

# Detekce zubních kazů z rentgenových snímků typu bitewing

Ing. Lukáš Kunt

ve spolupráci s

prof. Dr. Ing. Janem Kybicem a MDDr. Antonínem Tichým

Fakulta elektrotechnická  
České vysoké učení technické v Praze

25. listopadu 2022

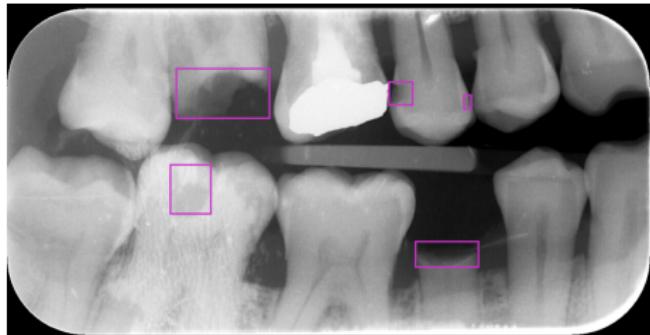


## Cíle

- Automatická detekce zubních kazů z rentgenových snímků typu bitewing
- Segmentace zubních výplní a implantátů

## Motivace

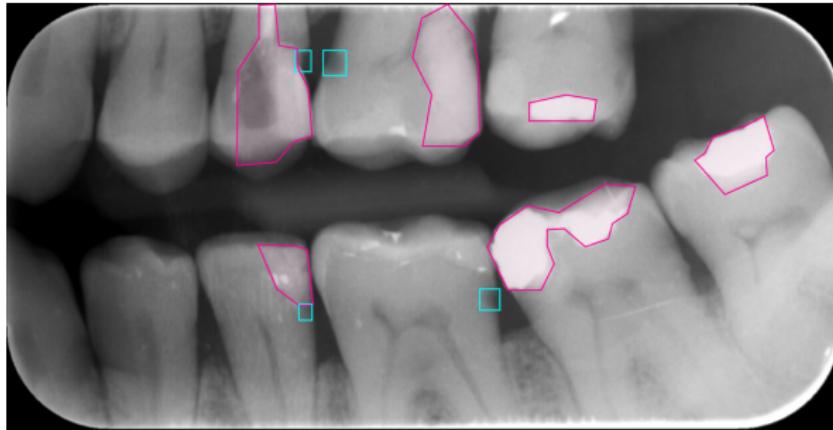
- Zubní kaz je nejčastější onemocnění na světě
- Kontrola pro zubaře
- Vzdělávací účely
- Snažší komunikace s pacientem



# Dataset

- Zrychlení anotačního procesu pomocí modelu
- 521 snímků s označenými výplněmi

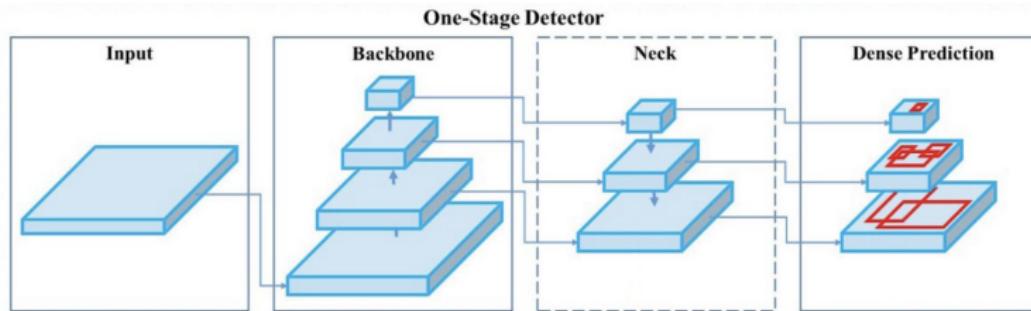
Verze	Počet snímků	Počet anotovaných kazů
1	1626	2416
2	2599	4328
3	2599	4575
4	3489	6087
5	3989	7257



# Metody pro detekci kazů

Detekce kazů pomocí metod hlubokého učení:

- Architektury: EfficientDet, RetinaNet, Faster R-CNN, YOLOv3, YOLOv5
- Backbones: EfficientNet, ResNet, Swin transformer, DarkNet
- Experimenty s trénovacím protokolem (optimizátor, lr-plánovače)
- Ensembling : NMS, S-NMS, NMW, WBF

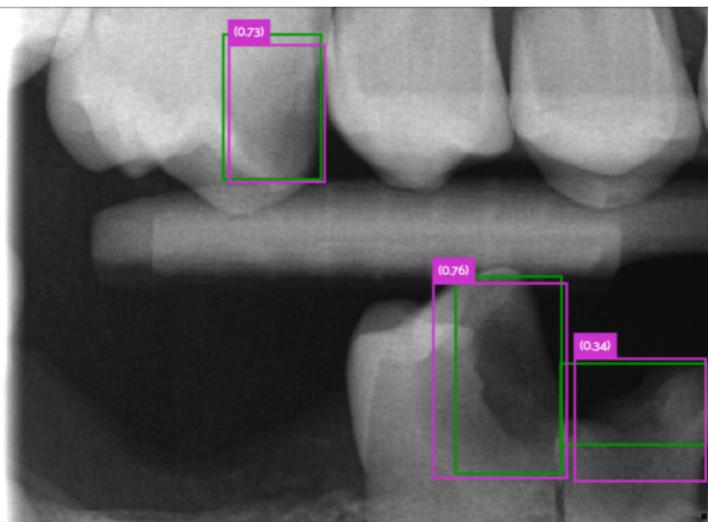


Obrázek 1: Nákres obecné detekční neuronové sítě

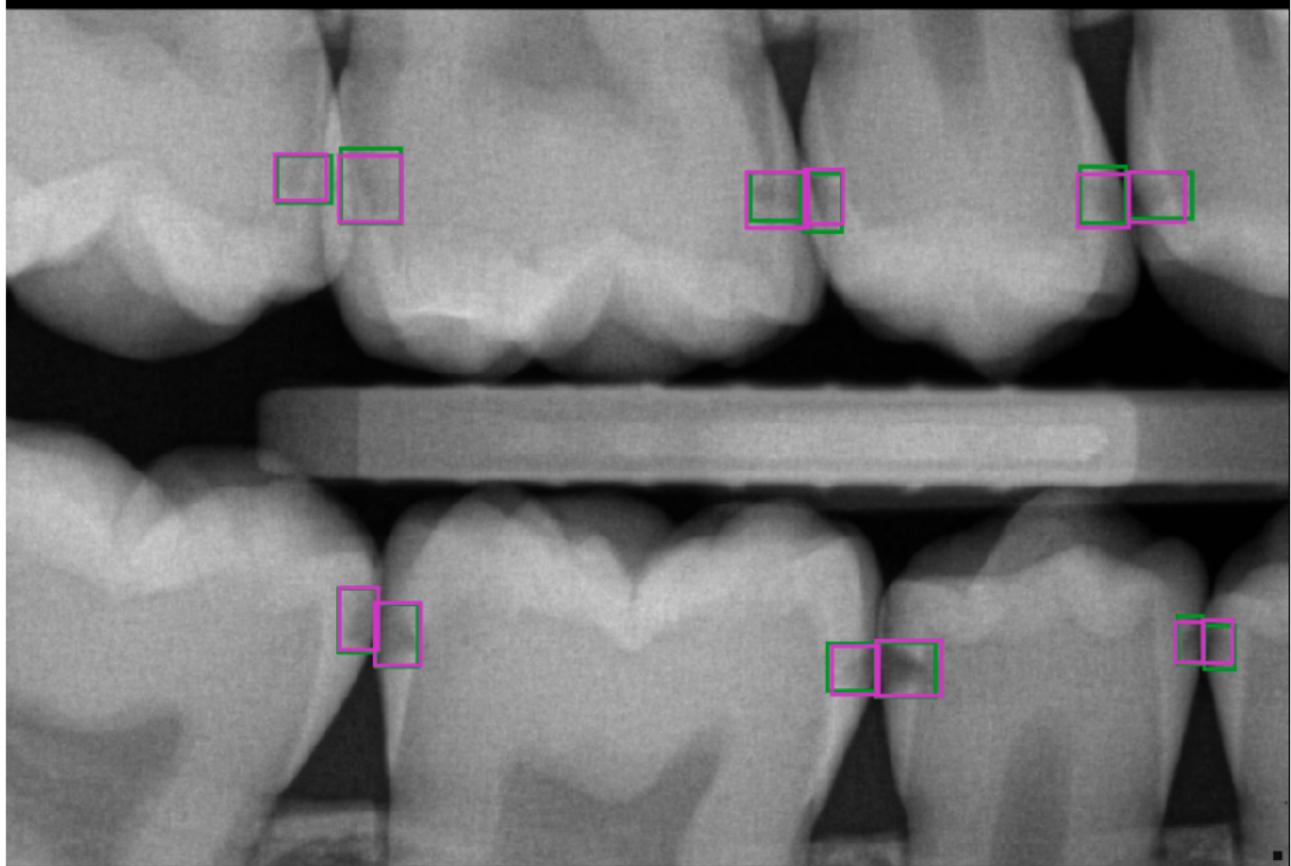


# Detekce zubních kazů

- Malé rozdíly ve výsledcích jednotlivých architektur
- Značné zlepšení výsledků ensemblingem
- Důležitost různých architektur



Model	AP@.5	AP@.75	AP@.5 <sub>S</sub>	AP@.5 <sub>M</sub>	AP@.5 <sub>L</sub>
RetinaNet-Swin	0.827	0.311	0.786	0.847	0.851
Stejné modely	0.841	0.39	0.814	0.862	0.802
Různé backbony	0.85	<b>0.418</b>	<b>0.821</b>	0.866	0.810
Různé architektury	<b>0.861</b>	0.405	<b>0.821</b>	<b>0.879</b>	<b>0.870</b>



# Testovací sada a porovnání modelu s zubními lékaři

- Testovací sada  $T_1$  obsahující 100 snímků
- Porovnání modelu s následujícími subjekty:
  - Původní anotátor  $E_0$
  - 4 zubní lékaři s více než 15-ti lety praxe - {  $E_1, E_2, E_3, E_4$  }
  - 3 zubní lékaři s méně než 15-ti lety praxe - {  $N_1, N_2, N_3$  }

Dataset	Přesnost	Citlivost	F-skóre
Původní sada $T_0$ (599 snímků)	0.832	0.77	0.8
Sada $T_1$ (100 snímků)	0.776	0.73	0.752

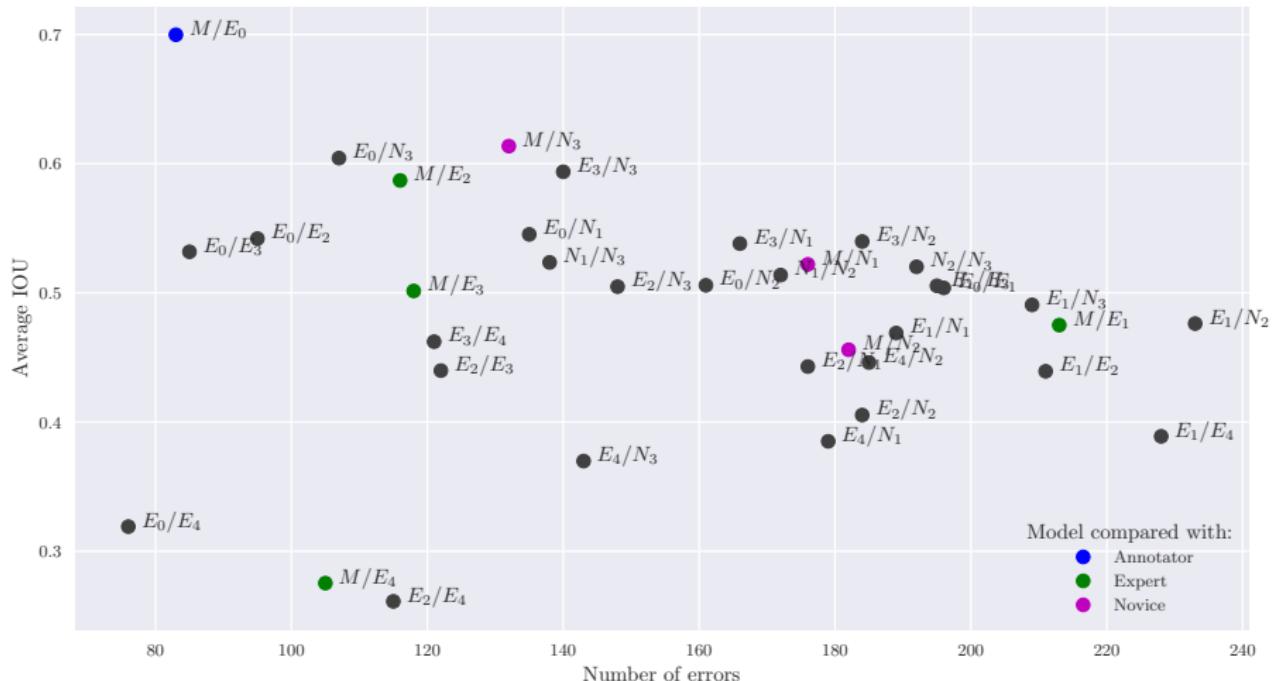
Tabulka 1: Porovnání výsledků modelu napříč testovacími sadami



# Mezi zubaři nepanuje shoda ohledně pozice kazů

Párové porovnání anotátorů

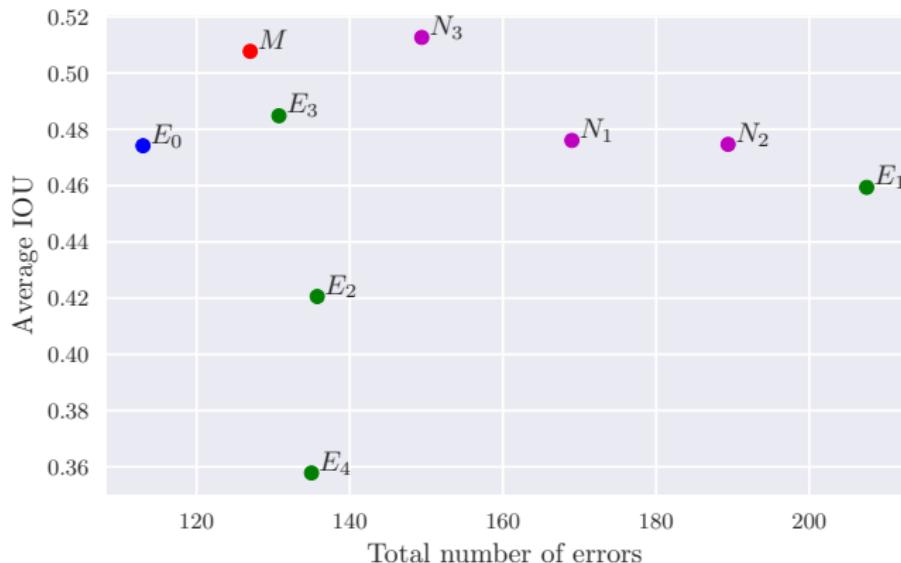
Nejlepší shoda (z pohledu počtu chyb) je mezi  $E_0$  a  $E_4$ , ale stále se jedná o 76 chyb na 100 snímků



# Párové porovnání s experty

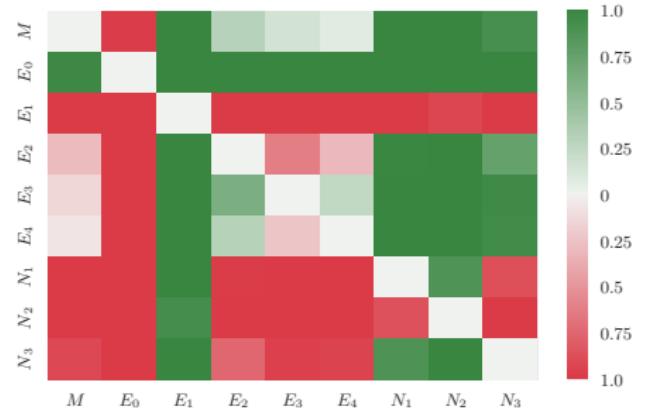
Průměr párového porovnání s ostatními experty:

- Anotátoři  $E_0$  a  $E_1$  silně vybočují
- Všichni experti (mimo  $E_0$ ) mají lepší shodu s ostatními experty, než novicové

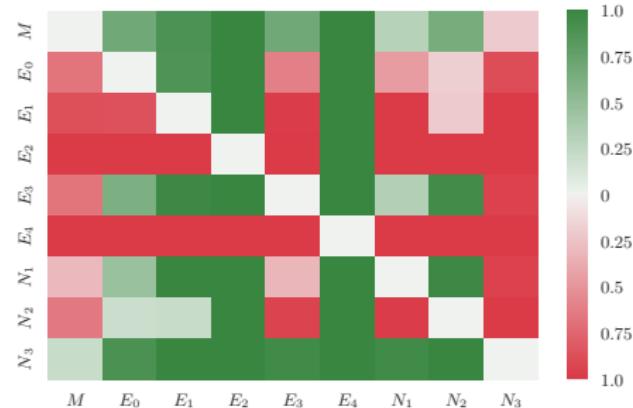


# Je model lepší než zubní lékaři?

Pomocí Wilcoxonova znamínkového testu:  $H_0$  - modely jsou nerozlišitelné,  
 $H_1$  - jeden z modelů je lepší než druhý



Obrázek 2: Pravděpodobnost  $H_1$  pro počet chyb



Obrázek 3: Pravděpodobnost  $H_1$  pro průměrné IOU



# Segmentace výplní

V literatuře pouze na OPG snímcích pomocí adaptivního prahování



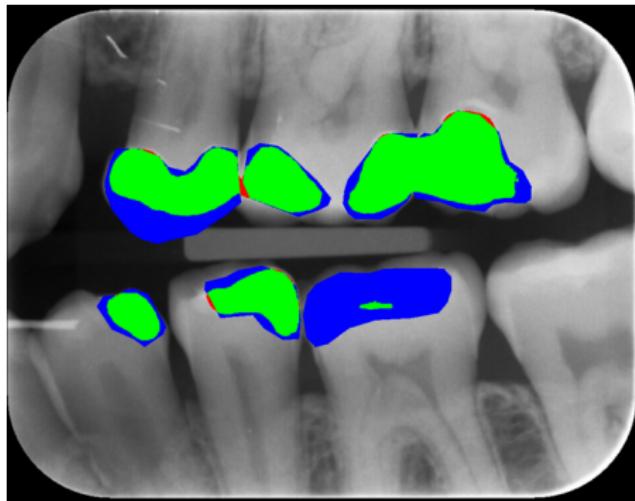
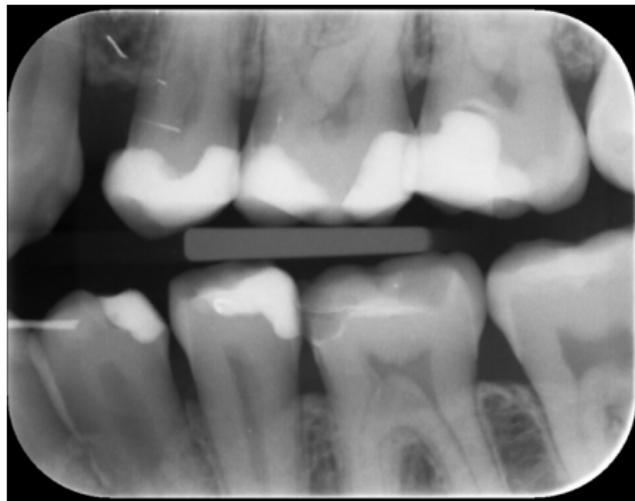
Vstupní obraz, ground truth, obraz po adaptivním prahování, odstranění okrajových pixelů, morfologické operace



Vstupní obraz, ground truth, predikce U-Net modelu, morfologické operace, výsledek



# Výsledky segmentace výplní



- TP zeleně
- FN modře
- FP červeně

Model	Dice	IOU
Adaptivní prahování	0.364	0.314
U-Net	0.760	0.67



## Závěr

- I přes datový posun (data-drift)  $T_1$  dosahuje model stejných/lepších výsledků než ostatní experti a lepších výsledků než všichni novicové
- U některých expertů nemáme dost důkazů abychom statisticky potvrdili, že model je lepší

## Použití v praxi

- Druhý názor pro zubního lékaře
- Nástroj pro vzdělávání studentů
- Pomoc při tvorbě léčebného plánu

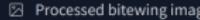


[huggingface.co/spaces/kuntik/BitewingCariesDetection](https://huggingface.co/spaces/kuntik/BitewingCariesDetection)

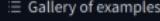
Navštivte webovou stránku a vyzkoušejte si automatickou detekci zubních kazů

Spaces:  kuntik/**BitewingCariesDetection**   like 0 • Running   Open logs

 App  Files  Community  Settings

 Input bitewing image  Processed bitewing image

Drop Image Here  
- or -  
Click to Upload

 Gallery of examples



Prediction Threshold 0.1

