

DETECTION OF ANATOMICAL STRUCTURES IN CT DATA USING CONVOLUTIONAL NEURAL NETWORKS

Dominika Kozlová

Master Degree Programme (2), FEEC BUT

E-mail: xkozlo03@stud.feec.vutbr.cz

Supervised by: Roman Jakubíček

E-mail: jakubicek@feec.vutbr.cz

Abstract: This paper deals with a detection of anatomical structures in medical images using convolutional neural networks (CNN). The designed algorithm contains 2 methods for region proposals and CNN for their classification into categories. Output of the CNN is then postprocessed to obtain the detection result. Categories for detection are head, spine, heart, left and right lung, aorta, liver, left and right kidney, spleen and background. For training and validation of the network were created 2 sets of CT data with annotated areas of selected structures.

Keywords: detection, convolutional neural network, region proposal, selective search

1 ÚVOD

Detekce anatomických struktur je důležitým krokem v klinickém zpracování obrazů pro plánování terapie a intervencí, bývá také předzpracováním pro segmentační metody. Jedná se o důležitou součást systémů pro pomocné stanovení diagnózy, neboť ušetří časově náročnou práci lékařům. V poslední době jsou pro tyto účely využívány také konvoluční neuronové sítě, které patří mezi metody strojového učení a pro jejich velmi dobré výsledky jsou voleny i v této práci. [1]


Metody strojového učení mají obecně fázi učební, při níž se učí na trénovací množině dat, a fázi predikce, kdy se naučený model využívá pro predikci výstupu u dosud neznámých dat. U konvolučních neuronových sítí je jednou z hlavních výhod fakt, že není třeba extrakce příznaků ze vstupních dat, jak je tomu u tradičních metod strojového učení. Od klasických neuronových sítí se liší zejména v architektuře, neboť využívají různého propojení neuronů v jednotlivých vrstvách, a jsou proto vhodnější pro zpracování obrazů. [2]

2 DATA

Pro tvorbu anotací databáze byla využita reálná CT data 25 pacientů, z nichž část pochází z veřejně přístupné části archivu National Biomedical Imaging Archive (NBIA), část z The Cancer Imaging Archive (TCIA) a část z Ústavu biomedicínského inženýrství VUT v Brně. Pro detekci bylo vybráno 10 anatomických struktur, konkrétně hlava, páteř, srdce, levá a pravá plíce, aorta, játra, levá a pravá ledvina a slezina. Pozice uvedených anatomických struktur byly v CT snímcích určeny a zaznamenány. Takto anotovaná data byla rozdělena na část trénovací pro učení sítě a část validační pro ověření funkčnosti sítě. Pro trénovací dataset byly vybrány snímky 18 pacientů a pro testovací 7 pacientů.

3 REALIZOVANÁ METODA

Navržená metoda detekce vychází z návrhů oblastí, které jsou ze vstupních dat získány v rámci předzpracování. Tyto oblasti jsou následně klasifikovány konvoluční neuronovou sítí do 11 tříd, z nichž 10 náleží anatomickým strukturám a 1 pozadí. Výstup sítě je následně podroben dalšímu zpracování pro získání výsledku detekce. Schéma realizované metody je na následujícím obrázku.



Obrázek 1: Schéma realizované metody.

3.1 ZÍSK NÁVRHŮ OBLASTÍ

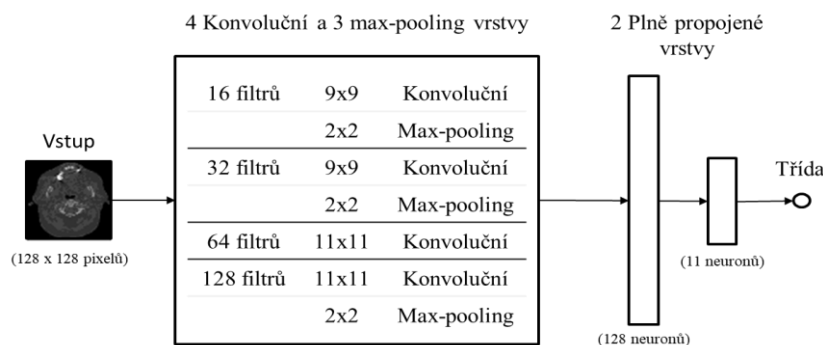
V rámci předzpracování dat jsou ze vstupního snímku generovány návrhy oblastí, které v něm potenciálně ohraničují hledanou strukturu. Získány jsou pomocí algoritmu selektivního vyhledávání (Selective Search [3]) anebo pomocí aplikace posuvného okna. Zde je možnost volby mezi metodami, neboť má každá svá specifika.

Pro trénování i validaci byly oblasti, které se překrývají s plochou objektu z více než 65 %, označeny třídou objektu. Ty oblasti, které jsou s označenou strukturou v překryvu menším než 30 %, jsou označeny jako pozadí. Oblasti s překryvem mezi stanovenými mezemi 30 a 65 % nejsou brány pro učení sítě v potaz. Následující konvoluční neuronová síť vyžaduje vstupní data stejné velikosti, proto je velikost všech získaných oblastí před vstupem upravena na 128 x 128 pixelů.

3.2 KONVOLUČNÍ NEURONOVÁ SÍŤ

Navržená konvoluční neuronová síť provede klasifikaci vstupních oblastí snímku do jedné z 11 tříd. Obecně navržená architektura sítě obsahuje několik vrstev konvolučních a dále vrstvy plně propojené. Konvoluční vrstvy mohou být následovány max-pooling vrstvami (s posuvným oknem velikosti 2x2). Pro aktivaci jsou v síti ReLU vrstvy zařazené za výstup vrstev konvolučních a plně propojených. Jen u výstupní vrstvy je využita aktivační funkce softmax, výhodná pro klasifikaci, neboť její výstupní hodnoty leží mezi 0 a 1 a udávají tak míru zařazení do jednotlivých tříd. Poslední vrstva sítě obsahuje tolik neuronů, kolik bylo zvoleno tříd pro klasifikaci dat, tedy 11.

Pro učení sítě byly počáteční hodnoty vah a prahu generovány jako náhodná čísla s normálním rozložením se směrodatnou odchylkou 0,05. Rychlost učení byla nastavena na hodnotu 0,0001. Jako kritériální funkce byla využita křížová entropie (cross entropy). Výsledná konvoluční neuronová síť je uvedena na následujícím obrázku. Obsahuje 4 vrstvy konvoluční, z nichž jsou 3 následovány max-pooling vrstvami, dále 2 vrstvy plně propojené se 128 a 11 neurony.



Obrázek 2: Schéma výsledné konvoluční neuronové sítě. U konvolučních a max-pooling vrstev je uveden počet filtrů a jejich velikost.

3.3 ZÁVĚREČNÉ ZPRACOVÁNÍ

Výstupy z konvoluční neuronové sítě tvoří oblasti vstupního obrazu zařazené do jednotlivých kategorií. Vzhledem k tomu, že je tímto způsobem získáno pro jednu hledanou strukturu zpravidla více výsledných oblastí, které se často z velké části překrývají, případně se vyskytují i falešné detekce, musí být provedeno další zpracování.

U více nalezených oblastí jedné anatomické struktury je určena míra jejich překryvu dle metriky Intersection over Union (IoU). Pokud se oblasti překrývají více, než je zvolená mez (např. 0.5), je vybrána jako výsledná oblast ta s vyšší mírou zařazení do třídy, danou výstupem z softmax funkce.

3.4 VÝSLEDKY

Na vytvořené učební a validační databázi anotovaných CT snímků bylo učeno několik navržených architektur CNN s různými počty i parametry jednotlivých vrstev. Stanovován pak byl maximální počet správných klasifikací u 2200 snímků z validační datové sady při učení CNN. Výsledná síť s 95,5 % správně klasifikovaných snímků z validační množiny, senzitivitou 0,98 a specificitou 0,6 je uvedena na obrázku 2. Výsledky klasifikace u jednotlivých anatomických struktur ukazuje následující tabulka s maticí záměn (confusion matrix).

		Predikované třídy										
		Páteř	Srdce	Levá plíce	Pravá plíce	Hlava	Aorta	Játra	Levá ledvina	Pravá ledvina	Slezina	Pozadí
Označené třídy	Páteř	100	0	0	0	0	0	0	0	0	0	0
	Srdce	2,5	97	0	0	0	0	0	0	0	0,5	0
	L. plíce	0	0	98,5	1	0	0	0,5	0	0	0	0
	P. plíce	0	0	0,5	99,5	0	0	0	0	0	0	0
	Hlava	4,5	1	0	0	94,5	0	0	0	0	0	0
	Aorta	0	0	0	0	0	99,5	0	0	0	0,5	0
	Játra	0	0,5	0	0	0	0	99	0	0	0,5	0
	L. ledvina	0	0	0	0	0	1,5	0,5	95	0	3	0
	P. ledvina	0	0	0	0	0	3	0	1,5	95,5	0	0
	Slezina	0	0	0	0	0	0	0	0	0	100	0
Pozadí	1	17	0	0	2	1	7	0	0	0	72	

Tabulka 1: Matice záměn s výsledky klasifikace CNN pro jednotlivé třídy v procentech vztahených k počtu 200 označených snímků jedné třídy.

4 ZÁVĚR

Pro práci s konvoluční neuronovou sítí byla vytvořena databáze anotovaných CT snímků od 25 pacientů s označenými oblastmi 10 anatomických struktur, rozdělená na trénovací a validační část. Pro detekci vybraných struktur byl realizován algoritmus vycházející z návrhů oblastí, které jsou následně klasifikovány konvoluční neuronovou sítí a dále zpracovány pro získání výsledku detekce. Metoda byla implementována v programovacím jazyce Python s využitím knihovny TensorFlow.

Provedeno bylo učení a validace několika navržených CNN na vytvořené anotační databázi. Maximálního počtu správných klasifikací snímků z validační množiny 95,5 % bylo dosaženo u sítě se 4 konvolučními vrstvami. Poměrně jednoduchá síť s nevelkým množstvím vrstev dobře klasifikovala i struktury pro detekci „obtížnější“. Na základě prezentovaných výsledků lze tedy konstatovat, že se CNN jeví jako vhodné řešení pro detekci různých anatomických struktur v CT datech.

REFERENCE

- [1] LITJENS, Geert, Thijs KOOI, Babak Ehteshami BEJNORDI, et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*. 2017, 42, 60-88, ISSN 13618415.
- [2] Introducing convolutional networks. NIELSEN, Michael. *Neural Networks and Deep Learning* [online]. Determination Press, 2015 [cit. 2017-08-14]. Dostupné z: http://neuralnetworksanddeeplearning.com/chap6.html#introducing_convolutional_networks
- [3] UIJLINGS, J. R. R., K. E. A. VAN DE SANDE, T. GEVERS a A. W. M. SMEULDERS. Selective Search for Object Recognition. *International Journal of Computer Vision*. 2013, 104(2), 154-171. DOI: 10.1007/s11263-013-0620-5. ISSN 0920-5691.