

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2020

Bc. LUCIE ČERNOHORSKÁ



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

**KLASIFIKACE ARTERIÁLNÍHO A ŽILNÍHO ŘEČIŠTĚ V
OBRAZOVÝCH DATECH SÍTNICE**

CLASSIFICATION OF ARTERIES AND VEINS IN RETINAL IMAGE DATA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Lucie Černohorská

VEDOUCÍ PRÁCE

ADVISOR

doc. Ing. Radim Kolář, Ph.D.

BRNO 2020

Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Bc. Lucie Černohorská

ID: 187787

Ročník: 2

Akademický rok: 2019/20

NÁZEV TÉMATU:

Klasifikace arteriálního a žilního řečiště v obrazových datech sítnice

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte rešerši z oblasti metod pro klasifikaci arteriálního a žilního řečiště v obrazových datech sítnice. Zaměřte se na přístupy využívající hluboké učení. 2) Seznamte se s dodanými daty, jejich vlastnostmi a se způsobem jejich akvizice. Vytvořte si segmentovanou a klasifikovanou sadu dat, kterou bude možné použít v dalších krocích. 3) Některý z přístupů pro klasifikaci řečiště si zvolte a implementujte. 4) Algoritmus dále optimalizujte pro dosažení co nejlepších výsledků a to jak na barevných snímcích sítnice, tak na datech z experimentálního video-ofthalmoskopu. 5) Dosažené výsledky vhodně kvantifikujte, dostatečně popište a diskutujte.

DOPORUČENÁ LITERATURA:

[1] LeCun, Y. et al., "Deep learning", Nature, 521 (7553), pp. 436–444, 2015.

[2] Tornow, R. et al. „Time resolved quantitative inter-eye comparison of cardiac cycle induced blood volume changes in the human retina“, Biomedical Optical Express, 9(12), pp. 6237-6254, 2018.

Termín zadání: 3.2.2020

Termín odevzdání: 29.5.2020

Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato práce je zaměřena na klasifikaci arteriálního a žilního řečiště v obrazových datech sítnice. Je zde popsána anatomie oka se zaměřením na cévní zásobení a dále jsou stručně uvedeny zobrazovací a diagnostické metody sítnice. V práci jsou zmíněny metody pro klasifikaci cévního řečiště s důrazem na hluboké učení. Praktická část probíhala v programovacím jazyku Python, kdy byla nejdříve předzpracována retinální sada dat spolu s výpočtem AV poměru. Na základě literární rešerše byla pro klasifikaci cévního řečiště zvolena architektura U-net, která byla modifikována pomocí open-source knihovny Keras. Trénování sítě probíhalo na datasetu získaném pomocí experimentálního video-ofthalmoskopu, který poskytuje šedotónové snímky. Modifikovaná architektura byla nejdříve využita pro klasifikaci cév do jednotlivých tříd, a z důvodů neuspokojivých výsledků byla dále implementována na segmentaci retinálního řečiště jako celku či zvlášť na žíly a tepny.

KLÍČOVÁ SLOVA

Sítnice, cévní řečiště sítnice, klasifikace, hluboké učení, Keras, Tensorflow

ABSTRACT

This master's thesis deals with the classification of the retinal blood vessels in retinal image data. The thesis contains a description of anatomy of the human eye with focus on the blood circulation, and imaging and diagnostic methods of the retina are briefly mentioned further. The thesis also summarizes methods of the blood circulation classification with emphasis on the deep learning. The practical section was implemented in Python programming language and describes the pre-processing of the data with determination of AV ratio. Based on a literature search, the U-net architecture was chosen for the classification of the retinal blood vessels. The architecture was modified using the open-source Keras library and tested on images from the experimental video-ophthalmoscope. The modified architecture was initially used for classification of vessels into the corresponding classes and because of unsatisfying results was modified another architecture segmenting retinal vessels, arteries or veins and a proposition of a method of the blood vessels classification.

KEYWORDS

Retina, blood vessels of retina, classification, deep learning, Keras, Tensorflow

ČERNOHORSKÁ, Lucie. *Klasifikace arteriálního a žilního řečiště v obrazových datech sítnice*. Brno, 2020, 54 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: doc. Ing. Radim Kolář, Ph.D.

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Klasifikace arteriálního a žilního řečiště v obrazových datech sítnice“ jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského 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, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autorky

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu diplomové práce panu doc. Ing. Radimu Kolářovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	10
1 Oko	11
1.1 Anatomie oka	11
1.2 Cévní zásobení sítnice	11
1.2.1 Vlastnosti cév sítnice	12
1.3 Zobrazovací a diagnostické metody sítnice	13
2 Klasifikace cévního řečiště pomocí metod strojového učení	16
2.1 Strojové učení	16
2.2 Neuronové sítě	16
2.3 Hluboké učení	19
2.3.1 Konvoluční neuronové sítě	19
2.4 Aplikované metody klasifikace cévního řečiště	21
2.4.1 U-net	22
2.4.2 VGG	23
2.4.3 Segnet	23
2.4.4 Konvoluční neuronová síť	24
3 Návrh metody pro klasifikaci cévního řečiště	26
3.1 Předzpracování retinálních snímků	26
3.2 Návrh zvolené architektury hlubokého učení a způsobu vyhodnocení .	30
3.2.1 Chybové funkce	31
3.2.2 Optimalizační algoritmus	32
3.2.3 Vyhodnocovací metriky	33
4 Implementace a vyhodnocení zvolené architektury hlubokého učení	35
4.1 Klasifikace cévního řečiště	35
4.2 Segmentace žil a tepen z cévního řečiště	39
4.3 Segmentace cévního řečiště	42
Závěr	46
Literatura	48
Seznam symbolů, veličin a zkratek	52
A Přílohy	53

Seznam obrázků

1.1	Anatomie oka [1]	11
1.2	Sítnice zachycená fundus kamerou	14
1.3	Sítnice zachycená experimentálním VO	15
2.1	Model jednovrstevné neuronové sítě [29]	17
2.2	Model vícevrstevné neuronové sítě [29]	18
2.3	Model zpětnovazebné neuronové sítě [29]	18
2.4	Konvoluce [15]	20
2.5	Podvzorkování [15]	21
2.6	Architektura U-net [35]	22
2.7	Architektura VGG [16]	23
2.8	Architektura Segnet [5]	24
2.9	Architektura konvoluční neuronové sítě [44]	25
3.1	Segmentovaný cévní strom	27
3.2	Ručně klasifikovaný cévní strom	27
3.3	Skeleton cévního stromu	28
3.4	Zprůměrovaná distanční matice	28
3.5	Maska 1	28
3.6	Maska 2	28
3.7	Maska 3	28
3.8	Výsledný snímek	28
3.9	AV poměr horní segment	29
3.10	AV poměr dolní segment	29
3.11	Modifikovaná architektura U-net	30
3.12	Matice záměn	33
3.13	ROC křivka	34
4.1	Původní snímek	35
4.2	Ořezaný snímek	35
4.3	Chybová funkce při klasifikaci cévního řečiště - váhy 0,7, 10, 22	36
4.4	Chybová funkce při klasifikaci cévního řečiště - váhy 0,6, 13, 22	36
4.5	Výsledná matice záměn pro klasifikaci cévního řečiště - váhy 0,7, 10, 22	37
4.6	Výsledná matice záměn pro klasifikaci cévního řečiště - váhy 0,6, 13, 22	37
4.7	Ground truth snímek 1	38
4.8	Predikovaný snímek 1 - váhy 0,7, 10, 22	38
4.9	Predikovaný snímek 1 - váhy 0,6, 13, 22	38
4.10	ROC křivka pro snímek 1 - váhy 0,7, 10, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly	38

4.11	ROC křivka pro snímek 1 - váhy 0,6, 13, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly	38
4.12	Ground truth snímek 2	39
4.13	Predikovaný snímek 2 - váhy 0,7, 10, 22	39
4.14	Predikovaný snímek 2 - váhy 0,6, 13, 22	39
4.15	ROC křivka pro snímek 2 - váhy 0,7, 10, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly	39
4.16	ROC křivka pro snímek 2 - váhy 0,6, 13, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly	39
4.17	Chybová funkce při segmentaci tepen	40
4.18	Chybová funkce při segmentaci žil	40
4.19	Výsledná matice záměn pro segmentaci tepen	41
4.20	Výsledná matice záměn pro segmentaci žil	41
4.21	Ground truth snímek tepny	41
4.22	Ground truth snímek žíly	41
4.23	Predikovaný snímek tepny	41
4.24	Ground truth snímek tepny	41
4.25	Ground truth snímek žíly	41
4.26	Predikovaný snímek žíly	41
4.27	ROC křivka pro snímek tepny	42
4.28	ROC křivka pro snímek žíly	42
4.29	Chybová funkce při segmentaci celého řečiště bez vah	43
4.30	Chybová funkce při segmentaci celého řečiště s vahou 2	43
4.31	Výsledná matice záměn pro segmentaci cévního řečiště bez vah	44
4.32	Výsledná matice záměn pro segmentaci cévního řečiště s vahou 2	44
4.33	Ground truth snímek 1 - segmentace cévního řečiště	44
4.34	Predikovaný snímek 1 - segmentace cévního řečiště bez vah	44
4.35	Predikovaný snímek 1 - segmentace cévního řečiště s vahou 2	44
4.36	ROC křivka pro cévní řečiště bez vah, snímek 1	45
4.37	ROC křivka pro cévní řečiště s vahou 2, snímek 1	45
4.38	Ground truth snímek 2 - segmentace cévního řečiště	45
4.39	Predikovaný snímek 2 - segmentace cévního řečiště bez vah	45
4.40	Predikovaný snímek 2 - segmentace cévního řečiště s vahou 2	45
4.41	ROC křivka pro cévní řečiště bez vah, snímek 2	45
4.42	ROC křivka pro cévní řečiště s vahou 2, snímek 2	45

Seznam tabulek

Úvod

Analýza retinálních snímků je nedílnou součástí diagnostických vyšetření. V dnešní době se klade velký důraz na rychlé a efektivní snímání a následné zpracování snímků sítnice. Každý detail snímku je velmi důležitý, a to především kvůli odhalení patologických stavů v počátečním stádiu.

Ke správné klasifikaci cévního řečiště je nutné znát anatomickou stavbu oka, především cévní zásobení sítnice, které je popsáno v kapitole 1. Sítnici lze snímat pomocí zobrazovacích metod, které poskytují rychlé a relevantní informace o fyziologickém stavu vyšetřovaného očního pozadí. Zobrazovací systémy, kterými jsou získány zpracovávané data této práce jsou uvedeny v kapitole 1.

Tato práce se zabývá klasifikací arteriálního a žilního řečiště pomocí umělé inteligence. V kapitole 2 jsou uvedeny publikované metody pro klasifikaci cévního řečiště, se zaměřením na architektury U-net, VGG a Segnet. Výběr vhodné architektury musí zohledňovat nejen velikost zpracovávaného datasetu, ale také obtížnost dané problematiky.


V kapitole 3 je popsáno předzpracování dat, spolu s výpočtem arterio-venulárního poměru, který je zásadní při diagnostice očního onemocnění. Předzpracovaná data jsou dále využita jako vstupní a výstupní dataset pro trénování hluboké neuronové sítě. Pro klasifikaci cévního řečiště byla zvolena architektura U-net, jejíž modifikace je popsána v kapitole 3. V této kapitole jsou dále uvedeny použité chybové funkce a optimalizační algoritmus. Součástí jsou také vyhodnocovací metriky.

V rámci práce je zvolená architektura U-net využita jak pro klasifikaci cévního řečiště do jednotlivých tříd, tak pro segmentaci cév jako celku, či tepen a žil odděleně. Výsledky jednotlivých řešeních problematik jsou diskutovány v kapitole 4.

1 Oko

1.1 Anatomie oka

Oko je smyslový párový orgán, jehož nejdůležitější součástí je oční koule, která má kulovitý tvar s průměrem asi 20 mm a zprostředkovává až 85% přijímaných informací z okolí, viz obrázek 1.1. Ze zadní části oční bulvy vystupuje zrakový nerv, který zachycenou informaci posílá do zrakových drah a centra. Zrakový orgán dále zahrnuje přídatné orgány, tj. víčko, spojivku, slzné ústrojí a okoohybné svaly, které mají ochrannou funkci. Oční bulva je uložena v očníci a je složena ze tří vrstev; povrchová - vazivová, střední - cévnatá, vnitřní - nervová. [3], [17], [36]



Obr. 1.1: Anatomie oka [1]

1.2 Cévní zásobení sítnice

Sítnice

Sítnice je jemná průhledná blána, která se nachází na vnitřní stěně oční koule a její tloušťka se pohybuje mezi 0,1 - 0,5 mm. Sítnice obsahuje 10 vrstev v optické části; pigmentový list, tyčinky a čípky, lamina limitans externa, jádra neuroepitelu, vnější plexiformní vrstva, jádra bipolárních buněk, vnitřní plexiformní vrstvu, gangliové

buňky, vsrtvu nervových vláken a lamina limitans interna. Pro zjednodušení lze sítnici rozdělit na dvě hlavní vrstvy:

- vnitřní vrstva sítnice (neuroretina),
- zevní vrstva jednovrstevného retinálního pigmentového epitelu.

Zevní vrstva sousedí s cévnatkou a vnitřní vsrtva se sklívcelem. Základní stavební jednotkou sítnice jsou nervové buňky, které jsou navzájem propojené. Svazky nervových buněk se spojují na sítnici v místě terče zřakového nervu. Výstup zřakového nervu na sítnici se nazývá optický disk. Na zevní vrstvu jednovrstevného retinálního pigmentového epitelu nasedá vrstva fotoreceptorů tj. tyčinky a čípky, jejichž podrážděním světelným stimulem dochází k převodu světelných parsků na elektrochemický signál. Vrstva tyčinek slouží při vidění za šera, díky nim rozeznáváme světlo a tmu. Vrstva čípků zajišťuje ostré vidění, rozeznávání barev a jejich největší koncentrace je na sítnici v místě, které se nazývá žlutá skvrna. [3], [17], [36]

Cévní zásobenění sítnice zajišťují dva cévní systémy - retinální a choroidální cévy. Oba dva systémy vycházejí z první větve vnitřní karotické artérie. Vnitřní retinální vrstvu zásobují retinální cévy, zatímco zevní vsrtva sítnice zahrnující pigmentový epitel a fotoreceptory, je avaskulární a vyživována difuzí z choriokapilaris.

Centrální tepna zásobující krví sítnici vysutpuje z papily zřakového nervu a následně se dělí na horní a dolní větev, které se dále dělí na nazální a temporální větévku. Tyto větve jsou terminální a nemají anastomózy s jinými tepnami. Po prvním dělení se z arterií obvykle stávají arterioly, jelikož ztrácejí elastická vlákna a vnitřní elastickou membránu. Artérie a vény protkávají vsrtvu nervových vláken, přičemž arterioly a venuly tvoří dvě hlavní mikrovaskulární sítě v hlubších vrstvách:

- povrchovou - ve vrstvě nervových vláken a gangliových buněk,
- hlubokou - ve vnitřní nukleární vrstvě.

Kolem zřakového nervu jsou kapilární sítě i několika vrstevné, naopak na periferii sítnice se kapiláry ztečují až na jednu vrstvu. Kapiláry zcela chybí ve žluté skvrně a na nejzazší periferii. [22]

1.2.1 Vlastnosti cév sítnice

Jak již bylo žmíněno v kapitole 1.2 cévní zásobenění vychází z první větve karotické artérie, přičemž jednotlivé tepny a žíly lze rozeznat na základě morfologických příznaků. Žíly jsou zpravidla tenčí a vyznačují se tmavší barvou, která je způsobena odváděním odkyslyčené krve. Naopak tepny jsou širší a díky okyslyčené krvi mají tepny světlejší barvu. Tepny dále zahrnují výraznější centrální reflex, který se projevuje jako světlý proužek viz obrázek 1.2. Pro cévy je dále charakteristické pravidelné střídání v okolí optického disku, tzn. vedle jedné žíly jsou v blízkosti dvě tepny a vedle jedné tepny jsou v blízkosti dvě žíly. [22]

Výše zmíněné příznaky nám poskytují dostatek informací, na jejichž základě lze úspěšně klasifikovat cévy na žíly a tepny. Existuje však mnoho příčin, které mohou samotnou klasifikaci ztížit, nebo dokonce znemožnit. Jeden z důvodů je nekvalitní snímek, na kterém není viditelný centrální reflex. Dalším důvodem může být příliš tmavý snímek, na kterém se tepny i žíly jeví stejně barevné. V neposlední řadě může klasifikaci zhoršovat nepravidelnost střídání tepen a žil. Dalším důvodem je neúměrná šířka cév; široké cévy u optického disku a naopak tenké cévy na periférii.

K diagnostice kardiovaskulárních onemocnění je zaveden poměr tepenného a žilního řečiště, tj. arterio-venulární poměr (A/V). AV poměr lze vypočítat pomocí rovnic

$$W_a = \sqrt{0,88 * (f^2 + l^2)} \quad (1.1)$$

$$W_v = \sqrt{0,95 * (f^2 + l^2)}, \quad (1.2)$$

$$AV = \frac{W_a}{W_v}, \quad (1.3)$$

kde W_a je průměrná šířka tepen, W_v je průměrná šířka žil, f je maximální šířka žíly/tepeny a l je minimální šířka žíly/tepeny. [32], [13]

Výpočtem AV poměru se zabývala například studie Heitmar a kol. [13] nebo studie Niemeijer a kol. [32]. Obě práce se shodly na fyziologické hodnotě AV poměru, která je 2:3. Ve studiích je dále zmíněno, že jakékoliv odchylky od této hodnoty poukazují na patologický nález. Vyšší hodnota AV poměru může značit například diabetes či hypertenzi.


1.3 Zobrazovací a diagnostické metody sítnice

V současné době patří snímání očního pozadí k základním vyšetřovacím metodám. Diagnostika fyziologického stavu zrakového aparátu pomáhá předcházet různým patologiím, například angiopatii, retinopatii nebo glaukomu. Níže zmíněné moderní zobrazovací metody poskytují včasnou, spolehlivou a především cenově dostupnou diagnózu, díky které lze zmírnit pacientovy obtíže nebo jim dokonce předejít.

Fundus Kamera

Fundus kamera je diagnostické zařízení, které využívá nepřímé oftalmoskopie pro fotodokumentaci zadního segmentu oka. Nepřímá oftalmoskopie využívá spojné čočky a světelný zdroj zabudovaný uvnitř přístroje. Světlo může být modifikováno různými


druhy filtrů pro snížení intenzity osvětlení nebo zvýšení kontrastu. Světelný paprsek je pomocí optické soustavy čoček a zrcadel fokusován do pacientova oka, kde se odrazí od sítnice do objektivu fundus kamery. Obraz je poté digitalizován nejčastěji CCD snímačem. Celkové zvětšení fundus kamery je 10x - 30x a rozsah snímání je od 20°- 50°. Jak lze vidět na obrázku 1.2 fundus kamera poskytuje barevný obraz očního pozadí. [6], [36]



Obr. 1.2: Sítnice zachycená fundus kamerou

Experimentální video-oftalmoskop

Experimentální VO (video-oftalmoskop) má podobné technické znaky jako výše zmíněná fundus kamera, tj. zahrnuje soustavu dvou achromatických čoček a oftalmické čočky. Optická soustava VO fokusuje světelný paprsek do oblasti zornice, kde paprsek diverguje a osvětluje sítnici. Odražené paprsky od sítnice jsou následně směřovány na CCD snímač. Takto nasnímaný obraz je dále zaznamenán počítačem, který je s CCD snímačem propojen pomocí USB kabelu. Zadní segment oka je snímán s frekvencí 25 snímků za sekundu, přičemž zorný úhel VO je 20° x 15° a výsledný obraz má rozměr 1000 x 770 pixelů. Hlavní rozdíl mezi fundus kamerou a experimentálním VO je ten, že VO využívá pro osvětlení očního pozadí střed pupily a zbytek pupily je využíván pro zobrazování, podobně jako v laserových skenovacích oftalmoskopech. Jako světelný zdroj se využívá jednoduchá dioda emitující světlo o vlnové délce 575 nm. Jak lze vidět na obrázku 1.3 VO poskytuje kvůli monochromatickému zdroji záření šedotónový obraz. [20], [41]



Obr. 1.3: Sítnice zachycená experimentálním VO

2 Klasifikace cévního řečiště pomocí metod strojového učení

V současné době lze v literatuře najít mnoho metod zabývajících se klasifikací retinálního řečiště. Většina studií se zaměřuje na metody založené na umělé inteligenci, jejichž hlavní podoblastí je strojové učení.

2.1 Strojové učení

Strojové učení je výpočetní metoda, zabývající se různými algoritmy a technikami, které umožňují počítači učit se, aniž by byl explicitně naprogramován. Při aplikaci strojového učení je důležité si nejdříve definovat hledaný problém, následně nashromáždit data a extrahovat jednotlivé příznaky. Data jsou dále rozdělena na trénovací a testovací, přičemž na trénovacích datech se algoritmus naučí a na testovacích otestuje. Počítač se tak sám naučí řešit definovaný problém. [43]

Strojové učení lze dělit na více kategorií, přičemž hlavní rozdělení je podle druhu učení: učení s učitelem, učení bez učitele, kombinace učení s učitelem a bez učitele a zpětnovazebné učení. Při strojovém učení s učitelem jsou algoritmu poskytnuty jak vstupní data, tak i požadované výstupy. Na rozdíl od učení bez učitele, kdy algoritmus nedostane požadované výstupy a musí je na základě příznaků sám vytvořit. U kombinace s učitelem a bez učitele jsou požadované výstupy známy pouze pro některé vstupní data, přičemž zpravidla pro velké vstupní data jsou výstupy neznámé. Zpětnovazebné učení je algoritmus, který je založený na učení s učitelem a dochází při něm k minimalizaci chyby, která je dána rozdílem mezi skutečnou a požadovanou odezvou neuronové sítě. Tento rozdíl nám dále určuje, jak se váhy jednotlivých neuronů změny pro danou iteraci. [37], [33], [43]

Strojové učení má mnoho využití, mezi základní úlohy patří klasifikace rozdělující vstupní data do jednotlivých tříd, dále regrese odhadující číselnou hodnotu výstupu podle vstupu nebo také shlukování zařazující vstupní data do shluků na základě podobných příznaků. [37], [33], [43]

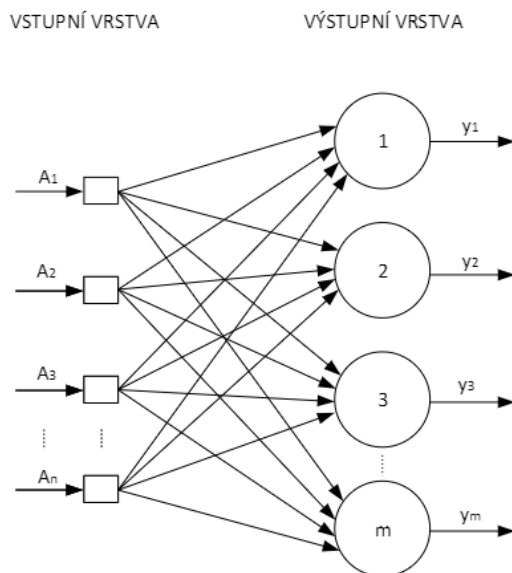
2.2 Neuronové sítě

Umělé neuronové sítě jsou matematické výpočetní modely, které svou funkcí napodobují biologické neuronové sítě. Neuronová síť se skládá z množiny umělých neuronů, též nazývaných perceptrony. Perceptrony jsou propojeny a navzájem si předávají zpracovávané informace, přičemž každý perceptron může mít více vstupů, avšak jen jeden výstup. Každý spoj je ohodnocen váhou, přičemž čím vyšší hodnotu váha má,

tím důležitější je daný vstup. Jednotlivé neurony se aktivují na základě přenosové funkce, která je vybrána podle typu samotných neuronů a typu neuronové sítě. Mezi přenosové funkce patří například sigmoida, hyperbolický tangens, skoková funkce nebo ReLu. [43], [31], [39]

Na řešení komplexních úloh by jeden neuron nestačil, a proto algoritmy využívají sítě složené z množiny neuronů. Dle architektury lze rozdělit neuronové sítě na jednovrstevnou dopřednou síť, vícevrstevnou dopřednou síť a zpětnovazebnou síť. [43], [31], [39]

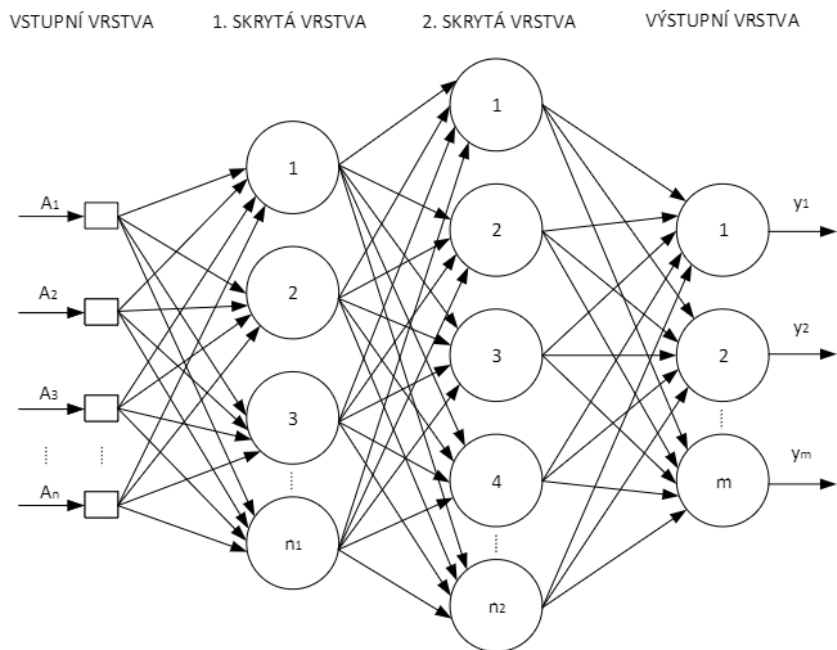
Příklad jednovrstevné dopředné sítě je na obrázku 2.1. Takováto síť má pouze jednu vrstvu tvořenou neurony, a to vrstvu výstupní. Vstupní vrstva je tvořena vektory obsahující binární nebo reálné hodnoty. Jednovrstevná síť se využívá například pro rekonstrukci neúplných nebo šumem poškozených obrazů.



Obr. 2.1: Model jednovrstevné neuronové sítě [29]

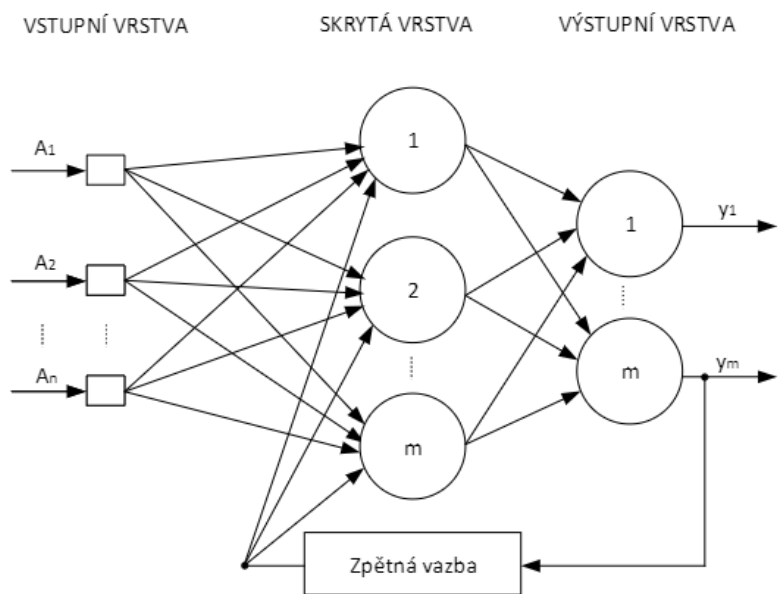
Na obrázku 2.2 je zobrazena vícevrstevná dopředná síť. První vrstva, kterou označujeme za vstupní, obsahuje informace o datech, signálech nebo měřených externích veličinách. Poslední vrstva se nazývá výstupní a zodpovídá za vytvoření finálních výstupů sítě. Ostatní vrstvy nacházející se mezi vstupní a výstupní vrstvou se nazývají skryté a zpracovávají přijaté informace. Počet skrytých vrstev je založen na složitosti řešeného problému. Tato síť nachází své uplatnění například při klasifikaci dat.

Zpětnovazebná síť je charakteristická tím, že jako vstup do neuronu je možné využít jak výstup neuronu z předchozí vrstvy, tak výstup neuronu z následující vrstvy.



Obr. 2.2: Model vícevrstevné neuronové sítě [29]

Díky tomu lze zpětnovazebné sítě využít pro zpracovávání časově proměnných systémů. Model zpětnovazebné sítě je obrázku 2.3.



Obr. 2.3: Model zpětnovazebné neuronové sítě [29]

2.3 Hluboké učení

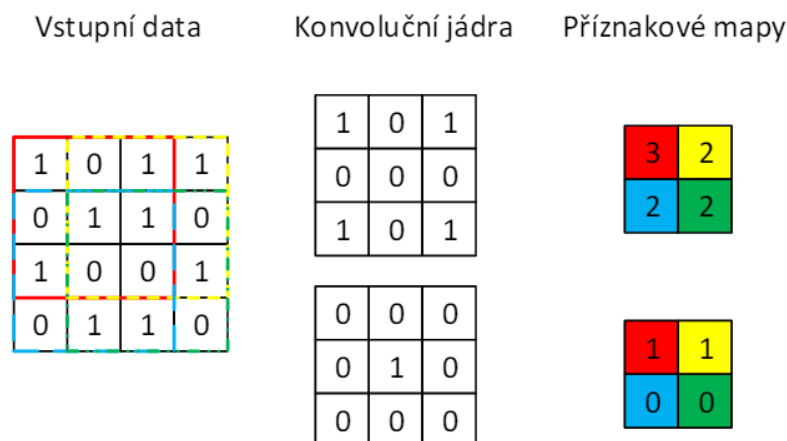
Hluboké učení je metoda spadající pod strojové učení a zahrnující mnohvrstevné nelineární výpočetní modely. Tyto modely zachovávají při zpracování určitou hierarchii, kdy učení probíhá od nejnižší do nejvyšší vrstvy skrz toto hierarchické uspořádání. Každá vrstva bere v úvahu určité spojitosti předchozí vrstvy a tím vytváří vyšší abstraktní úroveň. Hluboké učení využívá na trénování stovky až tisíce vstupních dat, přičemž samotné trénování probíhá v hlubokých neuronových sítích. Hluboké učení je průlomová metoda především v oblasti zpracování obrazů, videa, rozpoznávání řeči a zvuků, a dále také v oblasti detekci objektů. [31], [23], [12]

2.3.1 Konvoluční neuronové sítě

Konvoluční neuronové sítě (angl. convolution neural networks, dále jen CNN) jsou speciálním typem neuronových sítí, které se vyznačují velkým množstvím skrytých vrstev. CNN jsou vhodné především pro zpracování obrazů, tzn. 2D dat o známé velikosti. Architektura konvolučních sítí umožňuje extrakci příznaků pomocí konvoluce a následně klasifikaci získaných příznaků pomocí neuronové sítě. Charakteristická architektura CNN zahrnuje konvoluční vrstvy spolu s aktivační vrstvou ReLu/Softmax, sdružovací vrstvy a plně propojené vrstvy. [15]

Konvoluční vrstva

Princip konvoluční vrstvy je zobrazen na obrázku 2.4. Jako vstup slouží obraz o určité šířce, výšce a hloubce. Celý vstupní obraz je následně konvolován s konvolučním filtrem (kernelem) o zadané velikosti, tzn. násobíme jednotlivé pixely vstupního obrazu s hodnotami masky. Výsledné hodnoty skalárních součinů tvoří hodnoty pixelů ve výsledné příznakové mapě. Masku lze posouvat o libovolný počet kroků, přičemž vždy dojde ke zmenšení vstupního obrázku. Počet konvolučních filtrů je roven počtu výsledných příznakových map. [15]



Obr. 2.4: Konvoluce [15]

Aktivační vrstva

Nejvíce využívanou aktivační funkcí je ReLu, která díky svým parametrům zajišťuje stejnou velikost vstupní i výstupní vrstvy. Výhodou ReLu funkce je to, že dokáže velmi rychle trénovat danou síť. [15]


Pro aktivaci výstupní vrstvy je nejčastěji využívání funkce Softmax. Hlavní úlohou této aktivační funkce je převést reálné hodnoty do intervalu (0,1). Čím více se výstupní hodnota blíží k hodnotě 1, tím správnější je výstup. Softmax funkce se využívá především při klasifikaci. [15]

Podvzorkovací vrstva

Podvzorkovací vrstva zajišťuje redukcí příznaků v příznakové mapě. Díky tomu jsou data více robustní proti šumu a zkreslení. Jak je zobrazeno na obrázku 2.5, podvzorkování lze provést dvěma způsoby; hledáním průměrné hodnoty nebo hledáním maxima. Vstupní příznaková mapa má velikost 4x4, přičemž výsledná průměrná hodnota nebo výsledné maximum se hledá v regionu o velikosti 2x2. Výstupní příznaková mapa má velikost 2x2. [15]

Plně propojená vrstva

Plně propojené vrstvy se často používají jako konečné vrstvy konvolučních sítí. Jak již název napovídá, každý výstupní neuron má informace od každého předchozího neuronu. Tyto spojení mezi jednotlivými neurony mají rozdílné váhy podle důležitosti a konkrétní výsledek je dán matematickou kombinací těchto vah. [15]



Obr. 2.5: Podvzorkování [15]

DropOut vrstva

Dropout je metoda, která snižuje pravděpodobnost přečtení neuronové sítě. Během trénování dochází k deaktivaci některých neuronů. Tato deaktivace zlepšuje generalizaci tím, že nutí danou dropout vrstvu učit se s jiným počtem neuronů. Dropout se nejčastěji využívá v plně propojených vrstvách, ale je možné jej použít i po podvzorkovací vrstvě. [38]

BatchNorm vrstva

BatchNorm vrstva normalizuje vstupy pro další konvoluční nebo plně propojenou vrstvu. Data jsou transformována s jednotkovou standardní odchylkou a nulovou střední hodnotou. Normalizace snižuje kovariační posun, který nastává při změně zpracovávaných dat. [46]

2.4 Aplikované metody klasifikace cévního řečiště

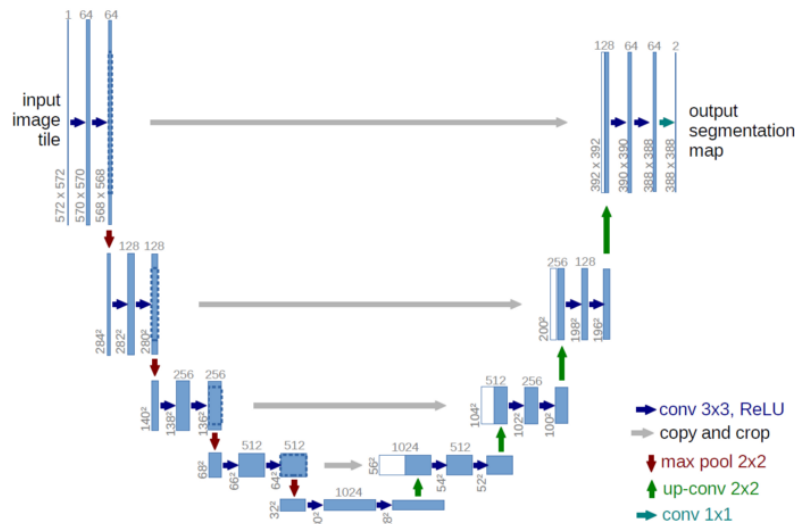
Klasifikace patří mezi základní metody analýzy obrazu, kdy jsou vybrané objekty zařazovány do jednotlivých tříd. Klasifikace je častokrát posledním krokem při diagnostickém postupu. Nasnímané obrazy jsou jako první nasegmentovány na specifické objekty, které jsou dále označeny. V takto označených objektech jsou dále extrahovány příznaky, které slouží jako vstupní data pro klasifikátor. Klasifikátor dále vyhodnocuje předložené vlastnosti a rozhoduje o tom, do které třídy bude daný objekt zařazen. Získané znaky mohou být například barva, tvar nebo struktura.

Celkové zpracování vstupních dat velmi závisí na kvalitním předzpracování, jelikož špatné rozlišení či šum mohou ovlivnit výsledky. [45]

V literatuře je popsána celá řada metod pro segmentaci cévního řečiště na základě hlubokého učení, avšak metod pro klasifikaci retinálního řečiště je publikováno mnohem méně. V této kapitole se práce zaměří na různé typy architektur založené na hlubokých neuronových sítích.

2.4.1 U-net

U-net je architektura hlubokého učení, která je založená na konvoluční neuronové síti. Tato síť dosahuje velmi přesné klasifikace i přesto, že pracuje s malým počtem trénovacích dat. U-net se skládá z kontraktilní části (levá strana) a expanzivní části (pravá strana), viz obrázek 2.6. Kontraktilní část se skládá ze dvou konvolučních vrstev, které využívají konvoluční filtry o velikosti 3x3. Za každou konvolucí následuje aktivační vrstva ReLu a poté podvzorkovací vrstva, jejíž výstupem je příznaková mapa o velikosti 2x2. Expanzní část zahrnuje nejdříve nadvzorkovací vrstvy s maskou 2x2 s krokem 2. Dále jsou použity konvoluční vrstvy s konvolučními filtry o velikosti 3x3 následované aktivační vrstvou ReLu. Na konci expanzní části je umístěna konvoluční vrstva, která má konvoluční filtr o velikosti 1x1, která zmapuje každý jeden příznak a přiřadí mu požadovanou třídu. [35]



Obr. 2.6: Architektura U-net [35]

Klasifikace retinálního cévního řečiště pomocí architektury U-net byla zmíněna ve studii Meyer a kol [28]. Zpracovávaná data byla z RITE dataset, což je veřejná databáze zahrnující 40 sad retinálních snímků rovnoměrně rozdělené na trénovací a tes-


tovací podmnožiny. Meyer a kol. přizpůsobili U-net pomocí BatchNorm a Dropout vrstvami, přičemž optimalizace byla realizována pomocí ADAM algoritmu. Klasifikace probíhala na jednotlivých kanálech RGB snímků, přičemž nejlepších výsledků bylo dosaženo při kombinacích RG a RB. Při RG kombinaci dosahovala přesnost 95 %, specificita 93 % a senzitivita 96 %. Při RB kombinaci dosahovala přesnost 96 %, specificita 96 % a senzitivita 95 %.

Klasifikace cévního řečiště na žíly a tepny pomocí architektury U-net je dále popsána ve studii Hemelings a kol [14]. Zpracovávaná data byla z databáze DRIVE a HRF. Obě tyto databáze jsou veřejně dostupné, přičemž dataset DRIVE obsahuje 40 snímků a HRF 45 snímků. Architektura U-net byla modifikována na klasifikaci RGB snímků, konvoluční filtry byly upraveny na velikost 5x5 a dále byly přidány dvě Dropout vrstvy s hodnotou 0,2 pro správnou regularizaci sítě. Výsledná úspěšnost klasifikace byla 94,3 %.

2.4.2 VGG

VGG je síť, která je opět založená na konvoluční neuronové síti. Tato síť se skládá z šestnácti konvolučních vrstev, které využívají konvoluční filtry o velikosti 3x3 s krokem jedna. Dále síť obsahuje podvzorkovací vrstvy s maskou 2x2 s krokem dva. Na konci sítě jsou tři vrstvy plně propojených vrstev s aktivační vrstvou Softmax. Výhoda VGG sítě je v její jednoduchosti. Architektura VGG sítě je zobrazena na obrázku 2.7. [16]

VGG síť byla implementována pro klasifikaci cévního řečiště ve studii Ventura a kol [42], kde využili cévní topologii pro správné zařazení žil a tepen. Snímky si rozdělili na jednotlivé podobrazy, ve kterých hledali konektivitu mezi tepnami a žilami. Úspěšnost vyhodnocovali pomocí F1 metriky, která dosahovala 78 %.



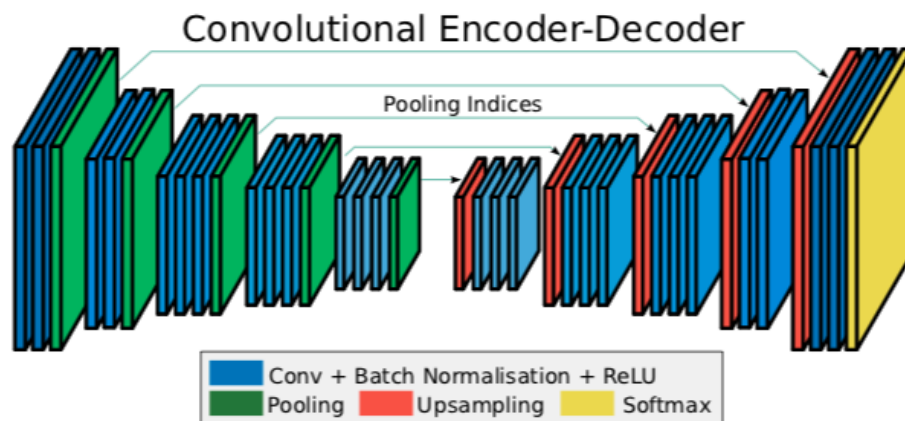
Obr. 2.7: Architektura VGG [16]

2.4.3 Segnet

Architektura Segnet se skládá se dvou hlavních částí, enkodéru a dekodéru, viz obrázek 2.8. Enkodér se skládá z 13 konvolučních vrstev, které odpovídají vrstvám sítě VGG16. Každá vrstva enkodéru má odpovídající vrstvu dekodéru, přičemž dekodér je zakončen vrstvou s aktivační funkcí softmax, která nám udává příslušnost daného

pixelu k určité třídě. Enkodér slouží k extrahování jednotlivých příznaků a na něj navazující dekodér tyto informace využívá pro klasifikaci snímku. [5]


Architektura Segnet byla využita pro klasifikaci retinálního řečiště ve studii Badawi a kol [4], kde zpracovávali volně dostupné datasey DRIVE a AVRDB. Trénování sítě probíhalo s učebním krokem 0,1 a jako optimalizační algoritmus byl využit stochastic gradient descent. Jako chybová funkce byla použita matice záměn, která porovnávala jednotlivé pixely z predikovaného snímku s ground truth snímkem. Výsledná úspěšnost trénování na datasetu DRIVE byla 96 % a pro dataset AVRDB byla úspěšnost 98 %.



Obr. 2.8: Architektura Segnet [5]

2.4.4 Konvoluční neuronová síť

Ke klasifikaci cévního řečiště lze využít i architektury, které jsou navrženy zcela od základu, jak je tomu například ve studii Welikala a kol [44]. Jejich navržená architektura, viz obrázek 2.9, se skládá z dvou bloků zahrnující konvoluční vrstvu, za kterou následuje aktivační vrstva ReLu, křížová kanálová normalizace a podvzorkovací vrstva. Síť dále obsahuje konvoluční blok z konvoluční vrstvy aktivovanou vrstvou ReLu a zakončenou křížovou kanálovou normalizací. Architektura dále zahrnuje 2 bloky tvořené plně propojenou vrstvou, aktivační vrstvou a zakončenou vrstvou DropOut. Poslední vrstva je tvořena plně propojenou vrstvou s aktivační funkcí softmax. Vstupní data byly RGB snímky z datasetu UK Biobank, přičemž výstupem byly dvě hodnoty odpovídající dvou třídám. Jako chybová funkce byla zvolena L2 regularizace a trénování modelu probíhalo na 30 epoch. Úspěšnost navržené sítě byla 86, 97 %.



Obr. 2.9: Architektura konvoluční neuronové sítě [44]

3 Návrh metody pro klasifikaci cévního řečiště

V rámci praktické části diplomové práce se zaměříme na předzpracování retinálních snímků a na návrh architektury hlubokého učení, která je následně využita pro klasifikaci cévního řečiště. Samotná segmentace cévního řečiště byla realizována v programu Matlab, přičemž předzpracování a klasifikace probíhala v programovacím jazyku Python. K návrhu vhodné architektury hlubokého učení byla využita open-source knihovna Keras. Tato knihovna je uživatelsky velmi intuitivní a umožňuje přehledné sestavení jednotlivých architektur neuronových sítí. Její velkou výhodou je, že je kompatibilní s open-source knihovnou Tensorflow. Tato knihovna byla vytvořena společností Google a zahrnuje výpočetní metody umožňující implementaci strojového a hlubokého učení. Díky tomu, že Tensorflow umožňuje provádět výpočty nejen na centrálním procesoru (CPU), ale také na grafické kartě (GPU) je celkový výpočet několikanásobně rychlejší. [18][40]


3.1 Předzpracování retinálních snímků

Pro analýzu byly použity snímky sítnice pořízené experimentálním VO a fundus kamerou, které jsou popsány v kapitole 1.3. Zpracovávané snímky z VO mají rozměr 1000 x 770, jsou šedotónové a obvykle poškozené nějakým druhem zkreslení. Zkreslení je nejčastěji způsobeno špatným zaostřením či pohybem oka. Naopak fundus kamera poskytuje barevné snímky s mnohem větší kvalitou, snímky obsahují menší úroveň šumu, jsou ostré a bez pohybových artefaktů. Na základě kvality byly snímky rozděleny do skupin označených jako +1 - snímky s nejvyšší kvalitou, 0 - snímky s nižší kvalitou a -1 - snímky s nejhorší kvalitou. Pro segmentaci byly použity snímky o nejvyšší kvalitě.


Segmentace cévního řečiště probíhala na zprůměrovaných snímcích získaných pomocí experimentálního VO v programu Matlab, viz obrázek 3.1. Hotové vysegmentované snímky byly dodány školitelem pro další zpracování. V rámci praktické částí této práce byly snímky ručně klasifikovány v programu Adobe Photoshop CC 2019. Pro přesnější klasifikaci byly využity i snímky získané pomocí fundus kamery. Fundus kamera poskytuje narozdíl od VO barevné snímky, které zachycují specifické příznaky cév zmíněné v kapitole 1.2.1. Na základě kombinace snímků získaných VO a fundus kamerou byl rozlišen cévní strom na jednotlivé žíly a tepny. Žíly zde byly označeny modrou barvou a tepny barvou červenou. Na snímcích se objevovaly i oblasti, kde klasifikace nebyla zcela zřejmá, viz obrázek 3.2. Neznáme segmenty byly označeny růžovou barvou. Takto zaklasifikované snímky dále sloužily jako ground

truth data pro hlubokou neuronovou síť.


Další předzpracování probíhalo v programovém prostředí jazyka Python. K získání arterio-venulárního poměru bylo zapotřebí zjistit šířku jednotlivých cév ve vybrané oblasti. Vstupní barevný obraz byl nejdříve převeden na binární, přičemž binární obraz byl dále použit pro výpočet distanční matice. Distanční matice přiřazuje jednotlivým pixelům hodnotu, která je shodná se vzdáleností daného pixelu od pozadí. Poté byl z binárního obrazu vyvořen skeleton zobrazený na obrázku 3.3, který byl využit pro výpočet výsledné šířky cév. Pro každý nenulový pixel skeletonu se hledala odpovídající hodnota v distanční matici, přičemž tato hodnota na dané pozici se uložila do nově vzniklé matice. Kvůli natočení a překrývání se cév byla poté matice obsahující jednotlivé šířky cév průměrována filtrem s maskou o velikosti 10x10 s krokem 20. V této masce se hledalo maximum v dané oblasti, které se uložilo na odpovídající pozice, viz obrázek 3.4. Na základě prostudovaných publikací týkajících se arterio-venulárního poměru [32], [13], byla zvolena zóna poskytující žíly a tepny pro daný výpočet podle průměru optického disku v aktuálním snímku, viz obrázek 3.5. K získání průměru optického disku byl aplikován algoritmus z knihovny OpenCV `minEnclosingCircle`, který vytvoří nejmenší možný kruh obklopující všechny vstupní body, viz obrázek 3.5 a 3.6. V našem případě se jednalo o referenční ručně vyznačené body kontury optického disku. Dále byl podle článků [32], [13] zvětšen průměr o polovinu původního průměru viz obrázek 3.6. Díky rozdílu těchto dvou kruhů byl získán prstenec. Tento výřez by však z důvodů své velikosti neposkytoval uspokojující výsledky a proto z něj byly dále využity jen konkrétní výseče, které byly získány třetí maskou viz obrázek 3.7. Z takto vysegmentovaného cévního řečiště byly dále eliminovány menší cévy pomocí hodnoty percentilu, která byla zvolena na 90, viz obrázek 3.8.



Obr. 3.1: Segmentovaný cévní strom




Obr. 3.2: Ručně klasifikovaný cévní strom




Obr. 3.3: Skeleton cévního stromu




Obr. 3.4: Zprůměrovaná
distanční matice




Obr. 3.5: Maska 1



Obr. 3.6: Maska 2



Obr. 3.7: Maska 3

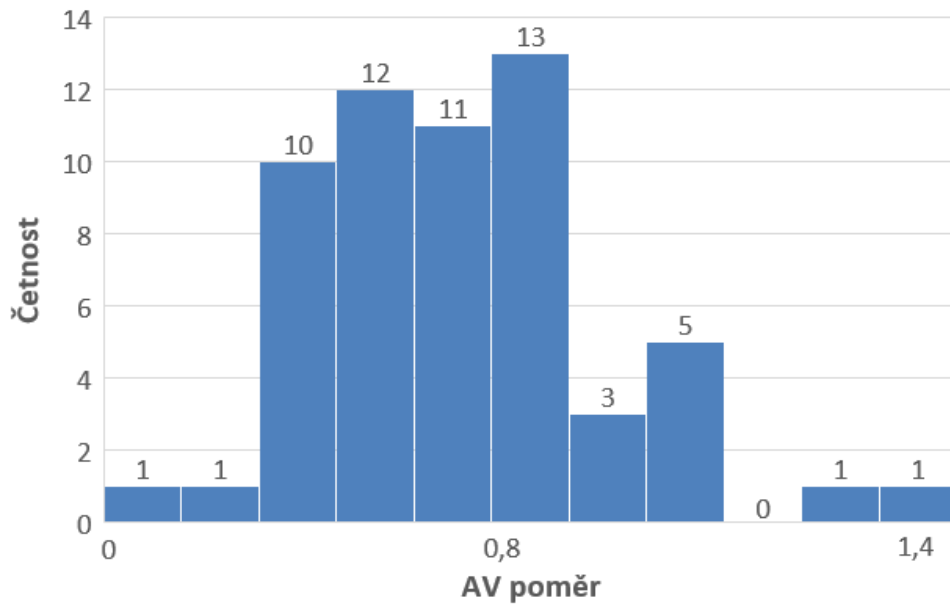


Obr. 3.8: Výsledný snímek

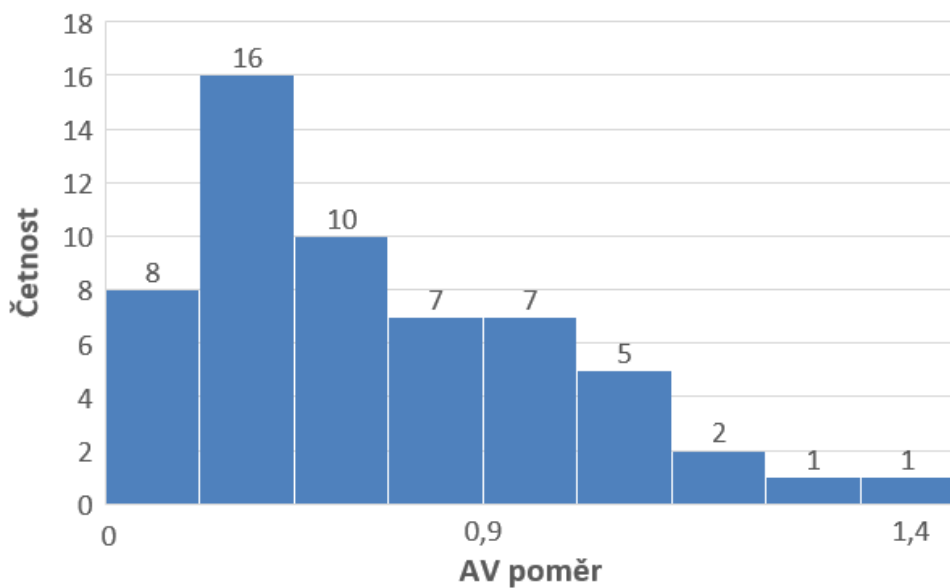
Pro výpočet AV poměru byl pomyslně snímek s vysegmentovanými řečištěm podélně rozdělen na horní a dolní segment. Pomocí algoritmu se hledala maxima šířky žil a maxima tepen zvláště v horním a dolním segmentu. Do výpočtu byl zahrnut průměr šířek žil a tepen v masce 50x50, přičemž jedna maska má střed v maximální hodnotě šířky žil a druhá maska má střed v maximální hodnotě šířky tepen. Vypočtené AV poměry pro horní segment jsou uvedeny na obrázku 3.9, kde je patrné, že se nejčastěji vyskytovala hodnota mezi 0,8 - 0,9. Průměrná hodnota AV poměru v horním segmentu je 0,81. Z obrázku 3.10 je zřejmé, že pro dolní segment se nejčastěji vyskytovala hodnota AV poměru v rozmezí 0,6 - 0,7, přičemž průměrná hodnota pro tento segment vycházela 0,78.

Jak již bylo uvedeno, při výpočtu AV poměru z dolního segmentu bylo dosaženo

lepšího výsledku, konkrétně 0,78, což je hodnota, která se více blíží té fyziologické, která je zhruba 2:3 tzn. 0,66, viz kapitola 1.2.1. Přesný výpočet AV poměru je zásadní pro diagnostiku kardiovaskulárních onemocnění, kdy léčba na základě včasné diagnózy může pacientovy obtíže zmírnit, nebo jim dokonce předejít. Odchytky výpočtu od fyziologické hodnoty mohou být způsobeny nepřesnou klasifikací cév do jednotlivých tříd či algoritmem pro výpočet šířek, který bere do úvahy pouze vymezené okolí.



Obr. 3.9: AV poměr horní segment




Obr. 3.10: AV poměr dolní segment

3.2 Návrh zvolené architektury hlubokého učení a způsobu vyhodnocení

Zvolená architektura byla inspirována sítí U-net[35] a upravena pro požadovanou problematiku. Implementovaná síť si zachovala svou charakteristickou stavbu, která se skládá z kontraktilní a expanzivní části, přičemž velikosti konvolučních vrstev, podvzorkovacích vrstev a nadvzorkovacích vrstev byly nezměněny. Dále byla ponechána i aktivační vrstva Relu, která následovala každou konvoluční vrstvu.

První a nezbytnou upravou byla změna rozměru vstupního obrazu. Další rozdíl oproti původní architektuře je ten, že po čtvrtém konvolučním bloku následuje Dropout vrstva s hodnotou 0.5, která náhodně deaktivuje polovinu příznaků. Další dropout vrstva je vložena za pátý konvoluční blok, opět s hodnotou 0.5. Tyto Dropout vrstvy snižují pravděpodobnost přeučení neuronové sítě. Oproti původní U-net síti je na konec přidána další konvoluční vrstva, která zajistí požadovaný rozměr výsledného snímku. Váhy jsou upravovány optimalizačním algoritmem ADAM, s krokem učení 0.0001. Dle zpracovávané problematiky je jako chybová funkce zvolena buď binární křížová entropie nebo váhovaná kategorická křížová entropie, které budou popsány blíže v následující kapitole.

Architektura modifikované U-net je znázorněna na obrázku 3.11, kde jsou šedě znázorněny konvoluční vrstvy, zeleně podvzorkovací vrstvy, modře vrstvy Dropout, červeně nadvzorkovací vrstvy a žlutě konvoluční vrstvy upravující výsledný rozměr.



Obr. 3.11: Modifikovaná architektura U-net

3.2.1 Chybové funkce

Chybová funkce je nejčastěji matematická funkce, vyjadřující aktuální chyby modelu, přičemž na základě její výsledné hodnoty jsou během trénování modifikovány vnitřní parametry. Trénovaná síť se snaží hodnotu této funkce minimalizovat resp. maximalizovat, například pomocí změn jednotlivých vah. Samotná chybová funkce je dále závislá na aktivační funkci poslední vrstvy trénované sítě. Hluboké neuronové sítě se během učení snaží nalézt řešení, které je nejvíce podobné tomu předkládanému, a proto je volba správné chybové funkce spolu s aktivační funkcí velmi důležitá. [24]

Binární křížová entropie

Binární křížová entropie se využívá při klasifikaci pixelu do jedné třídy. Jejím řešením je pravděpodobnost příslušnosti daného pixelu do dané třídy. [7] Binární křížovou entropii lze vypočítat pomocí rovnice

$$L(y, \hat{y}) = -\frac{1}{N} \sum_{i=0}^N (y * \log(\hat{y}_i) + (1 - y) * \log(1 - \hat{y}_i)), \quad (3.1)$$

kde y je ground truth hodnota, \hat{y} je predikovaná hodnota a N je počet testovaných dat.

Možnou modifikací binární křížové entropie je váhovaná binární křížová entropie. Tato úprava je vhodná při nevyváženém poměru pixelů mezi hledanou třídou a pozadím. Rozdíl oproti původnímu výpočtu je přidání váhy, jejíž hodnota může být zvolena například na základě procentuálního zastoupení hledané třídy v poměru k celému obrazu. Výsledná rovnice je

$$L(y, \hat{y}) = -\frac{1}{N} \sum_{i=0}^N w_i (y * \log(\hat{y}_i) + (1 - y) * \log(1 - \hat{y}_i)), \quad (3.2)$$

kde y je ground truth hodnota, \hat{y} je predikovaná hodnota, N je počet testovaných dat a w je váha.

Kategorická křížová entropie

Kategorická křížová entropie se využívá při klasifikaci do více nezávislých tříd. Výstupem je vektor o délce, která odpovídá počtu predikovaných tříd a jednotlivé pravděpodobnosti, které odpovídají s jakou přílušností daný pixel odpovídá dané třídě. [8] Kategorickou křížovou entropii lze vypočítat pomocí rovnice

$$L(y, \hat{y}) = -\sum_{j=0}^M \sum_{i=0}^N (y_{ij} * \log(\hat{y}_{ij})), \quad (3.3)$$

kde y je ground truth hodnota, \hat{y} je predikovaná hodnota, N je počet testovaných dat a M představuje počet tříd.

Stejně jako u binární křížové entropie lze kategorickou křížovou entropii modifikovat pomocí vah, avšak v tomto případě jsou váhy reprezentovány jako vektor o délce rovné počtu tříd. Hodnoty jednotlivých vah lze například získat na základě poměrů mezi jednotlivými třídami, čímž dostaneme rovnoměrného zastoupení tříd. Váhy lze určit ale i tak, aby určitá třída byla trénovanou sítí eliminována a jiná naopak brána s vyšší prioritou. Výsledná rovnice váhované kategorické křížové entropie je

$$L_w(y, \hat{y}) = - \sum_{j=0}^M \sum_{i=0}^N w_j(y_{ij} * \log(\hat{y}_{ij})), \quad (3.4)$$

kde y je ground truth hodnota, \hat{y} je predikovaná hodnota, N je počet testovaných dat, M představuje počet tříd a w jsou váhy.

3.2.2 Optimalizační algoritmus

Optimalizační algoritmy jsou metody, které se snaží minimalizovat resp. maximalizovat chybovou funkci pomocí změn vnitřních parametrů trénovaného modelu. Díky změnám vah nebo rychlosti učení je dosaženo přesnějších výsledků. Volba vhodné optimalizační metody je závislá na velikosti datasetu, různorodosti datasetu či výpočetní náročnosti.

ADAM

ADAM algoritmus neboli Adaptive Moment Estimation algoritmus je stochastická optimalizační metoda, která je založená na odhadu prvního a druhého momentu gradientu, které jsou korigovány pomocí hyperparametrů. Tento algoritmus lze vnímat jako kombinaci RMSprop metody a Stochastic Gradient Descent metody, a to z toho důvodu, že ve svém výpočtu bere do úvahy jak předchozí čtvercové gradienty, tak i klouzavé průměry gradientů. ADAM algoritmus postupně aktualizuje exponenciální klouzavé průměry gradientů, což umožňuje výpočet individuální rychlosti učení pro různé parametry. Velkou výhodou této metody je, že je snadno implementovatelná, výpočetně nenáročná a má nízké nároky na paměť. Následující rovnice popisují výpočet odhadu prvního momentu \hat{m}_t a druhého momentu \hat{v}_t :

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad (3.5)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}, \quad (3.6)$$

kde m_t je první moment, v_t je druhý moment a β_1^t, β_2^t jsou hyperparametry korigující korekci odhadu.

Výsledná úprava parametrů je vyjádřena pomocí:

$$\theta_t = \theta_{t-1} - \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \epsilon}}, \quad (3.7)$$

kde θ_t je výsledný parametr, který je vypočten z předchozí úpravy θ_{t-1} , ϵ číselné konstanty stability a odhadu prvního momentu \hat{m}_t a druhého momentu \hat{v}_t . [19]

3.2.3 Vyhodnocovací metriky

Matice záměn

Matice záměn slouží k vyhodnocení klasifikace do dvou a více tříd. Řádky této matice představují predikovanou třídu a sloupce obvykle představují požadovanou třídu. Hodnoty buněk umístěné na diagonále odpovídají správným výsledkům a hodnoty mimo diagonálu představují chyby, viz obrázek 3.12. [9] Matice záměn ukazuje:

- TP (true positive) - počet pixelů, které byly správně zaklasifikovány do třídy "+",
- TN (true negative) - počet pixelů, které byly správně zaklasifikovány do třídy "-",
- FP (false positive) - počet pixelů, které byly chybně zaklasifikovány do třídy "+",
- FN (false negative) - počet pixelů, které byly chybně zaklasifikovány do třídy "-".

		Požadovaná třída	
		+	-
Predikovaná třída	+	TP	FP
	-	FN	TN

Obr. 3.12: Matice záměn

ROC křivka


ROC graf je vyhodnocovací metrika, která se v dnešní době stala nedílnou součástí

vyhodnocení úspěšnosti testovaného klasifikátoru. Tato metoda nám udává vztah mezi specificitou a senzitivitou pro všechny přípustné hodnoty prahu našeho testu. Jak lze vidět na obrázku 3.13, tak na ose X jsou vyneseny hodnoty falešně pozitivních hodnot (FPR), které představují specificitu a na ose Y jsou vyneseny hodnoty správně pozitivních hodnot (TPR), které představují senzitivitu.[9] Falešně pozitivní hodnoty a správně pozitivní hodnoty se počítají pomocí vzorců:

$$TNR = \frac{TN}{TN + FP} \quad (3.8)$$

$$FPR = 1 - \frac{TN}{TN + FP} \quad (3.9)$$

Na obrázku 3.13 lze vidět výsledek testovaného klasifikátoru spolu s vyznačeným optimálním prahem. Optimální práh je charakteristický tím, že nalézá co nejlepší poměr mezi senzitivitou a specificitou. Dalším důležitým parametrem při analýze pomocí ROC křivky je oblast pod křivkou (Area under an ROC curve). Hodnota AUC se pohybuje mezi 0-1, přičemž ideální klasifikátor, který zcela odpovídá požadovanému výsledku má hodnotu 1. Na obrázku 3.13 lze dále vidět přerušovanou čáru, která značí AUC rovno hodnotě 0.5, což je hraniční hodnota, kdy je daný klasifikátor ještě brán jako dostačující. [9]



Obr. 3.13: ROC křivka


4 Implementace a vyhodnocení zvolené architektury hlubokého učení

V rámci diplomové práce bylo cévní řečiště klasifikováno do jednotlivých tříd, a z důvodů neuspokojivých výsledků dále také segmentováno jako celek či zvlášť na žíly a tepny. Pro všechny účely trénování byly použity snímky pořízené experimentálním video-oftlamoskopem popsáním v kapitole 1.3.

Datová sada se skládala z 51 snímků, které byly rozděleny na trénovací a testovací sadu, přičemž trénovací sada zahrnovala 43 snímků a testovací sada 8 snímků. Jednotlivé snímky měly původní velikost 1000 x 770 px, avšak v rámci předzpracování byly obrázky ořezány a zmenšeny na velikost 560 x 432 px, viz 4.2. Takto vzniklé snímky již neobsahovaly tolik artefaktů, jako například datum a čas snímání umístěné v levém horním rohu, viz původní obrázek 4.1. Jako ground truth data sloužila ručně klasifikovaná cévní řečiště popsaná v kapitole 3.1. Trénování modifikované sítě uvedené v kapitole 3.2 probíhalo v programovém prostředí jazyka Python.



Obr. 4.1: Původní snímek





Obr. 4.2: Ořezaný snímek

4.1 Klasifikace cévního řečiště

Jak již bylo zmíněno, trénovací datová sada se skládá z šedotónových snímků, které byly předzpracovány a zmenšeny na potřebnou velikost. Pro vytvoření ground truth snímků byly využity RGB ručně klasifikované cévní řečiště, viz kapitola 3.1. Tyto RGB snímky byly dále označeny tak, že pokud v původním snímku byla červená barva značící tepnu, tak se do nové matice uložila hodnota 1. Pokud byla v původním snímku modrá barva označující žílu, do nové matice se uložila hodnota 2. Místa, které nebyly jasně zařazené do žil nebo tepen a byly označeny růžovou barvou do úvahy brány nebyly. Takto označené snímky byly pomocí funkce *to_categorical* převedeny na binární reprezentaci, která se skládala z matice mající 3 dimenze. První matice

obsahovala hodnotu 1 všude tam, kde bylo pozadí a ostatní pozice měly hodnotu 0. Druhá matice měla hodnotu 1 všude tam, kde se nacházely tepny a třetí matice nabývala hodnoty 1 tam, kde byly žíly. Takto předzpracované snímky byly uloženy ve formátu numpy a použity jako ground truth data.

Trénování modifikované sítě U-net probíhalo na 40 epoch, optimalizační algoritmus byl použit ADAM s krokem učení 0,0001 a jako chybová funkce byla použita váhovaná kategorická křížová entropie. Hodnoty vah byly stanoveny na základě poměrů zastoupení jednotlivých tříd, přičemž jak se při trénování ukázalo, zvolení správných vah bylo velmi obtížné. Výsledky poukázaly, že i změna desetinného čísla může být zásadní. Nejlepších výsledků bylo dosaženo při hodnotě vah pro pozadí 0,7, 10 pro tepny a 22 pro žíly. Dobrých výsledků bylo dosaženo i při nastavení vah pro pozadí 0,6, 13 pro tepny a 22 pro žíly. Jak můžete vidět na obrázcích 4.3 a 4.4 v obou případech měla chybová funkce klesající tendenci, a to i po 40 epochách. Důvodem ukončení trénování bylo to, že chybová funkce sice stále klesala, avšak s ní začala klesat i úspěšnost. Při použití váhované křížové entropie začalo po určité době docházet k tomu, že síť začala dosazovat žíly i tam, kde být neměly z důvodů jejich vyšších vah.



Obr. 4.3: Chybová funkce při klasifikaci cévního řečiště - váhy 0,7, 10, 22 Obr. 4.4: Chybová funkce při klasifikaci cévního řečiště - váhy 0,6, 13, 22

Po natrénování sítě byl daný model otestován na testovací sadě pomocí funkce *predict* a jeho úspěšnost byla zjištěna díky funkce *evaluate*. Tato úspěšnost je však pouze orientační, jelikož klasifikovaný snímek zahrnuje velké zastoupení pixelů tvořící pozadí, a proto byly pro vyhodnocení využity jiné metriky a to konkrétně ROC křivka a matice záměn.

Výsledná matice záměn pro klasifikaci cévního řečiště s váhami 0,7 pro pozadí, 10 pro tepny a 22 pro žíly, viz obrázek 4.5, je patrné, že pozadí bylo zaklasifikováno na 83,8 %, tepny na 63,4 % a žíly na 71,8 %. V matici je dále naznačeno, že žíly byly až z 26,8 % klasifikovány jako tepny.

Váhy byly na základě toho upraveny tak, aby síť kladla větší důraz na tepny a menší na pozadí. Z další matice záměn pro klasifikaci cévního řečiště s váhami

0,6 pro pozadí, 13 pro tepny a 22 pro žíly, viz obrázek 4.6, je patrné, že pozadí bylo zaklasifikováno na 79,6 %, tepny na 71,2 % a žíly na 68,3 %. V matici je dále naznačeno, že pozadí bylo z 18 % predikováno na tepny a žíly byly dále z 30,5 % predikovány na tepny.

Díky změnám vah sice došlo k lepší predikci tepen, avšak na úkor horší klasifikace jak pozadí tak žil.

		Požadovaná hodnota		
		Pozadí	Tepny	Žíly
Predikovaná hodnota	Pozadí	0,838	0,124	0,014
	Tepny	0,125	0,634	0,268
	Žíly	0,037	0,241	0,718

Obr. 4.5: Výsledná matice záměn pro klasifikaci cévního řečiště - váhy 0,7, 10, 22

		Požadovaná hodnota		
		Pozadí	Tepny	Žíly
Predikovaná hodnota	Pozadí	0,796	0,118	0,012
	Tepny	0,178	0,712	0,305
	Žíly	0,027	0,170	0,683


Obr. 4.6: Výsledná matice záměn pro klasifikaci cévního řečiště - váhy 0,6, 13, 22

Výsledek klasifikace snímku 1 pro váhy 0,7 pro pozadí, 10 pro tepny a 22 pro žíly je zobrazen na obrázku 4.8, přičemž jemu odpovídající ground truth snímek je na obrázku 4.7. Výsledek druhé klasifikace je na obrázku 4.9. Již na první pohled je patrné, že na snímku 4.8 jsou žíly lépe zaklasifikovány, než na snímku 4.9. Dále je na obrázku 4.8 lépe rozeznáno pozadí. Snímek 4.9 se vyznačuje správnou detekcí tepen. Na obrázku 4.10 a 4.11 jsou vykresleny ROC křivky pro jednotlivé třídy, přičemž třída 0 značí pozadí, třída 1 označuje tepny a třída 2 označuje žíly. ROC křivky se vstahují k predikovaným snímkům 4.8 a 4.9.


Další příklad klasifikace pro váhy 0,7 pro pozadí, 10 pro tepny a 22 pro žíly je zobrazen na obrázku 4.13, přičemž jemu odpovídající ground truth snímek je na obrázku 4.12. Výsledek druhé klasifikace je na obrázku 4.14. Opět je ze snímků

patrné, že na obrázku 4.13 jsou žíly lépe zaklasifikovány a pozadí více rozpoznáno. Na obrázku 4.15 a 4.16 jsou vykresleny ROC křivky, které odpovídají predikovaným snímkům 4.13 a 4.14.


Důvodem špatných výsledků mohou být nekvalitní data, která jsou velmi zašuměná a rozmazaná. Dalším důvodem může být malý dataset. Z těchto důvodů byla klasifikace rozdělena na jednodušší podproblémy, konkrétně segmentaci, aby bylo otestováno, z jakých důvodů klasifikace do jednotlivých tříd nevychází.




Obr. 4.7: Ground truth snímek 1



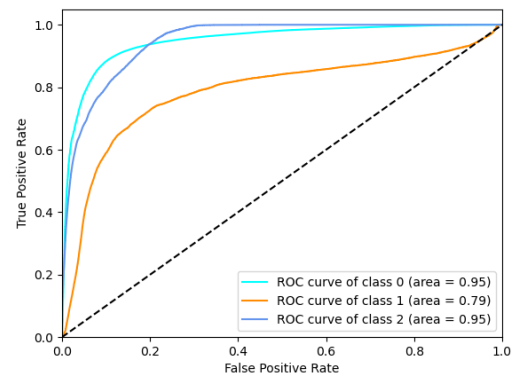
Obr. 4.8: Predikovaný snímek 1 - váhy 0,7, 10, 22




Obr. 4.9: Predikovaný snímek 1 - váhy 0,6, 13, 22




Obr. 4.10: ROC křivka pro snímek 1 - váhy 0,7, 10, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly




Obr. 4.11: ROC křivka pro snímek 1 - váhy 0,6, 13, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly




Obr. 4.12: Ground truth snímek 2




Obr. 4.13: Predikovaný snímek 2 - váhy 0,7, 10, 22



Obr. 4.14: Predikovaný snímek 2 - váhy 0,6, 13, 22



Obr. 4.15: ROC křivka pro snímek 2 - váhy 0,7, 10, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly


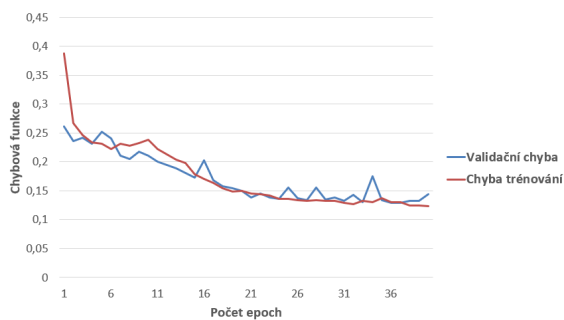


Obr. 4.16: ROC křivka pro snímek 2 - váhy 0,6, 13, 22. Třída 0 - pozadí, třída 1 - tepny, třída 2 - žíly

4.2 Segmentace žil a tepen z cévního řečiště

Z důvodu neuspokojivých výsledků při klasifikaci cévního řečiště do jednotlivých tříd byla modifikovaná U-net testována na segmentaci žil a tepen odděleně.

Stejně jako u klasifikace, se trénovací a testovací sada skládá z předzpracovaných šedotónových snímků. Pro vytvoření ground truth dat byly využity RGB ručně klasifikované cévní řečiště, přičemž cílem bylo vytvořit binární reprezentaci pro žíly a tepny odděleně. Místa, které nebyly jasně zařazené do žil nebo tepen a byly označeny růžovou barvou do úvahy brány nebyly. Trénování modifikované sítě U-net probíhalo na 40 epoch, optimalizační algoritmus byl použit ADAM s krokem učení 0,0001 a jako chybová funkce byla aplikována binární křížová entropie. Jak lze vidět na obrázcích 4.17 a 4.18, chybová funkce měla klesající tendenci jak při trénování tepen, tak při trénování žil.



Obr. 4.17: Chybová funkce při segmentaci tepen
 Obr. 4.18: Chybová funkce při segmentaci žil

Po natrénování sítě byl daný model otestován na testovací sadě pomocí funkce *predict* a jeho úspěšnost byla zjištěna díky funkce *evaluate*. Predikované snímky byly šedotónové, a proto je bylo nutné převést do binární reprezentace pomocí prahování OTSU metodou. Takto naprahované snímky byly dále vyhodnoceny maticí záměn. ROC křivka byla vytvořena z predikovaných šedotónových snímků.

Z výsledné matice záměn pro segmentaci tepen, viz obrázek 4.19, je patrné, že pozadí bylo zaklasifikováno na 97,1 % a tepny na 43,4 %. Na obrázku 4.21 lze vidět ground truth snímek tepny, na obrázku 4.22 ground truth snímek žíly a na obrázku 4.23 odpovídající predikovaný snímek tepen. Přestože byla modifikovaná U-net testována pouze na segmentaci tepen, ze snímku je patrné, že klasifikovala do tepen i pozadí spolu s náznakem žil. Tomu odpovídá i hodnota v matici záměn, která poukazuje na to, že až 56,6 % tepen bylo zaklasifikováno jako pozadí. Z výsledné matice záměn pro segmentaci žil, viz obrázek 4.20 vyplývá, že klasifikace žil měla o něco lepší výsledky, a to 98,8 % pro pozadí a 48,7 % pro žíly. Ground truth snímek tepny lze vidět na obrázku 4.24, ground truth snímek žíly 4.25 a predikovaný snímek žíly na obrázku 4.26. Stejně jako u segmentace tepen, docházelo ke klasifikaci žil jako pozadí a to až z 51 %. Na obrázcích 4.27 a 4.28 jsou vykresleny ROC křivky odpovídající predikovaným snímkům 4.23 a 4.26.

Výsledky oddělených segmentací potvrzují, že aktuální dataset není dostačující a modifikovaná U-net neposkytuje uspokojující výsledky ani při segmentaci. Při oddělené segmentaci mohlo špatné výsledky způsobit i to, že trénovaná síť neměla žádné spojitosti mezi žilou a tepnou a tudíž se snažila vysegmentovat více oblastí, než bylo požadováno. Tento problém byl hlavně u segmentace tepen, které jsou světlejší a charakteristické centrálním reflexem, avšak na některých snímcích tyto prvky nejsou patrné a tudíž byly finálně klasifikovány i jako žíly.


Z výše uvedených důvodů byla modifikovaná U-net dále testována na segmentaci celého cévního řečiště, kdy by se měly stírat rozdíly mezi žilou a tepnou a segmentace by měla být nejjednodušší.

		Požadovaná hodnota	
		Pozadí	Tepny
Predikovaná hodnota	Pozadí	0,971	0,566
	Tepny	0,029	0,434

Obr. 4.19: Výsledná matice záměn pro segmentaci tepen

		Požadovaná hodnota	
		Pozadí	Žíly
Predikovaná hodnota	Pozadí	0,988	0,513
	Žíly	0,012	0,487


Obr. 4.20: Výsledná matice záměn pro segmentaci žil




Obr. 4.21: Ground truth snímek tepny



Obr. 4.22: Ground truth snímek žíly




Obr. 4.23: Predikovaný snímek tepny





Obr. 4.24: Ground truth snímek tepny



Obr. 4.25: Ground truth snímek žíly



Obr. 4.26: Predikovaný snímek žíly




Obr. 4.27: ROC křivka pro snímek tepny Obr. 4.28: ROC křivka pro snímek žíly

4.3 Segmentace cévního řečiště


Z předchozích výsledků je patrné, že ani segmentace žil a tepen odděleně neposkytuje uspokojující výsledky. Předpoklad pro správnou segmentaci jsou celistvé informace, které by mělo poskytnout cévní řečiště jako takové.

Modifikovaná U-net byla testována na segmentaci celého cévního řečiště na stejných vstupních datech jako v předešlých případech, přičemž ground truth maska byla vytvořena binarizací RGB ručně klasifikovaných cév. První trénování sítě probíhalo na 40 epoch, jako optimalizační algoritmus byl použit ADAM s krokem učení 0,0001 a chybová funkce byla binární křížová entropie. Jak lze vidět na obrázku 4.29 chybová funkce měla klesající tendenci a nejnižší hodnoty dosáhla při poslední epoše.

Druhé trénování sítě bylo dále uskutečněno se stejnými parametry jako při prvním trénování, avšak s tím rozdílem, že jako chybová funkce byla aplikována váhovaná binární křížová entropie s hodnotou váhy 2. Hned na první pohled je ze snímku 4.30 zřejmé, že chybová funkce měla skákavý charakter a při 40 epoše nedosahovala svého minima. Jak již bylo zmíněno v kapitole 3.1 o předzpracování retinálních snímků, data pořízené experimentálním VO se vyznačují tím, že jsou poškozené různými druhy zkreslení, přičemž trend chybové funkce poukazuje na to, že trénovaný model je na jakékoliv změny v obraze velmi citlivý.



Obr. 4.29: Chybová funkce při segmentaci celého řečiště bez vah



Obr. 4.30: Chybová funkce při segmentaci celého řečiště s váhou 2

Po natrénování byly snímky opět naprahovány pomocí OTSU metody a vyhodnoceny pomocí maticí záměn a ROC křivky. Výsledná matice záměn pro první trénování bez vah značí, že 97,4 % pozadí a 53,2 % cév bylo zaklasifikováno správně, viz obrázek 4.31. Výsledky klasifikace druhého trénování s vahou jsou na obrázku 4.32. Z matice záměn je zřejmé, že došlo k velkému zhoršení klasifikace cév a to na 28,7 %. Porovnání nejlepších výsledků obou trénování je na snímcích 4.33 - 4.35. Na první pohled je patrné, že modifikovaná síť U-net v obou případech zaklasifikovala cévy jako pozadí, což potvrzují i hodnoty ve výsledných maticích záměn, které jsou pro první trénování bez vah 46,8 % a pro druhé trénování s vahou 71,3 %. Na obrázcích 4.36 a 4.37 jsou vykresleny ROC křivky odpovídající predikovaným snímkům 4.34 a 4.35. Neúspěšná segmentace obou trénování je zobrazena na snímcích 4.38 - 4.40. Na obrázcích 4.39 i 4.40 lze pozorovat špatnou klasifikaci cév na pozadí, přičemž horších výsledků bylo dosaženo při trénování s vahou 2.


Přestože by měla být segmentace celého cévního řečiště nejjednodušší problematika, výsledky tomu neodpovídají. Modifikovaná síť si neuměla najít potřebné spojitosti na to, aby oddělila cévy od pozadí. Velmi rušivým elementem se stal optický disk, který se objevuje na všech segmentovaných snímcích, viz obrázek 4.34, 4.35, 4.39 a 4.40. Spolu s výsledky z kapitol 4.1 a 4.2 lze říci, že velikost zpracovávaného datasetu není dostačující a jelikož kvalita šedotónových snímků z experimentálního VO je velmi nízká, modifikovaná síť U-net neposkytovala uspokojující výsledky ani v jedné z testovaných problematik.

		Požadovaná hodnota	
		Pozadí	Cévy
Predikovaná hodnota	Pozadí	0,974	0,468
	Cévy	0,026	0,532


Obr. 4.31: Výsledná matice záměn pro segmentaci cévního řečiště bez vah

		Požadovaná hodnota	
		Pozadí	Cévy
Predikovaná hodnota	Pozadí	0,986	0,713
	Cévy	0,014	0,287

Obr. 4.32: Výsledná matice záměn pro segmentaci cévního řečiště s vahou 2




Obr. 4.33: Ground truth snímek 1 - segmentace cévního řečiště




Obr. 4.34: Predikovaný snímek 1 - segmentace cévního řečiště bez vah



Obr. 4.35: Predikovaný snímek 1 - segmentace cévního řečiště s vahou 2




Obr. 4.36: ROC křivka pro cévní řečiště bez vah, snímek 1



Obr. 4.37: ROC křivka pro cévní řečiště s vahou 2, snímek 1




Obr. 4.38: Ground truth snímek 2 - segmentace cévního řečiště




Obr. 4.39: Predikovaný snímek 2 - segmentace cévního řečiště bez vah



Obr. 4.40: Predikovaný snímek 2 - segmentace cévního řečiště s vahou 2



Obr. 4.41: ROC křivka pro cévní řečiště bez vah, snímek 2



Obr. 4.42: ROC křivka pro cévní řečiště s vahou 2, snímek 2

Závěr

Tato diplomová práce se zabývá klasifikací arteriálního a žilního řečiště v obrazových datech sítnice. Jejím cílem bylo seznámit se s přístupy využívající hluboké učení a navrhnout vhodnou metodu pro danou problematiku. Na základě rešerše byla pro úlohu klasifikace cévního řečiště vybrána architektura sítě U-net, která byla testována na snímcích pořízených experimentálním video-oftalmoskopem.

V první části byla zmíněna anatomie zrakového orgánu s důrazem na sítnici a její cévní zásobení. Nedílnou součástí kapitoly bylo popsání vlastností cév, které byly dále využity při předzpracovávání snímků. Dále byly zmíněny zobrazovací a diagnostické metody se zaměřením na fundus kameru a experimentální VO, které byly využity na nasnímaní zpracovávaných snímků.

V kapitole 2 byly popsány publikované metody pro klasifikaci cévního řečiště se zaměřením na přístupy využívající hluboké učení. Na základě literární rešerše byla vybrána vhodná architektura hlubokého učení U-net, která byla dále modifikována, aby lépe vyhovovala řešené problematice.

Práce popisuje předzpracování segmentovaných snímků cévního řečiště, které probíhalo v programovém prostředí jazyka Python. Díky předzpracování byly získány klasifikované sady dat, které sloužily jako ground truth snímky pro trénování hlubokého učení. Dále byl vypočten arterio-venulární poměr v horním a dolním segmentu sítnic. Průměrná hodnota AV poměru v horním segmentu dosahovala 0,81 a v dolním segmentu 0,78. Z výsledků je patrné, že s hodnotou 0,78 se průměr v dolním segmentu více přibližoval fyziologické hodnotě.

Pomocí zvolené architektury U-net bylo cévní řečiště nejprve klasifikováno do jednotlivých tříd. Pro vyhodnocení výsledků byla využita matice záměn, kde úspěšnost klasifikace tepen byla 63,4 % a žil 71,8 % při váhované kategorické křížové entropii, kdy váha pro pozadí byla 0,7, pro tepny 10 a pro žíly 22. Úspěšnost klasifikace tepen 71,2 % a žil 68,3 % byla dosažena při nastavení vah pro pozadí na 0,6, pro tepny na 13 a pro žíly na 22. Z predikovaných snímků bylo patrné, že síť i přes váhovanou chybovou funkci nedosahuje uspokojivých výsledků. Z tohoto důvodu byl klasifikační problém rozdělen na jednodušší podproblémy a dále byly cévy segmentovány na žíly a tepny odděleně, přičemž klasifikace tepen dosahovala hodnoty 43,4 % a klasifikace žil měla úspěšnost 48,7 %. Z výsledků je zřejmé, že modifikovaná síť si neuměla najít rozdíly mezi žilou a tepnou a tudíž se snažila vysegmentovat více oblastí, než bylo požadováno. Z důvodů celistvosti informací bylo cévní řečiště segmentováno najednou, přičemž úspěšnost trénování bez vah dosahovala 53,2 % a při trénování sítě s váhovanou binární křížovou entropií byla úspěšnost 28,7 %. Z celkových výsledků lze říci, že velikost zpracovávaného datasetu nebyla dostačující a jelikož kvalita snímků z experimentálního VO je velmi nízká, architektura U-net

neposkytovala uspokojující výsledky.

Vzhledem k výsledkům by se případné rozšíření této problematiky mělo zaměřit na zvětšení zpracovávaného datasetu, které se ukázalo jako největší problém.

Literatura

- [1] Anatomie oka | Cukrovka. Cukrovka [online]. Copyright © Cukrovka.cz 2017 [cit. 31.12.2019]. Dostupné z: <https://www.cukrovka.cz/anatomie-oka>
- [2] ANITHA, J., et al. *Self Organizing neural network based pathology classification in retinal images*. In: 2009 World Congress on Nature Biologically Inspired Computing (NaBIC). IEEE, 2009. p. 1457-1462.
- [3] AUTRATA, Rudolf a Jana VANČUROVÁ. *Nauka o zraku*. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 2002. ISBN 80-7013-362-7.
- [4] BADAWI, Sufian A.; FRAZ, Muhammad Moazam. *Multiloss function based deep convolutional neural network for segmentation of retinal vasculature into arterioles and venules*. BioMed research international, 2019, 2019.
- [5] BADRINARAYANAN, Vijay; KENDALL, Alex; CIPOLLA, Roberto. *Segnet: A deep convolutional encoder-decoder architecture for image segmentation*. IEEE transactions on pattern analysis and machine intelligence, 2017, 39.12: 2481-2495.
- [6] BENEŠ, Pavel. *Přístroje pro optometrii a oftalmologii*. Brno: Národní centrum ošetřovatelství a nelékařských zdravotnických oborů, 2015. ISBN 978-80-7013-577-8. Dostupné také z: <http://www.digitalniknihovna.cz/mzk/uuid/uuid:e2f492b0-d18a-11e6-b5c0-005056827e51>
- [7] Binary crossentropy loss function | Peltarion Platform. Peltarion - the operational AI platform [online]. Copyright © 2020 Peltarion. [cit. 15.05.2020]. Dostupné z: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/binary-crossentropy>
- [8] Categorical crossentropy loss function | Peltarion Platform. Peltarion - the operational AI platform [online]. Copyright © 2020 Peltarion. [cit. 15.05.2020]. Dostupné z: <https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/categorical-crossentropy>
- [9] FAWCETT, Tom. *An introduction to ROC analysis*. Pattern recognition letters, 2006, 27.8: 861-874.
- [10] GIRARD, Fantin; CHERIET, Farida. *Artery/vein classification in fundus images using CNN and likelihood score propagation*. In: 2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP). IEEE, 2017. p. 720-724.

- [11] GIRARD, Fantin; KAVALEC, Conrad; CHERIET, Farida. *Joint segmentation and classification of retinal arteries/veins from fundus images*. Artificial intelligence in medicine, 2019, 94: 96-109.
- [12] GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep learning*. MIT press, 2016.
- [13] HEITMAR, Rebekka, et al. *Comparison of subjective and objective methods to determine the retinal arterio-venous ratio using fundus photography*. Journal of optometry, 2015, 8.4: 252-257.
- [14] HEMELINGS, Ruben, et al. *Artery-vein segmentation in fundus images using a fully convolutional network*. Computerized Medical Imaging and Graphics, 2019, 76: 101636.
- [15] HIJAZI, Samer; KUMAR, Rishi; ROWEN, Chris. *Using convolutional neural networks for image recognition*. Cadence Design Systems Inc.: San Jose, CA, USA, 2015.
- [16] HOLLEMANS, Matthijs. *Convolutional neural networks on the iPhone with VGGNet*. 2016. [Online]. [cit. 2020-05-15]. Dostupné z: <http://machinethink.net/blog/convolutional-neural-networks-on-the-iphone-with-vggnet/>
- [17] HYCL, Josef a Lucie TRYBUČKOVÁ. *Atlas oftalmologie*. 2. vyd. V Praze: Triton, 2008. ISBN 978-80-7387-160-4. Dostupné také z: <http://www.digitalniknihovna.cz/mzk/uuid/uuid:54411330-ab6e-11e3-9d7d-005056827e51>
- [18] Keras: the Python deep learning API. Keras: the Python deep learning API [online]. Dostupné z: <https://keras.io/>
- [19] KINGMA, Diederik P.; BA, Jimmy. *Adam: A method for stochastic optimization*. arXiv preprint arXiv:1412.6980, 2014.
- [20] KOLAR, Radim, Ralf. P. TORNOW, Jan ODSTRČILIK a Ivana LIBERDOVA. *Registration of retinal sequences from new video-ophthalmoscopic camera*. Biomedical Engineering OnLine [online]. 2016, 15(1), - [cit. 2019-12-28]. DOI: 10.1186/s12938-016-0191-0. ISSN 1475-925x. Dostupné z: <http://biomedical-engineering-online.biomedcentral.com/articles/10.1186/s12938-016-0191-0>

- [21] KONDERMANN, Claudia; KONDERMANN, Daniel; YAN, Michelle. *Blood vessel classification into arteries and veins in retinal images*. In: Medical Imaging 2007: Image Processing. International Society for Optics and Photonics, 2007. p. 651247.
- [22] KUČHYNKA, P. a kol. *Oční lékařství*. Praha: Grada Publishing a.s., 2007, 821 s. ISBN 9788024711638
- [23] LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. *Deep learning*. *nature*, 2015, 521.7553: 436-444.
- [24] Loss and Loss Functions for Training Deep Learning Neural Networks. Machine Learning Mastery [online]. Copyright © 2020 Machine Learning Mastery Pty. Ltd. All Rights Reserved. [cit. 15.05.2020]. Dostupné z: <https://machinelearningmastery.com/loss-and-loss-functions-for-training-deep-learning-neural-networks/>
- [25] MALATHI, K.; NEDUNCHELIAN, R. *A recursive support vector machine (RSVM) algorithm to detect and classify diabetic retinopathy in fundus retina images*. 2018.
- [26] MANSOUR, Romany F. *Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy*. Biomedical engineering letters, 2018, 8.1: 41-57.
- [27] MATEEN, Muhammad, et al. *Fundus Image Classification Using VGG-19 Architecture with PCA and SVD*. Symmetry, 2019, 11.1: 1.
- [28] MEYER, Maria Ines, et al. *Deep convolutional artery/vein classification of retinal vessels*. In: International Conference Image Analysis and Recognition. Springer, Cham, 2018. p. 622-630.
- [29] MYŠKA, V. *Rekurentní neuronové sítě pro klasifikaci textů*. 2017.
- [30] NAYAK, S. (2018). *Understanding AlexNet / Learn OpenCV*. Learn OpenCV. Dostupné z: <https://www.learnopencv.com/understanding-alexnet/>
- [31] NIELSEN, Michael A. *Neural networks and deep learning*. San Francisco, CA, USA.: Determination press, 2015.
- [32] NIEMEIJER, Meindert, et al. *Automated measurement of the arteriolar-to-venular width ratio in digital color fundus photographs*. IEEE Transactions on medical imaging, 2011, 30.11: 1941-1950.

- [33] NILSSON, Nils J. *Introduction to machine learning: An early draft of a proposed textbook*. 1996.
- [34] PIGOU, Lionel, et al. *Sign language recognition using convolutional neural networks*. In: European Conference on Computer Vision. Springer, Cham, 2014. p. 572-578.
- [35] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. *U-net: Convolutional networks for biomedical image segmentation*. In: International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015. p. 234-241.
- [36] ROZSÍVAL, P. *Oční lékařství*. 1. vyd. Praha: Galén, Karolinum, 2006. 373 s. ISBN 8072624040
- [37] SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. *Understanding machine learning: From theory to algorithms*. Cambridge university press, 2014.
- [38] SRIVASTAVA, Nitish, et al. *Dropout: a simple way to prevent neural networks from overfitting*. The journal of machine learning research, 2014, 15.1: 1929-1958.
- [39] STERGIOU, C. and Siganos, D. (2006) *Neural Networks*. Surveys and Presentations in Information Systems Engineering. SURPRISE 96 Journal.
- [40] TensorFlow. TensorFlow [online]. Dostupné z: <https://www.tensorflow.org/>
- [41] TORNOW, R. et al. „*Time resolved quantitative inter-eye comparison of cardiac cycle induced blood volume changes in the human retina*“, Biomedical Optical Express, 9(12), pp. 6237-6254, 2018.
- [42] VENTURA, Carles, et al. *Iterative deep learning for network topology extraction*. arXiv preprint arXiv:1712.01217, 2017.
- [43] VONDRÁK, Ivo. *Neuronové sítě. Fakulta elektrotechniky a informatiky VŠB. Učební text*. Ostrava, 2009.
- [44] WELIKALA, R. A., et al. *Automated arteriole and venule classification using deep learning for retinal images from the UK Biobank cohort*. Computers in biology and medicine, 2017, 90: 23-32.
- [45] ZÁLESKÁ, Kateřina. *Klasifikace obrazů pomocí umělých neuronových sítí*. 2011. PhD Thesis. Masarykova univerzita, Přírodovědecká fakulta.
- [46] ZHANG, Aston, et al. *Dive into Deep Learning. Unpublished draft*. 2019, 3: 319.

Seznam symbolů, veličin a zkratk

Adam	Adaptive Moment Estimation
AUC	Area under an ROC curve
AV	arterio-venulární
ROC	Receiver Operating Characteristic
VO	video-ofthalmoskop

A Přílohy

- /.....kořenový adresář
 - └ AV_pomer.....skripty pro výpočet AV poměru
 - └ vypocet_distancni_matice.py.....výpočet distanční matice
 - └ zprumerovani_distacni_matice.py.....zprůměrování distanční matice
 - └ orez_snimku.py.....ořez snímku
 - └ vypocet_AV_pomeru.py.....výpočet AV poměru
 - └ klasifikovane_reciste.....data ke zpracování
 - └ Study_02_00008_02_L_reg_AV.....data
 - └ Study_02_00008_02_L_reg_AV.png.....příklad snímku
 - └ Study_02_00008_02_L_registered_median.tif_OD_body_kontury_corrected kontura OD
 - └ klasifikace_cevniho_reciste.....skripty pro klasifikaci cévního řečiště
 - └ model_unet.py.....model architektury U-net
 - └ priprava_dat.py.....příprava dat
 - └ train_model.py.....trénování sítě
 - └ test_model.py.....testování sítě
 - └ vysledky_predikce.py.....uložení RGB predikci
 - └ matice_zamen_a_ROC_krivka.py.....vyhodnocení predikce klasifikace
 - └ vysledky_predikce.....uložení predikovaných snímků RGB
 - └ GT_RGB_test.....snímky pro snažší vyhodnocení
 - └ cevy_trenink.....ground truth snímky trénink neupravené
 - └ Study_02_00061_03_R_reg_AV.png.....příklad GT snímku
 - └ cevy_test.....ground truth snímky test neupravené
 - └ Study_02_00016_02_L_reg_AV.png.....příklad GT snímku
 - └ sedoton_trenink.....vstupní snímky trénink
 - └ Study_02_00061_03_R_registered_mean.tif..příklad vstupního snímku
 - └ sedoton_test.....vstupní snímky test
 - └ Study_02_00016_02_L_registered_mean.tif..příklad vstupního snímku
 - └ segmentace_zil_a_tepen.....skripty segmentaci žil a tepen
 - └ model_unet.py.....model architektury U-net
 - └ priprava_dat.py.....příprava dat
 - └ train_model.py.....trénování sítě
 - └ test_model.py.....testování sítě
 - └ otsu_prahovani.py.....prahování snímku
 - └ matice_zamen_a_ROC_krivka_zily.py.....vyhodnocení predikce žil
 - └ matice_zamen_a_ROC_krivka_tepny.py.....vyhodnocení predikce tepen
 - └ vysledky_predikce_zily.....uložení predikovaných snímků žil
 - └ vysledky_predikce_tepny.....uložení predikovaných snímků tepen
 - └ vysledky_predikce_zily_OTSU.....uložení snímků žil po naprahování otsu
 - └ vysledky_predikce_tepny_OTSU..uložení snímků tepen po naprahování otsu
 - └ GT_tepny_upravene_test.....ground truth snímky tepen test
 - └ GT_tepny_upravene_trenink.....ground truth snímky tepen trénink
 - └ GT_zily_upravene_test.....ground truth snímky žil test
 - └ GT_zily_upravene_trenink.....ground truth snímky žil trénink

└─ sedoton_trenink.....	vstupní snímky trénink
└─ Study_02_00061_03_R_registered_mean.tif ..	příklad vstupního snímku
└─ sedoton_test.....	vstupní snímky test
└─ Study_02_00016_02_L_registered_mean.tif ..	příklad vstupního snímku
└─ cevy_trenink.....	ground truth snímky trénink neupravené
└─ Study_02_00061_03_R_reg_AV.png.....	příklad neupraveného GT snímku
└─ cevy_test.....	ground truth snímky test neupravené
└─ Study_02_00016_02_L_reg_AV.png.....	příklad neupraveného GT snímku
└─ segmentace_cevniho_reciste.....	skripty segmentaci cévního řečiště
└─ model_unet.py.....	model architektury U-net
└─ priprava_dat.py.....	příprava dat
└─ train_unet.py.....	trénování sítě
└─ test_unet.py.....	testování sítě
└─ otsu_prahovani.py.....	prahování snímku
└─ matice_zamen_a_ROC_krivka.py.....	vyhodnocení predikce segmentace
└─ vysledky_predikce.....	uložení snímků po naprahování otsu
└─ GT_cevy_trenink.....	ground truth snímky trénink
└─ GT_cevy_test.....	ground truth snímky test
└─ cevy_trenink.....	ground truth snímky trénink neupravené
└─ Study_02_00061_03_R_reg_AV.png.....	příklad neupraveného GT snímku
└─ cevy_test.....	ground truth snímky test neupravené
└─ Study_02_00016_02_L_reg_AV.png.....	příklad neupraveného GT snímku
└─ sedoton_trenink.....	vstupní snímky trénink
└─ Study_02_00061_03_R_registered_mean.tif ..	příklad vstupního snímku
└─ sedoton_test.....	vstupní snímky test
└─ Study_02_00016_02_L_registered_mean.tif ..	příklad vstupního snímku