

Semiautomatické vyhledávání a charakterizace stenóz a uzávěrů plicních tepen u pacientů s chronickou tromboembolickou plicní hypertenzí

Autor: Ing. Evgeniia Mardanshina

Spolupráce: MUDr. Vladimír Černý, Ph.D. (Radiodiagnostická klinika 1. LF UK a VFN)

Cíle


- Navrhnout a implementovat algoritmus pro semiautomatickou detekci trombóz a uzávěrů v plicních tepnách s využitím CNN na základě získaných CTA snímků hrudníku pacientů s diagnózou CTEPH.
- Ověřit funkčnost algoritmu na pilotním souboru pacientů s anonymizovanými údaji a statisticky vyhodnotit výsledky.
- Charakterizovat a popsat typické projevy daného onemocnění plicních tepen a diskutovat, jak lze metodami radiomiky zhodnotit míru závažnosti poškození tepen.

Typické projevy CTEPH

- Vaskulární příznaky
- Plicní hypertenze
- Parenchymální příznaky
- Příznaky systémového kolaterálního oběhu




Vaskulární příznaky





Metody

- Aplikace *sémantické segmentace* pomocí hlubokých CNN



Metody I. *Trénovací množina*

-  *Neprázdné oblasti, kde se patologie plicních cév vyskytovat nemůže*
-  *Plicní okénka a nejmenší cévní struktury*
-  *Oblast zájmu, kde se patologie potenciálně může nacházet*
-  *Patologický projev CTEPH, který je vyznačen lékařem*
-  *Background (bez labelů)*





Metody II. *Trénování*

Trénování je realizováno na GPU NVIDIA GeForce GTX 1050 Ti 4.0 GB. Trénování trvalo 518 minut. Počet iterací na epochu je 65, celkový počet iterací je 6500

Parametr	Hodnota
Počet epoch	100
Velikost mini-batch	4
Počáteční rychlost učení	10^{-3}
Optimalizátor	Adam

Metody III. *Testovací množina*

Testovací množina zahrnuje snímky 25 pacientů s potvrzenou diagnózou CTEPH (35 snímků) a jednoho pacienta, u kterého dané onemocnění bylo vyloučeno (20 snímků)



Metody IV. *Statistika*

- Analýza vytvořeného algoritmu (*evaluateSemanticSegmentation*)
 - *Matice záměn, normalizovaná matice záměn*
 - *Metriky per class (přesnost, Intersection over Union, střední Boundary F1 skóre)*
 - *Metriky per image (globální a průměrná přesnost, průměrné a vážené IoU, střední BF skóre)*
 - *Metriky per dataset (globální a průměrná přesnost, průměrné a vážené IoU, střední BF skóre)*

- Statistická analýza výsledků detekce

- $Senzitivita = \frac{TP}{TP+FN}$

- $Specificita = \frac{TN}{TN+FP}$

Matthews correlation coefficient

- $$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}}$$

Výsledky sémantické segmentace

		Výsledky sémantické segmentace	
		Patologie	Background
Referenční snímky	Patologie	TP	FP
	Background	FN	TN

Výsledky. Hodnocení kvality algoritmu


Matice záměn

	Background	NemuzeSeVyskytovat	PlicniOkenko	ROI	Patologie
Background	21 726 210	92 622	17 580	66 093	156
NemuzeSeVyskytovat	183 864	30 048 741	316 863	242 652	8 421
PlicniOkenko	543	57 927	13 885 638	61 797	2 544
ROI	9	2 943	3 975	1677348	10 728
Patologie	0	0	0	0	12 930

Normalizovaná matice záměn

	Background	NemuzeSeVyskytovat	PlicniOkenko	ROI	Patologie
Background	0,9919	0,0042	$8,0264 \cdot 10^{-5}$	0,0030	$7,1224 \cdot 10^{-5}$
NemuzeSeVyskytovat	0,0060	0,9756	0,0103	0,0079	$2,7340 \cdot 10^{-4}$
PlicniOkenko	$3,8765 \cdot 10^{-5}$	0,0041	0,9912	0,0044	$1,8160 \cdot 10^{-4}$
ROI	$5,4097 \cdot 10^{-6}$	0,0017	0,0023	0,9896	0,0063
Patologie	0	0	0	0	1

Výsledek sémantické segmentace



Patologie



ROI



Plicní okénko




Nemůže se vyskytovat



Background

Ručně vyznačené oblasti




	<i>Patologie</i>	<i>Background</i>
<i>Patologie</i>	35	21 (FP)
Background	7 (FN)	55

$$\text{Senzitivita} = \frac{35}{35 + 7} = 0,83 \text{ neboli } 83 \%$$


$$\text{Specificita} = \frac{55}{55 + 21} = 0,72 \text{ neboli } 72 \%$$

$$\text{Matthews correlation coefficient} = \frac{35 \cdot 55 - 21 \cdot 7}{\sqrt{(35 + 21)(35 + 7)(55 + 21)(55 + 7)}} = 0,53$$

Výsledek sémantické segmentace ($2 \times TP, 1 \times FP$)



Reference



Diskuze I. *Výsledky*

- Přesnost sémantické segmentace přesahuje **97,5 %**. Drobné nepřesnosti mohly být způsobeny vynecháním pár pixelů při ručním labelování v jiných třídách než Patologie.
- Počet správně odhalených patologických míst je **TP=35**. Přičemž **4** z nich nebyly nejprve lékařem označeny, ale byly následně zkontrolovány po predikci algoritmem.
- Počet FP nálezů je **21**. Jde především o místa, kde se charakter změny kontrastu podobá skutečně pozitivním nálezům.
- V **83 %** případů navržený algoritmus správně odhalí přítomnou vaskulární patologii a v **72 %** přesně vybere případy, u nichž zkoumaná patologie nenastává.
- Predikční schopnost navrženého algoritmu se dá charakterizovat jako mírně pozitivní.

Diskuze II. *Metody, limitace a uplatnění v radiomice*

- Nejlepší výsledky přinesly:
 - definice 5 labelů,
 - CNN DeepLab V3+ s výpočetní základnou Xception,
 - modifikace vah pomocí mediánu frekvence
 - počet epoch 100
- Zaměření na určité projevy. Snaha zvýšit specifitu algoritmu.
- Citlivost algoritmu vůči změně kontrastu obrázku.
- Radiomika: získání dat, segmentace, extrakce příznaků a analýzy.
- Segmentace a extrakce příznaků: sémantická segmentace s použitím CNN.
- Při analýze by měly být brány v potaz nejen anatomické projevy CTEPH, ale také funkční.

Závěr

- Aplikace sémantické segmentace pomocí Modelu DeepLab V3+ s váhami inicializovanými z Xception.
- Přesnost sémantické segmentace neboli poměr správně klasifikovaných pixelů v k-té třídě ku celkovému počtu pixelů, přesahuje **97,5 %**.
- V **83 %** případů navržený algoritmus správně odhalí přítomnou vaskulární patologii a v **72 %** přesně vybere případy, u nichž zkoumaná patologie nenastává.
- Predikční schopnost navrženého algoritmu se dá charakterizovat jako mírně pozitivní.
- Navržený algoritmus by zatím mohl podpořit diagnostiku CTEPH, poskytnout radiologovi „druhý názor“ a zmenšit vliv subjektivních parametrů při stanovení diagnózy.