledovne. Na začiatku sa vyberie prvý pixel zo snímku a uložia sa jeho súradnice. V ďalšom kroku sa skontroluje či je hodnota pixelu väčšia ako je hodnota prahu. Ak hodnota pixelu nie je väčšia, tak sa vyberie ďalší pixel podľa pozície aktuálne vybraného pixelu a hodnoty kroku. Hodnota kroku okna určuje koľko pixelov sa preskočí pri výbere ďalšieho pixelu. Ak je hodnota vybraného pixelu väčšia, tak sa vytvorí okolo vybraného pixelu okno tak, že vybraný pixel je v strede okna. Z pixelov ktoré sa nachádzajú v tomto okne sa vytvorí podobraz. Trieda do ktorej patrí vytvorený podobraz sa určí podľa uložených súradníc vybraného pixelu. Triedu určuje hodnota pixelu v maske ktorý má rovnaké súradnice ako vybraný pixel. Ak je na súradniciach v maske pixel s bielou farbou,

tak vytvorený podobraz patrí do triedy true. Ak nie je na rovnakých súradniciach pixel s bielou farbou, tak vytvorený podobraz patrí do triedy false. Trieda true označuje podobrazy v ktorých sa v strede podobrazu nachádza pixel ktorý v snímku reprezentuje roztrúsená skleróza. Trieda false označuje podobrazy kde sa nenachádza roztrúsená skleróza. Obrázok 3.2 zobrazuje podobrazy vygenerované algoritmom klzajúceho okna. Podobrazy a) a b) zobrazujú roztrúsenú sklerózu, podobraz c) nezobrazuje roztrúsenú sklerózu.



Obr. 3.2: Vygenerované podobrazy, trieda true (a) a b)), trieda false (c)

Tabuľka 3.2 zobrazuje počet vygenerovaných podobrazov pre jednotlivé súbory dát a pre triedy true a false ktoré sa použili pri trénovaní UNS³. V tabuľke je tiež zobrazené koľko troj-rozmerných snímok bolo použitých na vygenerovanie podobrazov pre jednotlivé súbory dát.

Tab. 3.2: Počet vygenerovaných podobrazov pre jednotlivé súbory dát.

Súbor dát	Počet vygenerovaných podobrazov		Počet použitých 3D snímok
	trieda true	trieda false	
Trénovanie UNS	2000	2000	4
Testovanie UNS	2000	2000	3
Validácia UNS	18 000	18 000	3

3.2.2 Normalizácia podobrazov

Normalizácia dát (podobrazov) v súvislosti s umelými neurónovými sieťami je proces pri ktorom sa vstupné hodnoty prepočítajú tak, aby boli všetky v určitom rozsahu. Normalizácia vstupných dát pre neurónovú sieť pomáha predchádzať uviaznutiu

³Umelá neurónová sieť

v lokálnom minime pri optimalizácii váh neurónovej siete a napomáha k rýchlejšiemu trénovaniu neurónovej siete. Pre umelé neurónové siete sa najčastejšie používa normalizácia pre rozsah 0 až 1 alebo -1 až 1. Normalizácia podobrazov sa robila prepočítaním 8-bitových hodnôt pixelov (0-255) do rozsahu od 0 do 1.

3.3 Model umelej neurónovej siete

3.3.1 Hodnotenie modelu neurónovej siete

V oblasti klasifikácie objektov do tried sa na určovanie presnosti rôznych klasifikačných modelov používa chybová matica alebo tiež kontingenčná tabuľka. Každý stĺpec v tejto matici predstavuje klasifikované triedy. Jednotlivé riadky v matici predstavujú aktuálne (správne) triedy. Tabuľka 3.3 zobrazuje chybovú maticu. Hodnota TP v tabuľke označuje počet správne klasifikovaných vzorov triedy true, hodnota FP označuje počet nesprávne klasifikovaných vzorov triedy true. Hodnota TN označuje počet správne klasifikovaných vzorov triedy false a hodnota FN reprezentuje počet nesprávne klasifikovaných vzorov triedy false. [23, 32, 37]

Tab. 3.3: Zobrazenie chybovej matice.

		Klasifikované hodnoty	
		Trieda false	Trieda true
Správne hodnoty	Trieda false	TN (True Negative)	FP (False Positive)
	Trieda true	FN (False Negative)	TP (True Positive)

Podľa [32] knižnica Deelearning4j využíva na meranie úspešnosti rovnakú chybovú maticu ktorá je zobrazená v tabuľke 3.3. Z hodnôt uvedených v tejto tabuľke sa ďalej počítajú štyri parametre ktoré ohodnotili model neurónovej siete:

1. Úspešnosť (Accuracy) - táto hodnota určuje ako často klasifikačný model správne klasifikoval vzor, počíta sa podľa vzorca

$$\text{Úspešnosť} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (3.1)$$

2. Presnosť (Presicion) - keď klasifikátor priradí vzor do triedy true tak presnosť určuje ako často je vzor správne klasifikovaný, počíta sa podľa

$$\text{Presnosť} = \frac{TP}{TP + FP}. \quad (3.2)$$

3. Sensitivita (Recall) - táto hodnota vyjadruje správne klasifikované vzory k všetkým pozitívne klasifikovaným

$$\text{Sensitivita} = \frac{TP}{TP + FN}. \quad (3.3)$$

4. F1 skóre (F1 score) - je to vážený priemer hodnoty presnosť a sensitivity, počíta sa ako

$$\text{F1 skóre} = 2 \times \frac{\text{Presnosť} \times \text{Sensitivita}}{\text{Presnosť} + \text{Sensitivita}}. \quad (3.4)$$

[23, 32, 37]

3.3.2 Optimalizácia tréovania modelu neurónovej siete

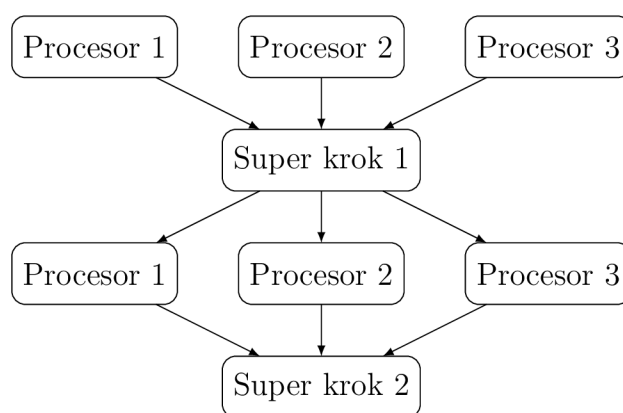
Učenie hlbokých neurónových sietí v závislosti od veľkosti tréovacieho súboru a počte parametrov neurónovej siete môže trvať niekoľko hodín až niekoľko dní. Optimalizácii učenia neurónových sietí sa preto venuje veľa úsilia o zefektívnenie tohto procesu. Jedným z možných riešení tohto problému je paralelné respektíve distribuované tréovanie neurónových sietí. Pri paralelnom tréovaní neurónovej siete sa vytvorí určitý počet modelov neurónovej siete. Tréovací súbor dát sa tiež, približne rovnomerne, rozdelí na rovnaký počet ako sa vytvorí modelov neurónovej siete. Pri paralelnom tréovaní sa potom jednotlivé modely neurónovej siete tréujú na rozdelenom súbore dát tak, že každý model neurónovej siete sa tréuje pomocou jedného z vytvorených súborov dát. Každý model neurónovej sietí využíva samostatné jadro procesoru (alebo samostatné vlákno). [21, 33]

Knižnica DeepLearning4j umožňuje prostredníctvom knižnice Spark paralelné ako aj distribuované tréovanie neurónovej siete. V použitej knižnici je paralelné respektíve distribuované tréovanie neurónovej siete implementované ako iteratívny MapReduce proces. MapReduce je technika ktorá sa využíva na paralelné spracovanie veľkých objemov dát. Táto technika sa skladá z dvoch krokov.

1. Operácia Map - aplikuje rovnakú výpočtovú operáciu na všetky prvky v zozname, táto operácia produkuje nový zoznam hodnôt.
2. Operácia Reduce - je to operácia ktorá sa aplikuje na zoznam hodnôt ktoré redukuje a vytvára nový menší zoznam hodnôt. [21, 33]

Pretože učenie neurónovej siete je iteratívny proces, pri ktorom sa postupne aktualizujú váhy neurónovej siete a minimalizuje sa globálna funkcia neurónovej siete, tak sa pri paralelnom učení neurónovej siete využíva iteratívny MapReduce proces. Pri učení neurónovej siete operácia Map distribuuje jednotlivé modely neurónovej siete a jednotlivé časti rozdeleného súboru dát na jednotlivé jadrá procesoru respektíve vlákna. Operácia Reduce potom priemeruje parametre všetkých modelov a distribuuje nový model s vypočítanými priemernými parametrami na všetky jadrá

respektíve vlákna. Iteratívny MapReduce proces pracuje podobne ako učenie neurónovej siete, v každej iterácii vykonáva rovnaký MapReduce proces. Obrázok 3.3 zobrazuje iteratívny MapReduce proces. V obrázku sú zobrazené tri procesory ktoré vykonávajú tréning jednotlivých modelov neurónovej siete. Blok nazvaný *Super krok 1, 2* v obrázku reprezentuje priemerovanie parametrov neurónovej siete a distribúciu nových parametrov na všetky procesory. Rovnaký proces sa aplikuje v prípade lokálneho tréningu na jednom procesore vo viacerých vláknoch ako aj v prípade distribuovaného tréningu na viacerých procesoroch poprípade na viacerých grafických kartách. [21, 33]



Obr. 3.3: Zobrazenie iteratívneho procesu MapReduce.

V praktickej časti tejto práce bolo vykonané experimentálne meranie času tréningu modelu umelej neurónovej siete. Cieľom tohto merania bolo získať údaje o optimálnom počte použitých vlákien pri paralelnom tréningu modelu neurónovej siete. Meranie prebiehalo pomocou modelu neurónovej siete ktorý sa trénoval postupne na dvoch procesoroch vo viacerých vláknoch. Počas merania času sa v modeli neurónovej siete menilo nastavenie v koľkých vláknoch sa má vykonávať tréning, ostatné parametre a nastavenia sa nemenili. Meranie pre každé nastavenie počtu vlákien určených na tréning modelu neurónovej siete sa robilo tri-krát. Výsledné hodnoty sa priemerovali. Pri tréningu modelu sa použilo 100 podobrazov pre každú z tried a bolo použitých 100 epoch.

Tabuľka 3.4 zobrazuje výsledky merania času tréningu modelu umelej neurónovej siete. Pri zvyšovaní počtu používaných vlákien na tréning siete sa čas potrebný na natréning postupne redukuje od 18 minút pre 1 použité vlákno po 10 minút pre 8 použitých vlákien. Ďalším zvyšovaním počtu vlákien sa čas potrebný

Tab. 3.4: Čas tréovania neurónovej siete v závislosti na počte vlákien.

Počet vlákien	Čas tréovania [minúty]
1 vlákno	18,281
2 vlákna	12,088
4 vlákna	11,185
6 vlákien	10,983
8 vlákien	10,267
10 vlákien	12,773
12 vlákien	14,279
14 vlákien	15,834
16 vlákien	17,178

na natréovanie zvyšuje. Podľa predpokladov, najlepší čas sa dosiahol pri použití 8 vlákien na tréovanie modelu umelej neurónovej siete.

Zhoršenie nameraného času pri použití 10 a viac vlákien je spôsobené tým, že meranie prebiehalo na dvoch štvor-jadrových procesoroch, ktoré môžu paralelne spracovávať 8 procesov bez prepínania. Pri použití 10 a viac vlákien na tréovanie modelu neurónovej siete dochádzalo k prepínaniu jednotlivých procesov, čo spôsobilo zhoršenie času pri tréovaní modelu neurónovej siete.

3.3.3 Realizácia modelu neurónovej siete

Ako model umelej neurónovej siete bola zvolená neurónová sieť so 7 vrstvami. Model umelej neurónovej siete využíval tréovací algoritmus spätného šírenia chýb. Krok učenia bol $1 \times e^{-7}$. Prvá vrstva bola konvolučná vrstva, vstupom do tejto vrstvy bol vektor hodnôt vytvorený z vygenerovaného podobrazu. Veľkosť filtru v prvej konvulčnej vrstve bol 5×5 pixelov a krok filtru 2×2 pixely. Výstupom bolo 30 aktivačných máp vstupného obrazu. Konvolučná vrstva využívala ako aktivačnú funkciu sigmoidu. Nasledujúca vrstva bola prevzorkovacia typu Maxpooling. Veľkosť filtru bola 2×2 pixely s krokom 2×2 pixely.

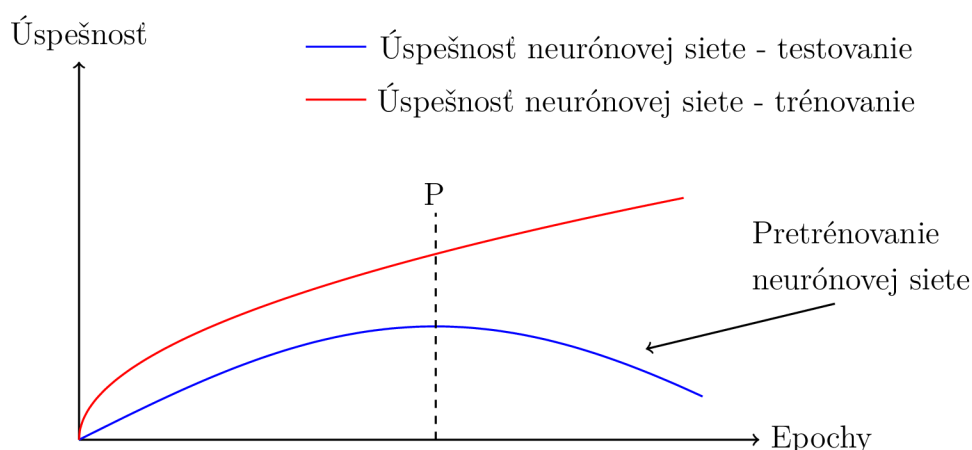
Tretiu a štvrtú vrstvu tvorili pár konvulčnej a prevzorkovacej vrstvy. Konvulčná vrstva mala veľkosť filtru 3×3 pixely a krok filtru 1×1 pixel. Výstupom druhej konvulčnej vrstvy bolo 60 aktivačných máp obrazu získaných pomocou konvulcie. Použitá aktivačná funkcia bola rovnako ako v prvej konvulčnej vrstve sigmoida. Druhá prevzorkovacia vrstva mala veľkosť filtru 2×2 pixely a krok filtru 2×2 pixely. Druhá prevzorkovacia vrstva bola typu Maxpooling.

Piata a šiesta vrstva v modeli umelej neurónovej siete boli plne pospojované neurónové vrstvy s aktivačnou funkciou ReLU⁴. Piata neurónová vrstva mala 500 neurónov a šiesta vrstva mala 250 neurónov. Výstupná vrstva využívala aktivačnú funkciu softmax a výstupom boli dva neuróny. Prvý výstupný neurón určoval pravdepodobnosť, že vstupný vzor patrí do triedy true. Druhý výstupný neurón určoval pravdepodobnosť, že vzor patrí do triedy false.

3.3.4 Trénovanie modelu neurónovej siete

Trénovanie neurónových sietí je dôležitým aspektom pri vytváraní modelov umeľých neurónových sietí. Pri trénovaní neurónových sietí často dochádza k javu ktorý sa nazýva pretrénovanie neurónovej siete. Tento jav zobrazuje graf v obrázku 3.4. Graf zobrazuje závislosť úspešnosti trénovania neurónovej siete na počte trénovacích epoch. [27]

V grafe sú dve krivky, modrá zobrazuje priebeh úspešnosti trénovania na tréno-
vacom súbore dát. Červená zobrazuje priebeh úspešnosti trénovania na testovacom
súbore dát. Ako je vidieť v grafe, s narastajúcim počtom epoch stúpa úspešnosť tré-
novania pre trénovací aj testovací súbor dát. Priamka P (čierna čiarkovaná) v grafe
zobrazuje bod, kde s ďalším trénovaním úspešnosť trénovania na testovacom súbore
dát ďalej stúpa ale na trénovacom súbore dát klesá. Tento jav sa nazýva pretréno-
vanie modelu neurónovej siete. [27]



Obr. 3.4: Zobrazenie pretrénovania neurónovej siete.

⁴Rectified Linear Unit - Usmernená lineárna funkcia

Aby sa zabránilo pretrénovanie modelu neurónovej siete, pri tréňovaní modelu sa po každej tréňovacej epoche zaznamenala úspešnosť modelu neurónovej siete na testovacom súbore dát. V prípade že zaznamenaná úspešnosť bola vyššia ako predchádzajúca, tak sa do pamäte uložili aktuálne hodnoty všetkých váh neurónovej siete a pokračovalo sa pri tréňovaní neurónovej siete. Ak zaznamenaná úspešnosť nebola vyššia tak sa pokračovalo pri tréňovaní. Takýmto procesom sa postupne ukladala do dočasnej pamäte stále lepšia a lepšia konfigurácia váh neurónovej siete a zabránilo sa pretrénovaniu neurónovej siete. Pretože na konci tréňovania sa použili váhy z najlepšej dosiahnutej úspešnosti na testovacom súbore dát a celý model neurónovej siete spolu s váhami uložil na harddisk počítaču pre neskoršie použitie.

Na tréňovanie modelu neurónovej siete v tejto práci boli použité tréňovacie epochy. Rozdiel medzi tréňovacou epochou a iteráciou je že pri iterácii sa neurónovej sieti predloží jeden tréňovací vzor n-krát, kde n je počet iterácií. Následne sa neurónovej sieti predloží ďalší tréňovací vzor n-krát až kým sa neurónovej sieti nepredložia všetky tréňovacie vzory. Pri jednej tréňovacej epoche sa sieti predložia všetky tréňovacie vzory jeden-krát. Na tréňovanie modelu neurónovej siete sa v tejto práci použilo 200 epoch a tréňovanie modelu neurónovej siete trvalo 591 minút.

3.4 Dosiahnuté výsledky

Validácia vytvoreného a natrénovaného modelu umelej neurónovej siete sa robila dvomi spôsobmi. Pri prvom spôsobe validácie modelu neurónovej siete sa použil validačný súbor dát. Použitý validačný súbor dát obsahol 18 000 vygenerovaných podobrazov pre každú z dvoch tried. Výsledky validácie modelu umelej neurónovej siete sú zobrazené v tabuľke 3.5 a 3.6. Výsledky validácie segmentovaním obrazu pomocou natrénovaného modelu umelej neurónovej siete a následným porovnaním s maskou sú zobrazené v tabuľkách 3.7, 3.8, 3.9 a 3.10.

Tab. 3.5: Zobrazenie výsledkov validácie v chybovej matici (validačný súbor dát).

		Klasifikované hodnoty	
		Trieda false	Trieda true
Správne hodnoty	Trieda false	17 056	944
	Trieda true	748	17 252

Tabuľka 3.5 zobrazuje výsledky validácie v chybovej matici. Ako je vidieť v matici, natrénovaný model umelej neurónovej siete správne klasifikoval 17 252 podobra-

zov, ktoré patrili do triedy true, z celkového počtu 18 000 a 17 056 podobrazov ktoré patrili do triedy false. Model neurónovej siete nesprávne klasifikoval 944 podobrazov ktoré priradil do triedy true, ale správne mali byť klasifikované ako trieda false. Pri klasifikovaní triedy false model umelej neurónovej siete tiež nesprávne klasifikoval 748 podobrazov ktoré patrili do triedy false, model neurónovej siete ich klasifikoval ako triedu true.

Tab. 3.6: Výsledky validácie modelu UNS (validačný súbor dát).

Parameter hodnotenia UNS	Hodnota [%]
Úspešnosť	95,3
Presnosť	94,81
Sensitivita	95,84
F1 Skóre	95,32

Zo získaných hodnôt v tabuľke 3.5 boli vypočítané parametre úspešnosti, ktoré sú zobrazené v tabuľke 3.6. Pri validácii modelu umelej neurónovej siete pomocou validačného súboru dát dosiahol model pre parameter F1 skóre 95,32 %.

Validácia modelu umelej neurónovej siete segmentovaním sa robila na jednom dvoj-rozmernom snímku z magnetickej rezonancie. Pri validácii modelu segmentovaním sa zo snímku vytvoril podobraz o veľkosti 29×29 pixelov. Vytvorený podobraz sa potom normalizoval a z dvoj-rozmerného poľa sa prekonvertoval na vektor. Vytvorený vektor slúžil ako vstup pre model umelej neurónovej siete. Výstupom modelu bol vektor dvoch čísiel v rozsahu od 0 do 1, ktoré určovali pravdepodobnosť ku každej z dvoch tried. Prvé číslo určovalo pravdepodobnosť, že vstupný podobraz patrí do triedy true. Druhé číslo určovalo pravdepodobnosť k triede false. Vstupné podobrazy sa vytvárali od prvého pixelu v snímku, po klasifikovaní triedy pomocou modelu neurónovej siete sa vytvoril ďalší podobraz a celý proces sa opakoval.

Podľa výstupu modelu neurónovej siete a podľa prahu sa vytvorila maska k originálnemu snímku z magnetickej rezonancie. Prah určoval minimálnu hodnotu prvého čísla vo výstupnom vektore, pri ktorej sa do vytvorenej masky zapísal pixel s bielou farbou. Keď bola hodnota prvého čísla menšia ako prah tak sa do masky zapísal pixel s čiernou farbou.

Obrázok 3.5 zobrazuje originálny snímok hlavy pacienta z magnetickej rezonancie (vľavo), masku vytvorenú segmentovaním pomocou modelu umelej neurónovej siete (v strede, prah 0,5) a originálnu masku vytvorenú lekárom (vpravo).



Obr. 3.5: Originálny snímok (vľavo), segmentovaný snímok UNS (v strede, prah 0,5) a maska snímku (vpravo).

Tabuľka 3.7 zobrazuje chybovú maticu pre validáciu modelu neurónovej siete pri segmentovaní. V tabuľke je vidieť že model neurónovej siete správne klasifikoval 337 pixelov pre triedu true a 146 722 pixelov pre triedu false. Model nesprávne klasifikoval 2 pixely ktoré označil ako triedu false ale pixely patrili do triedy true. V tabuľke je tiež vidieť, že model neurónovej siete nesprávne klasifikoval 12 939 pixelov do triedy true ale patrili do triedy false.

Tab. 3.7: Zobrazenie výsledkov validácie v chybovej matici (segmentácia, prah 0,5).

		Klasifikované hodnoty	
		Trieda false	Trieda true
Správne hodnoty	Trieda false	146 722	12 939
	Trieda true	2	337

Tabuľka 3.8 zobrazuje vypočítané parametre použité na hodnotenie modelu neurónovej siete. Z tabuľky je vidieť, že sa dosiahla presnosť iba 2,53% čo je spôsobené tým, že v maske sa ako biele pixely označili aj tie, ktoré model neurónovej siete označil s malou pravdepodobnosťou. Práh pre rozhodovanie či sa jedná o triedu true alebo false, respektíve či biely alebo čierny pixel bol 0,5. Dosiahnutá sensitivita je 99,41% čo predstavuje veľmi dobrý výsledok ale je to spôsobené veľkým počtom pixelov ktoré boli označené ako trieda true ale patrili do triedy false a malou hodnotou prahu pre určenie farby pixelu. Vypočítaná hodnota parametru F1 skóre sa dosiahla 4,93%, táto nízka hodnota je spôsobená nízkou presnosťou modelu neurónovej siete a malým prahom pri vytváraní masky.

Tab. 3.8: Výsledky validácie modelu UNS (segmentovanie, prah 0,5).

Typ vypočítanej hodnoty	Hodnota [%]
Úspešnosť	91,9
Presnosť	2,53
Sensitivita	99,41
F1 Skóre	4,93

Obrázok 3.6 zobrazuje originálny snímok hlavy pacienta z magnetickej rezonancie (vľavo), masku vytvorenú segmentovaním pomocou modelu umelej neurónovej siete (v strede, prah 0,99) a originálnu masku vytvorenú lekárom (vpravo).



Obr. 3.6: Originálny snímok (vľavo), segmentovaný snímok UNS (v strede, prah 0,99) a maska snímku (vpravo).

Tabuľka 3.9 zobrazuje namerané hodnoty pri validácii modelu neurónovej siete pomocou segmentácie snímku z magnetickej rezonancie. V tabuľke je vidieť, že pri porovnaní originálnej masky a masky vytvorenej pri segmentovaní sa zhodovalo 256 pixelov v triede true a 159 369 pixelov pre triedu false. Pri vytváraní masky sa nesprávne klasifikovalo 83 pixelov do triedy false a 292 pixelov do triedy true.

Tab. 3.9: Zobrazenie výsledkov validácie v chybovej matrice (segmentácia, prah 0,99).

		Klasifikované hodnoty	
		Trieda false	Trieda true
Správne hodnoty	Trieda false	159 369	292
	Trieda true	83	256

Tabuľka 3.10 zobrazuje vypočítané hodnoty parametrov použité na hodnotenie modelu neurónovej siete. Dosiahnutá úspešnosť bola 99,76% ale kvôli nízkej presnosti (46,71%) a sensitivite (75,51%) sa dosiahla hodnota F1 skóre 57,71%.

Tab. 3.10: Výsledky validácie modelu UNS (segmentovanie, prah 0,99).

Typ vypočítanej hodnoty	Hodnota [%]
Úspešnosť	99,76
Presnosť	46,71
Sensitivita	75,51
F1 Skóre	57,71

Parametre F1 skóre zobrazené v tabuľkách 3.8 a 3.10, získané pri validácii modelu neurónovej siete segmentovaním obrazu predstavujú nedostatočné hodnoty v porovnaní s dosiahnutou hodnotou F1 skóre v tabuľke 3.6 kde sa na validáciu modelu neurónovej siete použil validačný súbor dát o veľkosti 18 000 podobrazov pre každú z tried.

Rozdiel v hodnotách F1 skóre medzi validáciou pomocou validačného súboru dát a validáciou segmentovaním obrazu je spôsobený nevhodným výberom a malým počtom dát určených na tréning neurónovej siete.

4 ZÁVER

Diplomová práca sa zaoberá trénovateľnou segmentáciou obrazu s použitím hlbokých neurónových sietí. Práca je rozdelená do troch kapitol. Prvá kapitola sa venuje vysvetleniu základných princípov biologických a umelých neurónových sietí. Je tu vysvetlený model umelej neurónovej siete, topológia umelých neurónových sietí a spôsob trénovania a aktivácie neurónových sietí. V prvej kapitole sú tiež vysvetelné konvolučné vrstvy a ich možnosti.

Druhá kapitola sa venuje popisu problému detekcie roztrúsenej sklerózy pomocou umelých neurónových sietí. V druhej kapitole je vysvetlený základný princíp spracovania digitálneho obrazu a segmentácia obrazu. V tejto kapitole je tiež popísaná roztrúsená skleróza a možnosti ako ju detekovať pomocou umelých neurónových sietí.

Tretia kapitola sa venuje praktickej časti práce, je tu popísaný algoritmus klzajúceho okna použitý na generovanie podobrazov zo snímok z magnetickej rezonancie a model umelej neurónovej siete použitý na detekciu roztrúsenej sklerózy. V praktickej časti bol vytvorený algoritmus klzajúceho okna, ktorý sa použil na generovanie trénovacieho, testovacieho a validačného súboru dát.

V praktickej časti práce bol vytvorený model umelej neurónovej siete pomocou knižnice Deeplearning4j. Vytvorený model bol natrénovaný pomocou trénovacieho súboru dát. Pri trénovaní sa použil testovací súbor dát aby sa zabránilo pretrénovaniu modelu. Trénovanie modelu neurónovej siete bolo optimalizované na paralelné trénovanie pomocou knižnice Spark. Paralelné trénovanie prebiehalo na dvoch štvorjadrových procesoroch v ôsmich vláknoch. Trénovanie trvalo približne 10 hodín. Na trénovanie modelu neurónovej siete sa použilo 2 000 vygenerovaných podobrazov pre triedu true a false.

Validácia natrénovaného modelu neurónovej siete sa robila pomocou validačného súboru dát a segmentovaním snímku z magnetickej rezonancie a porovnaním s maskou. Pri validácii pomocou validačného súboru dát sa dosiahla hodnota parametru F1 skóre 95,32%. Validačný súbor dát obsahoval 18 000 podobrazov pre triedu true aj false. Pri validácii segmentovaním model neurónovej siete klasifikoval všetky pixely snímku do triedy true alebo false. Trieda true predstavovala vo vytvorenom obraze bielu farbu a miesto kde sa v originálnom snímku nachádza roztúsená skleróza, trieda false predstavovala čiernu farbu. Obraz ktorý vznikol sa ďalej prahoval, pretože niektoré pixely boli modelom neurónovej siete klasifikované s malou pravdepodobnosťou.

Pri validácii segmentovaním sa dosiahli hodnoty F1 skóre 4,93% (prah 0,5) a 57,71% (prah 0,99). Hodnota F1 skóre 4,93% sa dosiahla pri prahu 0,5, táto nízka hodnota je spôsobená tým, že model neurónovej siete klasifikoval 12 939 pixelov do

triedy true ale pixely patrili do triedy false. Hodnota F1 skóre 57,71% sa dosiahla pri použitom prahu 0,99. Pixely ktoré model neurónovej siete klasifikoval ako triedu true, ale klasifikoval ich s menšou hodnotou ako bol zvolený prah sa vo vytvorenej maske zmenili na triedu false respektíve čiernu farbu v maske.

Pri validácii segmentovaním sa dosiahli nízke hodnoty F1 skóre s prahom 0,5 a 0,99 oproti validácii pomocou validačného súboru dát, pretože na trénovanie sa použili nevhodné dáta a ich malý počet. Vysoký rozdiel v dosiahnutých hodnotách F1 skóre je spôsobený aj veľkým rozdielom medzi počtom trénovacích dát (2000 podobrazov) a validáciou segmentovaním (približne 140 000 podobrazov).

Zvýšenie úspešnosti klasifikácie modelu neurónovej siete sa dosiahne lepšie zvoleným súborom trénovacích dát, väčším počtom trénovacej množiny a ďalšou optimalizáciou parametrov neurónovej siete. Model umelej neurónovej siete natrénovaný v praktickej časti práce nie je vhodný na strojovú detekciu roztrúsenej pretože pri validácii segmentovaním sa dosiahli nízke hodnoty F1 skóre. Z výsledkov získaných pri validácii pomocou validačného súboru dát bolo zistené, že natrénovaný model umelej neurónovej siete sa dokáže naučiť rôzne vzory a podľa nich klasifikovať neznáme vzory do tried. Pri vytváraní modelu umelej neurónovej siete sa musí dbať na to aby sa správne zvolila trénovacia množina dát a jednotlivé parametre neurónovej siete.

LITERATÚRA

- [1] MICHAEL, N. *Neural Networks and Deep Learning* [online]. Posledná aktualizácia 22.1.2016 [cit.15.5.2016]. Dostupné z URL: <<http://neuralnetworksanddeeplearning.com/>>.
- [2] DANIEL, S. *The Nature of Code: Neural Networks* [online]. [cit.15.5.2016]. Dostupné z URL: <<http://natureofcode.com/book/chapter-10-neural-networks/>>.
- [3] STEPHEN, M. *Neuroscientific Basis and Practical Applications, Third Edition* [online]. [cit.15.5.2016]. Dostupné z URL: <http://assets.cambridge.org/97805218/57024/excerpt/9780521857024_excerpt.pdf>.
- [4] KIYOSHI, K. *Biological Neural Networks* [online]. Posledná aktualizácia 6.17.2000 [cit.15.15.2016]. Dostupné z URL: <http://osp.mans.edu.eg/rehan/ann/2_2%20Biological%20Neural%20Networks.htm>.
- [5] McCULLOCH W.S., PITTS W. *A Logical Calculus of the Ideas Immanent Nervous Activity* [online]. [cit.15.5.2016]. Dostupné z URL: <<http://deeplearning.cs.cmu.edu/pdfs/McCulloch.and.Pitts.pdf>>.
- [6] <http://www.healthline.com/health/multiple-sclerosis> [online]. Posledná aktualizácia 2013 [cit.15.5.2016]. Dostupné z URL: <<http://www.healthline.com/health/multiple-sclerosis>>.
- [7] *Čo je skleróza multiplex* [online]. poslední aktualizace 2012 [cit.15.5.2016]. Dostupné z URL: <<http://www.skleroza.info/fakty-a-myty/co-je-skleroza-multiplex>>.
- [8] *Types of MS* [online]. [cit.15.15.2016]. Dostupné z URL: <<http://www.nationalmssociety.org/What-is-MS/Types-of-MS>>.
- [9] RAJESHWAR D., PRIYANKA, SWAPNA D. *Image Segmentation Techniques* [online]. [cit.15.5.2016]. Dostupné z URL: <<http://www.iject.org/vol3issue1/rajeshwar.pdf>>.
- [10] KHAN A. M., RAVI S. *Image Segmentation Methods: A Comparative Study* [online]. [cit.15.5.2016]. Dostupné z URL: <<http://www.ijscce.org/attachments/File/v3i4/D1760093413.pdf>>.
- [11] *Image Segmentation* [online]. [cit.15.5.2016]. Dostupné z URL: <<https://www.cs.auckland.ac.nz/courses/compsci773s1c/lectures/ImageProcessing-html/topic3.htm>>.

- [12] ZHOU B., YANG X., LIU X., WEI W. *Image Segmentation with Partial Differential Equations* [online]. 2010, [cit. 15. 15. 2016]. Dostupné z URL: <<http://scialert.net/fulltext/?doi=itj.2010.1049.1052&org=11>>.
- [13] SONKA M., HLAVAC V., BOYLE R. *Image processing, Analysis and Machine Vision* Third edition, ISBN: 978-0-495-08252-1, Thomson Learning.
- [14] *How do Google's self-driving cars work?* [online]. Posledná aktualizácia 2014 [cit. 15. 5. 2016]. Dostupné z URL: <<http://www.alphr.com/cars/7038/how-do-googles-self-driving-cars-work>>.
- [15] *Convolutional Neural Networks* [online]. Posledná aktualizácia 2010 [cit. 15. 5. 2016]. Dostupné z URL: <<http://deeplearning.net/tutorial/lenet.html>>.
- [16] *Deeplearning for Java* [online]. Posledná aktualizácia 2015 [cit. 12. 12. 2015]. Dostupné z URL: <<http://deeplearning4j.org/>>.
- [17] KVASNIČKA V., BEŇUŠKOVÁ L., POSPÍCHAL J., FARKAŠ I., TIŇO P., KRÁL A. *Úvod do teórie neuronových sietí* [cit. 15. 5. 2016].
- [18] WIDROW B., HOFF M.E. *Adaptive switching circuits* WESCON convention record, IV: 96-104, 1960. [cit. 15. 5. 2016].
- [19] TAIGMAN Y., YANG M., RANZATO M., WOLF L. *DeepFace: Closing the Gap to Human-Level Performance in Face Verification* 2014. [cit. 15. 5. 2016].
- [20] GOODFELLOW I., BENGIO Y., COURVILLE A., *Deep Learning* 2016. [cit. 15. 5. 2016]. Dostupné z URL: <<http://www.deeplearningbook.org>>
- [21] DEANAND J., GHEMAWAT S. *MapReduce: Simplified Data Processing on Large Clusters* 2004. [cit. 15. 5. 2016]. Dostupné z URL: <<https://static.googleusercontent.com/media/research.google.com/en/us/archive/mapreduce-osdi04.pdf>>
- [22] WAN L., ZEILER M., ZHANG S., LECUN Y., FERGUS R. *Regularization of Neural Networks using DropConnect* Posledná aktualizácia 2013 [cit. 15. 5. 2016]. Dostupné z URL: <<http://cs.nyu.edu/~wanli/dropc/>>
- [23] MARKHAM K. *Simple guide to confusion matrix terminology* Posledná aktualizácia 2014 [cit. 15. 5. 2016]. Dostupné z URL: <<http://www.dataschool.io/simple-guide-to-confusion-matrix-terminology/>>

- [24] KAIMING H., XIANGYU Z., SHAOQING R., JIAN S. *Deep Residual Learning for Image Recognition* Posledná aktualizácia 2015 [cit. 15. 5. 2016]. Dostupné z URL: <<http://arxiv.org/pdf/1512.03385v1.pdf>>
- [25] CIRESAN D., MEIER U., SCHMIDHUBER J. *Multi-column Deep Neural Networks for Image Classification* Posledná aktualizácia 2012 [cit. 15. 5. 2016]. Dostupné z URL: <<http://people.idsia.ch/~cirestan/data/cvpr2012.pdf>>
- [26] LECUN Y., KAVUKCUOGLU K., FARABET C. *Convolutional Networks and Applications in Vision* [cit. 15. 5. 2016]. Dostupné z URL: <<http://yann.lecun.com/exdb/publis/pdf/lecun-iscas-10.pdf>>
- [27] *Early Stopping* [cit. 15. 5. 2016]. Dostupné z URL: <<http://deeplearning4j.org/earlystopping>>
- [28] NIELSEN M. *How the backpropagation algorithm works* [cit. 15. 5. 2016]. Dostupné z URL: <<http://neuralnetworksanddeeplearning.com/chap2.html>>
- [29] MCDONNELL M.D. *Enhanced image classification with a fast-learning shallow convolutional neural network* ISSN: 2161-4393. [cit. 15. 5. 2016].
- [30] *Spark* [cit. 15. 5. 2016]. Dostupné z URL: <<http://spark.apache.org/>>
- [31] *Deeplearning4j on Spark* [cit. 15. 5. 2016]. Dostupné z URL: <<http://deeplearning4j.org/spark>>
- [32] *org.deeplearning4j.eval.Evaluation* [cit. 15. 5. 2016]. Dostupné z URL: <<http://deeplearning4j.org/doc/org/deeplearning4j/eval/Evaluation.html>>
- [33] *Iterative Reduce With DL4J on Hadoop and Spark* [cit. 15. 5. 2016]. Dostupné z URL: <<http://deeplearning4j.org/iterativereduce>>
- [34] GRAHAM B. *Fractional Max-Pooling* Posledná aktualizácia 2015. [cit. 15. 5. 2016]. Dostupné z URL: <<http://arxiv.org/abs/1412.6071>>
- [35] *CIFAR-10 - Object Recognition in Images* Posledná aktualizácia 2016. [cit. 15. 5. 2016]. Dostupné z URL: <<https://www.kaggle.com/c/cifar-10>>
- [36] *CIFAR-10* Posledná aktualizácia 2016. [cit. 15. 5. 2016]. Dostupné z URL: <http://rodrigob.github.io/are_we_there_yet/build/classification_datasets_results.html#43494641522d3130>
- [37] BURGET R. *Teoretická informatika* ISBN: 978-80-214-4897-1.

- [38] POGORELC D. *New molecular test in clinical trials could help physicians identify multiple sclerosis earlier* Posledná aktualizácia 2012. [cit. 15. 5. 2016]. Dostupné z URL: <<http://medcitynews.com/2012/12/new-molecular-test-in-clinical-trials-could-help-physicians-identify-multiple-sclerosis-earlier/>>

ZOZNAM SYMBOLOV, VELIČÍN A SKRATIEK

ADALINE	Adaptive Linear Neuron - Adaptívny lineárny neurón
API	Application programming interface - Rozhranie pre programovanie aplikácií
CSV	Comma separated values - Hodnoty oddelené čiarkami
CT	Computer Tomography - Počítačová tomografia
DL4J	Deeplearning for Java - Hlboké učenie pre programovací jazyk Java
Lidar	Light Detection and Ranging - Detekcia svetla a vzdialenosti
ReLU	Rectified Linear Unit - Usmernená lineárna funkcia
SRM	Statistical region merging - Spájanie regiónov v obraze podľa štatistiky
UNS	Umelá Neurónová Sieť

ZOZNAM PRÍLOH

A	Obsah priloženého CD	46
A.1	Použité triedy v praktickej časti	46
A.2	Postup pri použití modelu UNS	46
A.3	Adresárová štruktúra priloženého CD	47

A OBSAH PRILOŽENÉHO CD

Na priloženom CD sa nachádza elektronická verzia diplomovej práce a exportovaný projekt z vývojového prostredia Eclipse. Exportovaný projekt obsahuje všetky zdrojé kódy a model neurónovej siete použitý v praktickej časti diplomovej práce.

A.1 Použité triedy v praktickej časti

Exportovaný projekt pozostáva zo šiestich základných tried, ktoré predstavujú súbory:

1. `LogBackFilter.java` - táto trieda slúži ako filter pre logovanie
2. `DataUtils.java` - táto trieda obsahuje metódu určenú na vytváranie súboru dát a metódu na vytvorenie obrazu z uložených dát v súbore CSV
3. `ImageUtils.java` - obsahuje pomocné metódy pre prácu s obrazmi
4. `NeuralNetworkUtils.java` - táto trieda obsahuje metódy pre vytváranie konfigurácie neurónovej siete a pomocné metódy pre ukladanie modelu neurónovej siete jeho obnovenie z pamäte
5. `SlidingWindow.java` - trieda slúži na generovanie podobrazov a ich uloženie do súboru CSV
6. `Run.java` - v tejto triede prebieha generovanie podobrazov, trénovanie modelu neurónovej siete a jeho validácia

A.2 Postup pri použití modelu UNS

Základnou triedou, ktorá ovláda celý beh aplikácie, predstavuje spustiteľná trieda `Run`. Táto trieda obsahuje štyri riadiace konštanty, ktoré určujú ktorá časť aplikácie sa bude vykonávať. Ukážka zdrojového kódu A.1 zobrazuje tieto riadiace konštanty.

Zdrojový kód A.1: Definícia riadiacich konštánt.

```
private static final boolean GENERATE_WINDOWS_FROM_IMAGES = true;
private static final boolean TRAIN_NETWORK = false;
private static final boolean LOAD_AND_VALIDATE_NETWORK = false;
private static final boolean SEGMENTATE_IMAGE_WITH_NETWORK = false;
```

V prípade, že je konštanta z A.1 nastavená na hodnotu `true`, tak sa vykoná tá časť aplikácie, ktorá zodpovedá konštante. Napríklad ak bude nastavená konštanta `GENERATE_WINDOWS_FROM_IMAGES` a `TRAIN_NETWORK` na hodnotu `true`, tak sa vygenerujú podobrazy zo snímkov z magnetickej rezonancie a natrénuje sa model neurónovej siete. Ďalšie možnosti nastavenia sú uvedené ako komentáre v priložených zdrojových kódach.

A.3 Adresárová štruktúra priloženého CD

Základná adresárová štruktúra priloženého CD:

```
Priložené CD
├── Elektronická verzia diplomovej práce
├── DP_MajtánMartin
│   ├── .settings
│   ├── data
│   │   ├── csv
│   │   ├── image
│   │   ├── 0101AS
│   │   │   └── masks
│   │   ├── 0102HS
│   │   │   └── masks
│   │   ├── 0103PR
│   │   │   └── masks
│   │   ├── 0104VR
│   │   │   └── masks
│   │   ├── 0105ZL
│   │   │   └── masks
│   │   ├── 0106KR
│   │   │   └── masks
│   │   ├── 0107LE
│   │   │   └── masks
│   │   ├── 0108NE
│   │   │   └── masks
│   │   ├── 0109PL
│   │   │   └── masks
│   │   └── 0110PA
│   │       └── masks
│   ├── logs
│   ├── NN_models
│   ├── results
│   ├── src
│   │   ├── main
│   │   │   ├── java
│   │   │   └── resources
│   ├── target
│   ├── .classpath
│   ├── .project
│   └── pom.xml
```

Adresárová štruktúra na priloženom CD obsahuje elektronickú verziu diplomovej práce a exportovaný projekt z vývojového prostredia Eclipse¹. Exportovaný projekt obsahuje všetky zdrojové kódy ktoré sa nachádzajú v adresári `java`. Adresár `image` obsahuje jednotlivé 3D snímky hlavy z magnetickej rezonancie, každý snímok je vo vlastnom adresári (`0101AS`, `0102HS`, atď.). V adresári so snímkami sa nachádza adresár s maskami (`masks`). V adresári `csv` sa nachádza trénovací, testovací a validačný súbor dát vo formáte CSV². Uložený model neurónovej siete sa nachádza v adresári `NN_models`. Výsledky segmentácie snímky z magnetickej rezonancie pomocou modelu umelej neurónovej siete sa nachádzajú v adresári `results`.

¹<https://eclipse.org/>

²Comma separated values - Hodnoty oddelené čiarkami