

SEGMENTACE A REGISTRACE
ULTRAZVUKOVÝCH A HISTOLOGICKÝCH
OBRAZŮ PRO ÚČELY HODNOCENÍ
STABILITY ATEROSKLEROTICKÉHO PLÁTU
V KAROTIDĚ

ING. MICHAL REIMER



Úvod a motivace

- Ateroskleróza krkavice je jednou z hlavních příčin mozkové mrtvice a řadí se tak mezi hlavní příčiny úmrtí celosvětově (1 ze 17 případů).
- Včasná detekce přítomnosti aterosklerotických plátů a jejich monitoring je však stále velký problém- jedná se často o invazivní metody, a je značně závislá na zkušenostech vyšetřujícího lékaře.
- Hlavním cílem našeho projektu je identifikace a popis vlastností rizikových aterosklerotických plátů na obrazech získaných za pomoci 2D ultrazvukových snímků a histologických vyšetření a vytvoření metodiky pro automatickou detekci rizikových aterosklerotických plátů za pomoci neinvazivních vyšetření.



Princip analýzy rizikovosti aterosklerotického plátu

- Ateroskleróza je chronické onemocnění cévní stěny, kdy dochází k akumulaci lipidových či vápenitých částic, fibrózních tkání a dalších krevních komponent na stěně cévy, což vede ke snížení průtoku krve a může vést ke kompletnímu ucpání, či uvolnění části aterosklerotického plátu, což se řadí mezi nejčastější příčiny mozkové mrtvice.
- K detekci přítomnosti a rizikovosti aterosklerotického plátu dochází bohužel velmi často až při invazivních zákrocích souvisejících s komplikacemi způsobenými ucpáním cévy, či uvolněním části aterosklerotického plátu.
- Neinvazivní ultrazvukové vyšetření bohužel nedosahuje dostatečných kvalit a přesnosti, abychom z něj mohli spolehlivě pohledem analyzovat aterosklerotický plát.
- Cílem naší práce je tedy využití detailních histologických obrazů pro nalezení odpovídajících identifikátorů jednotlivých součástí aterosklerotického plátu v ultrazvukových snímcích, a v kombinaci s využitím souvisejících anamnéz se pokusit definovat příznaky rizikovosti aterosklerotického plátu v ultrazvukových obrazech.


Vstupní dataset



Vstupní dataset



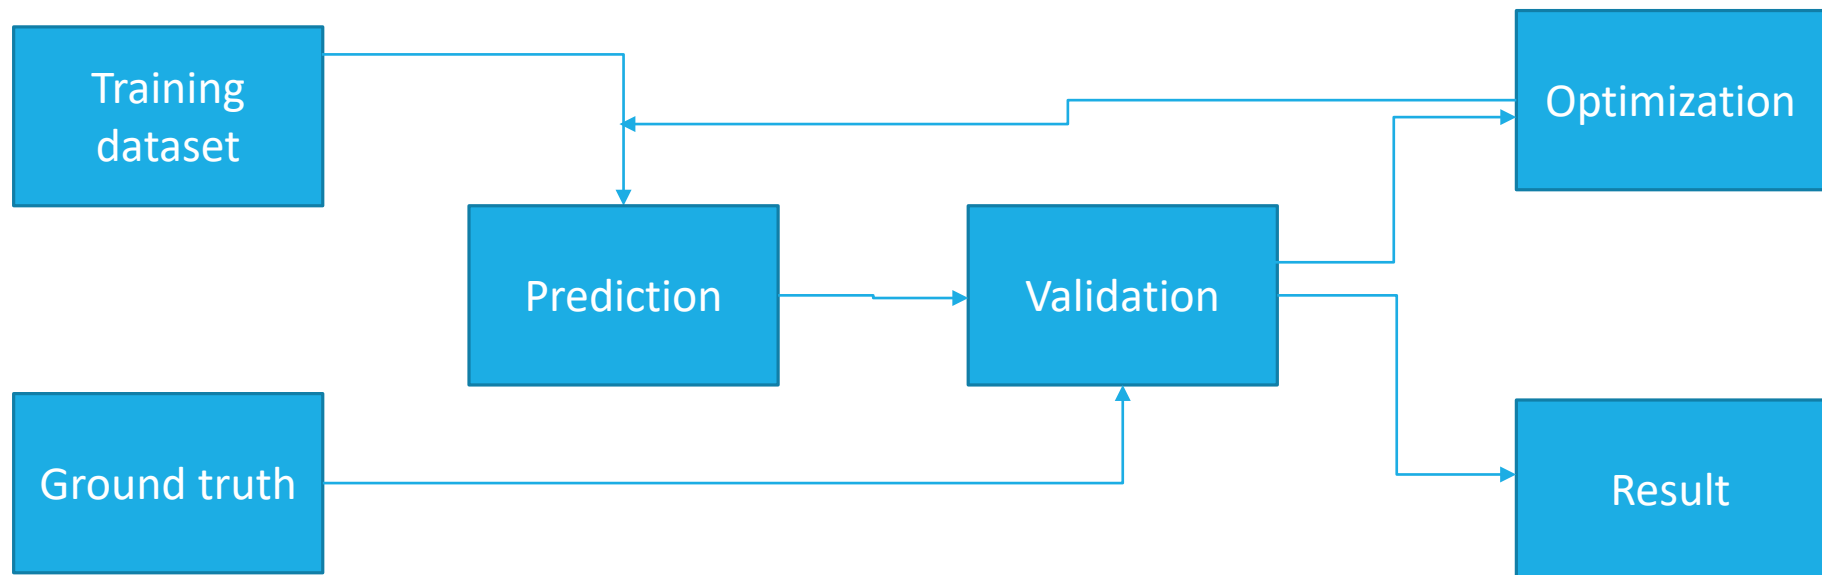
Vstupní dataset



Navrhovaný postup



1. Analýza vstupních dat a jejich filtrace
2. Segmentace ultrazvukových snímků pro účely registrace
3. Segmentace histologických snímků pro účely registrace
4. Segmentace histologických snímků pro účely analýzy aterosklerotického plátu
5. Registrace a spárování ultrazvukových a histologických snímků
6. Analýza a segmentace ultrazvukových snímků na základě odpovídajících dat z histologických snímků
7. Využití anamnézy pacientů pro upřesnění analýzy rizikových aterosklerotických plátů na ultrazvukových snímcích

Supervised learning model



1. Analýza vstupních dat a jejich filtrace

- 138 pacientů s různou úrovní prezenze aterosklerotického plátu
 - Manuální filtrací vybrány 3-4 použitelné ultrazvukové snímky (pro každý histologický řez)
 - 2-4 histologické snímky pro každé ze dvou použitých barviv
 - Světlé = hematoxylin-eosin pro hodnocení základní struktury tkáně
 - Tmavé- Waigert van Giesonovo barvení pro zvýšení kontrastu kolagenního vaziva





2. Segmentace ultrazvukových snímků pro účely registrace

- Pro účely automatické segmentace jsme využili strojového učení postaveném na využití architektury U-net a Deeplab V3, kde byla zároveň porovnávána jejich efektivita a přesnost.
- Bylo vybráno 150 snímků tak, aby zastupovali co nejvyšší variabilitu možností. Tato data byla nejprve manuálně segmentována na 4 třídy: plak (plaque), lumen, šum (artifacts) a pozadí (background) a zkontrolována odborníkem.
- Následně bylo náhodně vybráno 50 snímků pro trénovací sadu a 15 pro testovací sadu.
- Proces učení byl opakován 4x pro ověření přesnosti
- Parametry pro učení
 - Encoder: resnet50
 - Optimizer: Adam
 - Epochs: 1000
 - Batch size: 4
 - Similarity metric: Dice

2. Segmentace ultrazvukových snímků pro účely registrace- výsledky

	U-Net	Deeplab V3
Průměrná přesnost (%)	95.7	96.2
Doba učení (min)	210	240




4. Segmentace histologických snímků pro účely analýzy aterosklerotického plátu

- Bylo vybráno celkem 840 (120) histologických snímků pro zastoupení co možná nejvyšší variability
- Odborníkem byla manuálně provedena segmentace na třídy:
 - Aterosklerotická lipidová tkán
 - Fibrózní vazivo
 - Kalcifikace
 - Staré krvácení
 - Čerstvé krvácení
 - Lumen
- Tato segmentace byla využita jako ground truth pro obecnou segmentaci histologie, kde byly použity pouze třídy Aterosklerotický plak a Lumen.


4. Segmentace histologických snímků pro účely analýzy aterosklerotického plátu


- Pro segmentaci pomocí strojového učení byly zvoleny následující parametry
 - Architecture: DeepLab V3
 - Optimizer: Adam
 - Encoder: Resnet 34
 - Batch size: 8
 - Epochs: 600
 - Training dataset: 184 images (92 Hem, 92 WG)
 - Testing dataset: 25 images
 - Cycles: 4
- Výsledky: průměrná přesnost 82% pro komplexní segmentaci, 91% pro obecnou segmentaci

756515_2_1_HE_0814.png




Prediction: 756515_2_1_HE_0814.png






764947_1_2_HE_1030.png




- Background
- Atheroma
- Fibrous Ligament
- Calcification
- Old Bleeding
- Lumen
- Plaque

Prediction: 764947_1_2_HE_1030.png






- Background
- Atheroma
- Fibrous Ligament
- Calcification
- Old Bleeding
- Lumen
- Plaque

236862_1_1_VG_2147.png



Prediction: 236862_1_1_VG_2147.png





5. Registrace a spárování ultrazvukových a histologických snímků

- Navrhována metoda využití dvou po sobě následujících konvolučních sítí
 - První síť by byla trénována na segmentačních labelech histologických a ultrazvukových snímků pro obecnou registraci- využití tvaru aterosklerotického plátu a umístění a tvaru lumenu jako hlavních klíčových bodů- výsledná transformační maska by byla aplikována na původní snímky.
 - Druhá síť by byla trénována na výstupních datech z prvního kroku, a tedy obecné registrace odpovídajících snímků, a jejím cílem by bylo najít precizní registraci , čehož by následně bylo využito pro přenos komplexních segmentačních masek z histologických snímků na ultrazvukové
- Alternativním návrhem, který je též v procesu testování, je využití konvolučních sítí pro generaci umělého ultrazvukového snímku z histologie, registrace tohoto snímku s odpovídajícím reálným ultrazvukovým snímkem- čímž se vyhneme problematice s modalitou a následná regresivní transformace histologického snímku

Závěr

- V našem celkovém postupu jsme doposud úspěšně vyřešili úlohu segmentace jednotlivých snímků, úlohu jejich registrace nám ale i nadále komplikuje jejich značně rozdílná kvalita, množství artefaktů a značná variabilita mezi jednotlivými snímky. Řešením pro tento problém nám snad bude aplikace řady propojených konvolučních sítí. Zároveň usilujeme o získání většího množství dat pro ověřování a testování.