



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

**FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

**Katedra biomedicínské techniky**

**Semiautomatická detekce defektů plicních tepen u  
pacientů s chronickou tromboembolickou plicní hypertenzí**

**Semiautomatic detection of pulmonary arteries defects for  
patients with chronic thromboembolic pulmonary  
hypertension**

Bakalářská práce

Studijní program: Biomedicínská a klinická technika

Vedoucí práce: Ing. Evgeniia Mardanshina

**Anton Saller**

---

**Kladno2023**



# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Saller** Jméno: **Anton** Osobní číslo: **453289**  
Fakulta: **Fakulta biomedicínského inženýrství**  
Garantující katedra: **Katedra biomedicínské techniky**  
Studijní program: **Biomedicínská a klinická technika**  
Studijní obor: **Biomedicínský technik**

## II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

**Semiautomatická detekce defektů plicních tepen u pacientů s chronickou tromboembolickou plicní hypertenzí**

Název bakalářské práce anglicky:

**Semiautomatic detection of pulmonary arteries defects for patients with chronic thromboembolic pulmonary hypertension**

Pokyny pro vypracování:

Navrhněte algoritmus pro semiautomatickou detekci defektů plicních tepen, který zahrnuje segmentaci plicních tepen z CT snímků pro pacienty s chronickou tromboembolickou plicní hypertenzí (CTEPH). Pro realizaci detekcí využijte metod konvolučních neuronových sítí (CNN). Funkčnost algoritmu ověřte na pilotním souboru pacientů s anonymizovanými údaji.

Seznam doporučené literatury:

- [1] PREIM, Bernhard, BOTHA Charl, Visualization of Vascular Structures. Visual Computing for Medicine, Elsevier, 2014, doi:10.1016/B978-0-12-415873-3.00011-0, ISBN 9780124158733
- [2] Tajbakhsh, N., Gotway, M. B., Liang, J., Computer-Aided Pulmonary Embolism Detection Using a Novel Vessel-Aligned Multi-planar Image Representation and Convolutional Neural Networks, ed. 1, Springer, 2015, ISBN 978-3-319-24570-6
- [3] CHOLLET, François, Deep learning v jazyku Python: knihovny Keras, Tensorflow., ed. Přeložil Rudolf PECINOVSKÝ, Praha: Grada Publishing, 2019, ISBN 978-80-247-3100-1

Jméno a příjmení vedoucí(ho) bakalářské práce:

**Ing. Evgeniia Mardanshina**

Jméno a příjmení konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **14.02.2023**

Platnost zadání bakalářské práce: **20.09.2024**

doc. Ing. Martin Rožánek, Ph.D.  
vedoucí katedry

prof. MUDr. Jozef Rosina, Ph.D., MBA  
děkan

## PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou práci s názvem „Semiautomatická detekce defektů plicních tepen u pacientů s chronickou tromboembolickou plicní hypertenzí“ vypracoval samostatně a použil k tom úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k bakalářské práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu § 60 Zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů.

V Kladně dne 18.5.2023

.....

Jméno autor a vč. titulů + podpis

## **PODĚKOVÁNÍ**

Rád bych poděkoval svoji vedoucí bakalářské práce Ing. Evgenie Mardanshině za výborné vysvětlení rozebírané problematiky, pomoc v hledání aktuálních zdrojů a výjimečnou pomoc v praktické části dané práce. Taky bych rad poděkoval svoji manželce Ing. Elizavetě Saller, která mě neustále podporovala a pomáhala.

## **ABSTRAKT**

Chronická tromboembolická plicní hypertenze (CTEPH) je život ohrožující chronické onemocnění, které je charakterizováno shromážděním intraluminálně organizovaných trombů, stenóz a uzávěrů jednotlivých větví plicnice.

Cílem bakalářské práce je navrhnout algoritmus pro semiautomatickou detekci oblastí výskytu plicních tepen na segmentovaných CT snímcích u pacientů, u kterých byla diagnostikována chronická tromboembolická plicní hypertenzí. Princip detekce bude založen na využití sémantické segmentace na základě konvolučních neuronových sítí.

Soubor s anonymizovanými snímky byly předem segmentovány pomocí prostředku Materialise Mimics. Jako metodu sémantické segmentace jsem použil DeepLabV3 na základě sítě Xception. Celková přesnost trénovacího procesu byla 99,69 %.

Senzitivita dané metody je 73,1 %, specifita – 86,9 %,  $\phi$  koeficient který vyjadřuje predikční schopnost sítě byl 60,6 %.

Daná metoda využití konvolučních neuronových sítí může být užitečnou podporou pro lékařskou diagnostiku nejenom pacientů s CTEPH, ale taky u pacientů s celou řadou jiných onemocnění. CNN dokáže mnohem rychleji, občas i přesněji detekovat patologie, pro lékaře zbývá jenom ověřit dané rozhodnutí.

### **Klíčová slova**

chronická tromboembolická plicní hypertenze, CTPA, konvoluční neuronová síť, sémantická segmentace, semiautomatická detekce

## **ABSTRACT**

Chronic thromboembolic pulmonary hypertension (CTEPH) is a life-threatening chronic disease characterized by the collection of intraluminal organized thrombi, stenoses and occlusions of individual branches of the pulmonary artery.

My main goal in this thesis is to propose an algorithm for semi-automatic detection of occurrence areas of pulmonary arteries on segmented CT images in patients diagnosed with chronic thromboembolic pulmonary hypertension. The principle of detection will be based on the use of semantic segmentation based on convolutional neural networks.

The dataset with anonymized data was pre-segmented using Materialise Mimics program. I used DeepLabV3 based on the Xception network as a semantic segmentation method. The global accuracy of the training process was 99.69%.

The sensitivity of this method is 73.1%, specificity – 86.9%, the  $\phi$  coefficient, which expresses the predictive ability of the network, was 60.6%,

Such method of using convolutional neural networks can be a useful support for the medical diagnosis not only of patients with CTEPH, but also patients with a whole range of other diseases. CNN can detect pathology much faster and sometimes even more accurately, all that remains for the doctor is to verify the given decision.

## **Keywords**

chronic thromboembolic pulmonary hypertension, CTPA, convolutional neural network, semantic segmentation, semi-automatic detection

# Obsah

<b>1 Úvod .....</b>	<b>9</b>
<b>2 Přehled současného stavu.....</b>	<b>10</b>
<b>3 Cílepráce .....</b>	<b>11</b>
<b>4 Metody.....</b>	<b>12</b>
<b>4.1. Segmentace plicních tepen .....</b>	<b>13</b>
<b>4.2. Ground truth dataset.....</b>	<b>14</b>
<b>4.3. Trénování CNN.....</b>	<b>17</b>
<b>4.3.1. Struktura sítě .....</b>	<b>17</b>
<b>4.3.2. Sémantická segmentace.....</b>	<b>18</b>
<b>4.3.3. Trénovací parametry.....</b>	<b>18</b>
<b>4.4. Vyhodnocení kvality sítě .....</b>	<b>19</b>
<b>4.5. Aplikace sémantické segmentace.....</b>	<b>21</b>
<b>4.6. Kvantitativní hodnocení kvality navržené metody .....</b>	<b>21</b>
<b>5 Výsledky .....</b>	<b>23</b>
<b>5.1. Hodnocení kvality sítě .....</b>	<b>23</b>
<b>5.2. Kvantitativní hodnocení kvality navržené metody .....</b>	<b>24</b>
<b>PřílohaA: Přehled výstupů z algoritmu a porovnání predikce sítí s referenčními snímky .....</b>	<b>33</b>
<b>PřílohaB: Obsahpřiloženého CD .....</b>	<b>43</b>

# Seznam symbolů a zkratek

## Seznam zkratek

Zkratka	Význam
CTEPH	Chronická tromboembolická plicní hypertenze
CTPA	CT plicní angiografie
CNN	Konvoluční neuronová síť
TP	True positive
TN	True negative
FP	False positive
FN	False negative
IoU	Průměrný průnik přes sjednocení všech tříd( <i>intersection over union</i> )



# 1 Úvod

Chronická tromboembolická plicní hypertenze (CTEPH) je vzácné, progresivní plicní vaskulární onemocnění, které patří k nejčastějším příčinám těžké chronické prekapilární hypertenze. Je způsobena perzistující trombotickou obstrukcí plicních tepen, a pak periferní cévní remodelací. Důsledkem je vzestup plicní cévní rezistence (akutní plicní embolie) vedoucí k zatížení pravé komory srdeční a k pravostrannému srdečnímu selhání. CTEPH obvykle začíná přetrvávající obstrukcí velkých nebo středně velkých plicních tepen organizovanými tromby. Neúspěch trombů může souviset s abnormální fibrinolýzou nebo základními hematologickými nebo autoimunitními poruchami [1].

Cílem diagnostiky CTEPH je na prvním místě vyloučení nebo potvrzení přítomnosti plicní hypertenze, zjištění příčin obtíží nemocného, následuje určení velikosti plicní hypertenze a určení její etiologie. Pokud je prokázáno, že se skutečně jedná o CTEPH, je nutné určit lokalizaci a rozsah postižení plicního cévního řečiště. Základní metody používané v diagnostice CTEPH představují echokardiografie s dopplerovským vyšetřením, plicní scintigrafie a pravostranná srdeční katetrizace. K určení lokalizace postižení jednotlivých větví plicnice slouží výpočetní tomografie a magnetická rezonance s podáním kontrastní látky. Nejčastější diagnostickou metodou je zejména CT plicní angiografie. [2,3]

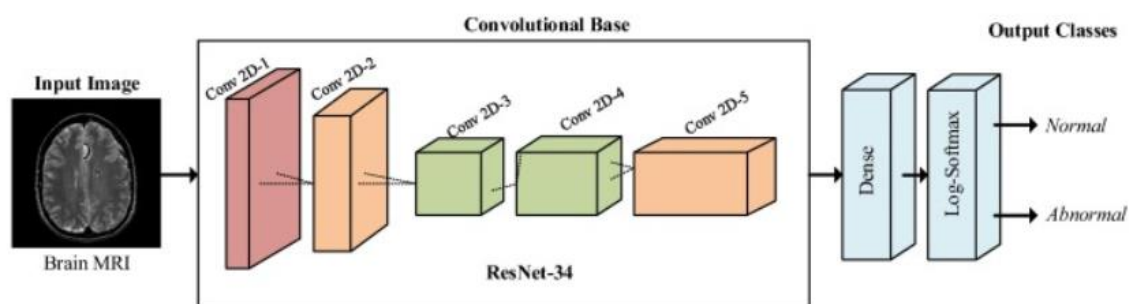
Konvoluční neuronová síť (z angl. CNN – convolutional neuro network) je typ neuronové sítě s hlubokým učením běžně používaný pro rozpoznávání obrazu nebo videa, detekci objektů a segmentaci obrazu. CNN se skládá z několika vrstev neuronů, které jsou navrženy tak, aby se automaticky učily a extrahovaly funkce ze vstupních obrázků. První vrstva obvykle aplikuje sadu filtrů nebo jader které se prolínají se vstupním obrazem, aby extrahovaly prvky nízké úrovně, jako jsou hrany a rohy. Následující vrstvy pak kombinují tyto nízkourovňové prvky a extrahují prvky vyšší úrovně, jako jsou tvary, textury a vzory. Poslední vrstvy CNN obvykle provádějí klasifikační nebo regresní úkoly a používají naučené funkce ke klasifikaci nebo predikci vstupního obrazu. [9]

V lékařských zobrazovacích metodách (jako CT, MRI atd) CNN lze využít pro analýzu a klasifikaci snímku. Konvoluční neuronové síť dokážou identifikovat určité znaky na obrázcích, což je velkou výhodou při diagnóze nemoci, kde je velmi obtížné pro lékaře odhalit patologickou oblast z CT snímků.

## 2 Přehled současného stavu

V současné době v lékařské diagnóze velkou roli hraje využívání výpočetních a zobrazovacích metod, pomoci kterých je možné neinvazivně odhalit patologie vnitřních tkání a orgánů. Samotnou detekci nemoci pak provádí lékař na základě vlastních znalostí v té nebo jiné oblasti. Problémem je, že taková detekce je pak ovlivněná různými faktory, jako například pozornost, únava atd. Z toho důvodu dnes nabývají větší váhy metody, které jsou založeny na automatické detekce patologických míst.

Jedna z takových metod je konvoluční neuronová síť, která v poslední době je užitečným nástrojem pro detekci patologií a abnormalit. Například Talo et al., použily předtrénovaný model sítě ResNet34 k detekci normálních a abnormálních MRI snímků mozku. [4]



Obrázek 2.1: Architektura použité sítě[4]

Podobný problém řešili také Swati et al., s použitím modelu VGG19. [5] Následně Lu et al., předložili doladěnou AlexNet strukturu pro detekci mozkových abnormalit. [6]

Konvoluční neuronové sítě je možné použít například k detekci určitých tkání, které nejsou dobře pozorovatelné na CT snímcích. Například Guo et al., využili metodu CNN pro detekci abnormalit v cévách sítnice. Hlavní myšlenkou bylo automatické a přesné stanovení patologií, jako je například diabetická retinopatie. [21]

### 3 Cíle práce

Cílem bakalářské práce je navrhnout algoritmus pro semiautomatickou detekci patologických oblastí plicních tepen na segmentovaných CT snímcích u pacientů, u kterých byla diagnostikována chronická tromboembolická plicní hypertenzí. Princip detekce bude založen na využití sémantické segmentace na základě konvolučních neuronových sítí.

Cílem je kvantitativně vyhodnotit kvalitu navržené metody na základě toho, jak je daný algoritmus schopný odhalit problematická místa, a zároveň určit té oblasti, kde patologie nebyla nalezena.

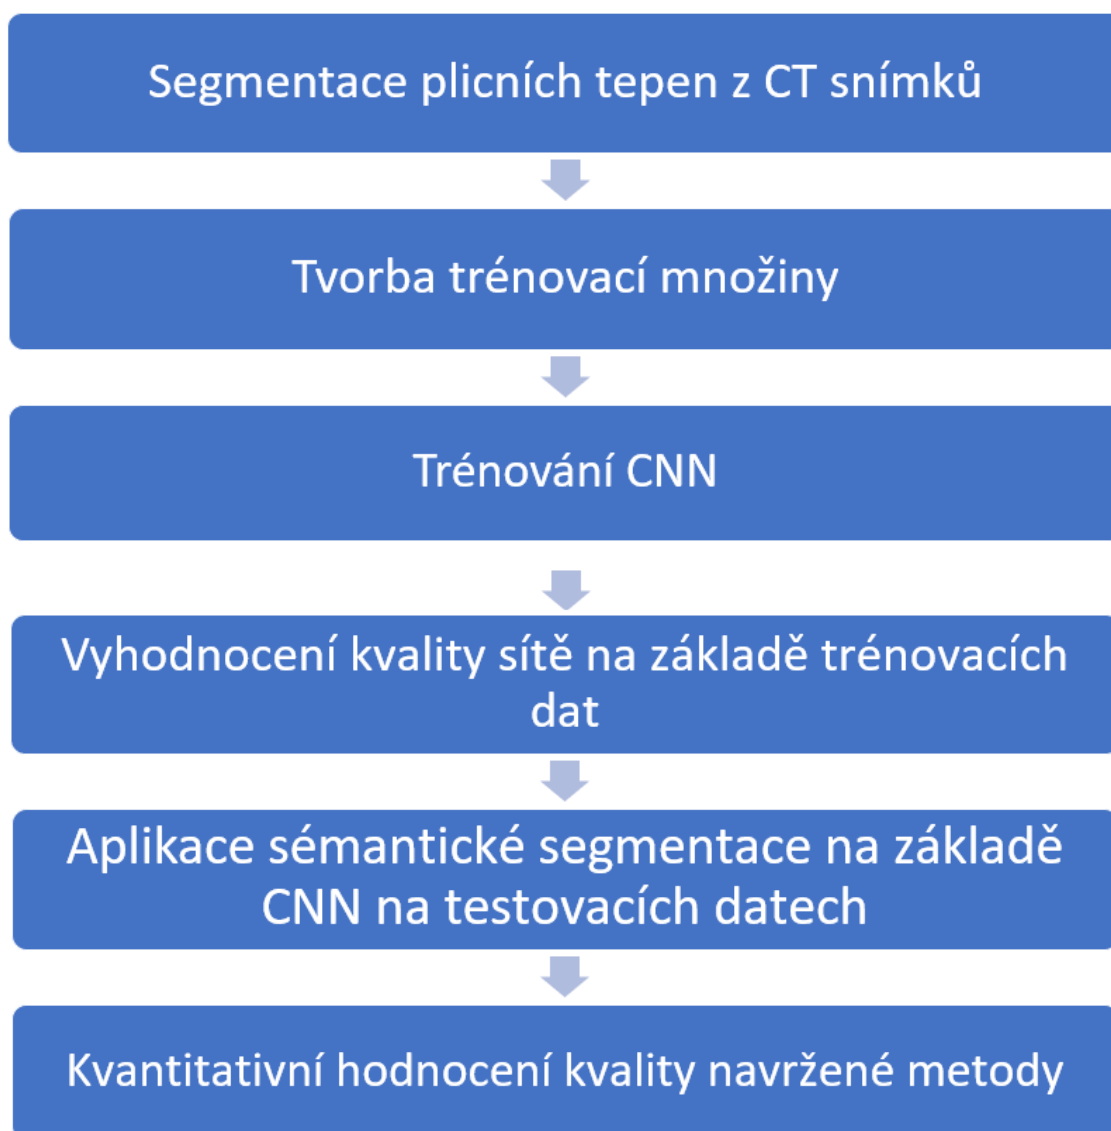
Ověření funkčnosti dané metody je potřeba provést na pilotním souboru dat s anonymizovanými údaji u pacientů s CTEPH a zdravého pacienta.

## 4 Metody

Pro semiautomatickou detekci defektů plicních tepen byla využita metoda hlubokých neuronových sítí, výsledkem které byla sémantická segmentace.

Pro zvýšení senzitivity a specifity metody snímky z CT angiografie byly předem segmentovány tak, aby na výsledných snímcích byla přítomna jenom plicní tepna.

Na následujícím blokovém schématu (obr. 4.1) je znázorněn pracovní postup s využitím několika metod.



**Obrázek 4.1: Souhrn postupů při řešení problematiky**


## 4.1. Segmentace plicních tepen

Provedl jsem segmentaci vybraných oblastí plicní tepny z CTPA snímků u pacientů s CTEPH. Radiodiagnostická klinika 1. LF UK a VFN poskytla anonymizované soubory CTPA snímků hrudníku ve formátu DICOM o velikosti 512x512 pixelů. Každý soubor obsahoval průměrně 300-500 axiálních řezů s tloušťkou 0,9 mm.

Úkolem v dané metodě bylo oddělit plicnici od ostatních struktur jako plíce, kosti a další tkáně. Daný krok byl proveden v programovém prostředí Materialise Mimics 24.0.

Segmentace byla provedena pomocí metod prahování (threshold). Prah denzity byl zvolen 226 – 3071 HU (Hounsfield unit), což bylo programem nastaveno automaticky. Hodnota dolního prahu denzity je optimální a neovlivní kvalitativní výsledky segmentace.[8]


Jako grafickou metodu jsem použil Split Mask, pomocí které jsem odděloval struktury od sebe. Při této manipulaci jsem zasahoval manuálně. Na obrázku 4.2 je vidět snímek se všemi strukturami (plicnice je označena zelenou barvou).



Obrázek 4.2: 3D snímek všech struktur včetně plicnice

Po segmentaci plicní tepny jsem použil nástroj Edit Mask, pomocí kterého jsem manuálně upravoval konečný tvar vymazáním drobných částí ostatních struktur, které nebyly odděleny v předchozím kroku.

Konečný výsledek je znázorněn na obrázku 4.3




**Obrázek 4.3: CTPA snímek s označenou plicnicí (vlevo) a segmentovaná plicnice (vpravo)**

Data jsem exportoval jako pointcloud (tabulka s osami x, y, z a příslušnými hodnotami HU). Následně jsem provedl reslice dané pointcloud tabulky do obrázku. Ve své podstatě je to proces převedení trojrozměrných pointcloud dat do dvourozměrné obrazové reprezentace

## **4.2. Ground truth dataset**

Po segmentaci plicních tepen jsem připravil trénovací množinu pro tvorbu ground truthdatasetu. Trénovací množina obsahovala CT snímky devíti pacientů. Referenční snímky byly označeny radiologem z VFN a jsou brány jako zlatý standard..



**Obrázek 4.4: Označené patologie na CTPA snímcích**

Trénovací množina v sobě zahrnuje 40 vzorů patologií plicních tepen (stenóz a chronických trombů), vyskytujících se jen na segmentárních plicních tepnách (průměr do cca 2 mm). Pro velké stenózy jsem vybíral větší počet snímků (2-3 snímky před a za referenčním), na kterých patologie se projevuje v objemu několika snímků. Celkově trénovací množina obsahuje 124 snímky.

Tvorba ground truth datasetu byla provedena v aplikaci Image Labeler v programovém prostředí Matlab verzi R2019a. Všechny snímky trénovací množiny o rozměru 512x512 pixelů byly ručně označeny do tří oblastí:

1. Oblast zájmu, kde se patologie může potenciálně vyskytovat
2. Patologický projev CTEPH (stenóza)
3. Background (mrtvý prostor)


Na následujícím obrázku jsou dané oblasti označeny různými barvami (oblast zájmu – oranžová, patologie – fialová, background – tmavě modrý).



**Obrázek 4.5: Snímek s označenými oblastmi**

Následně jsem exportoval všechny označené snímky do šedotónových obrázku, na kterých každá oblast měla příslušný label.

1. Oblast zájmu - 2
2. Stenóza - 4
3. Background - 1



**Obrázek 4.6: Exportované šedotónové obrázky**



## 4.3. Trénování CNN

Pro detekci patologických oblastí na snímcích z ground truth datasetu jsem použil metodu sémantické segmentace na základě konvolučních neuronových sítí. Ve své práci jsem pracoval s předtrénovanou CNN. Je to typ neuronové sítě, která byla předem natrénována na velkém souboru dat, jako je ImageNet. Jakmile je síť natrénována na tomto datovém souboru, naučené váhy lze pak použít k inicializaci nového CNN pro jiný úkol související s obrazem, jako je klasifikace obrazu nebo v mém případě rozpoznávání objektů. Dané předtrénované sítě jsou schopny rychleji se učit a dosahovat lepšího výkonu s menším množstvím trénovacích dat. [10, 19]

### 4.3.1. Struktura sítě

Jako sémantickou segmentaci na základě CNN jsem využil DeepLabV3. V mém případě DeepLabV3 využívá základní předtrénovanou síť Xception, která je trénovaná na více než milion snímků z datasetu ImageNet. [19]

V metodě sémantické segmentace byla využita struktura encoder-decoder, základní myšlenkou je, že se skládá ze dvou hlavních součástí: kodéru a dekodéru. [18]

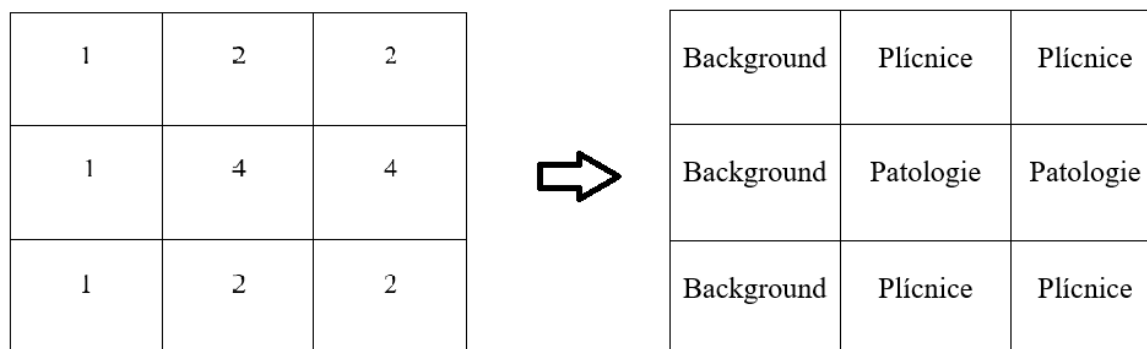
Kodér zachycuje vstupní data dlouhého dosahu prostupným zmenšováním prostorového rozměru příznakových map. Ten proces kódování je navržen tak, aby zachytil nejdůležitější vlastnosti vstupních dat v komprimované podobě.

Dekodér pak vezme tuto zakódovanou reprezentaci a použije ke generování výstupu, který určitým způsobem souvisí s původním vstupem. To znamená, že dekodér pomáhá obnovit důležité detaily objektu (jako například hrany) a zároveň obnovit prostorové rozměry.

Příznakové mapy zachycují různé aspekty vstupního obrazu (hrany, rohy, textury) a se používají jako vstup do následujících vrstev sítí pro další zpracování a extrakci prvků. Tím, že vstupní data procházejí hlubším vrstvami sítě, příznakové mapy pak představují prvky na vyšší úrovni vstupu. Například příznakové mapy v hlubších vrstvách CNN může představovat přítomnost určitého objektu nebo tvaru ve vstupním obrázku. [20]

### 4.3.2. Sémantická segmentace

Sémantická segmentace je proces přiřazení znaku (labelu) každému pixelu na obrázku. Principem je segmentování obrázku do smysluplných oblastí na základě sémantického obsahu. Tento proces v sobě zahrnuje použití algoritmů hlubokého učení ke klasifikaci každého pixelu na obrázku, který patří ke konkrétnímu objektu nebo třídě.



**Obrázek 4.7: Vstupní obrázek (vlevo) a sémantická segmentace (vpravo)**

Sémantickou segmentaci obvykle používají konvoluční neuronové sítě, které byly trénovány na velkých souborech dat anotovaných obrázků, aby se naučily sémantické informace nezbytné pro přesnou segmentaci. [10]


### 4.3.3. Trénovací parametry

Trénování CNN probíhalo na bázi grafické paměti GPU NVIDIA GeForce GTX 950, a celkem trvalo 928 minut.

**Tabulka 4.1: Parametry trénování sítě**

Parametr	Hodnota
Počet epoch	100
Počet iterací	3100
Velikost mini-batch	4
Optimalizátor	Adam

Epocha je jeden trénovací cyklus, za který algoritmus zpracuje celý dataset. Počet iterací na jednu epochu byl 31. Velikost mini-batch určuje počet trénovacích vzorků, které procházejí každou iterací. Optimalizátor Adam (Adaptive Moment Estimation) je optimalizační algoritmus, který efektivně aktualizuje parametry neuronové sítě během procesu trénování s cílem minimalizovat funkci ztrát. [11]



**Obrázek 4.7: Průběh trénování sítě**

#### 4.4. Vyhodnocení kvality sítě

Pro hodnocení kvality natrénované sítě jsem použil metriky sémantické segmentace, jako jsou matice záměn, normalizovaná matice záměn, a taky metriky datasetu, tříd a obrázků. [12]

*Matice záměn (confusion matrix)* je tabulka, používána k popisu výkonu klasifikačního modelu nebo algoritmu. Tato tabulka poskytuje podrobný rozpis predikovaných a skutečných tříd nebo kategorií, ukazující počet pravých pozitiv (TP), pravých negativ (TN), falešných pozitiv (FP) a falešných negativ. [14]

*Normalizovaná matice záměn (normalized confusion matrix)*, také normalizovaná kontingenční tabulka nebo chybová matice, je varianta matice záměn, která reprezentuje výsledky klasifikace v normalizované formě. Na rozdíl od běžné matice záměn, která zobrazuje počty, normalizovaná matice záměn prezentuje relativní frekvence nebo poměry předpovídaných a skutečných tříd.

Pro získání normalizované matice záměn jsou počty v každé buňce matice záměn děleny celkovým počtem instancí ve výběru. Tento normalizační proces zajišťuje, že hodnoty v matici se sčítají na 1, což představuje poměr nebo procento instancí patřících do jednotlivých kategorií.

*Dataset metrics* představuje míry a charakteristiky specifické pro označený soubor obrázků použitý pro trénování a vyhodnocování modelu sémantické segmentace. Tyto metriky pomáhají posoudit kvalitu, složitost a rozmanitost datasetu a zajišťují jeho vhodnost pro trénování segmentačního modelu.

Parametry metrik datasetu:

- *Global Accuracy* - poměr správně klasifikovaných pixelů k celkovému počtu pixelů bez ohledu na třídu.
- *Mean Accuracy* - poměr správně klasifikovaných pixelů v každé třídě k celkovému počtu pixelů, zprůměrněný na všechny třídy.
- *Mean IoU (intersection over union)* - průměrný průnik přes sjednocení všech tříd.
- *Weighted IoU* - průměrný průnik přes sjednocení všech tříd, vážený počtem pixelů ve třídě.
- *Mean BF (boundary F1) Score* - průměrné hraniční skóre všech obrázků.[13]

*Class metrics* je další metrikou sémantické segmentace pro každou třídu, představena jako tabulka. Patří sem přesnost (accuracy) a IoU.

Parametry metriky tříd:

- *Accuracy* - poměr správně klasifikovaných pixelů v každé třídě k celkovému počtu pixelů patřících do této třídy podle ground truth. Přesnost se vyjadřuje v procentech, a může být vypočtena pomocí následujícího zvrce:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

- *IoU* - poměr správně klasifikovaných pixelů k celkovému počtu pixelů, které jsou dané třídě přiřazeny ground truth a prediktorem.

$$IoU = \frac{TP}{TP + FP + FN} \quad (4.2)$$

*Image metrics* jetaky jednou z metrik sémantické segmentace pro každý obrázek, představena jako tabulka. Zahrnuje v sobě body stejné jako i pro metriky datasetu.

## 4.5. Aplikace sémantické segmentace

Konvoluční neuronovou síť s výše uvedenou strukturou a parametry na základě sémantické segmentace jsem aplikoval na další anonymizovaný soubor dat, poskytnutý 1. LF UK a VFN. Daný soubor obsahoval následující složky: snímky nových pacientů, snímky jednoho zdravého pacienta a taky referenční obrázky.

Provedl jsem segmentaci plicní tepny na nových datech stejně jako v kapitole 4.1. Výsledný soubor v sobě obsahoval 40 snímků segmentovaných plicních tepen, z nich 25 bylo od 15 nemocných pacientů, a 15 od jednoho zdravého pacienta. Otestoval jsem navrženou síť na daném souboru a porovnal jsem ho s referenčními snímky.

## 4.6. Kvantitativní hodnocení kvality navržené metody

Posledním krokem bylo kvantitativní hodnocení kvality navržené metody, což je rozhodnutí o tom, zda použitá metoda je funkční. Takové hodnocení se obvykle provádí vypočítáním senzitivity a specifity dané metody.

*Senzitivita* metody, také nazývaná jako citlivost, je statistická metrika, která měří schopnost diagnostického testu nebo metody identifikovat skutečně pozitivní případy. [15] Vyjadřuje, jak efektivně a citlivě metoda detekuje skutečné případy, které mají danou vlastnost nebo podmínku. Jednotkou senzitivity je procento, a vypočítá se pomocí následujícího vzorce:

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad (4.3)$$

*Specifita* metody je podobná senzitivě, ale měří schopnost diagnostického testu nebo metody identifikovat skutečně negativní případy. [15] Vyjadřuje, jak efektivně a specificky metoda rozpoznává osoby nebo vzorky, které nevykazují danou vlastnost nebo podmínku. Jednotkou je taky procento, a vypočítá se pomocí následujícího vzorce:

$$\text{Specifita} = \frac{TN}{TN + FP} \quad (4.4)$$

Další možná kritéria jsou:

- *Přesnost (accuracy)*– poměr správných predikcí a celkového počtu predikcí. Vypočítá se podle vzorce 4.1
- *Precision*–poměr pravých pozitiv a celkového počtu pozitivních predikcí.

$$Precision = \frac{TP}{TP + FP} \quad (4.5)$$

- *F1 Score* – harmonický průměr přesnosti (*precision*) a senzitivity. [13]

$$F1\ Score = \frac{2 \cdot Precision \cdot Senzitivita}{Precision + Senzitivita} \quad (4.6)$$

- *FPR (False Positive Rate)* – poměr falešných pozitiv a celkového počtu negativních predikcí.

$$FPR = \frac{FP}{FP + FN} \quad (4.7)$$

- *Korelační koeficient  $\varphi$*  - určuje sílu a směr vztahu mezi dvěma binárními proměnnými. Jinými slovy, to je koeficient, vyjadřující predikční schopnost navržené sítě. [16]

$$\varphi = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (4.8)$$

## 5 Výsledky

### 5.1. Hodnocení kvality sítě

V následujících tabulkách jsou znázorněny matice změn. Na vodorovné části tabulek jsou výsledky z ground truth, na svislé jsou výsledky sémantické segmentace. A proto mě nejvíc zajímají hodnoty, ukázány na diagonále, které reprezentují kvalitu trénování sítě.

**Tabulka 5.1:** Matice záměn

	Background	Oblast zájmu	Patologie
Background	<b>31932320</b>	86051	8860
Oblast zájmu	198	<b>459962</b>	4710
Patologie	0	36	<b>13719</b>

**Tabulka 5.2:** Normalizovaná matice záměn

	Background	Oblast zájmu	Patologie
Background	<b>0,9970</b>	0,0027	0,00027
Oblast zájmu	0,00043	<b>0,9894</b>	0,0101
Patologie	0	0,0026	<b>0,9974</b>

**Tabulka 5.3:** Metriky datasetu

Global Accuracy	Mean Accuracy	Mean IoU	Weighted IoU	Mean BF Score
0,9969	0,9946	0,7780	0,9945	0,9876

**Tabulka 5.4:** Metriky tříd

	Accuracy	IoU	Mean BF Score
Background	0,9970	0,9970	0,9964
Oblast zájmu	0,9894	0,8348	0,9874
Patologie	0,9974	0,5021	0,9790

## 5.2. Kvantitativní hodnocení kvality navržené metody

Na konci jsem kvantitativně ohodnotil funkčnost navrženého algoritmu.

**Tabulka 5.5:** Matice záměn

	Patologie	Background
Patologie	<b>19</b>	6
Background	7	<b>40</b>

Pomocí vzorců 4.1 až 4.6 jsem vypočítal všechna kritéria, potřebná pro hodnocení kvality dané metody. Výsledky jsou uvedeny v následující tabulce.

**Tabulka 5.6:** Vypočítaná kritéria


Kritérium	Hodnota
Senzitivita	0,731
Specifita	0,869
Accuracy	0,819
Precision	0,760
F1 Score	0,745
FPR	0,131
$\phi$ koeficient	0,606



## 6 Diskuse

Ve své bakalářské práci jsem navrhoval algoritmus pro semiautomatickou detekci defektů plicních tepen u pacientu s chronickou tromboembolickou plicní hypertenzí. Využil jsem metodu konvolučních neuronových sítí na základě sémantické segmentace.


Před trénováním CNN jsem provedl segmentaci plicních tepen z CT snímků, aby na výsledných obrazcích byla přítomna jen plicnice bez ostatních struktur. Segmentaci jsem prováděl manuálně, s použitím různých grafických metod jako Split Mask, Edit Mask atd. V prvním kroku bylo důležité správně zvolit dolní práh denzity. Výběr dolního prahu má za následek odlišné kvantitativní parametry pro posouzení míry postižení tepny.



**Obrázek 6.1: Závislost dolního prahu denzity na výstupní kvalitě modelu [8]**

Vybral jsem dolní práh denzity 226 HU, což bylo v mém případě optimální pro zobrazení celé plicnice. Z důvodu, že zásah byl jenom ruční, manipulace byla provedena jen s velkými tepnami, kde nebylo obtížné odhalit patologické místo.

Pro tvorbu ground truth datasetu jsem připravil trénovací množinu, která obsahovala 124 snímků segmentované plicní tepny. Při exportování souboru obrázků z Materialise Mimics měl jsem část snímků, které byly s obrazovým artefaktem.




**Obrázek 6.2: Segmentované snímky s obrazovým artefaktem**

V daném případě tento artefakt neovlivní trénování sítě, protože každá struktura je brána jako geometrický obraz, ve kterém změna kontrastu není tak hranatá jako samotný artefakt.

Dalším důležitým krokem bylo správně zvolit trénovací parametry. Určení správného počtu epoch, velikost mini-batch a optimalizátoru zásadně ovlivní výkon navrženého modelu a trénovací dobu. Optimální počet epoch se pohybuje v rozmezí 50 až 150. Ve finálním trénování jsem nastavil 100 epoch, 31 iterace na epochu. Velikost mini-batch určuje kolik snímků bude bráno současně. Kvůli tomu, že jsem pracoval s malým souborem dat, nebyla potřeba volit velký mini-batch, a proto jsem zvolil 4.

Kromě DeepLabV3 na základě Xception jsem taky pracoval s jinými druhy CNN, jako například U-Net. [17] Zkoušel jsem nastavení různých vah, které přímo ovlivňují výstup trénování. [12] Po několika různých pokusech jsem měl neuspokojivé výsledky, které jsou znázorněny na dalším obrázku 6.2. Je těžké říct, co konkrétně bylo hlavním důvodem takových výsledků, ale s velkou pravděpodobností se to mohlo nastat kvůli špatně zvoleným vahám ve vnitřní struktuře neuronové sítě.



**Obrázek 6.2: Výsledek špatně natrénované sítě**


Z výsledků trénování, které jsou uvedeny v kapitole 5.1 je vidět, že proces učení byl docela přesný. Hodnota *GlobalAccuracy* byla 99,69 %. Výsledky všech metrik ukazují na to, že síť velmi přesně určila TP nálezy, což může znamenat, že parametry a struktura sítě byly zvoleny správně.

Z finálního hodnocení výsledků jsem vypočítal senzitivitu metody, která vyšla 73,1 %. Tím můžu tvrdit, že navržený algoritmus je mírně citlivý a detekuje skutečné případy, které mají danou vlastnost nebo podmínku. Celkový počet TP predikcí byl 19, počet FP výstupů byl 6.

Jako další kritérium jsem vypočítal specifitu metody, která byla 86,9 %. Pomocí daného kritéria můžu rozhodnout, že CNN dobře odhalí negativní výsledky predikce. Celkový počet FN nálezu byl 7, počet TN výsledků byl 40.

Taky dobrým kritériem pro kvantitativní hodnocení kvality sítě je koeficient  $\phi$ , který vyjadřuje predikční schopnost sítě. Hodnota koeficientu vyšla 60,6 %. Ze všech naměřených výsledků můžu říct, že navržený algoritmus je mírně funkční

Vyzkoušel jsem taky daný algoritmus na souboru snímků, na kterých byly označeny všechny struktury (plicní tepna nebyla předem segmentována). Z toho důvodu, že trénování sítě jsem prováděl jen na segmentovaných snímcích, CNN nemohla správně určit patologií. Navíc výsledné obrázky vypadaly takto:



**Obrázek 6.3: Výsledek sémantické segmentace CT snímku se všemi strukturami**

Daný výsledek pravděpodobně je způsoben tím, že na obrázcích je velká variabilita kontrastu a jasů mezi odlišné struktury. Tím vlastně neuronová síť začne vnímat větší počet vrstev a znaků, což zřejmě velmi ovlivní výstupní obrázek.

## 7 Závěr

Cílem dané práce bylo navrhnout algoritmus pro semiautomatickou detekci oblastí defektů plicních tepen na segmentovaných CT snímcích u pacientů s diagnózou CTEPH. Princip detekce byl založen na využití sémantické segmentace na základě konvoluční neuronové sítě. Ve své práci jsem vyzkoušel dva různé algoritmy sítě, pracoval jsem hlavně s DeepLabV3 na bázi Xception.

Výsledkem trénování CNN byla celková přesnost 99,69 %. Dalším hodnocením kvality trénování byly matice záměru a normalizovaná matice záměru, které hlavně reprezentovaly počet TP a TN výsledků predikce.

Ověření navrženého algoritmu jsem provedl na pilotním souboru anonymizovaných dat pacientů s CTEPH, a kvantitativně ohodnotil kvalitu sítě pomocí několika hlavních kritérií. Senzitivita je 73,1 %, specifita je 86,9 %,  $\phi$  koeficient je 60,6 %, přesnost – 81,9%, precision – 76,0 %, F1 Score – 74,5 %, a FPR – 13,1 %. Z výše uvedených hodnot lze tvrdit, že navržený algoritmus je mírně funkční.

Daná metoda využití konvolučních neuronových sítí může být užitečnou podporou pro lékařskou diagnostiku nejenom pacientů s CTEPH, ale taky u pacientů s celou řadou jiných onemocnění. CNN dokáže mnohem rychleji, občas i přesněji detekovat patologie, pro lékaře zbývá jenom ověřit dané rozhodnutí.

## Seznam použité literatury

[1] SIMONNEAU, Gérald, Adam TORBICKI, Peter DORFMÜLLER a Nick KIM. The pathophysiology of chronic thromboembolic pulmonary hypertension. *European Respiratory Review* [online]. 2017, 26(143) [cit. 2022-03-29]. ISSN 0905-9180.

Dostupné z: <https://doi.org/10.1183/16000617.0112-2016>

[2] CASTAÑER, Eva, Xavier GALLARDO, Eva BALLESTEROS, Marta ANDREU, Yolanda PALLARDÓ, Josep Maria MATA a Lluís RIERA. CT Diagnosis of Chronic Pulmonary Thromboembolism. *RadioGraphics* [online]. 2009, 29(1), 31-50 [cit. 2020-04-20]. DOI:10.1148/rg.291085061. ISSN 0271-5333.

Dostupné z: <http://pubs.rsna.org/doi/10.1148/rg.291085061>

[3] SINGH, R, DV SHAH a JM JOSHI. Chronic thromboembolic pulmonary hypertension--diagnosed on spiral CT angiography. *Journal-association of physicians of india* [online]. PubMed, 2003 Nov [cit. 2020-04-02].

Dostupné z: <https://www.ncbi.nlm.nih.gov/pubmed/15260404>

[4] Talo M., Baloglu U.B., Yildirim Ö., Acharya U.R. Application of deep transfer learning for automated brain abnormality classification using mr images. *Cogn Syst Res.* 2019;54:176–188.

Dostupné z: <https://doi.org/10.1016/j.cogsys.2018.12.007>

[5] Swati Z.N.K., Zhao Q., Kabir M., Ali F., Ali Z., Ahmed S., Lu J. Brain tumor classification for mr images using transfer learning and fine-tuning. *Comput Med Imaging Graph.* 2019;75:34-46. Dostupné z: <https://doi.org/10.1016/j.compmedimag.2019.05.001>

[6] Lu S., Lu Z., Zhang Y.-D. Pathological brain detection based on alexnet and transfer learning. *J Comput Sci.* 2019;30:41–47.

Dostupné z: <https://doi.org/10.1016/j.jocs.2018.11.008>

[7] Sajjad M., Khan S., Muhammad K., Wu W., Ullah A., Baik S.W. Multi-grade brain tumor classification using deep cnn with extensive data augmentation. *J Comput Sci.*

2019;30:174–182.

Dostupné z:<https://doi.org/10.1016/j.jocs.2018.12.003>

[8] UUS, Alena, Panos LIATSIS a Ronak RAJANI. The influence of vessel segmentation threshold on the accuracy of patient-specific coronary blood flow simulations. In: 2016 IEEE 59th International Midwest Symposium on Circuits and Systems (MWSCAS) [online]. IEEE, 2016, 2016, s. 1-4 [cit. 2022-03-29]. ISBN 978-1-5090-0916-9.

Dostupné z: <https://doi.org/10.1109/MWSCAS.2016.7870126>

[9] CSURKA, Gabriela a Florent PERRONNIN. An Efficient Approach to Semantic Segmentation. International Journal of Computer Vision [online]. 2011, 95(2), 198-212 [cit. 2020-04-24]. DOI:10.1007/s11263-010-0344-8. ISSN 0920-5691.

Dostupné z: <http://link.springer.com/10.1007/s11263-010-0344-8>

[10] Semantic Segmentation Using Deep Learning. MathWorks: Help Center [online]. [cit. 2020-04-19]. Dostupné z: <https://uk.mathworks.com/help/vision/examples/semantic-segmentation-using-deep-learning.html>

[11] TrainingOptions. MathWorks: Help Center [online]. [cit. 2020-04-29]. Dostupné z: [https://uk.mathworks.com/help/deeplearning/ref/trainingoptions.html#bu80qkw3\\_head](https://uk.mathworks.com/help/deeplearning/ref/trainingoptions.html#bu80qkw3_head)

[12] pixelClassificationLayer. MathWorks: Help Center [online]. [cit. 2020-04-29]. Dostupné z: <https://uk.mathworks.com/help/vision/ref/nnet.cnn.layer.pixelclassificationlayer.html>

[13] bfscore. MathWorks: Help Center [online]. [cit. 2020-04-29]. Dostupné z: <https://uk.mathworks.com/help/images/ref/bfscore.html#d120e6042>

[14] WISDOM, Banso D. Understanding the Confusion Matrix (II). DEV [online]. 2019 [cit. 2020-04-29]. Dostupné z: <https://dev.to/overrideveloper/understanding-theconfusion-matrix-264j>

[15] Sensitivity and specificity. In: Wikipedia: the free encyclopedia [online]. San Francisco (CA): Wikimedia Foundation, 2001-, 27 April 2020 [cit. 2020-04-29]. Dostupné z: [https://en.wikipedia.org/wiki/Sensitivity\\_and\\_specificity](https://en.wikipedia.org/wiki/Sensitivity_and_specificity)

[16] Yule, G. Udny (1912). "On the Methods of Measuring Association Between Two Attributes". *Journal of the Royal Statistical Society*. 75 (6): 579–652. Dostupné z doi:10.2307/2340126. JSTOR 2340126

[17]RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX. U-Net:ConvolutionalNetworks for Biomedical Image Segmentation. NAVAB, Nassir,Joachim HORNEGGER, WilliamM. WELLS a Alejandro F. FRANGI, ed.Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015[online]. Cham: Springer International Publishing, 2015, 2015-11-18, s. 234-241[cit. 2020-05-05]. *Lecture Notes in Computer Science*. DOI: 10.1007/978-3-319-24574-4\_28. ISBN 978-3-319-24573-7.Dostupné z:[http://link.springer.com/10.1007/978-3-319-24574-4\\_28](http://link.springer.com/10.1007/978-3-319-24574-4_28)

[18]CHEN, Liang-Chieh, Yukun ZHU, George PAPANDREOU, Florian SCHROFF aHartwig ADAM. Encoder-Decoder with Atrous Separable Convolution forSemantic Image Segmentation. FERRARI, Vittorio, Martial HEBERT, CristianSMINCHISESCU a Yair WEISS, ed. *Computer Vision – ECCV 2018* [online].Cham: Springer International Publishing, 2018, 2018-10-06, s. 833-851 [cit. 2020-04-24]. *Lecture Notes in Computer Science*. DOI: 10.1007/978-3-030-01234-2\_49.ISBN 978-3-030-01233-5. Dostupné z: [https://link.springer.com/chapter/10.1007/978-3-030-01234-2\\_49](https://link.springer.com/chapter/10.1007/978-3-030-01234-2_49)


[19] PANCIONI, Luca, Friedhelm SCHWENKER a Edmondo TRENTIN, ed. *ArtificialNeuralNetworks in Pattern Recognition* [online]. Cham: Springer InternationalPublishing, 2018 [cit. 2020-04-29]. *Lecture Notes in Computer Science*. doi:10.1007/978-3-319-99978-4. ISBN 978-3-319-99977-7.


[20]CHOLLET, Francois. Xception: Deep Learning with Depthwise SeparableConvolutions. In:2017 IEEE Conference on Computer Vision and PatternRecognition (CVPR) [online]. IEEE, 2017, 2017, s. 1800-1807 [cit. 2020-04-25].DOI: 10.1109/CVPR.2017.195. ISBN 978-1-5386-0457-1. Dostupné z:<http://ieeexplore.ieee.org/document/8099678/>




[21] Guo, S., Meng, L., Liu, H., Yuan, L., Zhao, N., Ni, J., Zhang, Y., Ben, J., Li, Y.P., Ma, J. (2021) Trio cooperates with Myh9 to regulate neural crest-derived craniofacial development. *Theranostics*. 11:4316-4334.











## Příloha A: Přehled výstupů z algoritmu a porovnání predikce sítí s referenčními snímky





























## **Příloha B: Obsah přiloženého CD**

TrenovaniCNN.m – kód v Matlab pro trénování navržené CNN

TestCNN.m – kód v Matlab pro testování navržené CNN

Složka s testovacími daty a příslušnými referencemi