



Analýza signálu a obrazu v praxi II

KI/ASO

RNDr. Zbyšek Posel, Ph.D.



Ústí nad Labem 2020

Kurz: Analýza signálu a obrazu v praxi II

Obor: Aplikovaná informatika

Klíčová slova:

Anotace: Předmět navazuje a rozšiřuje znalosti úvodního předmětu *Analýza signálu a obrazu v praxi I* s důrazem na klasifikační algoritmy založené na metodách učení bez učitele (jako jsou K-means, DBSCAN a teselační algoritmy) a s učitelem, kde je pozornost zaměřena zejména na konvoluční neuronové sítě. Aplikace těchto metod je zaměřena do oblasti medicínských dat.

Jazyková korektura nebyla provedena, za jazykovou stránku odpovídá autor.

© Katedra informatiky, PřF, UJEP v Ústí nad Labem, 2020

Autor: RNDr. Zbyšek posel, Ph.D.

Obsah

Úvodní slovo	4
1 Úvod	6
2 Klasifikace událostí ve fyziologickém signálu	9
3 Rozpoznání a klasifikace objektů-I	12
4 Rozpoznání a klasifikace objektů-II	15
5 Rozpoznání a klasifikace objektů-III	18
6 Zpracování biologických dat	21

Úvodní slovo

Opora k předmětu *Analýza signálu a obrazu v praxi II* je tematicky rozdělena do dvou částí. V první části, která představuje menšinu, jsou probrány jednotlivé přístupy pro klasifikaci fyziologického signálu, které tak rozšiřují a doplňují znalosti o zpracování signálu získané v předmětu *Analýza signálu a obrazu v praxi I*. Jedná se zejména o klasifikaci signálu pomocí metod využívajících učení bez učitele (shluková analýza, PCA aj.) a učení s učitelem, kde je pozornost zaměřena jednak na rekurentní síť (zejména LSTM) a na konvoluční síť.

Ve zbývajících částech opory je pozornost upřena na klasifikaci obrazových (2D) dat. Nejprve jsou demonstrovány spíše klasické metody založené na triangulaci a teselaci, dále různé varianty shlukové analýzy včetně zohlednění hustoty objektů na ploše, až po složitější přístupy, které se realizují pomocí frameworků a zejména na specializovaném hardwaru (reziduální a konvoluční síť). Poslední část opory je zaměřena na využití nabytých znalostí při segmentaci buněk ze snímků pořízených různými mikroskopy (např. fluorescenční nebo optický). Všechny výše zmíněné kapitoly jsou doplněny o implementace v jazyku Python, které lze prostudovat po přihlášení do e-learningového systému MOODLE.

Příklad seminární práce

V průběhu kurzu bude zadána jedna seminární práce, na které budou moci studenti pracovat v rámci speciálně vyčleněných seminářů a využívat lokální výpočetní zdroje (lokální HPC klastr), alternativně také přístup na rozsáhlejší výpočetní infrastrukturu. V rámci plnění seminárních prací je možné vytvořit skupiny (nejvýše po 3 lidech), a odevzdat jednu práci za skupinu na konci semestru. Rozdělením do skupin jsou procvičovány dovednosti zaměřené na práci v týmu, sdílení znalostí, výstupů aj. Práce bude tematicky rozdělena do dvou částí, kdy v první části bude student využívat zejména vestavěné nástroje jazyka Python a částečně i frameworky pro klasifikaci fyziologických signálů. Druhá část práce je zaměřena tematicky zaměřena na segmentaci snímků buněk pořízených mikroskopy a intenzivní využití frameworků a jejich možnosti využít pro výpočet HPC infrastrukturu nebo například grafický akcelerátor.

Jednotlivá zadání se budou odvíjet buď od probíhající spolupráce s externími subjekty, typicky jde o Krajskou zdravotní, a.s. nebo bude zadání motivováno aktuálními trendy v oblasti zpracování medicínských dat. Jako příklad lze uvést části zadání různých hackatonů nebo tzv. „challenges“.

1 Úvod



CÍLE KAPITOLY

Cílem této úvodní kapitoly je poskytnout přehled klasifikačních metod, které se využívají při zpracování signálu a obrazu. Metody jsou rozděleny na základě principu učení na ty bez učitele (shluková analýza, (H)DBSCAN, teselační algoritmy) a s učitelem (zejména rekurentní a konvoluční neuronové sítě). V návaznosti na tyto algoritmy budou představeny i současné výzvy v oblasti klasifikace dat a s tím spojené veřejně dostupné databáze signálů a obrazových dat.

V této kapitole se dozvíte

- jaké jsou současné trendy ve využití klasifikačních metod pro zpracování signálu a obrazu,
- jaké jsou nejvíce používané metody a zda existují jejich implementace v jazyku Python,
- jaké jsou současné výzvy v oblasti zpracování signálu a obrazu,
- kde lze získat veřejně dostupná data pro testování navržených algoritmů.



KLÍČOVÁ SLOVA

klasifikace dat, učení s učitelem, učení bez učitele, dataset

Náplň látky je popsána v následujících zdrojích

- Přehled klasifikačních metod pro analýzu signálu lze nalézt například zde [1] nebo zde [2].
- Přehled klasifikačních metod pro analýzu obrazu lze nalézt například zde [3], zde [4] nebo zde [5].

Implementace jednoduchých klasifikačních algoritmů na vybrané signály a obrazová data lze dále nalézt v systému MOODLE.



SHRNUTÍ

Po prostudování byste měli mít následující dovednosti a znalosti.

- Mít přehled o klasifikačních metodách pro zpracování signálu.

- Mít přehled o klasifikačních metodách pro zpracování obrazu.
- Mít přehled o současných výzvách v oblasti zpracování signálu a obrazu.
- Umět získat datasety z veřejně dostupných databází a načíst je do prostředí Pythonu.
- Aplikovat jednoduché klasifikační metody (typicky shluková analýza) na získaná data.

OTÁZKY

1. Proč se klasifikační metody využívají při zpracování signálu?
2. Proč se klasifikační metody využívají při zpracování obrazu?
3. Jaké znáte veřejně dostupné databáze signálů a obrazových dat?
4. Jaké znáte balíky jazyka Pythonu, které obsahují výše zmíněné metody?

OTÁZKY K ZAMYŠLENÍ

1. Jak se využívají masivně paralelní systémy při zpracování signálu a obrazu?

ÚKOLY

1. Z veřejně dostupné databáze stáhněte datasety obsahující signál nebo obrazová data do prostředí Pythonu.
2. Na datasety aplikujte jednoduché klasifikační algoritmy využívající učení bez učitele.
3. Ukažte vliv jednotlivých parametrů algoritmů na výsledek.
4. V případě většího objemu dat zohledněte možnost paralelizace Vaší úlohy.

2 Klasifikace událostí ve fyziologickém signálu



CÍLE KAPITOLY

Cílem této kapitoly je rozšířit znalosti z předmětu *Analýza signálu a obrazu v praxi I* týkající se zpracování fyziologického signálu a to o klasifikační metody bez učitele a s učitelem. V případě první skupiny budou nejdříve představeny přístupy založené na shlukové analýze (K-Means, c-Means, harmonická varianta metody), PCA metodě nebo na metodě zohledňující tzv. matici rozdílnosti. V případě metod s učitelem je pozornost zaměřena zejména na konvoluční a rekurentní neuronové sítě (zejména Long short-term memory sítě).

V této kapitole se dozvíte:

- jaké klasifikační metody (s učitelem i bez učitele) se využívají pro zpracování fyziologického signálu,
- jaké jsou principy klasifikačních metod bez učitele,
- jaké jsou principy klasifikačních metod s učitelem,
- jak jsou výše zmíněné metody implementovány v jazyku Python,
- jak se výše uvedené metody aplikují na reálné fyziologické signály.



KLÍČOVÁ SLOVA

shluková analýza, klastr, PCA, RNN, CNN, LSTM

Náplň látky je popsána v následujících zdrojích

- Přehled klasifikačních metod bez učitele využívajících i shlukovou analýzu lze nalézt například zde [6].
- Přehled klasifikačních metod využívajících zpětnou vazbu od učitele lze nalézt například zde [7].
- Principy rekurentních a konvolučních neuronových sítí lze nalézt například zde [8] a zde [9].
- Implementace neuronových sítí pomocí frameworku Keras lze nalézt například zde [10] nebo pomocí frameworku TensorFlow zde [11].

- Příklady aplikaci klasifikačních metod na fyziologické signály lze nalézt zde [2] nebo zde [12].

Implementace klasifikačních metod bez učitele a využívající zpětnou vazbu od učitele na zpracování fyziologických signálů můžete dále nalézt v systému MOODLE.



SHRNUTÍ

Po prostudování byste měli mít následující dovednosti a znalosti:

- Umět popsat rozdíl mezi klasifikačními metodami bez učitele a s učitelem.
- Umět popsat princip klasifikačních metod bez učitele a jejich využití pro zpracování fyziologických signálů.
- Umět popsat princip klasifikačních metod s učitelem a jejich využití pro zpracování fyziologických signálů.
- Mít povědomí o implementaci těchto metod v některém z frameworků pro datovou analýzu založeném na jazyku Python (Keras, TensorFlow).



OTÁZKY

1. Na jaké typy úloh se využívají algoritmy bez učitele a s učitelem?
2. Jaký je rozdíl mezi rekurentní a konvoluční sítí?
3. Jaké fyziologické signály se klasifikačními algoritmy nejvíce zpracovávají a které události se nejvíce detekují?
4. Jak časově náročné je klasifikovat 30 minutový záznam EKG?



OTÁZKY K ZAMYŠLENÍ

1. Co je tensor processor unit (TPU) a jak je možné tuto jednotku využít pro zpracování signálů?
2. Jaké jsou databáze signálů, které lze využít pro ověření Vašeho algoritmu?



ÚKOLY

1. Z veřejně dostupné databáze získajte fyziologický signál a postupně aplikujte klasifikační metody bez učitele.
2. Pomocí jednoho z frameworků (Theano, TensorFlow nebo Keras) proveďte klasifikaci signálu pomocí rekurentní nebo konvoluční neuronové sítě.
3. Algoritmy porovnejte a diskutujte.

3 Rozpoznání a klasifikace objektů-I



CÍLE KAPITOLY

Cílem této kapitoly je podat přehled metod pro rozpoznání a klasifikaci obrazových dat a to pomocí technik založených na 2D teselaci. Jde zejména o představení různých technik teselace, interpretace Voroného diagramu a klasifikace obrazových dat na základě vlastností Voroného buněk.

V této kapitole se dozvíte:

- jaký je princip teselace a triangulace,
- jaké informace nám mohou tyto přístupy poskytnout pro klasifikaci systému,
- jak jsou tyto techniky implementovány v jazyku Python,
- jaké charakteristiky lze z výsledného dláždění získat.



KLÍČOVÁ SLOVA

Delaunayho triangulace, Voroného teselace, dláždění, hrana, Thiessenovy polygony, konvexní obálka

Náplň látky je popsána v následujících zdrojích

- Přehled teselačních technik lze nalézt například zde [13].
- Implementace Delaunayovy triangulace a Voroného teselace v jazyku Python lze nalézt například zde [14].
- Aplikace Delaunayovy triangulace a Voroného teselace lze nalézt na příklad zde [15].



SHRNUTÍ

Po prostudování byste měli mít následující dovednosti a znalosti:

- Umět popsat princip triangulace a teselace a definovat polygon.
- Mít povědomí o konstrukci polygonů a o jejich vlastnostech.
- Umět provést triangulaci a teselaci pomocí knihovny SciPy jazyka Python.
- Umět klasifikovat stav vybraných systémů pomocí vlastností jednotlivých polygonů.

OTÁZKY

1. Jaký je rozdíl mezi traingulací a teselací?
2. Jaké vlastnosti nejčastěji sledujeme u zkonstruovaných polygonů?
3. Jaké jsou nejčastější aplikace triangulace a teselace?

OTÁZKY K ZAMYŠLENÍ

1. V jakých případech by klasifikace systému pomocí traingulace nebo teselace nebyla úspěšná?

ÚKOLY

1. Nagenertejete soustavu bodů na plochu, které vykazují jednak pravidelné vzory nebo jsou zcela náhodné.
2. Proveďte traingulaci a teselaci a porovnejte výsledky a získané informace.
3. Vizualizujte vlastnosti polygonů.

4 Rozpoznání a klasifikace objektů-II



CÍLE KAPITOLY

Cílem této kapitoly je rozšířit detekci a klasifikaci objektů z předchozí části o metody využívající učení bez učitele, zejména o metody shlukové analýzy, nejbližší sousedy a metody založené na hustotě bodů ((H)DBSCAN aj.). Dále budou v této kapitole představeny metody klasifikující objekty pomocí residuálních a konvolučních neuronových sítí.

V této kapitole se dozvíte:

- jaké jsou metody klasifikace jednoduchých objektů pomocí shlukové analýzy, nejbližších sousedů a metod založených na hustotě objektů,
- jaké typy neuronových sítí se pro tento typ úlohy používá,
- jak jsou výše zmíněné metody implementovány v jazyku Python,
- jaké výstupy výše zmíněných metod lze pro klasifikaci objektů použít.



KLÍČOVÁ SLOVA

Shluková analýza, nejbližší sousedé, DBSCAN, HDBSCAN, residuální síť, konvoluční síť

Náplň látky je popsána v následujících zdrojích

- Princip metody shlukové analýzy je popsán například zde [16].
- Princip metody shlukové analýzy založené na hustotě objektů je popsán například zde [17].
- Implementace vybraných metod shlukové analýzy v jazyku Python lze nalézt například zde [18].
- Princip konvolučních a residuálních neuronových sítí lze nalézt zde [9] a zde [19].
- Implementace konvolučních a residuálních sítí v jazyku Python pomocí frameworku Keras lze nalézt zde [10].

Implementace vybraných metod shlukové analýzy a konvolučních nebo residuálních neuronových sítí lze dále nalézt v systému MOODLE.



SHRNUTÍ

Po prostudování byste měli mít následující dovednosti a znalosti:

- Mít přehled o metodách klasifikace pomocí shlukové analýzy, metody nejbližších sousedů nebo pomocí shlukové analýzy zohledňující hustotu objektů.
- Mít povědomí o principu fungování konvolučních a residuálních sítí.
- Mít přehled o implementacích výše zmíněných metod v prostředí jazyka Python.
- Umět implementovat výše zmíněné sítě pomocí některého z dostupných frameworků.

OTÁZKY

1. Vyjmenujte některé aplikace, kdy je při shlukování nutné zohlednit hustotu objektů?
2. Dokážete popsat jak spolu souvisí výstupy z klasifikační metody založené na nejbližších sousedech a například Voroného diagram?
3. Jaké typy objektů je výhodnější detekovat pomocí shlukové analýzy a jaké pomocí neuronových sítí?

OTÁZKY K ZAMYŠLENÍ

1. Jak bude detekci objektů ovlivňovat kvalita snímku?
2. Jaké metody znáte pro vylepšení kvality snímku před samotnou detekcí a klasifikací?

ÚKOLY

1. Libovolný snímek s objekty (náhodně nagenované nebo např. snímky buněk) upravte pomocí prahování a binarizace do formy snímku černá a bílá.
2. Pomocí shlukové analýzy detekujte jednotlivé objekty. Diskutujte úspěšnost detekce v závislosti na velikosti a četnosti objektů na snímku.
3. Pomocí konvoluční sítě proveďte detekci objektů na stejných snímcích a výsledky porovnejte.

5 Rozpoznání a klasifikace objektů-III



CÍLE KAPITOLY

Cílem této kapitoly je poskytnout přehled frameworků pro detekci a klasifikaci objektů a jejich napojení na využití výpočetních prostředků větších datových center. Přehled frameworků bude zúžen na ty nejvíce používané a typicky jde o frameworky Caffé, TensorFlow nebo Theano, které poskytují možnost škálovat výpočet v závislosti na množství dostupných výpočetních prostředků.

V této kapitole se dozvíte:

- jak se tvoří model pomocí frameworku,
- jaké metody nebo sítě jsou v různých frameworkcích již uloženy nebo předtrénovány, případně, jak lze natrénovanou síť uložit,
- jak lze alokovat výpočetní prostředky a provést přepracování dat,
- jak se jednotlivé úlohy škálují v závislosti na množství dostupných prostředků,
- jak takovýto výpočet kontrolovat na HPC klastru.



KLÍČOVÁ SLOVA

framework, Theano, Caffé, TensorFlow, Amazon AWS, HPC, NVIDIA, TensorRT

Náplň látky této kapitoly je popsána v následujících zdrojích.

- Popis jednotlivých frameworků a alokace výpočetních zdrojů lze nalézt například zde [10], zde [11] nebo zde [20].
- Popis implementace Caffé do platformy NVIDIA lze nalézt zde [21].
- Alokace výpočetních zdrojů v rámci sdružení Metacentrum lze nalézt zde [22]. Návod na získání přístupu a výpočetního času na lokálním klastru lze získat až na hodině.
- Návod, jak získat čas na jiných světových výpočetních centrech lze nalézt například zde [23].

Příklady spouštěcích skriptů nutných pro provedení úlohy na lokálním klastru a příklady využití frameworků pro klasifikaci objektů v datech většího objemu lze dále nalézt v systému MOODLE.

SHRNU TÍ

Po prostudování byste měli mít následující dovednosti a znalosti:

- Umět připravit vybraný framework pro využití různých výpočetních prostředků, včetně grafických akcelérátorů.
- Umět pracovat s většími modely v rámci HPC infrastruktury nebo v rámci cloudového řešení.

OTÁZKY

1. Co je nutné udělat, aby bylo možné využít grafický akcelérátor pro řešení Vaší úlohy?
2. Jaký je rozdíl mezi frameworky využívajícími cloudové řešení a čistě lokální HPC řešení?
3. Jak probíhá přiřazení prostředků na HPC klastru a jaké zásady je nutné dodržovat?

OTÁZKY K ZAMYŠLENÍ

1. Jaké úlohy se hodí pro řešení na HPC nebo cloudové infrastruktuře a které naopak ne?

ÚKOLY

1. Vámi vybraný framework připravte pro využití grafického akcelérátoru a optimalizujte práci s daty.
2. Vyberte si úlohu s variabilním množstvím dat (např. počet snímků).
3. Úlohu zařaďte do frontového systému na HPC klastru a proveďte výpočet.
4. Proveďte škálování Vaší úlohy v závislosti na množství přidělených prostředků a na množství dat, která zpracováváte.

6 Zpracování biologických dat



CÍLE KAPITOLY

Cílem této kapitoly je poskytnout přehled metod pro klasifikaci biologických dat, například snímků buněk v různých spektrech včetně viditelného, a to včetně nutného předzpracování dat. Metody této části budou zaměřeny nejprve na samotnou segmentaci dat a poté na jejich klasifikaci.

V této kapitole se dozvíte:

- jak lze počítačově zpracovávat snímky buněk v různých spektrech, včetně viditelného,
- jak probíhá následná klasifikace buněk a získávání dalších informací ze snímků.



KLÍČOVÁ SLOVA

segmentace buněk, watershed algoritmus, konvoluční síť, tvarové faktory, Mahotas

Náplň látky je popsána v následujících zdrojích

- Princip segmentace buněk pomocí Watershed algoritmu lze nalézt například zde [24] nebo zde [25].
- Porovnání metod pro klasifikaci krevních buněk lze nalézt například zde [5] nebo zde [26].
- Popis využití konvolučních sítí pro klasifikaci shluků buněk lze nalézt například zde [27].
- Zdroj snímků buněk lze nalézt například zde [28].
- Popis frameworku CLARA od firmy NVIDIA pro segmentaci buněk lze nalézt například zde [29].
- Implementace nástrojů pro segmentaci buněk v jazyku Python lze nalézt například zde [30] nebo zde [4].
- Popis frameworku CLARA od firmy NVIDIA pro segmentaci buněk lze nalézt například zde [29].

Příklady segmentace buněk z fluorescenčního nebo optického mikroskopu lze dále nalézt v systému MOODLE.



SHRNUTÍ

Po prostudování byste měli mít následující dovednosti a znalosti:

- Mít přehled o metodách segmentace a klasifikace biologických dat, zejména buněk.
- Znat zdroje dat (snímků) pro testování metod segmentace.
- Využít pro segmentaci jeden z možných frameworků, které byly probírány.



OTÁZKY

1. Jaké artefakty se vyskytují ve snímcích buněk v závislosti na spektru, a jak se odstraňují?
2. Jaké metody segmentace se využívají a na čem jsou založené?
3. Jaké jsou dostupné zdroje snímků, které lze například pro testování nebo učení algoritmů využít?



OTÁZKY K ZAMYŠLENÍ

1. Jaké artefakty lze jen stěží odstranit a jak by neměly vypadat snímky určené pro segmentaci?



ÚKOLY

1. Z veřejně dostupného repozitáře stáhněte snímky buněk v různých spektrech (například fluorescenční data nebo data z optického mikroskopu).
2. Postupně aplikujte vybrané metody segmentace tak, jak jsou popsány v uvedených zdrojích a porovnejte jejich spolehlivost a náročnost implementace.

Literatura

- [1] RANGAYYAN, Rangaraj M. *Biomedical signal analysis*. IEEE Press, 2015. ISBN 978-0-470-0-91139-6.
- [2] ed. CERUTTI, Sergio; MARCHESI, Carlo. *Advanced Methods of Biomedical Signal Processing*. IEEE Press, 2011. ISBN 978-0-470-42214-4.
- [3] scikitimage-image processing in python [online]. The scikit-image development team: ©2020 [cit. 19.03.2020], Dostupné z: <https://scikit-image.org/>.
- [4] OpenCV [online], OpenCV team: ©2020 [cit. 19.03.2020], Dostupné z: <https://opencv.org/>
- [5] HEDGE, Roopa B. et al. Comparison of traditional image processing and deep learning approaches for classification of whiteblood cells in peripheral blood smear images. *Bio-cybernetics and Biomedical Engineering*. 2019, **39**(2), 382-392. ISSN 0208-5216.
- [6] ed. CELEBI, Emre M.; Aydin, Kemal. *Unsupervised Learning Algorithms*. Springer, 2016. ISBN 978-3-319-24209-5.
- [7] LITTLE, Max A. *Machine Learning for Signal Processing; Data Science, Algorithms and Computational Statistics*. Oxford University Press, 2019. ISBN 978-0-19-871493-4.
- [8] ed. ROGERSON, Jeremy. *Theory, Concepts and Methods of Recurrent Neural Networks and Soft Computing*. ML Books International, 2019. ISBN 978-1632404930.
- [9] Zemouri, Ryad et al. Deep Learning in the Biomedical Applications: Recent and Future Status. *Applied Sciences*. 2019, **9**(8), 1526-1566. ISSN 2076-3417.
- [10] Keras: Simple Flexible. Powerfull [online]. Keras developers. ©2020 [cit. 19.03.2020], Dostupné z: <https://keras.io/>
- [11] TensorFlow: An end-to-end open source machine learning platform [online]. TensorFlow developers. ©2020 [cit. 19.03.2020], Dostupné z: <https://www.tensorflow.org/>
- [12] GACEK, Adam; PEDRYCZ, Witold. *ECG Signal Processing, Classification and Interpretation*. Springer, 2012. ISBN 978-0-85729-867-6.
- [13] OKABE, Atsuyuki; BOOTS, Barry; SUGIHARA, Kokichi; CHIU, Sung Nok. *Spatial tessellations: Concepts and Applications of Voronoi Diagrams*. John Wiley and Sons, 2000. ISBN 0-471-98635-6.
- [14] SciPy [online]. SciPy developers: ©2020 [cit. 19.03.2020], Dostupné z: <https://www.scipy.org/>
- [15] AURENHAMMER, Franz; KLEIN, Rolf; LEE, Der-Tsai. *Voronoi Diagrams and Delaunay Triangulations*. World Scientific, 2013. ISBN 978-9814447638.

- [16] MELOUN, Milan; MILITKÝ, Jiří. *Kompndium statistického zpracování dat*. Academia, 2006. ISBN 80-200-1396-2.
- [17] ESTER, Martin et al. A density-based algorithm for discovering clusters in large spatial databases with noise. *KDD'96: Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*. 1996, 226-231.
- [18] scikit learn [online]. The scikit learn development team: ©2020 [cit. 19.03.2020], Dostupné z: <https://scikit-learn.org/stable/modules/clustering.html>.
- [19] HE, Kaiming et al. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016, DOI: 10.1109/CVPR.2016.90.
- [20] Caffe [online]. The Caffe development team: ©2020 [cit. 19.03.2020], Dostupné z: <https://caffe.berkeleyvision.org/>.
- [21] Caffe2 Deep Learning Framework [online]. NVIDIA Corporation ©2020 [cit. 19.03.2020], Dostupné z: <https://developer.nvidia.com/caffe2>.
- [22] MetaCentrum VO - virtuální organizace pro celou akademickou obec [online]. CESNET ©2020 [cit. 19.03.2020], Dostupné z: <https://metavo.metacentrum.cz/>.
- [23] Amazon AWS [online]. Amazon Web Service ©2020 [cit. 19.03.2020], Dostupné z: <https://aws.amazon.com/>.
- [24] KORNILOV, Anton S. et al. An Overview of Watershed Algorithm Implementations in Open Source Libraries. *Journal of Imaging*. 2018, **4**(10), 123-138. ISSN 2313-433X.
- [25] BARNES, Richard et al. Priority-Flood: An Optimal Depression-Filling and Watershed-Labeling Algorithm for Digital Elevation Models. *Computers & Geosciences*. 2014, **62**, 117-127. ISSN 0098-3004.
- [26] VICAR et al. Cell segmentation methods for label-free contrast microscopy: review and comprehensive comparison. *BMC Bioinformatics*. 2019, **20** (360), 1-25, ISSN 1471-2105.
- [27] OEI, Ronald W. et al. Convolutional neural network for cell classification using microscope images of intracellular actin networks. *PLOS ONE*. 2019, **14** (3), 1-13, ISSN 1932-6203.
- [28] THE HUMAM PROTEIN ATLAS [online]. THE HUMAM PROTEIN ATLAS ©2020 [cit. 19.03.2020], Dostupné z: <https://www.proteinatlas.org/>.
- [29] NVIDIA Clara Imaging [online]. NVIDIA Corporation ©2020 [cit. 19.03.2020], Dostupné z: <https://developer.nvidia.com/clara-medical-imaging>.
- [30] Mahotas: Computer Vision in Python [online], Luis Pedro Coelho: ©2008-2016 [cit. 19.03.2020], Dostupné z: <https://mahotas.readthedocs.io/en/latest/>