

TRAINABLE IMAGE SEGMENTATION USING DEEP NEURAL NETWORKS

Martin Majtán

Master Degree Programme (2), FEEC BUT

E-mail: xmajta02@stud.feec.vutbr.cz

Supervised by: Pavol Harár

E-mail: harar@phd.feec.vutbr.cz

Abstract: This paper is focused on trainable segmentation of image with use of deep neural networks. In this paper, the principle of creating images from magnetic resonance, generating data with algorithm of sliding window, creating a data set used for training neural network and principal segmentation of image with neural network is described. In practical part the algorithm of sliding window is created for generating data from magnetic resonance images and created model of artificial neural network used for image segmentation. In the practical part was achieved accuracy of segmentation 64 %.

Keywords: neural network, deep learning, segmentation, MRI, DL4J, multiple sclerosis

1 ÚVOD

Roztrúsená skleróza je ochorenie centrálného nervového systému ktoré postihuje autoimunitný systém, zrakové nervy, miechu a mozog. Pri ochorení imunitný systém napáda myelínový obal nervových vlákien. Myelínový obal ktorý obklopuje nervové vlákna je potrebný k správne šíreniu elektrických signálov. [3]

Táto práca sa venuje trénovateľnej segmentácii obrazu s použitím hlbokých neurónových sietí. Segmentácia obrazu je proces pri ktorom sa obraz rozdeľuje na segmenty tak že jednotlivé segmenty v obraze predstavujú reálne objekty. V danej práci sa trénovateľná segmentácia obrazu využíva na segmentáciu snímok hlavy ľudí z magnetickej rezonancie a následnú detekciu roztrúsenej sklerózy.

2 PRÍPRAVA DÁT PRE NEURÓNOVÚ SIŤ

Ako vstupné dáta pre proces segmentácie boli použité čiernobiele troj-rozmerné snímky hlavy z magnetickej rezonancie a k nim prislúchajúce masky, ktoré určujú kde v obraze sa nachádza roztrúsená skleróza. Masky majú rovnaké rozmery ako snímky. Na tom istom mieste kde sa v maske nachádza biela farba je v snímku vyznačená roztrúsená skleróza. Masky boli vytvorené manuálne lekárom. Pomocou snímok a masiek boli vytvorené dva datasey ktoré slúžili na tréovanie a testovanie neurónovej siete.


Pomocou algoritmu kľzajúceho okna boli vytvorené podobrazy zo snímok, ktoré sa použili na tréovanie a testovanie neurónovej siete. Algoritmus kľzajúceho okna postupne posúva okno po jednotlivých pixeloch s určitým krokom a z pixelov ktoré sa aktuálne nachádzajú v okne vytvorí nový podobraz. Trieda do ktorej patrí aktuálny podobraz sa určí podľa toho akú farbu má pixel v maske, ktorý je na rovnakej pozícii ako stredový pixel aktuálneho podobrazu. Ak sa v maske nachádza biely pixel tak aktuálne okno patrí do triedy true (trieda true označuje okná kde sa nachádza roztrúsená skleróza), inak patrí do triedy false. Takýmto procesom sa vygenerovalo 8000 podobrazov pre tréovací a testovací dataset. Každý dataset bol rozdelený na triedu true a false, pre každú triedu bolo vygenerovaných 4000 podobrazov. Vygenerované podobrazy mali veľkosť 29×29 pixelov. Obrázok 1

zobrazuje snímok hlavy z magnetickej rezonancie, žltý štvorec predstavuje kľúčajúce okno použité na generovanie podobrazov pre neurónovú sieť. [1, 2, 5]



Obrázek 1: Obrázok zobrazuje snímok z magnetickej rezonancie a kľúčajúce okno (žltý štvorec).

Pretože vygenerované podobrazy rovnako ako originálne snímky sú čiernobiele a hodnoty pixelov sú v rozsahu od 0 do 255 je potrebné normalizovať hodnoty pixelov. Normalizácia vstupných dát pre neurónovú sieť je dôležitá pre efektívnejšie a rýchlejšie učenie neurónovej siete a minimalizáciu chýb. Normalizácia sa robila prepočítaním hodnôt pixelov z rozsahu od 0 do 255 do rozsahu od 0 do 1.



Obrázek 2: Vygenerované podobrazy pomocou algoritmu kľúčajúceho okna.

Obrázok 2 zobrazuje dva vygenerované podobrazy pred normalizáciou. Prvý podobraz patrí do triedy false, nezobrazuje roztrúsenú sklerózu. Druhý podobraz patrí do triedy true, zobrazuje roztrúsenú sklerózu. Po normalizácii podobrazov sa dvojrozmerné dáta previedli na vektor dát a pridalo sa k nim označenie do ktorej triedy jednotlivé podobrazy patria.

3 MODEL UMELEJ NEURÓNOVEJ SIETE

Na vytvorenie modelu umelej neurónovej siete bola použitá knižnica Deep Learning for Java (DL4J) [4]. V tejto knižnici bol vytvorený model umelej neurónovej siete s ôsmimi vrstvami. Pri tréňovaní modelu neurónovej siete bol použitý krok učenia 0,000001, na učenie bolo použitých 8000 vygenerovaných okien pri 250 iteráciách a algoritmus spätného šírenia chýb. Aby sa zabránilo pretréňovaniu neurónovej siete, tak po každej tréňovacej iterácii sa sieť otestovala na tréňovacích dátach. Následne sa uložili aktuálne váhy a úspešnosť modelu. Po skončení tréňovania sa vyhládala najvyššia dosiahnutá úspešnosť modelu a použili sa váhy patriace k tejto úspešnosti. Tabuľka 1 zobrazuje vrstvy a parametre umelej neurónovej siete použitej pri segmentácii obrazu. Pri tréňovaní modelu neurónovej siete sa dosiahla úspešnosť 96 %. [1]

Segmentácia obrazu pomocou natréňovanej siete sa robila rovnako ako generovanie okien. Vytvorilo sa okno ktoré sa normalizovalo a vložilo do natréňovanej siete. Výstupom siete boli dve pravdepodobnosti, kde každá určovala príslušnosť k jednej z dvoch tried. Podľa pravdepodobností sa určilo či

Vrstva neurónovej siete	Popis vrstvy neurónovej siete
Konvolučná vrstva 1	veľkosť filtru 5×5 pixelov, aktivačná funkcia typu Relu
Podvzorkovacia vrstva 1	veľkosť filtru 2×2 pixelov, výber pixelu s maximálnou hodnotou
Konvolučná vrstva 2	veľkosť filtru 2×2 pixelov, aktivačná funkcia typu Relu
Podvzorkovacia vrstva 2	veľkosť filtru 2×2 pixelov, výber pixelu s maximálnou hodnotou
Perceptronová vrstva 1	počet neurónov 500, aktivačná funkcia typu Relu
Perceptronová vrstva 2	počet neurónov 400, aktivačná funkcia typu Relu
Perceptronová vrstva 3	počet neurónov 300, aktivačná funkcia typu Relu
Výstupná vrstva	aktivačná funkcia typu Softmax

Tabulka 1: Tabuľka zobrazuje jednotlivé vrstvy a parametre umelej neurónovej siete.

pixel v strede podobrazu predstavuje alebo nepredstavuje roztrúsenú sklerózu. Výsledný obraz predstavoval masku k vstupnému snímku z magnetickej rezonancie. Biele pixely vo vytvorenej maske určovali roztrúsenú sklerózu označenú modelom neurónovej siete. Validácia natrénovanej neurónovej siete bola robená segmentáciou snímku. Dosiagnutá úspešnosť bola 64 % a pri validácii bolo použité nastavenie neurónovej siete z tabuľky 1. [1, 2, 5]

4 ZÁVER

Práca sa venuje trénovateľnej segmentácii obrazu s použitím hlbokých neurónových sietí. Trénovateľná segmentácia obrazu sa v práci využíva na segmentovanie snímok hlavy z magnetickej rezonancie a následnú detekciu roztrúsenej sklerózy. V práci bol vytvorený algoritmus klzajúceho okna na generovanie podobrazov a model umelej neurónovej siete použitý na segmentovanie snímok z magnetickej rezonancie. Pri trénovaní modelu neurónovej siete sa dosiahla úspešnosť 96 %. Pri validácii natrénovaného modelu neurónovej siete sa dosiahla úspešnosť 64 %. Takto natrénovaný model neurónovej siete nie je vhodný na detekciu roztrúsenej sklerózy kvôli nízkej úspešnosti pri segmentácii. Nízka úspešnosť je spôsobená slabým natrénovaním modelu neurónovej siete, malým počtom iterácií pri trénovaní a malým datasetom trénovacích dát. Ďalšie zvýšenie presnosti sa dosiahne použitím vyššieho počtu vygenerovaných podobrazov, ktoré budú použité na trénovanie umelej neurónovej siete a optimalizáciou jednotlivých parametrov neurónovej siete (počet vrstiev a neurónov).

REFERENCE

- [1] NIELSEN, M.: Neural Networks and Deep Learning [online]. 2016 [cit. 2015-03-06]. Dostupné z: <http://neuralnetworksanddeeplearning.com/>
- [2] KRIZHEVSKY, A., SUTSKEVER I., HINTON, G.: ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems. 2012, (25): 9. Dostupné z: <http://www.cs.toronto.edu/%7Efritz/absps/imagenet.pdf>
- [3] Sclerosis multiplex: Ochorenie [online]. 2016 [cit. 2015-03-06]. Dostupné z: <http://sclerosis-multiplex.sk/ochorenie/>
- [4] What is Deeplearning4j? [online]. 2016 [cit. 2015-03-06]. Dostupné z: <http://deeplearning4j.org/>
- [5] CHEN, L., PAPANDREOU G., KOKKINOS I., MURPHY K., L. YUILLE A.: Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs [online]. 2014 [cit. 2015-03-27]. Dostupné z: <http://arxiv.org/abs/1412.7062v3>