

Design a implementace vybraných evolučních strategií pro optimalizaci regionálních segmentačních modelů s cílem identifikace objektů z medicínských obrazů

Design and Implementation of Selected Evolution Strategies for Optimization of Regional Segmentation Models with the Aim of Objects Identification from Medical Images

Bc. Petr Bílek

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D.

Ostrava, 2022

Zadání diplomové práce

Student:

Bc. Petr Bílek

Studijní program:

N0988A060001 Biomedicínské inženýrství

Téma:

Design a implementace vybraných evolučních strategií pro optimalizaci regionálních segmentačních modelů s cílem identifikace objektů z medicínských obrazů
Design and Implementation of Selected Evolution Strategies for Optimization of Regional Segmentation Models with the Aim of Objects Identification from Medical Images

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Nastudování základních principů segmentace biomedicínských obrazových dat.
2. Nastudování evolučních strategií pro segmentaci medicínských obrazů.
3. Rešerše aplikací segmentace medicínských obrazů, optimalizované evolučními strategiemi.
4. Tvorba datové báze medicínských obrazů pro testování segmentačních procedur.
5. Implementace vybraných konvenčních a evolučních segmentačních metod pro segmentaci obrazu.
6. Testování metod na medicínských obrazech s cílem extrakce a modelování vybraných objektů zájmu.
7. Analýza efektivity a robustnosti segmentačních metod v kontextu variabilního deterministického šumu s dynamickou intenzitou.
8. Komparativní analýza a modelování efektivity segmentace testovaných metod v závislosti na parametrech segmentačních strategií.
9. Vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

- [1] AGGARWAL, Charu C., ed. Data classification: algorithms and applications. Boca Raton: CRC Press, Taylor & Francis Group, [2015]. Chapman & Hall/CRC data mining and knowledge discovery series. ISBN 978-1-4665-8674-1.
- [2] SEUL, Michael, Lawrence O'GORMAN a Michael J. SAMMON. Practical algorithms for image analysis: description, examples, and code. Cambridge: Cambridge University Press, 2000. ISBN 0-521-66065-3.
- [3] SIVANANDAM, S. N. a S. N. DEEPA. Introduction to genetic algorithms. Berlin: Springer, c2010. ISBN 978-3-642-09224-4.
- [4] WINTER, G., ed. Genetic algorithms in engineering and computer science. Chichester: Wiley, c1995. ISBN 0-471-95859-X.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubíček, Ph.D.**

Datum zadání: 01.09.2021

Datum odevzdání: 30.04.2022

prof. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry

prof. Ing. Jan Platoš, Ph.D.
děkan fakulty

Abstrakt

Tématem této diplomové práce je testování efektivity segmentačních algoritmů při segmentaci medicínských obrazových dat, jejichž akvizice byla provedena pomocí MRI, fundus kamery a ultrazvuku. V druhé části práce týkající se segmentace vybraných objektů zájmu byly použity snímky CT, MRI a ultrazvuku. Šum v obraze představuje nežádoucí aditivní složku, která mění jasovou intenzitu pixelů, a mohou tak při klasifikaci pixelů do jednotlivých segmentačních regionů vznikat chyby. V práci byla pro testování medicínských snímků dvojice použita dvojice algoritmů Fuzzy-ABC a F-FCM, které stojí na principu fuzzy logiky a jsou doplněny o lokální statistickou agregaci pro účely potlačení vlivu šumu. Další dvojicí algoritmů představují metody K-means a Otsu prahování. Tyto dva algoritmy se řadí mezi tzv. konvenční algoritmy a jejich segmentační efektivita byla porovnána s efektivitou obou fuzzy algoritmů. Teoretická část práce je stručně věnována základním principům segmentace obrazových dat a vybraných evolučních strategií pro segmentaci obrazu. Byla provedena také rešerše týkající se segmentace obrazu optimalizované pomocí evolučních strategií. Hlavním cílem práce byla analýza efektivity a robustnosti segmentačních metod v kontextu variabilního deterministického šumu s dynamickou intenzitou a následná komparativní analýza a modelování efektivity segmentace testovaných metod v závislosti na parametrech segmentačních strategiích. Testovány byly obrazy obsahující Gaussovský šum, Salt&Pepper a Speckle. K evaluaci výsledků byly použity objektivní evaluační metody MSE, korelace a SSIM.

Klíčová slova

Segmentace obrazu; K-means; FCM; Otsu; Optimalizace rojem včel; Lokální statistická agregace; Evoluční strategie; Efektivita segmentace; Gaussovský šum; Šum sůl a pepř; Speckle

Abstract

The topic of this diploma thesis is testing the effectiveness of segmentation algorithms in the segmentation of medical image data, the acquisition of which was performed using MRI, fundus camera and ultrasound. In the second part of the work dealing with the segmentation of selected objects of interest, CT, MRI and ultrasound images were used. Noise in the image is an undesirable additive component that changes the brightness intensity of the pixels, and thus errors can occur when classifying pixels into individual segmentation regions. A pair of Fuzzy-ABC and F-FCM algorithms, which are based on the principle of fuzzy logic, were tested in this work. These algorithms overcome the problem of pixel misclassification caused by local statistical aggregation. Another pair of algorithms are the K-means and Otsu thresholding methods. These two algorithms are so-called conventional algorithms, and their segmentation efficiency was compared with the efficiency of both fuzzy algorithms. The theoretical part of the work is briefly devoted to the basic principles of image data segmentation and selected evolutionary strategies for image segmentation. A review of such evolutionary strategies used for image segmentation was also made. The main goal of the work was to analyze the effectiveness and robustness of segmentation methods in the context of variable deterministic noise (gaussian, salt&pepper, speckle) with dynamic intensity and subsequent comparative analysis and modeling of the effectiveness of segmentation of tested methods depending on the parameters of segmentation strategies. Objective evaluation methods were used to evaluate the results (corelation, MSE and SSIM).

Key words

Image Segmentation; K-means; FCM; Otsu; Artificial Bee Colony Optimization; Local Statistical Aggregation; Evolutionary Strategies; Segmentation Efficiency; Gaussian Noise; Salt and Pepper Noise; Speckle

Poděkování

Děkuji panu Ing. Janu Kubíčkovi, Ph.D. za rady, věcné připomínky, odborné konzultace a přístup při tvorbě a vedení této diplomové práce.

Obsah

| | |
|---|-----------|
| Seznam obrázků a tabulek..... | 11 |
| Úvod..... | 15 |
| 1 Segmentace obrazu..... | 16 |
| Konvenční metody využívané pro segmentaci medicínských obrazů..... | 17 |
| 1.1 Manuální prahování..... | 17 |
| 1.1.1 Histogram | 17 |
| 1.2 Obrazová hrana a její detekce | 18 |
| 1.2.1 Detekce hran pomocí první a druhé derivace | 18 |
| 1.3 Automatické prahování a Otsu prahování | 19 |
| 1.4 Metody regionální segmentace..... | 20 |
| 1.4.1 Metoda růstu oblasti | 20 |
| 1.4.2 Metoda spojování oblastí, dělení oblastí, dělení a spojování oblastí..... | 21 |
| 1.4.3 Aktivní kontury | 21 |
| 1.5 Shluková analýza..... | 22 |
| 1.5.1 Euklidovská vzdálenost..... | 22 |
| 1.5.1.1 K-means..... | 23 |
| 1.5.2 Metody měkkého shlukování | 23 |
| 1.5.2.1 Fuzzy C-means (FCM)..... | 23 |
| 2 Evoluční algoritmy | 25 |
| 2.1 Genetický algoritmus | 25 |
| 2.1.1 Fitness funkce..... | 25 |
| 2.1.2 Selektce..... | 25 |
| 2.1.3 Ruletová selektce..... | 26 |
| 2.1.4 Elitismus..... | 26 |
| 2.1.5 Křížení | 26 |
| 2.1.6 Mutace..... | 27 |
| 2.2 Diferenciální evoluce | 28 |
| 2.3 Optimalizace rojem částic | 29 |
| 2.4 Optimalizace rojem včel..... | 30 |
| 2.4.1 Fitness funkce..... | 31 |
| 2.4.1.1 Kapurova entropie | 32 |

| | | |
|----------|--|-----------|
| 3 | Rešerše aplikací evolučních algoritmů pro segmentaci obrazových dat | 33 |
| 3.1 | Diferenciální evoluce | 33 |
| 3.2 | Optimalizace rojem včel..... | 34 |
| 3.3 | Optimalizace rojem částic | 36 |
| 3.4 | Genetický algoritmus | 38 |
| 3.5 | Optimalizace mravenčí kolonií | 39 |
| 4 | Tvorba datové báze pro testování..... | 40 |
| 4.1 | Tvorba datové báze pro testování..... | 40 |
| 4.1.1 | Vybrané typy šumu v medicínských obrazech..... | 41 |
| 4.2 | Metody objektivního hodnocení kvality výsledných dat..... | 45 |
| 4.2.1 | Pearsonův korelační koeficient..... | 45 |
| 4.2.2 | Střední kvadratická odchylka | 45 |
| 4.2.3 | Index strukturální podobnosti..... | 45 |
| 4.3 | Princip hodnocení výsledků a nastavení testování | 46 |
| 5 | Výsledky testování – Globální evaluace efektivity metod..... | 48 |
| 5.1 | Dataset MRI | 48 |
| 5.1.1 | Gaussovský šum..... | 48 |
| 5.1.2 | Šum Salt&Pepper | 51 |
| 5.1.3 | Šum Speckle | 54 |
| 5.2 | Dataset UZV..... | 57 |
| 5.2.1 | Gaussovský šum..... | 57 |
| 5.2.2 | Šum Salt&Pepper | 60 |
| 5.2.3 | Šum Speckle | 63 |
| 5.3 | Dataset Retina | 66 |
| 5.3.1 | Gaussovský šum..... | 66 |
| 5.3.2 | Šum Salt&Pepper | 69 |
| 5.3.3 | Šum Speckle | 72 |
| 6 | Výsledky testování – Porovnání efektivity metod dle výsledků nejlepších nastavení. 75 | 75 |
| 6.1 | Srovnání K-means, Otsu a Fuzzy-ABC algoritmu v datasetu MRI | 75 |
| 6.1.1 | Gaussovský šum..... | 75 |
| 6.1.2 | Šum Salt&Pepper | 80 |
| 6.1.3 | Šum Speckle | 85 |
| 6.2 | Srovnání nejlepších výsledků Fuzzy-ABC a F-FCM v datasetu MRI | 90 |

| | | |
|-----------|--|------------|
| 6.2.1 | Gaussovský šum, Srovnání metod v rámci počtu regionů..... | 90 |
| 6.2.2 | Šum Salt&Pepper, Srovnání metod v rámci počtu regionů..... | 93 |
| 6.2.3 | Šum Speckle, Srovnání metod v rámci počtu regionů..... | 96 |
| 6.3 | Dataset UZV a dataset Retina | 99 |
| 6.4 | Výpočetní náročnost algoritmů | 100 |
| 7 | Segmentace vybraných objektů zájmu vybraných algoritmů..... | 102 |
| 7.1 | Segmentace objektů pomocí Fuzzy-ABC algoritmu, dataset CT..... | 104 |
| 7.2 | Segmentace objektů pomocí Fuzzy-ABC algoritmu, dataset MRI | 106 |
| 7.3 | Segmentace objektů pomocí Fuzzy-ABC algoritmu, dataset UZV..... | 108 |
| 7.4 | Segmentace objektů pomocí F-FCM algoritmu, dataset CT | 110 |
| 7.4.1 | Průměrová agregace | 110 |
| 7.4.2 | Mediánová agregace..... | 111 |
| 7.5 | Segmentace objektů pomocí F-FCM algoritmu, dataset MRI..... | 113 |
| 7.5.1 | Průměrová agregace | 113 |
| 7.5.2 | Mediánová agregace..... | 114 |
| 7.6 | Segmentace objektů pomocí F-FCM algoritmu, dataset UZV | 116 |
| 7.6.1 | Průměrová agregace | 116 |
| 7.6.2 | Mediánová agregace..... | 117 |
| 8 | Diskuse | 119 |
| 9 | Závěr..... | 121 |
| 10 | Literatura a jiné zdroje: | 122 |

Seznam použitých symbolů zkratk

| Zkratka | Význam |
|-------------|---|
| MRI | Magnetit resonance imaging (magnetická rezonance) |
| CT | Computed tomography (výpočetní tomografie) |
| RTG | Rentgen |
| RoI | Region of interest (oblast zájmu) |
| FCM | Fuzzy C-means |
| GA | Genetic algorithm (genetický algoritmus) |
| ABC | Artificial Bee Colony (optimalizace rojem včel) |
| MSE | Mean squared error (střední kvadratická odchylka) |
| SSIM | Structural similarity index measure (index strukturální podobnosti) |
| μ | Střední hodnota |
| σ | Směrodatná odchylka |
| σ^2 | Rozptyl |
| d | Denzita šumu Salt&Pepper |

Seznam obrázků a tabulek

| | |
|---|----|
| Obr. 1: Segmentace obrazu pomocí binarizace | 17 |
| Obr. 2: Příklad histogramu | 18 |
| Obr. 3: Základní typy hran v obraze | 18 |
| Obr. 4: Detekce hran pomocí I. a II. derivace | 19 |
| Obr. 5: Metoda Region growing | 20 |
| Obr. 6: Metoda Region growing, znázornění segmentace mozku s počtem iterací | 20 |
| Obr. 7: Aktivní kontury | 21 |
| Obr. 8: Příklad shlukové analýzy pomocí metody k-means..... | 22 |
| Obr. 9: Euklidovská vzdálenost | 22 |
| Obr. 10: Příklad lokální průměrové agregace | 24 |
| Obr. 11: Soubor fuzzy funkcí příslušností | 24 |
| Obr. 12: Ruletová selekce | 26 |
| Obr. 13: Křížení chromozomů a vznik potomků | 26 |
| Obr. 14: Mutace chromozomu | 27 |
| Obr. 15: Schéma genetického algoritmu s binárním kódováním | 27 |
| Obr. 16: Princip vzniku nového bodu | 28 |
| Obr. 17: PSO, znázornění principu konvergence k hledanému objektu | 30 |
| Obr. 18: Výsledky optimalizace umístění inicializačních bodů pro metodu růstu regionu | 33 |
| Obr. 19: Výsledky segmentace mléčné žlázy..... | 34 |
| Obr. 20: Výsledky segmentace..... | 34 |
| Obr. 21: Extrahovaný tumor..... | 34 |
| Obr. 22: Výsledky segmentace pomocí metody ABC-PS..... | 35 |
| Obr. 23: Binarizovaný obraz | 35 |
| Obr. 24: Výsledek segmentace..... | 35 |
| Obr. 25: Výsledky z článku [35] | 36 |
| Obr. 26: Výsledek z článku [30] | 36 |
| Obr. 27: Výsledky z článku [45] | 37 |
| Obr. 28: Výsledky segmentace pomocí GA při různém počtu prahů..... | 38 |
| Obr. 29: Výsledky segmentace MRI snímku mozku pomocí GA..... | 38 |
| Obr. 30: Výsledky segmentace mozkových komor pomocí algoritmu z článku..... | 39 |
| Obr. 31: Segmentace MRI snímku mozku pomocí AAC algoritmu | 39 |
| Obr. 32: Segmentace maligních nádorových buněk pomocí AAC | 39 |
| Obr. 33: Princip zašumění nativních obrazových dat..... | 40 |
| Obr. 34: Ukázka dat z datasetu MRI (tumory mozku) | 41 |
| Obr. 35: Ukázka dat z datasetu Retina (retinální cévy na očním pozadí) | 41 |
| Obr. 36 Ukázka dat z datasetu UZV (benigní nádory prsu)..... | 41 |
| Obr. 37: Ukázka dat z datasetu MRI po aplikaci Gaussovského šumu..... | 42 |
| Obr. 38: Ukázka dat z datasetu Retina po aplikaci Gaussovského šumu..... | 42 |
| Obr. 39: Ukázka dat z datasetu UZV po aplikaci Gaussovského šumu | 42 |
| Obr. 40: Příklad centrálního pixelu zasaženého šumem typu Salt&Pepper..... | 43 |
| Obr. 41: Ukázka dat z datasetu MRI po aplikaci šumu Salt&Pepper | 43 |
| Obr. 42: Ukázka dat z datasetu Retina a UZV po aplikaci šumu Salt&Pepper..... | 43 |

| | |
|---|----|
| Obr. 43: Ukázka dat z datasetu MRI po aplikaci šumu Speckle..... | 44 |
| Obr. 44: Ukázka dat z datasetu Retina po aplikaci šumu Speckle..... | 44 |
| Obr. 45: Ukázka dat z datasetu UZV po aplikaci šumu Speckle..... | 45 |
| Obr. 46: Blokové schéma principu testování a evaluace výsledků analýz..... | 46 |
| Obr. 47: Segmentační masky snímku z datasetu MRI, K-means, Gaussovský šum..... | 48 |
| Obr. 48: Segmentační masky snímku z datasetu MRI, Fuzzy-ABC algoritmus, Gauss. šum..... | 49 |
| Obr. 49: Segmentační masky snímku z datasetu MRI, F-FCM algoritmus, Gauss. šum..... | 49 |
| Obr. 50: Segmentační masky snímku z datasetu MRI, K-means, Šum Salt&Pepper..... | 51 |
| Obr. 51: Segmentační masky snímku z datasetu MRI, Fuzzy-ABC, Šum Salt&Pepper..... | 52 |
| Obr. 52: Segmentační masky snímku z datasetu MRI, F-FCM, Šum Salt&Pepper..... | 52 |
| Obr. 53: Segmentační masky snímku z datasetu MRI, K-means, šum Speckle..... | 54 |
| Obr. 54: Segmentační masky snímku z datasetu MRI, Fuzzy-ABC algoritmus, Šum Speckle..... | 55 |
| Obr. 55: Segmentační masky snímku z datasetu MRI, F-FCM algoritmus, Šum Speckle..... | 55 |
| Obr. 56: Segmentační masky snímku z datasetu UZV, K-means, Gaussovský šum..... | 57 |
| Obr. 57: Segmentační masky snímku z datasetu UZV, Fuzzy-ABC algoritmus, Gauss. šum..... | 58 |
| Obr. 58: Segmentační masky snímku z datasetu UZV, F-FCM algoritmus, Gauss..... | 58 |
| Obr. 59: Segmentační masky snímku z datasetu UZV, K-means, šum Salt&Pepper..... | 60 |
| Obr. 60: Segmentační masky snímku z datasetu UZV, Fuzzy-ABC, šum Salt&Pepper..... | 61 |
| Obr. 61: Segmentační masky snímku z datasetu UZV, F-FCM, šum Salt&Pepper..... | 61 |
| Obr. 62: Segmentační masky snímku z datasetu UZV, K-means, šum Speckle..... | 63 |
| Obr. 63: Segmentační masky snímku z datasetu UZV, Fuzzy-ABC, šum Speckle..... | 64 |
| Obr. 64: Segmentační masky snímku z datasetu UZV, F-FCM, šum Speckle..... | 64 |
| Obr. 65: Segmentační masky snímku z datasetu Retina, K-means, Gaussovský šum..... | 66 |
| Obr. 66: Segmentační masky snímku z datasetu Retina, Fuzzy-ABC, Gaussovský šum..... | 67 |
| Obr. 67: Segmentační masky snímku z datasetu Retina, F-FCM, Gaussovský šum..... | 67 |
| Obr. 68: Segmentační masky snímku z datasetu Retina, K-means, šum Salt&Pepper..... | 69 |
| Obr. 69: Segmentační masky snímku z datasetu Retina, Fuzzy-ABC, šum Salt&Pepper..... | 70 |
| Obr. 70: Segmentační masky snímku z datasetu Retina, F-FCM, šum Salt&Pepper..... | 70 |
| Obr. 71: Segmentační masky snímku z datasetu Retina, K-means, šum Speckle..... | 72 |
| Obr. 72: Segmentační masky snímku z datasetu Retina, Fuzzy-ABC, šum Speckle..... | 73 |
| Obr. 73: Segmentační masky snímku z datasetu Retina, F-FCM, šum Speckle..... | 73 |
| Obr. 74: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd..... | 75 |
| Obr. 75: Srovnání výsledků metod pro 3 segmentační třídy, med. agregace, Gauss. šum..... | 76 |
| Obr. 76: Srovnání výsledků metod pro 5 seg. tříd, med. agregace, Gaussovský šum..... | 77 |
| Obr. 77: Srovnání výsledků metod pro 8 segmentačních tříd, med. agregace, Gauss. šum..... | 78 |
| Obr. 78: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd..... | 80 |
| Obr. 79: Srovnání výsledků metod pro 3 seg. třídy, med. agregace, šum Salt&Pepper..... | 81 |
| Obr. 80: Srovnání výsledků metod pro 5 seg. tříd, med. agregace, šum Salt&Pepper..... | 82 |
| Obr. 81: Srovnání výsledků metod pro 8 seg. tříd, med. agregace, šum Salt&Pepper..... | 83 |
| Obr. 82: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd..... | 85 |
| Obr. 83: Grafická srovnání výsledků metod pro 3 seg. třídy, med. agregace, šum Speckle..... | 86 |
| Obr. 84: Grafická srovnání výsledků metod pro 5 seg. tříd, med. agregace, šum Speckle..... | 87 |
| Obr. 85: Grafická srovnání výsledků metod pro 8 seg. tříd, med. agregace, šum Speckle..... | 88 |
| Obr. 86: Grafická srovnání výsledků metod pro 8 segmentačních tříd, Gaussovský šum..... | 91 |

| | |
|---|-----|
| Obr. 87: Nativní zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM, 8 seg. tříd..... | 92 |
| Obr. 88: Grafická srovnání výsledků metod pro 8 segmentačních tříd, šum Salt&Pepper..... | 94 |
| Obr. 89: Nativní zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM, 8 seg. tříd..... | 95 |
| Obr. 90: Grafická srovnání výsledků metod pro 8 segmentačních tříd, šum Speckle..... | 97 |
| Obr. 91: Zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM při 8 seg. třídách..... | 98 |
| Obr. 92: Grafické zobrazení průměrné výpočetní náročnosti K-means a Otsuovy metody..... | 100 |
| Obr. 93: Grafické zobrazení průměrné výpočetní náročnosti Fuzzy-ABC a F-FCM..... | 100 |
| Obr. 94: Blokové schéma řešení segmentace konkrétních objektů z medicínských obrazů..... | 102 |
| Obr. 95: Ukázky segmentace v datasetu CT..... | 104 |
| Obr. 96: Ukázky segmentace v datasetu MRI..... | 106 |
| Obr. 97: Ukázky segmentace v datasetu UZV..... | 108 |
| Obr. 98: Ukázky segmentace v datasetu CT..... | 110 |
| Obr. 99: Ukázky segmentace v datasetu CT..... | 111 |
| Obr. 100: Ukázky segmentace v datasetu MRI..... | 113 |
| Obr. 101: Ukázky segmentace v datasetu MRI..... | 114 |
| Obr. 102: Ukázky segmentace v datasetu UZV..... | 116 |
| Obr. 103: Ukázky segmentace v datasetu UZV..... | 117 |
| | |
| Tab. 1: Výsledky z článku [33]; AW-PSO je konkurenční metoda a HRC-PSO je metoda autorů..... | 37 |
| Tab. 2: Sumarizační tabulka evaluačních parametrů..... | 48 |
| Tab. 3: Sumarizační tabulka evaluačních parametrů..... | 51 |
| Tab. 4: Sumarizační tabulka evaluačních parametrů..... | 54 |
| Tab. 5: Sumarizační tabulka evaluačních parametrů..... | 57 |
| Tab. 6: Sumarizační tabulka evaluačních parametrů..... | 60 |
| Tab. 7: Sumarizační tabulka evaluačních parametrů..... | 63 |
| Tab. 8: Sumarizační tabulka evaluačních parametrů..... | 66 |
| Tab. 9: Sumarizační tabulka evaluačních parametrů..... | 69 |
| Tab. 10: Sumarizační tabulka evaluačních parametrů..... | 72 |
| Tab. 11: Objektivní srovnání výsledků korelace nejlepších nastavení Fuzzy-ABC, K-means a Otsu.. | 75 |
| Tab. 12: Objektivní srovnání výsledků MSE nejlepších nastavení Fuzzy-ABC, K-means a Otsu. | 75 |
| Tab. 13: Objektivní srovnání výsledků SSIM nejlepších nastavení Fuzzy-ABC, K-means a Otsu..... | 75 |
| Tab. 14: Obj. srovnání výsledků korelace nejlepších nastavení K-means, Otsu a Fuzzy-ABC..... | 80 |
| Tab. 15: Obj. srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu..... | 80 |
| Tab. 16: Obj. srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. | 80 |
| Tab. 17: Obj. srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. | 85 |
| Tab. 18: Obj. srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu..... | 85 |
| Tab. 19: Obj. srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. | 85 |
| Tab. 20: Objektivní srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC..... | 90 |
| Tab. 21: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. . | 90 |
| Tab. 22: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. . | 90 |
| Tab. 23: Objektivní srovnání výsledků korelace nastavení F-FCM a Fuzzy-ABC algoritmu. | 93 |
| Tab. 24: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. . | 93 |
| Tab. 25: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. . | 93 |

| | |
|--|-----|
| Tab. 26: Objektivní srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC..... | 96 |
| Tab. 27 Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.... | 96 |
| Tab. 28 Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu. . | 96 |
| Tab. 29: Výsledky segmentací objektů; Fuzzy-ABC v datasetu CT..... | 105 |
| Tab. 30: Výsledky segmentací objektů; Fuzzy-ABC v datasetu MRI. | 107 |
| Tab. 31: Výsledky segmentací objektů; Fuzzy-ABC v datasetu UZV..... | 108 |
| Tab. 32: Výsledky segmentací objektů F-FCM algoritmu (průměrová agregace) v datasetu CT..... | 112 |
| Tab. 33: Výsledky segmentací objektů F-FCM algoritmu (mediánová agregace) v datasetu CT. | 112 |
| Tab. 34: Výsledky segmentací objektů; F-FCM algoritmu (průměrová agregace) v datasetu MRI... | 115 |
| Tab. 35: Výsledky segmentací objektů; F-FCM algoritmu (mediánová agregace) v datasetu MRI... | 115 |
| Tab. 36: Vyhodnocení srovnání segmentací objektu pomocí F-FCM algoritmu (průměrová agregace) v datasetu UZV. | 118 |
| Tab. 37: Vyhodnocení srovnání segmentací objektu pomocí F-FCM algoritmu (mediánová agregace) vůči zlatému standardu v datasetu UZV. | 118 |

Úvod

V dnešní době se stávají nejrůznější segmentační expertní systémy nedílnou součástí klinické praxe, neboť často dokážou v medicínských obrazových datech detekovat i patologické děje, které mohou být zejména v počátečních fázích lidským okem velice snadno přehlédnutelné například pro méně zkušené lékaře. U segmentačních metod v medicíně je zásadním požadavkem přesnost. Tuto přesnost může významně narušovat přítomnost aditivního šumu.

Tato diplomová práce se zabývá algoritmy regionální segmentace, které mají za úkol rozdělit obraz do předem definovaného počtu segmentačních tříd neboli regionů. Regionem je myšlen shluk pixelů, které mají podobné vlastnosti, díky kterým je možné rozpoznání jednotlivých objektů v obraze.

Velkou částí práce je komparativní analýza použitých metod v závislosti na tom, jak dobře se dokážou vyrovnat s aditivním šumem s dynamickou intenzitou. Otestovány byly konvenční metody K-means, Otsuova metoda prahování, F-FCM algoritmus a Fuzzy algoritmus založený na evoluční strategii ABC algoritmu. Poslední dvě zmíněné metody byly navíc doplněny o lokální statistickou agregaci, která potlačuje vliv šumu na výsledných segmentovaných obrazech. Testování bylo provedeno v prostřední tří datasetů zahrnující medicínské snímky z MRI, ultrazvuku a fundus kamery.

Další část práce zahrnuje aplikaci Fuzzy-ABC algoritmu a dvojího nastavení F-FCM algoritmu pro extrakci vybraných objektů z obrazů. Zde byly objekty extrahovány z datasetů CT, MRI a ultrazvuku. Souhrnně se jedná o extrakci nádorů.

Práce je rozdělena na teoretickou část, která v první kapitole obsahuje úvod do problematiky segmentace obrazu a jsou zde popsány konvenční metody i F-FCM algoritmus. Druhá kapitola popisuje vybrané evoluční strategie a základní principy jejich funkce. Třetí kapitola obsahuje rešerši aplikací evolučních strategií pro segmentaci obrazu.

Na pomezí teoretické a praktické části je čtvrtá kapitola, která popisuje princip celého testování efektivity jednotlivých algoritmů vůči dynamicky se měnícímu zašumění. Součástí této kapitoly je také popis vybraných typů aditivního šumu, které byly v rámci práce otestovány. Důležitou součástí této kapitoly je také popis vybraných evaluačních parametrů sloužících pro objektivní zhodnocení výsledků. Mezi tyto parametry patří korelace, střední kvadratická odchylka a index strukturální podobnosti.

Pátá kapitola už ukazuje přímo praktické výsledky. Zde jsou všechny metody porovnány globálně vůči sobě. Na základě tohoto srovnání je možné obecné posouzení efektivity jednotlivých metod, ale není možné srovnat výstupy s ohledem na jednotlivá nastavení metod a počet regionů.

Z výše zmíněného důvodu šestá kapitola ve své první části obsahuje srovnání nejlepších výsledků Fuzzy-ABC algoritmu, K-means a Otsuovy metody. Srovnání bylo provedeno formou tabulek, grafických výstupů i obrazových výstupů. V druhé části kapitoly bylo provedeno srovnání pouze Fuzzy-ABC a F-FCM algoritmů, a to opět na základě nejlepších výsledků v rámci jednotlivých segmentačních tříd. I zde pro srovnání slouží tabulky, grafy a obrazové výstupy.

Sedmá a poslední kapitola se týká extrakce vybraných objektů zájmu z obrazů. Zde byly binární segmentační masky porovnávány vůči manuální segmentaci sloužící jako zlatý standard a výstupy byly objektivně ohodnoceny.

1 Segmentace obrazu

Obrazová data hrají v medicíně velmi významnou roli ve smyslu diagnózy i léčby. Poskytují lékařům široké neinvazivní možnosti nahlédnutí do anatomických struktur vyšetřované oblasti lidského těla a umožňují tak určení diagnózy a následné léčby [1–3].

Segmentační metody se dnes uplatňují na biomedicínských snímcích pořízených pomocí nejrůznějších zobrazovacích metod. Nejpoužívanější jsou dnes metody založené na RTG, kdy se využívá elektromagnetického záření o vlnové délce 10^{-8} až 10^{-12} m a vysoké energii, a dále na metodách, které zobrazují příčné řezy tělem pacienta (tomografie). Mezi takové metody patří výpočetní tomografie (CT) využívající RTG záření, magnetická rezonance (MR, MRI) využívající silného magnetického pole, SPECT, PET, které využívají principu měření radiace pocházející z radiofarmaka podaného pacientovi a následné konstrukce obrazu, anebo ultrazvuk. [1–3].

Zpracování obrazu se současně s rozvojem výpočetní techniky začalo stále více objevovat v různých medicínských aplikacích. Dnes se využívá zejména k odstraňování artefaktů, registraci obrazu, segmentaci a velice často se využívá také při chirurgických operacích, kdy je obrazových dat využito k navádění chirurgických nástrojů (image-guided surgery). Při registraci obrazu jde nejčastěji o upravení registrovaného obrazu tak, aby co nejvíce odpovídal vztažnému obrazu. Typickým příkladem mohou být RTG snímky zlomenin pořízené s časovým odstupem několika týdnů, kdy oba zobrazují stejnou oblast zájmu, ale kvůli posunu nebo odlišného úhlu dochází k prostorovému zkreslení obrazu [2, 4–9].

Segmentace obrazu je jednou z hlavních součástí široké palety metod, kterou dnes zpracování obrazu nabízí. Segmentací obrazu je možné provést extrakci oblastí zájmu (ROI) pomocí automatické nebo poloautomatické metodiky. Metod, které se používají pro segmentaci tkání a orgánů, je mnoho a fungují na různých principech, které zahrnují například detekci obrazových hran, shlukování pixelů do shluků na základě hodnoty intenzity jasu, tvaru, barvy atd. [2].

Základním smyslem segmentování biomedicínských obrazových dat je dekompozice obrazu do různého počtu segmentačních tříd, ve kterých mají objekty stejné vlastnosti (features). Tyto vlastnosti zahrnují například barvu, jas, tvar a jiné [2, 9].

Některé z medicínských aplikací obrazové segmentace zahrnují detekci hran v angiogramech koronárních tepen, chirurgické plánování, detekci a segmentaci nádorů, funkční mapování mozku pomocí fMRI, automatickou klasifikaci krevních buněk, kdy se jednotlivé krevní elementy rozdělují do skupin nejčastěji na základě tvaru, hromadné vyhodnocení mamogramů atd. [2, 9].

Segmentace obrazu je obecně závislá zejména na kvalitě vstupního obrazu, který má být segmentován. Aby došlo ke kvalitnímu rozpoznání objektu a jeho zařazení do správné segmentační třídy je nutné, aby bylo jasové spektrum uvnitř tohoto objektu co nejvíce homogenní. V reálném světě však jasovou homogenitu narušují nejrůznější artefakty a šum. Kvůli těmto fenoménům se velice často využívá metod předzpracování obrazu za účelem potlačení těchto jevů [9].

Během segmentace může dojít k zařazení dvou objektů do stejné segmentační třídy, ačkoli tyto dva objekty je žádoucí segmentovat odděleně. Klasickým příkladem může být segmentování kostí, které mají na snímku stejné jasové parametry, jsou tedy zařazeny do stejné třídy. Pokud tyto dvě kosti chceme rozlišit, je nutné využít složitější algoritmy, které stojí na využití apriorních informací k identifikaci objektů. Segmentační modely pracující s těmito algoritmy se nazývají metody sémantické segmentace

a spadají do kategorie umělé inteligence. Čím přesněji jsme schopni definovat určitý objekt, tím přesněji jsme schopni nastavit parametry segmentace tak, aby bylo dosaženo co nejlepších výsledků. Takové definování vlastností objektu zahrnují například jeho tvar, pozici a orientaci v prostoru, jeho vztah vůči okolí nebo definování jeho hranic [9].

Konvenční metody využívané pro segmentaci medicínských obrazů

1.1 Manuální prahování

Prahování představuje nejzákladnější, nejstarší a nejjednodušší metodu segmentace obrazu. Celý princip spočívá v rozdělení histogramu obrazu na dvě části pomocí prahové hodnoty. Práh je nejzákladnější vstupním parametrem, kterého je třeba pro prahování obrazu. Po aplikaci jednoho globálního prahu vzniká obraz, jehož jasové spektrum obsahuje pouze dvě hodnoty pixelů – 0 – černou, a bílou - 255. Jedná se o tzv. binární obraz. Skupině pixelů, jejichž hodnota je menší než hodnota prahovací úrovně, je přiřazena hodnota 0 a jsou přeneseny do pozadí snímku a pixelům, jejichž hodnota je rovna alespoň hodnotě prahu, je přiřazena hodnota 1 a jsou přeneseny do popředí snímku [10].

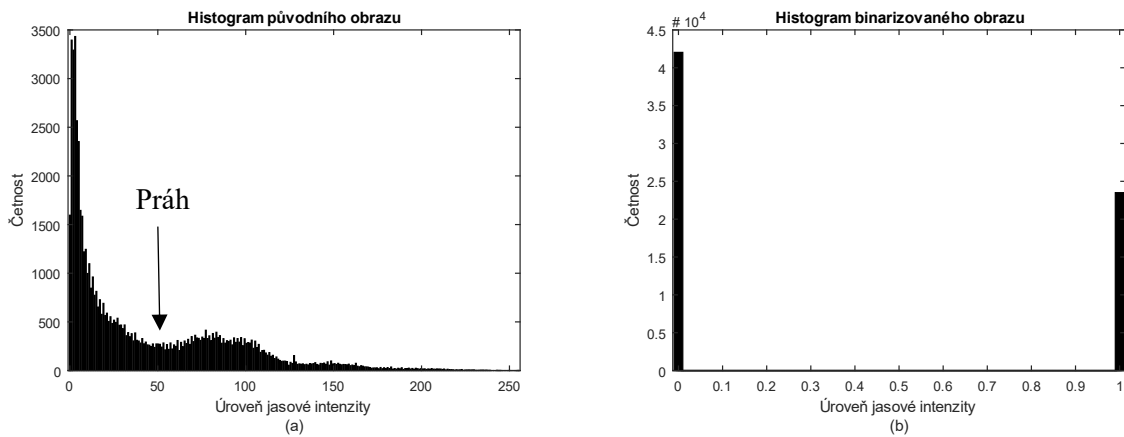
Tato metoda je jednoduchá, ale je zde riziko nesprávné klasifikace objektů v obrazech, v kterých je proměnlivý kontrast. Sofistikovanější metodou je prahování adaptivní, při kterém je obraz rozdělen na více podobrazů a pro každý je určen práh zvlášť [9, 10].



Obr. 1: Segmentace obrazu pomocí binarizace, (vlevo) Originální MRI snímek kolene, (vpravo) Binarizovaný MRI snímek kolene [vlastní zdroj]

1.1.1 Histogram


Histogram je dvourozměrný graf zobrazující četnost zastoupení jednotlivých úrovní podél vertikální osy a hodnoty jasové intenzity v obraze podél horizontální osy. Hodnota 0 na horizontální ose odpovídá v monochromatickém obraze černé barvě, zatímco hodnota 255 barvě bílé.



Obr. 2: Příklad histogramu binarizovaného (a) a nebinarizovaného obrazu (b). Jedná se o histogramy obrazů z Obr. 1. Jako prahovací úroveň byla v histogramu (a) zvolena jasová úroveň 50 [Zdroj vlastní].

1.2 Obrazová hrana a její detekce

Princip detekování hran spočívá v detekci skupiny pixelů, které tvoří hranici mezi dvěma objekty. Aby bylo možné tuto hranici najít, musí se jasové spektrum okrajů objektů lišit – ideální hranu tvoří přechod mezi černou a bílou. Hrana je tedy definována jako oblast prudké změny jasu mezi dvěma objekty viz Obr. 3 [9–11].

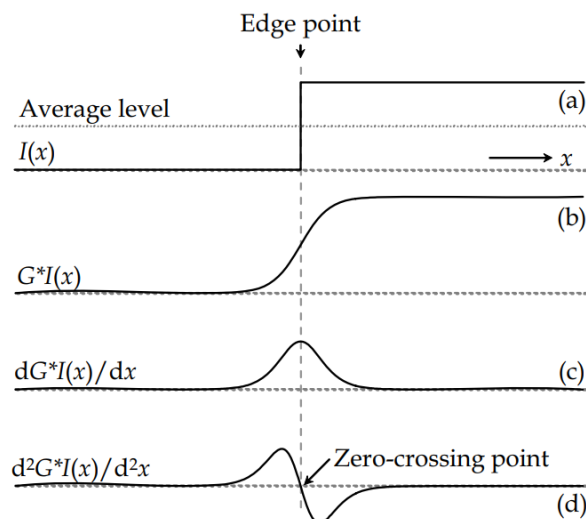


Obr. 3: Základní typy hran v obraze. Zleva: skoková hrana, náběžná hrana a střešovitá hrana [12].

1.2.1 Detekce hran pomocí první a druhé derivace

Metody založené na první derivaci vycházejí ze skutečnosti, že v místech konstantní jasové úrovně je hodnota výstupu první derivace rovna nule. Metody, které pracují s první derivací jsou také nazývány gradientní metody. Nejznámější gradientní operátory jsou Robertsův operátor, Sobelův operátor a operátor Prewittové. Všechno jsou to operátory udávající strmost jasové funkce [9, 10].

Jak je patrné na Obr. 4, hrana se po aplikování první derivace projevuje jako lokální maximum a v případě druhé derivace je hranou místo, kde prochází druhá derivace nulou. Je patrné, že stejně jako v případě hrany se jako prudké oscilační změny se v distribuční funkci jasu projevuje také šum, který právě proto narušuje nebo úplně znemožňuje úspěšnou detekci hrany.



Obr. 4: Detekce hran pomocí I. a II. derivace, (a) Distribuční funkce jasu, (b) Výstup Gaussova filtru aplikovaného na jasovou funkci $I(x)$, (c) Hrana detekovaná pomocí I. derivace, (d) hrana detekovaná pomocí II. derivace [11]

1.3 Automatické prahování a Otsu prahování

Z výše uvedeného je odvoditelné, že manuální určení prahu nedosahuje ideálních výsledků. Existují i metody automatického určení prahu, kdy je práh v bimodálním histogramu umístěn v tzv. údolí, které se nachází mezi dostatečně vzdálenými maximy. Jako práh je tedy nastaveno lokální minimum funkce. Pro nalezení lokálního minima funkce je nutné provést vyhlazení histogramu, neboť oscilace signálu znemožňují identifikaci tohoto minima pomocí derivace, která je na oscilace citlivá [9].

Nejpopulárnější metoda pro automatické nalezení prahu je v současnosti Otsu metoda, která práh stanovuje výpočtem vnitřního rozptylu uvnitř shluků anebo mezi-rozptylu mezi shluky v obraze. Stejně jako u předešlých typů prahování funguje metoda Otsu v prostoru histogramu. Před započítáním hledání ideální hodnoty prahu jsou tímto prahem potenciálně všechny jasové úrovně, které jsou v histogramu zastoupeny. Stejně jako u klasické metody automatického určení prahu Otsu metoda předpokládá, že histogram je bimodální, což implikuje rozlišitelné pozadí a popředí v obraze. Postupným výpočtem pro každý pixel je nakonec jako optimální hodnota prahu určena ta, která má hodnotu vnitřního rozptylu nejnižší anebo hodnotu mezi-rozptylu naopak nejvyšší. Z praktických důvodů se nejčastěji pracuje s výpočtem mezi-rozptylu [2, 9, 13].

Mezi-rozptyl je definován vztahem[13]:


$$\sigma_B^2 = W_b \cdot W_f \cdot (\mu_b - \mu_f)^2 \quad (1)$$

Kde W_b je váha pozadí, μ_b je průměrná hodnota intenzity pozadí, W_f je váha popředí a μ_f je průměrná hodnota intenzity popředí [13].

1.4 Metody regionální segmentace


1.4.1 Metoda růstu oblastí (angl. Region growing)

Tato metoda spočívá v postupném propojování sousedících pixelů, které mají spolu vůči okolí podobnou jasovou hodnotu. Jedná se o interaktivní segmentační techniku, u které je nutné zadat inicializační bod – taktéž zvaný semeno neboli seed, od kterého dochází do všech směrů k seskupování pixelů. Region postupně narůstá na základě splnění podmínek homogenity, kdy dochází k porovnávání parametrů seedu a konkrétního pixelu [2, 10, 14].



Obr. 5: Metoda Region growing. (a) Originální snímek, (b) až (d) Postupný růst regionu, (e) výsledný segmentovaný obraz [10]

Velikost výsledného segmentovaného obrazu je přímo úměrná počtu iterací. Nevýhoda této metody spočívá v tom, že velmi záleží na správném umístění inicializačního bodu. Výsledek tedy velmi záleží na zkušenostech uživatele. Tato metoda je oproti šumu robustnější než prahování, ale také může dojít k neuspokojivým výsledkům. Dobrého uplatnění nachází tato metoda při analýze mamogramů [2, 10, 14].



Obr. 6: Metoda Region growing, znázornění segmentace mozku s počtem iterací [15] - upraveno.

1.4.2 Metoda spojování oblastí, dělení oblastí, dělení a spojování oblastí (angl. Region merging, Region splitting, Split & Merge)

Princip všech těchto metod stojí na principu homogenity pixelů uvnitř obrazu. Pixely, které mají podobné vlastnosti a splňují kritérium homogenity, jsou spojovány do skupiny, která tvoří homogenní region. Nejčastějším kritériem homogenity je úroveň jasové intenzity v obraze [3, 14]


Na začátku segmentace metodou spojování regionů jsou malé oblasti (mohou to být i jednotlivé pixely) na základě splnění podmínky homogenity propojovány a dochází tak k růstu regionu. Celý proces trvá tak dlouho, dokud není u všech oblastí rozhodnuto o jejich příslušnosti k danému regionu [2, 3].

U metody dělení regionů dochází k postupnému rozložení na jednotlivé regiony, dokud není možné dalšího dělení [3].

Metoda dělení a spojování regionů spojuje principy výše uvedených metod. Obraz je nejdříve rozložen na čtyři podobrazy a v rámci těchto podobrazů se posuzuje jejich homogenita. Pokud není Podmínka homogenity splněna, je podobraz znovu rozložen na čtyři podobrazy a celý proces se opakuje. Sousedící regiony splňující podmínku homogenity jsou spojeny do jednoho regionu [2, 3].

1.4.3 Aktivní kontury (angl. active contour, snake)

Segmentace medicínských obrazů je obvykle složitý úkol zejména kvůli šumu a artefaktům vzniklým při vzorkování nebo při akvizici dat. Velice často je žádané nalezení objektu v obraze, který má hladký charakter a je jasně ohraničený. Aktivní konturu si lze představit jako uzavřenou pružnou křivku, která je vkreslena do objektu, který si přejeme ohraničit, a následně tato uzavřená křivka přilne k hranám objektu (viz Obr. 7) na základě principu analogického k fyzikální síle a energii. Tato metoda tedy pracuje na principu hledání hran v obraze, ale na rozdíl od jiných metod je robustnější proti šumu, na který jsou například detektory hran na základě derivací velmi náchylné [10, 14].



(a)

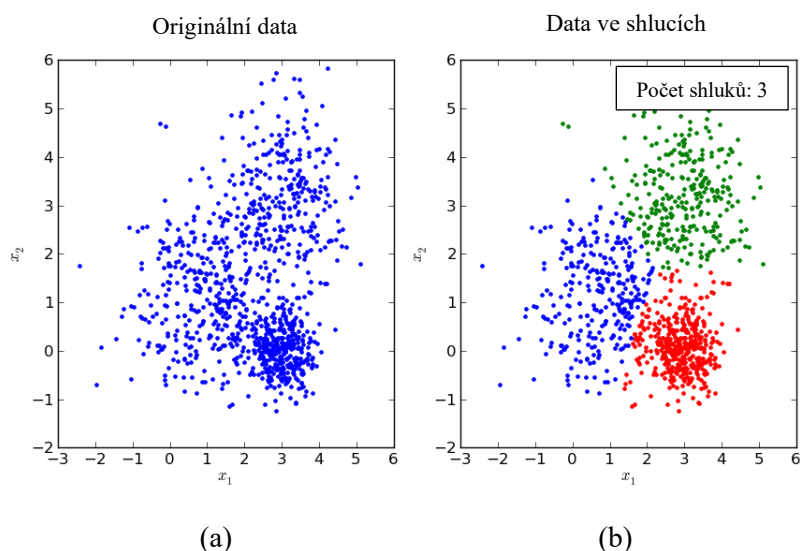
(b)

(c)

Obr. 7: Aktivní kontury, (a) Zadání inicializační kontury (b) Průběh postupného hledání hran objektu (c) Finální hranice objektu [10]

1.5 Shluková analýza (angl. clustering)

Shluková analýza slouží k rozřazení pixelů do předem definovaného počtu skupin (clusterů, regionů) v závislosti na tom, jak jsou si mezi sebou podobné. Pro vyhodnocení této podobnosti je podobnost měřena vůči všem clusterům a nejčastěji se k tomu využívá Euklidovské vzdálenosti [2, 10, 16].



Obr. 8: Příklad shlukové analýzy pomocí metody k-means, (a) Původní data (b) Data segmentovaná do tří clusterů [17] - upraveno


1.5.1 Euklidovská vzdálenost

Vzdálenost mezi dvěma body se rovná délce přímky, které tyto body spojuje. V Euklidovské rovině mějme bod mající kartézské souřadnice (x_1, y_1) a mějme bod mající souřadnice (x_2, y_2) . Vzdálenost d mezi těmito lze vyjádřit jako [18]:

$$d(x, y)^2 = (x_2 - x_1)^2 + (y_2 - y_1)^2 \quad (2)$$

Po úpravě

$$d(x, y) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (3)$$



Obr. 9: Euklidovská vzdálenost [19] Tvrdé shlukování (angl. Hard clustering)

Tyto metody shlukují data do clusterů na základě tvrdě nastavených prahových hodnot. Pixel buďto do clusteru patří nebo nepatří. Obecně se počítá vzdálenost pixelu od těžiště clusterů, kdy kratší vzdálenost znamená zařazení do tohoto clusteru. Princip těchto metod je snadný a výpočetně nenáročný [2, 10, 16].

1.5.1.1 K-means

V kontextu segmentace obrazových dat jsou v prostoru histogramu náhodně vygenerována těžiště, jejichž počet souhlasí s požadovaným počtem regionů a následně na základě minimalizace Euklidovské vzdálenosti jsou analyzovány hodnoty jasových intenzit jednotlivých pixelů. Každý pixel je tak přiřazen k nejbližšímu těžišti.

Po prvotním přiřazení jednotlivých složek jasové intenzity k těžištím jsou z jednotlivých nově vzniklých shluků vypočítána nová těžiště pomocí prostého aritmetického průměru a celý proces se opakuje tak dlouho, dokud nedojde k ustálení shluků [2, 10, 16]. Příklad je zobrazen na Obr. 8.

1.5.2 Metody měkkého shlukování (angl. Soft clustering)

Metody měkkého shlukování jsou založené na fuzzy teorii, kde pojem fuzzy lze přeložit jako mlhavý či nejasný. Standardně se však nepřekládá [20]. Fuzzy přístup k řešení problémů říká, že jednotlivé sledované elementy náležící určitému shluku s určitou mírou příslušnosti, které se říká stupeň členství (angl. membership degree). Elementům, které do shluku nepatří naopak mají přidělenou svou míru nepřislušnosti nazvanou stupeň nečlenství (angl. non-membership degree) [20]. Jeden element tedy může být zařazen do více shluků s určitým stupněm příslušnosti.

1.5.2.1 Fuzzy C-means (FCM)


Tato metoda byla poprvé prezentována Jamesem C. Bezdekem v roce 1981. Princip FCM algoritmu pracuje se stupni příslušnosti a Euklidovskou vzdáleností mezi elementy a těžišti (centeroidy) shluků. Čím blíže je element k těžišti shluku, tím vyšší má míru příslušnosti [2, 10, 16].

Princip této metody spočívá v nalezení těžišť v histogramu pomocí shlukové analýzy a následné konstrukci trojúhelníkových fuzzy funkcí s vrcholy v nalezených těžištích. Počet těžišť odpovídá požadovanému počtu regionů. Na základě rozložení fuzzy funkcí v histogramu je každé jasové úrovni přiřazena hodnota členství ke každému z těžišť.

V kontextu této práce byly hodnoty příslušnosti jednotlivých pixelů ošetřeny pomocí lokální statistické agregace. Vlivem šumu dochází v prostoru hodnot členství k chybám, které mohou později způsobovat nesprávnou klasifikaci objektů. Těmto chybám se říká blind spots.

Lokální agregace tento problém řeší na principu 2D konvoluce, kdy je okenní funkcí definovaných rozměrů postupně procházen prostor členských funkcí a hodnota členství šumových pixelů je upravena. Nakonec jsou hodnoty členských funkcí jednotlivých pixelů přiřazeny ke konkrétnímu těžišti pomocí maximalizace, čímž vzniká výsledný segmentovaný obraz. [2, 13, 16, 20, 21].

| | | |
|-----|----------|-----|
| 0.7 | 0.7 | 0.7 |
| 0.7 | 0 | 0.7 |
| 0.7 | 0.7 | 0.7 |




| | | |
|-----|------------|-----|
| 0.7 | 0.7 | 0.7 |
| 0.7 | 0.7 | 0.7 |
| 0.7 | 0.7 | 0.7 |

Obr. 10: Příklad lokální průměrové agregace s vyznačenou chybou příslušnosti (Blind Spot) [Zdroj vlastní].

Funkce příslušnosti musí splňovat kritéria:

- Pokud $\mu_n(k_0) = 1$, pak $\mu_m(k_0) = 0, \forall n \neq m$
- Normalita: $\max(\mu_n(k)) = 1$
- Křížení dvou fuzzy množin: $\mu_n(k_0) = \mu_{n+1}(k_0) = 0.5 \parallel \mu_{n-1}(k_0) = \mu_n(k_0) = 0.5$



Obr. 11: Soubor fuzzy funkcí příslušností definující rozložení stupně členství pixelů pro jednotlivé regiony [21].

2 Evoluční algoritmy

Evoluční algoritmy (EA) jsou heuristické metody, pro jejichž vytvoření našli jejich tvůrci inspiraci v přírodě. Některé EA fungují na principu simulování Darwinistické evoluce a jiné jsou například inspirovány chováním zvířat či roje hmyzu při hledání potravy nebo nejkratší cesty. Navzdory rozdílům mají všechny EA společný cíl, kterým je nalezení optimálního řešení daného problému. K docílení tohoto úkolu slouží strategie založená na populacích řešení, které se iteračně vylepšují a dojde tak k „vyšlechtění“ optimálního řešení. EA vynikají zejména při řešení komplexních úloh obsahující velké množství lokálních minim, protože snáze prohledávají celý prostor potenciálních řešení a konvergují ke globálnímu minimu. EA jsou definovány velice obecně, což je předurčuje k řešení téměř jakéhokoliv optimalizačního problému, ale lepších výsledků většinou dosahují EA vytvořené přímo na míru řešenému problému [22].

2.1 Genetický algoritmus (angl. Genetic algorithm – GA)

Genetický algoritmus je heuristická metoda založená na principu evoluční biologie sloužící k řešení problémů, pro které neexistuje na míru určené řešení. Metoda pracuje s biologickými operacemi jako je mutace, křížení, dědičnost a přirozený výběr. [23, 24]

Metoda pracuje s velkým množstvím řešení. Každé řešení dané vlastnosti problému je součástí struktury, které se říká chromozom. Každé chromozom zastupuje v analogii s biologií jedince a soubor všech jedinců (chromozomů) společně tvoří populaci nebo také generaci. Kromě první generace je každá další generace vytvořena z jednoho nebo více jedinců předchozí generace. Tito jedinci ztělesňují nejlepší výsledky z předešlé generace a jejich geny se tak šíří dál prostřednictvím potomků. K tvorbě potomků se využívají dva elementární genetické děje, kterými jsou křížení a mutace. K výběru nejlepších jedinců se využívá evaluačních hodnot, který jsou získány pomocí tzv. fitness funkce, která vyhodnocuje optimálnost jedincem nabízeného řešení pro řešení daného problému. Jedinci s vyšší hodnotou fitness funkce mají následně vyšší šanci uspět v genetické soutěži, ve které jde o předání svých genů další generaci [23, 24].

Pojmy

Chromozom představuje jedno z možných řešení. Někdy může být označen jako genotyp nebo genom [25].

Chromozom se skládá z lineárně uspořádaných genů, což znamená, že n-tý gen v chromozomech stejného typu se týká stejné vlastnosti. Hodnotám genů se říká alely [25].

2.1.1 Fitness funkce

Každé potenciální řešení je nutné ohodnotit, aby bylo možné nalezení optimálního řešení problému. Tato funkce je zásadní při rozhodování, které chromozomy se budou podílet na další generaci a které nikoliv. Čím vyšší je hodnota fitness funkce, tím je dané řešení kvalitativně vhodnější [23, 24].


2.1.2 Selektce

Jedná se o mechanismus na základě kterého je vytvořena ze stávající populace chromozomů nová populace. Selektce má za úkol vybrat z populace ty chromozomy, které se budou účastnit tvorby potomků. Výběr rodičů stojí na principu Darwinovy teorie o původu druhů, tedy že silnější jedinci mají

vyšší šanci se prosadit a přežít. Čím vyšší má jedinec hodnotu fitness funkce, tím vyšší má šanci k přiřazení partnera. Selekcčních metod je více typů, ale nejtypičtější je tzv. ruletová selekce [23, 24].

2.1.3 Ruletová selekce

Tuto metodu si lze představit jako náhodný pokus, kdy se točí ruletovým kolem, na kterém je obvod rozdělen do oblastí podle odpovídajících hodnotám fitness funkce jednotlivých jedinců. Jedinec s vyšší fitness má vyšší šanci uspět [23, 24].




Obr. 12: Ruletová selekce. Jedinci s vyšší fitness zabírají větší část obvodu ruletového kola a mají tak vyšší šanci na vybrání [26].

2.1.4 Elitismus

V elitismu je vybráno n nejlepších jedinců z populace a jsou přímo zkopírováni do nové generace. Může tak dojít k předčasné konvergenci celého algoritmu, protože elitismem dochází se snižování rozmanitosti potenciálních řešení optimalizačního problému [23, 24].

2.1.5 Křížení


Při křížení dochází k „rozstřížení“ rodičovských chromozomů v jednom nebo více bodech a výměně takto vzniklých částí mezi rodiči. Vznikají tak dva noví potomci, z nichž každý má část genů od každého z rodičů. Obvykle nastává s pravděpodobností 0,75 až 0,95 [23, 24].



Obr. 13: Křížení chromozomů a vznik potomků [27]

2.1.6 Mutace

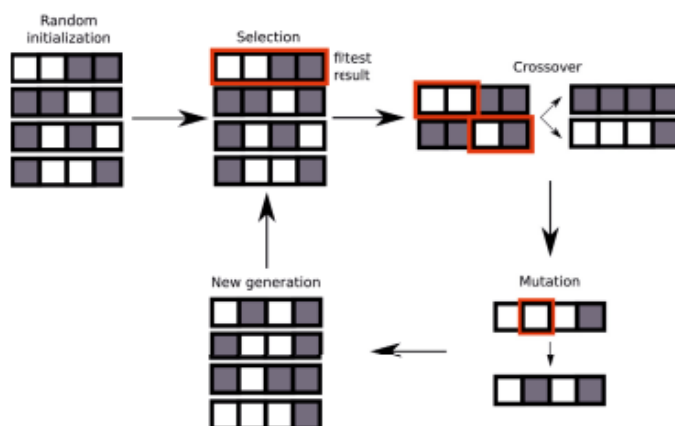
Celý princip mutace je velmi jednoduchý a spočívá v náhodné záměně hodnoty genu. V populaci tedy s určitou pravděpodobností u některých jedinců dojde ke změně hodnoty genu v chromozomu. Mutace je velmi důležitá, jelikož potomci sice vznikají z nejlepších jedinců minulé generace, ale tito jedinci si mohou být velmi podobní. Mutace tedy zaručuje vyšší genovou rozmanitost populace. Obvykle nastává s pravděpodobností 0,001 až 0,05 [23, 24].



Obr. 14: Mutace chromozomu [28]

Příklad genetického algoritmu:


- 1) Vygenerování prvotní populace
- 2) Ohodnocení jedinců v populaci
- 3) Tvorba dvojic
- 4) Tvorba potomků
 - a. Křížení
 - b. Mutace
- 5) Návrat do bodu 2) a opakování cyklu až do ukončovací podmínky (maximální počet generací, nalezení optimálního řešení atd.).



Obr. 15: Schéma genetického algoritmu s binárním kódováním [23]

2.2 Diferenciální evoluce

Diferenciální evoluce (DE) je další z heuristických metod určených k hledání minima ve funkci. Jedná se o velmi populární při řešení nejrůznějších optimalizačních problémů a je často modifikován a rozvíjen [22].



Obr. 16: Princip vzniku nového bodu (vektoru) [22]

Jako jiné EA funguje DE na principu populace možných řešení, které v tomto případě reprezentují vektory. Optimalizování probíhá tvorbou nových vektorů z vektorů stávající populace a dochází tak k vytvoření nové generace. Nová generace je vytvořena tak, že pro každý bod x_i původní generace vznikne nový bod u , porovnájí se jejich fitness hodnoty a do nové generace se zařadí bod s lepší hodnotou fitness. Dva nejčastější způsoby generování nového bodu u jsou tzv. RAND a BEST. Při RAND je nový bod u generován pomocí tří bodů staré populace. Využívá se k tomu vztahu [22, 23]:

$$u = r_1 + F(r_2 - r_3)$$

kde r_{1-3} jsou vybrané body v původní populaci, F je vstupní parametr a musí platit $F > 0$.

U postupu BEST se místo tří náhodných bodů používají body čtyři a nejlepší bod z populace [22, 23]:

$$u = X_{best} + F(r_1 + r_2 - r_3 - r_4)$$

Kde r_{1-4} jsou vybrané body v původní populaci lišící se od bodu x_i i X_{best} . F je opět vstupní parametr a $F > 0$.

Je patrné, že vektor u vzniká pomocí genetického operátoru mutace. K mutaci dochází ve chvíli, kdy je rozdíl vektorů násoben koeficientem F , který může nabývat hodnot v intervalu $[0, 2]$. Tento koeficient ovlivňuje diferenční rozmanitost. Dalším bodem je křížení neboli rekombinace, kdy jsou spolu kříženy vektory u a x_i . Po ukončení křížení jsou porovnány hodnoty fitness jak vektoru x_i tak vektoru nově vzniklého (u). Vektor s vyšší hodnotou fitness je zařazen do nové generace [22, 23].

2.3 Optimalizace rojem částic (angl. Particle Swarm Optimization)

Jedním z přírodou inspirovaných algoritmů je PSO. Její základy sahají do sociální psychologie, umělé inteligence (AI), inženýrství a počítačových věd. Inspirací vedoucí ke vzniku této metody je sociální chování hejna ptáků, kteří hledají potravu, chování ryb nebo roje hmyzu. Při hledání potravy se ptáci pohybují rozptýlení po okolí a jakmile jeden z nich potravu najde nebo zpozoruje, ostatní ptáci se k němu začnou slétávat (konvergence) [20, 29, 30].

Stejně jako genetický algoritmus tato metoda pracuje s náhodným souborem jedinců (částic) a hledá optimální řešení daného problému. Na rozdíl od genetického algoritmu ale nepoužívá evoluční operátory jako je mutace, křížení nebo selekce. Na začátku PSO algoritmu je vygenerována inicializační skupina náhodných prvků, z nichž každý je potenciální řešení optimalizačního problému. Těmto prvkům se říká částice (particle) [20, 29–36].

Pro nalezení co nejoptimálnějšího řešení je žádoucí, aby pohyb částic byl ovlivněn zbytkem roje, ale také je důležité, aby si pro co nejlepší prozkoumání prostoru částice zachovala určitou míru náhodnosti. Každá částice se pohybuje po prostoru. Hodnota kvality řešení optimalizačního problému je vyhodnocována pomocí fitness funkce na základě vzdálenosti částice a globálního optima. Směr pohybu částice je upravován na základě nejlepšího výsledku samotné částice, ale také globálně nejlepšího výsledku celého roje. Částice si mezi sebou předávají informace o nejlepších pozicích na jejichž základě upravují svůj směr dalšího pohybu [20, 29–36].


Nejlepší pozice (Good positions) lze rozdělit na dvě skupiny. První z nich je globální nejlepší pozice (Global best), která je okamžitě po nalezení předána všem částicím roje. Do druhé skupiny spadá lokální nejlepší pozice (Neighborhood best), kdy si částice předávají informace o nejlepších pozicích jen v rámci určité oblasti [20, 31, 36].

Každá částice si pamatuje pozice řešení, které prošla a jejich hodnotu fitness. Dosud nejlepší řešení částice je nazýváno Pbest (Personal best). Pokud je využito lokálního přístupu, říká se nejlepšímu řešení Lbest (Local best) a pokud se jedná o globálně nejlepší řešení, nazývá Gbest (Global best) [20, 31, 36].

Matematický popis PSO lze vyjádřit jako [20]:

$$v_i(t + 1) = \omega v_i(t) + c_1 r_1 [pbest(t) - x_i(t)] + c_2 r_2 [gbest(t) - x_i(t)] \quad (4)$$

kde $v_i(t)$ je rychlost a $x_i(t)$ značí pozici částice i v čase t . ω , c_1 a c_2 jsou parametry, kterými se určuje rychlost a míra, kterou je částice přitahována osobním a globálním nejlepším řešením. Konstanta ω udává setrvačnost, tedy tendenci částice pokračovat v pohybu stejným směrem. Hodnota c_1 je určená vlivu individuality (vliv Pbest) a hodnota c_2 je vliv sociálního chování (vliv Gbest). r_1 a r_2 jsou náhodná čísla z intervalu $[0,1]$ [20].



Obr. 17: PSO, znázornění principu konvergence k hledanému objektu [37]

Oproti jiným evolučním strategiím spočívají výhody PSO v nezávislosti na velikosti problému nebo nelinearitě a ve schopnosti konvergence k optimálnímu řešení problému i v případech, ve kterých jiné metody nedosahují kvalitních výsledků. Velkou výhodou PSO třeba oproti genetickému algoritmu je i méně nastavitelných parametrů, jednodušší implementace, ale také to, že u genetického algoritmu zpravidla zanikají některá řešení a dochází tak ke zmenšování rozmanitosti populace, což se zde neděje [22].

Příklad PSO algoritmu:

- 1) Vygenerování roje a rozprostření částí náhodně po prohledávaném prostoru.
- 2) Výpočet fitness každé částice.
- 3) Porovnání fitness částice s jejím Pbest a případná aktualizace Pbest. Zapsání polohy částice.
- 4) Nalezení částice s nejvyšší fitness, její uložení do Gbest a zapsání polohy této částice.
- 5) Aktualizování pozic částic a jejich rychlostí.
- 6) Kroky 2-5 se opakují až do splnění terminální podmínky (maximální počet iterací nebo nalezení dostatečně velké fitness)

2.4 Optimalizace rojem včel (angl. Artificial Bee Colony)

ABC algoritmus je evoluční optimalizační technika založená na sociálním chování včel, které hledají potravu. Roj se skládá ze tří druhů včel. Konkrétně se jedná o dělnice, pozorující včely a průzkumníky. Každé z těchto typů včel prohledává prostor a pátrá po potravě bohaté na nektar. Každá jednotka potravy reprezentuje jedno možné řešení optimalizačního problému. Včely si předávají informaci o množství (fitness) nalezeného nektaru a v okolí jeho nejbohatšího zdroje dochází k vyššímu prohledávání oblasti. Roj má tak tendenci konvergovat k nejlepším zdrojům potravy. ABC algoritmus je sestaven ze tří fází [21, 38].

Fáze dělnic

V této fázi je každé dělnici přiřazen zdroj potravy (potenciální řešení) V_i a v jeho okolí je nalezeno řešení V_i , pro které platí:

$$V_{ik} = X_{ik} + \phi_{ik} \cdot (X_{ik} - X_{jk}) \quad (5)$$

Kde X_{jk} představuje náhodné potenciální řešení ($i \neq j$), k je náhodný index, ϕ_{ik} je generátor náhodných čísel $[-0.1; 0.1]$. X_i a V_i jsou následně ohodnoceny pomocí fitness funkce. Pokud je fitness

X_i vyšší než V_i ($fit_{X_i} > fit_{V_i}$), je vygenerováno nové V_i . Toto se může opakovat n -krát ($n = 10$). Pokud během těchto n pokusů není nalezena vyšší hodnota fitness funkce pro řešení V_i , pak je toto řešení vymazáno a řešení X_i zůstává uloženo v paměti a je označeno za vyčerpané řešení. Pokud ale platí $fit_{X_i} < fit_{V_i}$, pak se uloženo řešení V_i jako možné řešení optimalizace [21].

Fáze pozorujících včel

V této fázi jsou pozorující včely s vyšší pravděpodobností vábeny k potravě, která má vyšší fitness. Jinými slovy se jedná o globální hodnocení kvality řešení. Vyšší P_i indikuje lepší řešení (rovnice (8)). V okolí řešení X_i , s $\max(P_i)$ je vygenerováno nové řešení V_i podle rovnice (5). Stejně jako v předchozí fázi znamená vyšší fitness lepší řešení [21].

$$P_i = \frac{fit_i}{\sum_{j=1}^{SN} fit_j} \quad (6)$$

Fáze průzkumníků

Průzkumníci prohledávají prostor a nalézají nová řešení různých od těch vyčerpaných podle rovnice:

$$X_{ik} = lb_j + rand(0, 0.1) \cdot (ub_j - lb_j) \quad (7)$$

kde lb a ub označují spodní a horní limit rozměru prostoru (hranice normalizovaného intenzitního spektra [0; 1]).

Všechny tři fáze probíhají tak dlouho, dokud není vyčerpan definovaný počet iterací. Na konci je vybráno řešení s nejvyšší P_i .

V kontextu této práce byla využita modifikovaná verze ABC. Zdroj potravy (potenciální řešení) zde představuje náhodné rozložení fuzzy trojúhelníkových funkcí v prostoru histogramu. Rozložení těchto fuzzy trojúhelníkových funkcí je naprosto zásadní krokem v segmentačním algoritmu. Každé řešení je ohodnoceno fitness funkcí, která je založena na entropii. V této práci je vyhodnocování efektivity řešení (fitness) založeno na Kapurově entropii. Je předpokládáno, že vyšší entropie koresponduje s lepší distribucí souboru fuzzy trojúhelníkových funkcí. Optimální rozdělení fuzzy funkcí je tedy to, které dosáhne nejvyšší hodnoty fitness funkce [21, 38].

2.4.1 Fitness funkce

Fitness funkce slouží k ohodnocení kvality každého řešení při hledání optimálního řešení daného problému. Pro nalezení takového řešení byla v rámci této práce brána v potaz Kapurova entropie každého regionu. Entropie počítá pravděpodobnostní rozložení pixelů každého segmentovaného regionu. Pokud určitá oblast v histogramu neobsahuje významné rozdíly v hladinách jasových intenzit pixelů, je tato oblast ohodnocena vyšší hodnotou entropie, protože jednotlivé pixely se v této oblasti vyskytují s vyšší pravděpodobností. Naopak oblast obsahující významné jasové fluktuace intenzitní hodnoty pixelů, které mohou být projevem šumu a různých artefaktů, mají nižší míru pravděpodobnosti. Z toho důvodu fitness funkce maximalizuje Kapurovu entropii [21, 38].

2.4.1.1 Kapurova entropie

Kapurova entropie byla využita k hodnocení kompaktnosti a rozlišitelnosti segmentačních tříd. Pokud $[th_1, th_2, th_n]$ jsou reprezentace těžišť, na základě kterých jsou tvořeny fuzzy funkce příslušnosti rozdělující obraz do několika regionů, potom je Kapurova entropie definována jako [21, 38]:

$$H(th_1, th_2, \dots, th_n) = H_0 + H_1 + \dots + H_n \quad (8)$$

$$H_0 = -\sum_{j=0}^{th_1-1} \frac{p_j}{\omega_0} \ln \frac{p_j}{\omega_0}, \omega_0 = \sum_{j=0}^{th_1-1} p_j \quad (9)$$

$$H_1 = -\sum_{j=0}^{th_2-1} \frac{p_j}{\omega_1} \ln \frac{p_j}{\omega_1}, \omega_1 = \sum_{j=0}^{th_2-1} p_j \quad (10)$$

$$H_n = -\sum_{j=th_n}^{L-1} \frac{p_j}{\omega_n} \ln \frac{p_j}{\omega_n}, \omega_n = \sum_{j=th_n}^{L-1} p_j \quad (11)$$

kde: $H_{0,1,n}$ – hodnota entropie jednotlivých tříd, $\omega_{0,1,2}$ – pravděpodobnost každého regionu.

Pro nalezení optimálního nastavení umístění těžišť fuzzy funkcí příslušnosti je fitness funkce maximalizována [21, 38]:


$$f_{Kapur}(th_1, th_2, \dots, th_n) = \operatorname{argmax}\{H(th_1, th_2, \dots, th_n)\} \quad (12)$$

3 Rešerše aplikací evolučních algoritmů pro segmentaci obrazových dat

3.1 Diferenciální evoluce (angl. Differential evolution (DE))


Pro vyhledání rešeršních článků byla použito následujících parametrů: klíčová slova: differential evolution, medical image, segmentation; databáze: Web of Science; časové rozpětí 1945 až 2021; nalezeno článků: 125

Thomaz et al. [39] zkoumali efektivitu segmentování snímků jater pořízených pomocí CT. Tento úkol představuje komplexní problém, protože játra se svými jasovými vlastnostmi velmi podobají okolním tkáním, a navíc na ně tyto tkáně těsně naléhají. Algoritmus DE byl použit pro nalezení optimálních poloh pro inicializační body (seedy) algoritmu pro růst regionu. Při tomto řešení bylo dosaženo u 7 z 10 datasetů úspěšnosti nad 85 %. U zbývajících datasetů bylo rozpětí falešné pozitivivity od 38 % do 63 %. Jak je vidět na Obr. 18, u některých snímků byly seedy zasazeny do břišního svalu a u některých mířily spíše k tumoru v bezprostřední blízkosti jater. Celkově však metoda dle autorů dosáhla přijatelných výsledků a dalším laděním algoritmu by mohla dosáhnout přesnějších a robustnějších výsledků.



Obr. 18: Výsledky optimalizace umístění inicializačních bodů pro metodu růstu regionu [39].

V [40] se Fan et al. zabývali automatickou detekcí mléčné žlázy. Efektivita segmentace byla posuzována na základě podobnosti s obrazem segmentovaným expertem. Hlavním sledovaným algoritmem byl algoritmus založený na DE fuzzy entropii, ale pro porovnání byly použity i další fuzzy evoluční algoritmy fungující na principu PSO, BFO (Bacterial Foraging Optimization), ABC, BAT (Bat Algorithm) a Firefly. Algoritmus založený na principu DE dosáhl v konkurenci ostatních metod jasně nejlepších výsledků. Obrazový výstup z tohoto článku lze vidět na Obr. 19.




Obr. 19: Výsledky segmentace mléčné žlázy. Obraz na kraji vlevo byl segmentován expertem a použit jako zlatý standard [40].

3.2 Optimalizace rojem včel (angl. Artificial Bee Colony – ABC)

Pro vyhledání rešeršních článků byla použito následujících parametrů: klíčová slova: ABC, medical image, segmentation; databáze: Web of Science; časové rozpětí 1945 až 2021; nalezeno článků: 46

Hancer et al. [41] provedli porovnání algoritmu ABC s metodami K-means, FCM a GA. K-means a FCM byly zvoleny, protože se jedná o nejčastější shlukovací algoritmy a GA je zase velmi populární na poli evolučních algoritmů. Pracováno bylo s MRI snímky hlavy a hlavním cílem byla úspěšná segmentace a extrakce tumoru.



Obr. 20: Výsledky segmentace. Zleva: Originální obraz, metoda ABC, K-means, FCM [41].



Obr. 21: Extrahovaný tumor. Zleva: ABC, K-means, FCM [41].


Z publikovaných výsledků je patrné, že segmentace založená na ABC překonala ostatní metody ve skoro všech případech (na Obr. 21 lze vidět jen malý výběr z publikovaných výsledků). K-means ani FCM nebyly schopny poskytnou oproti ABC a GA dobré výsledky. Na základě prezentovaných výstupů článku je testovaný algoritmus založený na ABC podle autorů vhodný k segmentaci MRI obrazových dat.

Hassanien et al. [42] se zabývali segmentací retinálních cév. Využili k tomu ABC optimalizaci, FCM a PS (Pattern search). Ačkoli mají snímky pořízené fundus kamerou vysoké rozlišení, celkový kontrast je mezi objekty v obraze obvykle velmi nízký. Z toho důvodu autoři využili dvou stupňů optimalizace, kdy v první fázi byly pomocí ABC a FCM nalezeny hrubé cévy. Jelikož jemná zakončení cév mají tendenci splývat s pozadím, využili také druhého stupně optimalizace, kdy pomocí PS došlo na základě tvaru k vylepšení výsledků ABC. Zatímco PS je robustním řešením pro lokální optimalizaci, ABC je zaměřen na globální optimalizaci a dobře se tak doplňují. Dosažené výsledky ukazují, že toto řešení je srovnatelné s v současné době nejefektivnějšími metodami, co se týče senzitivity, specificity a přesnosti. Příklad výsledků lze vidět na Obr. 22.




Obr. 22: Výsledky segmentace pomocí metody ABC-PS. První sloupec – původní snímky, druhý sloupec – výsledky segmentace [42].

Ali et al. [43] se zabývali segmentací jater z CT snímku pomocí ABC algoritmu vylepšeného pomocí metody růstu regionu. Celý obraz byl v prvním kroku segmentován do velkého množství shluků reprezentující jednotlivé centeroidy jasových hodnot. Různými morfologickými operacemi bylo docíleno vzniku binárního obrazu, který byl následně přenásoben originálním obrazem a poté zpracován růstem regionu (Obr. 24). Tento přístup dosáhl lepších výsledků než samostatný Růst regionu, Level set a K-means vylepšený taktéž Růstem regionu.



Obr. 23: Binarizovaný obraz (b) byl přenásoben původním obrazem (a) a výsledkem je obraz (c) [43].




Obr. 24: Výsledek segmentace. Na obraz (c) z Obr. 19 byl aplikován Růst oblasti [43].

3.3 Optimalizace rojem částic (angl. Particle Swarm Optimization – PSO)

Pro vyhledání rešeršních článků byla použito následujících parametrů: klíčová slova: particle swarm optimization, medical image, segmentation; databáze: Web of Science; časové rozpětí 2016 až 2021; nalezeno článků: 115


V posledních pěti letech se PSO ukazuje jako zajímavá metoda pro segmentaci medicínských obrazových dat. Od svého vzniku v roce 1995 eviduje databáze WoS 196 článků týkající se segmentace pomocí PSO a z tohoto počtu jich 115 vyšlo v posledních pěti letech.

PSO je možné použít pro detekci hran na základě hledání globálního prahu. V [35] bylo nastaveno 400 částic, setrvačnost 2 a počet iterací 200. Výsledky lze vidět na Obr. 25.



Obr. 25: Výsledky z článku [35]; (a) Původní obrázky, (b) Segmentace provedená běžným grafickým editorem, (c-d) Segmentace pomocí PSO ((c) – počet iterací 200, (d) – počet iterací autoři neuvádí) [35].

V [30] byl u PSO a SFLA upraven algoritmus fitness funkce a oba algoritmy byly aplikovány na MRI snímky mozku. SFLA je jednou z metod fungující na principu SI (Swarm intelligence). Zkratka SFLA znamená Shuffled Frog Leaping Algorithm.



Obr. 26: Výsledek z článku [30]; (a) Originální MRI snímek mozku, (b) Segmentovaný snímek pomocí PSO [30].


Aplikace PSO velice často souvisí s kombinací s jinou metodou. Takto vzniklé hybridní algoritmy většinou dosahují kvalitnějších anebo alespoň rychlejších výsledků. Lepších výsledků nemusí být dosaženo jen vzájemnou kombinací vlastností obou metod, ale také vylepšení nebo tvorba různých algoritmů, které upravují vstupní parametry metod.

V [44] byla PSO zkombinována s klasickou regionální metodou segmentace, kterou byla metoda Otsu, a došlo ke zrychlení algoritmu o 25 až 68 % vůči porovnávaným metodám. V [36] byla provedena kombinace FCM a PSO za účelem segmentace infračervených snímků. Hlavní myšlenkou pro tvorbu této kombinace bylo to, že FCM je algoritmus, který se zabývá hledáním lokálního optima, zatímco PSO standardně slouží k nalezení globálního optima. Experimentální metoda dosáhla lepších výsledků než Otsu prahování a algoritmus založený na GA. V [33] autoři vylepšili PSO o faktor komprese (compression factor) a regionální equilibrium (Region equilibrium). Standardní PSO může mít tendenci předčasně konvergovat k lokálnímu optimu a tomu se autoři pokusili předejít právě pomocí výše zmíněných vylepšení. Ve výsledku se hodnoty optimálních prahů příliš nezměnily, ale došlo k výraznému zrychlení konvergence.

Tab. 1: Výsledky z článku [33]; AW-PSO je konkurenční metoda a HRC-PSO je metoda autorů.

| Image | AW-PSO | | HRC-PSO | |
|-------|--------------------|-------|--------------------|-------|
| | The threshold time | | The threshold time | |
| (a) | (90,147) | 0.423 | (90,147) | 0.071 |
| (b) | (66,140) | 0.386 | (60,140) | 0.062 |
| (c) | (82,138) | 0.365 | (82,138) | 0.058 |

V [45] byla řešena detekce nádorů plic pomocí algoritmu PSO-SGNF, který je kombinací PSO a SGNF, což je metoda založená na neuronových sítích. Metoda vůči zlatému standardu vytvořenému experty dosáhla 88,9% překrytí pixelů. PSO v této metodě slouží k nalezení optimálních inicializačních bodů, podle kterých se formují jednotlivé clustery. Výsledek lze vidět na Obr. 27.




Obr. 27: Výsledky z článku [45]; (a) Snímek nádoru plic a okolí, (b) Průběh nalézání řešení, (c) Výsledek segmentace, (d) Finální oblast nádoru [45].


3.4 Genetický algoritmus (angl. Genetic algorithm – GA)

Pro vyhledání rešeršních článků byla použito následujících parametrů: klíčová slova: genetic algorithm, medical image, segmentation; databáze: Web of Science; časové rozpětí 1945 až 2021; nalezeno článků: 3619

Vikram et al. [46] aplikovali GA na MRI snímky hlavy a experimentovali jak s různými nastaveními vstupních parametrů genetického algoritmu, tak s počtem segmentačních prahů. Při nastavení počtu prahů n je obraz segmentován do $n+1$ tříd. Různá nastavení velikosti populace příliš výsledky neovlivnila. Maximální hodnota jasové intenzity byla nastavena na 255, tedy 256 úrovní šedé. Zvyšováním počtu iterací postupně došlo k vylepšení výsledků, pokud je úroveň kontrastu v obraze nízká. Na Obr. 28 lze vidět výsledky segmentace při různém počtu segmentačních prahů.



Obr. 28: Výsledky segmentace pomocí GA při různém počtu prahů, Zleva: Originální obraz, 2 prahy, 5 prahů, 10 prahů [46].



Obr. 29: Výsledky segmentace MRI snímku mozku pomocí GA při různém počtu prahů v obraze s velmi nízkým kontrastem mezi šedou a bílou hmotou mozkovou. Zleva: Originální obraz, 2 prahy, 5 prahů, 10 prahů [46].

Na Obr. 29 je i okem patrné, že segmentace dosáhla velice dobrého výsledku i v případě, u kterého by běžné konvenční segmentační metody neuspěly.

V [47] Yong Fan et al. segmentovali ventriculi laterales pomocí paralelního genetického algoritmu. Rozdíl oproti klasickému GA spočívá v tom, že pro nalezení optimálního řešení se využívá více subpopulací, které se iteračně vylepšují samostatně pomocí genetických operátorů (křížení, mutace, selekce) a periodicky si mezi sebou vyměňují nejlepší jedince pomocí operátoru migrace. Podle [48] tak PGA dosahuje kvalitnějších a robustnějších výsledků, než GA. Metoda popsaná v [47] mimo PGA pracuje také s aktivní konturou. Presentovaná metoda dosáhla velice kvalitních výsledků, jejichž příklad je zobrazen na Obr. 30.




Obr. 30: Výsledky segmentace mozkových komor pomocí algoritmu z článku [47].

3.5 Optimalizace mravenčí kolonií (ang. Artificial Ant Colony – AAC)


Pro vyhledání rešeršních článků byla použito následujících parametrů: klíčová slova: artificial ant colony, medical image, segmentation; databáze: Web of Science; časové rozpětí 1945 až 2021; nalezeno článků: 19

V [49] Huang et al. zkoumali efektivitu AAC algoritmu na MRI snímcích hlavy a získali velmi kvalitní výsledky. Z výsledků v článku je patrné, že algoritmus AAC je velmi robustní vůči šumu a je tedy vhodný pro segmentaci obrazu.



Obr. 31: Segmentace MRI snímku mozku pomocí AAC algoritmu. První obraz je původní obraz a zbývající obrazy jsou výstupy vzestupného počtu iterací [49].

V [50] Selmani et al. pomocí AAC segmentovali maligní nádorové buňky. Metoda byla schopna nalézt více buněk než expert. Příklad je na Obr. 32.



Obr. 32: Segmentace maligních nádorových buněk pomocí AAC [50].

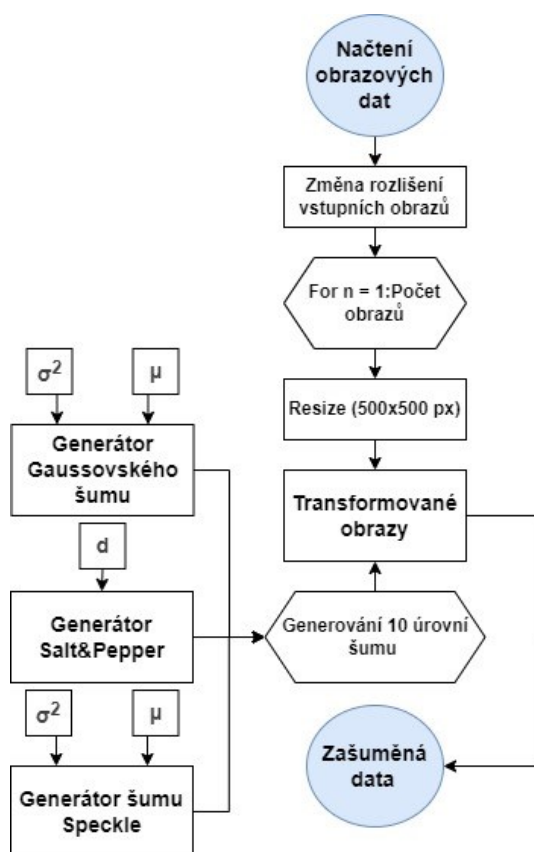
4 Tvorba datové báze pro testování, typy šumu, princip testování a popis použitých evaluačních metod

4.1 Tvorba datové báze pro testování

Jako základ testovacího prostředí bylo využito 60 obrazů, které tvoří základní kámen 3 datasetů. Každý z datasetů byl sestaven z 20 obrazů a následně na každý z těchto obrazů byly přidány 3 typy šumu o 10 úrovních s parametry shodnými napříč datasety. Parametry byly nastaveny následovně:

- pro Gaussovský šum byla nastaven rozptyl na hodnotu 0,01 a střední hodnota v rozmezí 0,02 až 0,2 s krokem 0,02,
- u šumu Salt&Pepper byl parametr hustoty nastaven v rozmezí 0,01 až 0,1 s krokem 0,01
- u šumu Speckle byla střední hodnota nastavena na 0 a rozptyl v rozmezí 0,01 až 0,1 s krokem 0,01.

Princip přípravy obrazů pro testování je zobrazen na Obr. 33.



Obr. 33: Princip zašumění nativních obrazových dat [Zdroj vlastní].


Datasety zahrnují hned několik zobrazovacích metod, podle kterých byly datasety zároveň pojmenovány. Jedná se to datasety, MRI – snímky z magnetické rezonance, UZV – ultrazvukové snímky a dataset Retina, který je sestaven ze snímků očního pozadí pořízených fundus kamerou. Nativní snímky z jednotlivých datasetů je možné si prohlédnout na Obr. 34, Obr. 35 a Obr. 36.



Obr. 34: Ukázka dat z datasetu MRI (tumory mozku) [Zdroj vlastní].



Obr. 35: Ukázka dat z datasetu Retina (retinální cévy na očním pozadí) [Zdroj vlastní].



Obr. 36 Ukázka dat z datasetu UZV (benigní nádory prsu) [Zdroj vlastní].

4.1.1 Vybrané typy šumu v medicínských obrazech


Šum je nežádoucí a informačně prázdnu intenzitní odchylkou jasů, která vzniká při akvizici obrazu. Vlivem dochází ke zhoršení kvality obrazu, čímž může dojít k omezení informační hodnoty snímku. Tato ztráta kvality je o to horší, pokud je obraz málo kontrastní a hodnoty šumu jsou vysoké. Vlastnosti šumu jsou závislé na jeho fyzikálním původu. V kontextu této práce je obrazový šum problém zejména protože segmentační algoritmy pracují nejčastěji na základě zpracování jasové matice obrazu a vzhledem k tomu, že šum do této jasové matice zanáší jasové hodnoty, které tam nemají být, může dojít k negativnímu ovlivnění segmentačních výsledků.

Gaussovský šum


Je to nejčastěji vyskytující se aditivní šum. Charakterizuje jej normálním rozložením pravděpodobnosti. Tento šum pokrývá celou plochu obrazu. Gaussovský šum je výsledkem fyzikálních procesů, jakými jsou například tepelná vibrace atomů. Lze jej popsat jako:

$$P(z) = \frac{1}{\sqrt{2\pi\sigma^2}} \cdot e^{-\frac{(z-m)^2}{2\sigma^2}} \quad (13)$$


Kde $P(z)$ je pravděpodobnost výskytu hodnoty stupně šedi z , m je střední hodnota a směrodatnou odchylku šumu označuje σ . Příklad tohoto šumu v biomedicínských obrazech je vyobrazen



Obr. 37: Ukázka dat z datasetu MRI po aplikaci Gaussovského šumu, Zleva: Nativní obraz; $\sigma^2 = 0.01$, $\mu = 0.1$; $\sigma^2 = 0.01$, $\mu = 0.2$ [Zdroj vlastní].



Obr. 38: Ukázka dat z datasetu Retina po aplikaci Gaussovského šumu, Zleva: Nativní obraz; $\sigma^2 = 0.01$, $\mu = 0.1$; $\sigma^2 = 0.01$, $\mu = 0.2$ [Zdroj vlastní].



Obr. 39: Ukázka dat z datasetu UZV po aplikaci Gaussovského šumu, Zleva: Nativní obraz; $\sigma^2 = 0.01$, $\mu = 0.1$; $\sigma^2 = 0.01$, $\mu = 0.2$ [Zdroj vlastní].

Šum Salt&Pepper

Salt&Pepper je impulzní šum, který se na snímku vyskytuje ve dvou intenzitách. Pixely jsou tímto šumem zasaženy buďto maximální nebo minimální hodnotou v závislosti na typu přenosu obrazu. Pro 8bitový obraz nabývá hodnot 0 a 255. Obraz degradovaný tímto typem šumu obsahuje bílé a černé pixely rozprostřené v závislosti na parametru d , který definuje hustotu šumu.

Příklad degradace dat tímto typem šumu je zobrazen na Obr. 40, kdy je zasažena prostřední hodnota matice. Tento pixel se bude v obraze jevit jako černá tečka. V opačném případě, kdy by byl pixel při hodnotě 255 zbarven čistě bílou barvou.


$$\begin{bmatrix} 231 & 215 & 134 \\ 106 & 246 & 59 \\ 21 & 85 & 49 \end{bmatrix} \rightarrow \begin{bmatrix} 231 & 215 & 134 \\ 106 & 0 & 59 \\ 21 & 85 & 49 \end{bmatrix}$$

Obr. 40: Příklad centrálního pixelu zasaženého šumem typu Salt&Pepper [51]

Ukázky tohoto typu šumu na jednotlivých datasetech jsou zobrazeny na Obr. 41 až Obr. 42. Každý obrázek obsahuje tři snímky zahrnující původní nativní obraz a dvojici zašuměných obrazů s parametry šumu uvedenými v titulku.



Obr. 41: Ukázka dat z datasetu MRI po aplikaci šumu Salt&Pepper, Zleva: Nativní obraz; $d = 0.05$, $d = 0.1$ [Zdroj vlastní].



Obr. 42: Ukázka dat z datasetu Retina a UZV po aplikaci šumu Salt&Pepper, Zleva: Nativní obraz; $d = 0.05$, $d = 0.1$ [Zdroj vlastní].

Šum Speckle

Šum typu speckle je charakteristický zejména pro ultrazvukové zobrazování. Projevuje se jako světlé i tmavé body, které vznikají po interferenci ultrazvukových vln odražených z různých míst v tkáních. Pokud ultrazvuková vlna při průchodu tkání narazí na částici, které je menší než vlnová délka vlny, dojde k částečnému pohlcení energie vlny částicí, například červenou krvinkou, a následnému vyzáření této energie formou vlnoploch, které spolu interferují. Jedná se o náhodný šum, ale při dvojitém měření jednoho objektu při stejných podmínkách, jako je například úhel snímání, je vzor šumu stejný.

$$P(z) = \frac{z^{\alpha-1}}{(\alpha-1)! \cdot a^\alpha} \cdot e^{-\frac{z}{a}} \quad (14)$$

Kde $P(z)$ je rozdělení pravděpodobnosti, z je zastoupení stupnice jasu a a^α označuje odchylku.


Ukázky tohoto typu šumu na jednotlivých datasetech jsou zobrazeny na Obr. 43 až Obr. 45. Každý obrázek obsahuje tři snímky zahrnující původní nativní obraz a dvojici zašuměných obrazů s parametry šumu uvedenými v titulku.



Obr. 43: Ukázka dat z datasetu MRI po aplikaci šumu Speckle; Zleva: Nativní obraz, $\sigma^2 = 0.05$, $\mu = 0$; $\sigma^2 = 0.1$, $\mu = 0$ [Zdroj vlastní].



Obr. 44: Ukázka dat z datasetu Retina po aplikaci šumu Speckle; Zleva: Nativní obraz, $\sigma^2 = 0.05$, $\mu = 0$; $\sigma^2 = 0.1$, $\mu = 0$ [Zdroj vlastní].



Obr. 45: Ukázka dat z datasetu UZV po aplikaci šumu Speckle; Zleva: Nativní obraz, $\sigma^2 = 0.05$, $\mu = 0$; $\sigma^2 = 0.1$, $\mu = 0$ [Zdroj vlastní].

4.2 Metody objektivního hodnocení kvality výsledných dat

4.2.1 Pearsonův korelační koeficient

Korelace je vyjádřením vzájemné linearity mezi dvěma proměnnými. Jedná se o bezrozměrný parametr, který v rámci zpracování obrazu nabývá hodnot na intervalu $[-1;1]$. Hodnota 1 znamená, že oba obrazy jsou totožné. Principem je vypočet rozdílnosti intenzitních hodnot každého pixelu v obou obrazech vůči celkové průměrné intenzitě celého obrazu.

4.2.2 Střední kvadratická odchylka (angl. Mean Squared Error – MSE)

Je to průměrná kvadratická chyba mezi dvěma daty. Využívá se často, ale hodí se zejména jako doplněk jiným hodnotícím metodám, neboť z výsledků MSE není možné úplné posouzení kvality. Jedná se o bezrozměrný parametr, jehož výsledek je nezáporný a je žádoucí co nejnižší hodnota. Definiční obor není nijak vymezen.

MSE počítá výsledek z kvadratického rozdílu hodnot mezi referenčním a hodnoceným obrazem. Popsat ji lze jako [52]:

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (p_{i,j} - f_{i,j})^2 \quad (15)$$

kde $p_{i,j}$ jsou hodnoty hodnoceného obrazu a $f_{i,j}$ jsou hodnoty referenčního obrazu. M a N jsou rozměry okenní funkce.

4.2.3 Index strukturální podobnosti (angl. Structural Similarity Index Measure – SSIM)

SSIM je metoda, která modeluje vnímanou kvalitu obrazu. Používá se pro měření podobnosti mezi referenčním a hodnoceným obrazem. SSIM obrazovou degradaci popisuje jako strukturální změnu, ale počítá také s jasnem a kontrastem. Dynamický rozsah SSIM je definován na intervalu $[-1;1]$. Matematický popis jest [53]:

$$SSIM = \frac{(2\bar{x}\bar{y} + c_1) \cdot (2\sigma_{xy} + c_2)}{(\bar{y}^2 + \bar{x}^2 + c_1) \cdot (\sigma_y^2 + \sigma_x^2 + c_2)} \quad (16)$$

Kde: L – Dynamický rozsah pixelů v obraze (256 hodnot)

c_1, c_2 – stabilizační konstanty:

$$c_1 = (k_1 \cdot L)^2$$

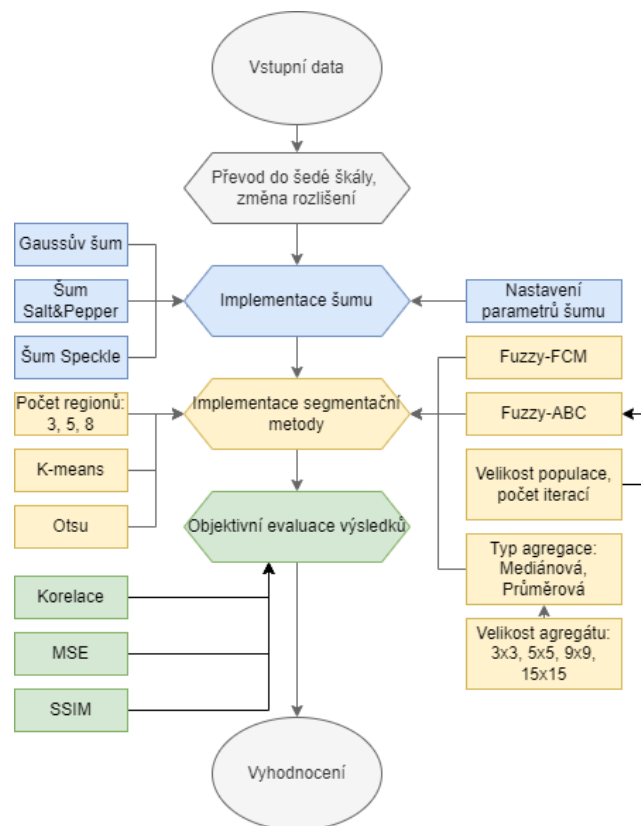
$$c_2 = (k_2 \cdot L)^2$$

$$k_1 = 0.01; k_2 = 0.03$$

4.3 Princip hodnocení výsledků a nastavení testování

V rámci testování F-FCM algoritmu bylo v každém datasetu testováno celkem 200 obrazů (20 obrazů x 10 úrovní šumu) a v případě Fuzzy-ABC algoritmu to bylo 50 obrazů (5 obrazů x 10 úrovní šumu).

V rámci každého datasetu byly testovány tři typy šumu popsané výše. Každý obraz byl zašuměn 10 intenzitami od každého typu šumu. Následně byl každý obraz podroben segmentaci prostřednictvím každého z testovaných algoritmu: F-FCM, Fuzzy-ABC, K-means, Otsu. Společným nastavením pro všechny algoritmy byl počet požadovaných výsledných segmentačních regionů. Jedná se o jediné nastavení, které se provádí u K-means a Otsuovy metody. U dvojice fuzzy algoritmů se navíc nastavuje velikost a typ agregace. U Fuzzy-ABC algoritmu je ještě nastavuje velikost populace, která představuje množinu řešení optimalizačního problému, a počet iterací, během kterých se algoritmus pokouší najít co nejoptimálnější řešení. Přehled nastavení jednotlivých metod je možné vidět v Tab. 1 a blokové schéma principu testování na Obr. 46.



Obr. 46: Blokové schéma principu testování a evaluace výsledků analýz

Tab. 1: Přehled nastavení jednotlivých metod

| | Počet regionů: | Typ agregace: | Velikost agregace | Počet iterací: | Velikost populace: |
|----------------|----------------|---------------|-------------------|----------------|--------------------|
| Otsuova metoda | 3, 5, 8 | - | | - | - |
| K-means | 3, 5, 8 | - | | - | - |
| F-FCM | 3, 5, 8 | průměrová | 3x3 | - | - |
| | | | 5x5 | | |
| | | | 9x9 | | |
| | | | 15x15 | | |
| | | mediánová | 3x3 | | |
| | | | 5x5 | | |
| | | | 9x9 | | |
| | | | 15x15 | | |
| Fuzzy-ABC | 3, 5, 8 | průměrová | 3x3 | 50 | 100 |
| | | | 5x5 | 100 | 200 |
| | | | 9x9 | 200 | 500 |
| | | | 15x15 | | |
| | | mediánová | 3x3 | 50 | 100 |
| | | | 5x5 | 100 | 200 |
| | | | 9x9 | 200 | 500 |
| | | | 15x15 | | |

5 Výsledky testování – Globální evaluace efektivity metod


Vzhledem k velkému množství výsledných dat byla tato data zprůměrována a vložena do sumarizačních tabulek. Každý řádek sumarizační tabulky obsahuje průměrnou hodnotu jednotlivých evaluačních parametrů vytvořenou ze všech výsledků testování pro všechna nastavení parametrů pro každou z metod.

5.1 Dataset MRI


5.1.1 Gaussovský šum

Tab. 2: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.8285 | 1.2476 | 0.9574 | 0.0247 | 0.0154 |
| K-means | 0.6364 | 2.6032 | 0.9029 | 0.1138 | 0.0566 |
| Fuzzy-ABC (Med. agregace) | 0.6436 | 0.4948 | 0.9740 | 0.0648 | 0.0110 |
| Fuzzy-ABC (Prům. agregace) | 0.6565 | 0.4477 | 0.9752 | 0.0656 | 0.0134 |
| F-FCM (Med. agregace) | 0.9038 | 0.6585 | 0.9829 | 0.0258 | 0.0071 |
| F-FCM (Prům. agregace) | 0.9523 | 0.2726 | 0.9933 | 0.0109 | 0.0034 |



Obr. 47: Segmentační masky snímku z datasetu MRI, **K-means**, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 48: Segmentační masky snímku z datasetu MRI, **Fuzzy-ABC** algoritmus, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 49: Segmentační masky snímku z datasetu MRI, **F-FCM** algoritmus, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 2 je patrné, že globálně dosahuje v datasetu MRI při zatížení Gaussovským šumem nejlepších výsledků F-FCM algoritmus s průměrovou agregací, a to ve všech evaluačních parametrech. S mediánovou agregací dosáhl tento algoritmus o něco horších, ale stále dobrých výsledků. Naopak nejhorších výsledků dosahuje ve všech parametrech konvenční metoda K-means.


Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM i Otsuova metoda, ale z hlediska MSE dosahuje pro obě agregace nejlepších výsledků. Byť je rozdíl korelace Otsu a Fuzzy-ABC algoritmu poměrně velký, z hlediska SSIM dosahuje Fuzzy-ABC lepších výsledků.

Z výstupních segmentačních map na Obr. 47, Obr. 48 a Obr. 49 je i okem patrné, že F-FCM metoda byla schopná napříč všemi počty regionů dosáhnout nejpřesnějších výsledků vůči segmentaci nativního obrazu, která sloužila jako zlatý standard.


5.1.2 Šum Salt&Pepper

Tab. 3: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.7984 | 0.7817 | 0.9835 | 0.0324 | 0.0048 |
| K-means | 0.7446 | 0.9384 | 0.9631 | 0.1070 | 0.0364 |
| Fuzzy-ABC (Med. agregace) | 0.7958 | 0.5357 | 0.9718 | 0.0817 | 0.0156 |
| Fuzzy-ABC (Prům. agregace) | 0.7735 | 0.5438 | 0.9706 | 0.0839 | 0.0161 |
| F-FCM (Med. agregace) | 0.9697 | 0.1533 | 0.9962 | 0.0116 | 0.0049 |
| F-FCM (Prům. agregace) | 0.9735 | 0.1212 | 0.9969 | 0.0096 | 0.0043 |



Obr. 50: Segmentační masky snímku z datasetu MRI, **K-means**, Šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 51: Segmentační masky snímku z datasetu MRI, **Fuzzy-ABC** algoritmus, Šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 52: Segmentační masky snímku z datasetu MRI, **F-FCM**, Šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 3 je patrné, že globálně dosahuje v datasetu MRI při zatížení šumem Salt&Pepper nejlepších výsledků F-FCM algoritmus s průměrovou agregací, a to ve všech evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve všech parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM i Otsuova metoda. Zatímco u předchozího typu šumu dosáhl Fuzzy-ABC nejlepších hodnot MSE, v tomto případě jsou tyto výsledky horší než u F-FCM, ale stále lepší než u Otsu a K-means.

Otsuova metoda zde překonává v parametru SSIM Fuzzy-ABC algoritmus, K-means, ale je stále horší, než F-FCM.


Z výstupních segmentačních map na Obr. 50, Obr. 51 a Obr. 52 je patrné, že nejhorších segmentačních výstupů dosáhla metoda K-means. Nejlepšího výsledku opět dosáhla metoda F-FCM, ale jedná se o srovnatelné výsledky s Fuzzy-ABC. Obě metody si však dokázaly dobře poradit s šumem narozdíl od konvenční metody K-means.

F-FCM metoda byla schopná napříč všemi počty regionů dosáhnout nejpřesnějších výsledků vůči segmentaci nativního obrazu, která sloužila jako zlatý standard.


5.1.3 Šum Speckle

Tab. 4: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.9267 | 0.2961 | 0.9937 | 0.0127 | 0.0036 |
| K-means | 0.7912 | 0.7611 | 0.9675 | 0.0964 | 0.0340 |
| Fuzzy-ABC (Med. agregace) | 0.8120 | 0.2332 | 0.9917 | 0.0940 | 0.0071 |
| Fuzzy-ABC (Prům. agregace) | 0.8342 | 0.1714 | 0.9936 | 0.1061 | 0.0078 |
| F-FCM (Med. agregace) | 0.9335 | 0.3992 | 0.9915 | 0.0202 | 0.0057 |
| F-FCM (Prům. agregace) | 0.9677 | 0.1720 | 0.9966 | 0.0089 | 0.0038 |



Obr. 53: Segmentační masky snímku z datasetu MRI, **K-means**, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 54: Segmentační masky snímku z datasetu MRI, **Fuzzy-ABC** algoritmus, Šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: 3, 5 a 8 seg. tříd



Obr. 55: Segmentační masky snímku z datasetu MRI, **F-FCM** algoritmus, Šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, nativní zašuměný snímek, zleva: 3, 5 a 8 seg. tříd

Z Tab. 4 je patrné, že globálně dosahuje v datasetu MRI při zatížení šumem Speckle nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve všech parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM i Otsuova metoda. Nejlepší hodnoty MSE zde dosahuje Fuzzy-ABC algoritmus pro oba typy agregací i vůči F-FCM algoritmu.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Algoritmy Fuzzy-ABC a Otsuova metoda dosahují podobných výsledků.

Z výstupních segmentačních map na Obr. 53, Obr. 54 a Obr. 55 je patrné, že nejhorších segmentačních výstupů dosáhla metoda K-means. Nejlepšího výsledku opět dosáhla metoda F-FCM. Na rozdíl od předchozího případu zde nelze ohodnotit výsledky Fuzzy-ABC a F-FCM za srovnatelné. Na základě výstupu F-FCM by bylo stále možné poměrně dobře extrahovat tumor z centrální části snímku. U Fuzzy-ABC by toto nebylo možné. F-FCM algoritmus dokázal lépe překonat vliv šumu.


F-FCM metoda byla schopná napříč všemi počty regionů dosáhnout nejpřesnějších výsledků vůči segmentaci nativního obrazu, která sloužila jako zlatý standard.

5.2 Dataset UZV


5.2.1 Gaussovský šum

Tab. 5: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.8701 | 0.9005 | 0.9744 | 0.0406 | 0.0104 |
| K-means | 0.7142 | 1.3012 | 0.9645 | 0.1371 | 0.0361 |
| Fuzzy-ABC (Med. agregace) | 0.7323 | 0.8790 | 0.9658 | 0.0799 | 0.0099 |
| Fuzzy-ABC (Prům. agregace) | 0.7680 | 0.7625 | 0.9691 | 0.0682 | 0.0101 |
| F-FCM (Med. agregace) | 0.9245 | 0.5411 | 0.9873 | 0.0336 | 0.0107 |
| F-FCM (Prům. agregace) | 0.9577 | 0.2200 | 0.9941 | 0.0200 | 0.0034 |



Obr. 56: Segmentační masky snímku z datasetu UZV, **K-means**, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 57: Segmentační masky snímku z datasetu UZV, **Fuzzy-ABC** algoritmus, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: 3, 5 a 8 seg. tříd



Obr. 58: Segmentační masky snímku z datasetu UZV, **F-FCM** algoritmus, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 5 je patrné, že globálně dosahuje v datasetu UZV při zatížení Gaussovským šumem nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve všech parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM i Otsuova metoda. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Algoritmy Fuzzy-ABC a Otsuova metoda i K-means dosahují podobných výsledků.


Z výstupních segmentačních map na Obr. 56, Obr. 57 a Obr. 58 je patrné, že nejhorších segmentačních výstupů dosáhla metoda K-means.

Na základě podobnosti segmentovaného snímku a zlatého standardu dosáhla nejlepších výsledků metoda F-FCM. V úloze extrakce nádoru v centrální části snímku ale lepšího výsledku dosáhla metoda Fuzzy-ABC.


5.2.2 Šum Salt&Pepper

Tab. 6: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.8592 | 0.7628 | 0.9849 | 0.0319 | 0.0044 |
| K-means | 0.7560 | 1.2952 | 0.9608 | 0.1313 | 0.0428 |
| Fuzzy-ABC (Med. agregace) | 0.8641 | 0.5026 | 0.9831 | 0.0658 | 0.0093 |
| Fuzzy-ABC (Prům. agregace) | 0.8815 | 0.4043 | 0.9854 | 0.0591 | 0.0086 |
| F-FCM (Med. agregace) | 0.9802 | 0.1104 | 0.9973 | 0.0122 | 0.0017 |
| F-FCM (Prům. agregace) | 0.9809 | 0.0668 | 0.9981 | 0.0085 | 0.0014 |



Obr. 59: Segmentační masky snímku z datasetu UZV, **K-means**, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. Tříd



Obr. 60: Segmentační masky snímku z datasetu UZV, **Fuzzy-ABC** algoritmus, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 61: Segmentační masky snímku z datasetu UZV, **F-FCM**, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 6 je patrné, že globálně dosahuje v datasetu UZV při zatížení šumem Salt&Pepper nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve všech parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Algoritmy Fuzzy-ABC a Otsuova metoda dosahují podobných výsledků. Otsu v tomto parametru překonává mediánovou agregaci Fuzzy-ABC.


Z výstupních segmentačních map na Obr. 59, Obr. 60 a Obr. 61 je patrné, že nejhorších segmentačních výstupů dosáhla metoda K-means.

Na základě podobnosti segmentovaného snímku a zlatého standardu dosáhla nejlepších výsledků metoda F-FCM. V úloze extrakce nádoru v centrální části snímku by metody F-FCM i Fuzzy-ABC dosáhly podobných výsledků.


5.2.3 Šum Speckle

Tab. 7: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.8959 | 0.5933 | 0.9888 | 0.0214 | 0.0036 |
| K-means | 0.7964 | 0.9656 | 0.9744 | 0.1185 | 0.0326 |
| Fuzzy-ABC (Med. agregace) | 0.7958 | 0.6475 | 0.9831 | 0.0650 | 0.0091 |
| Fuzzy-ABC (Prům. agregace) | 0.8798 | 0.2827 | 0.9908 | 0.0418 | 0.0045 |
| F-FCM (Med. agregace) | 0.8815 | 0.9710 | 0.9819 | 0.0325 | 0.0080 |
| F-FCM (Prům. agregace) | 0.9582 | 0.2151 | 0.9958 | 0.0128 | 0.0018 |



Obr. 62: Segmentační masky snímku z datasetu UZV, **K-means**, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 63: Segmentační masky snímku z datasetu UZV, **Fuzzy-ABC** algoritmus, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 64: Segmentační masky snímku z datasetu UZV, **F-FCM**, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 7 je patrné, že globálně dosahuje v datasetu UZV při zatížení šumem Speckle nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve většině parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM. Otsuova metoda dosahuje lepší úrovně korelace než K-means, oba typy agregací u Fuzzy-ABC a mediánová agregace F-FCM. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Fuzzy-ABC pro oba typy agregací dosahuje lepší hodnoty SSIM než F-FCM s mediánovou agregací. Otsuova metoda dosahuje lepšího SSIM než mediánové agregace F-FCM a Fuzzy-ABC.

Z výstupních segmentačních map na Obr. 62, Obr. 63 a Obr. 64 je patrné, že nejhorších segmentačních výstupů dosáhla metoda K-means.


Na základě podobnosti segmentovaného snímku a zlatého standardu dosáhla nejlepších výsledků metoda F-FCM. V úloze extrakce nádoru v centrální části snímku by metody F-FCM i Fuzzy-ABC dosáhly podobných výsledků.

5.3 Dataset Retina


5.3.1 Gaussovský šum

Tab. 8: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.7701 | 1.2594 | 0.9676 | 0.0315 | 0.0098 |
| K-means | 0.7160 | 1.5837 | 0.9450 | 0.0855 | 0.0293 |
| Fuzzy-ABC (Med. agregace) | 0.6037 | 0.7407 | 0.9571 | 0.0953 | 0.0320 |
| Fuzzy-ABC (Prům. agregace) | 0.6123 | 0.7215 | 0.9564 | 0.0927 | 0.0320 |
| F-FCM (Med. agregace) | 0.8240 | 1.4415 | 0.9595 | 0.0525 | 0.0187 |
| F-FCM (Prům. agregace) | 0.9241 | 0.3368 | 0.9915 | 0.0222 | 0.0043 |



Obr. 65: Segmentační masky snímku z datasetu Retina, **K-means**, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 66: Segmentační masky snímku z datasetu Retina, **Fuzzy-ABC** algoritmus, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 67: Segmentační masky snímku z datasetu Retina, **F-FCM**, Gaussovský šum; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 8 je patrné, že globálně dosahuje v datasetu Retina při zatížení Gaussovským šumem nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve většině parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM. Otsuova metoda dosahuje lepší úrovně korelace než K-means a oba typy agregací u Fuzzy-ABC. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací. Průměrová agregace této metody má po K-means druhý nejhorší výsledek.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Fuzzy-ABC pro oba typy agregací dosahuje horší SSIM Otsuova metoda.


Z výstupních segmentačních map na Obr. 65, Obr. 66 a Obr. 67 je patrné, že nejhorších segmentačních výstupů dosáhla metoda opět K-means.

Na základě podobnosti segmentovaného snímku a zlatého standardu dosáhla nejlepších výsledků metoda Fuzzy-ABC. Všechny metody ale vykázaly při segmentaci problémy.


5.3.2 Šum Salt&Pepper

Tab. 9: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| Segmentační metoda: | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.7791 | 0.8083 | 0.9832 | 0.0414 | 0.0048 |
| K-means | 0.8277 | 0.9992 | 0.9762 | 0.0922 | 0.0271 |
| Fuzzy-ABC (Med. agregace) | 0.8356 | 0.2579 | 0.9877 | 0.1686 | 0.0469 |
| Fuzzy-ABC (Prům. agregace) | 0.8341 | 0.2686 | 0.9629 | 0.1433 | 0.0443 |
| F-FCM (Med. agregace) | 0.9797 | 0.0961 | 0.9975 | 0.0150 | 0.0048 |
| F-FCM (Prům. agregace) | 0.9804 | 0.0924 | 0.9976 | 0.0148 | 0.0036 |



Obr. 68: Segmentační masky snímku z datasetu Retina, **K-means**, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 69: Segmentační masky snímku z datasetu Retina, **Fuzzy-ABC** algoritmus, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 70: Segmentační masky snímku z datasetu Retina, **F-FCM**, šum Salt&Pepper; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 9 je patrné, že globálně dosahuje v datasetu Retina při zatížení šumem Salt&Pepper nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Naopak nejhorších výsledků dosahuje ve většině parametrech konvenční metoda K-means.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace horších hodnot než F-FCM. Otsuova metoda dosahuje lepší úrovně korelace než K-means a oba typy agregací u Fuzzy-ABC. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací. Mediánová agregace této metody má po K-means druhý nejhorší výsledek.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Fuzzy-ABC pro oba typy agregací dosahuje horší SSIM Otsuova metoda.

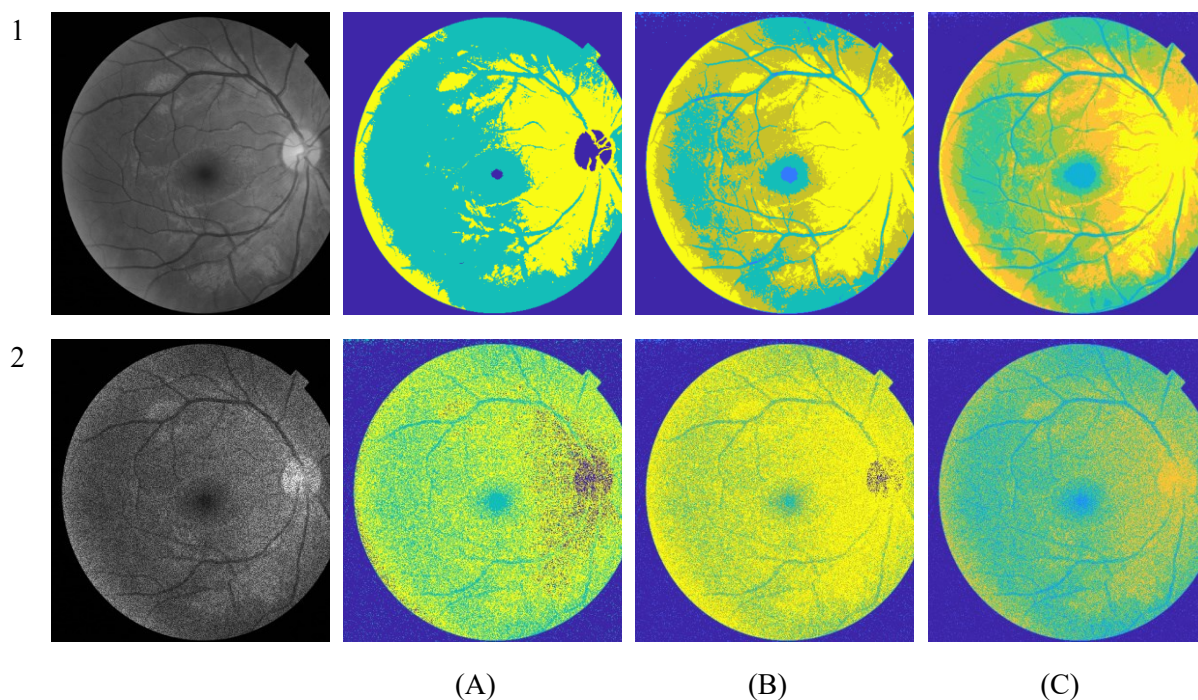
Z výstupních segmentačních map na Obr. 68, Obr. 69 a Obr. 70 je patrné, že nejhorších segmentačních výstupů dosáhla opět metoda K-means.

Na základě podobnosti segmentovaného snímku a zlatého standardu dosáhla nejlepších výsledků metoda Fuzzy-ABC. Všechny metody ale vykázaly při segmentaci značné problémy.


5.3.3 Šum Speckle

Tab. 10: Globální sumarizační tabulka evaluačních parametrů pro všechny testované metody a jejich nastavení.


| | Kor (-) | MSE (-) | SSIM (-) | σ Kor (-) | σ SSIM (-) |
|----------------------------|---------------|---------------|---------------|------------------|-------------------|
| Otsu | 0.8295 | 0.6654 | 0.9861 | 0.0373 | 0.0039 |
| K-means | 0.8193 | 0.7172 | 0.9832 | 0.0938 | 0.0234 |
| Fuzzy-ABC (Med. agregace) | 0.7059 | 1.2351 | 0.9527 | 0.0927 | 0.0236 |
| Fuzzy-ABC (Prům. agregace) | 0.7597 | 1.1088 | 0.9559 | 0.0951 | 0.0246 |
| F-FCM (Med. agregace) | 0.8110 | 1.7312 | 0.9553 | 0.0530 | 0.0146 |
| F-FCM (Prům. agregace) | 0.9124 | 0.4881 | 0.9889 | 0.0237 | 0.0041 |



Obr. 71: Segmentační masky snímku z datasetu Retina, **K-means**, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 72: Segmentační masky snímku z datasetu Retina, **Fuzzy-ABC** algoritmus, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd



Obr. 73: Segmentační masky snímku z datasetu Retina, **F-FCM**, šum Speckle; **řada 1** – segmentace nativního snímku, zleva: nativní snímek, 3, 5 a 8 seg. tříd; **řada 2** – segmentace snímku při nejvyšší úrovni zašumění, zleva: nativní zašuměný snímek, 3, 5 a 8 seg. tříd

Z Tab. 10 je patrné, že globálně dosahuje v datasetu Retina při zatížení šumem Speckle nejlepších výsledků F-FCM algoritmus s průměrovou agregací ve většině evaluačních parametrech. Objektivně nejhorších výsledků zde dosahuje mediánová agregace Fuzzy-ABC algoritmu.

Z hlediska korelace dosahuje Fuzzy-ABC pro oba typy agregace nejhorších výsledků. Otsuova metoda dosahuje druhých nejlepších výsledků po průměrové agregaci u F-FCM algoritmu. Nejlepší hodnoty MSE zde dosahuje F-FCM s průměrovou agregací a nejhorší F-FCM s mediánovou agregací.

Nejlepší hodnoty SSIM dosahuje opět F-FCM algoritmus s průměrovou agregací. Otsuova metoda dosahuje lepších výsledků než oba typy agregací Fuzzy-ABC.

Z výstupních segmentačních map na Obr. 71, Obr. 72 a Obr. 73 je patrné, šum Speckle představuje pro použité metody velkou překážku. Pokud by šlo o segmentaci retinálních cév, nejlepších výsledků by zde dosáhla metoda K-means. Ta dosáhla také nejlepších výsledků vůči zlatému standardu.

6 Výsledky testování – Vzájemné porovnání efektivity metod podle výsledků nejlepších nastavení

6.1 Srovnání K-means, Otsu a Fuzzy-ABC algoritmu (nejlepší výsledky) v datasetu MRI

6.1.1 Gaussovský šum

Tab. 11: Objektivní srovnání výsledků korelace nejlepších nastavení Fuzzy-ABC, K-means a Otsu.


| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | Kor ABC | Kor. K-means | Kor. Otsu |
|-----------|---------------|---------------------|----------------------|---------|--------------|-----------|
| Fuzzy-ABC | 3 | 100it., pop.200 | Prům. 3x3 | 0.7280 | 0.5588 | 0.8059 |
| K-means | 5 | 50it., pop.100 | Prům. 5x5 | 0.8470 | 0.6568 | 0.8294 |
| Otsu | 8 | 200it., pop.500 | Prům. 5x5 | 0.9127 | 0.6938 | 0.8501 |

Tab. 12: Objektivní srovnání výsledků MSE nejlepších nastavení Fuzzy-ABC, K-means a Otsu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | MSE ABC | MSE K-means | MSE Otsu |
|-----------|---------------|---------------------|----------------------|---------|-------------|----------|
| Fuzzy-ABC | 3 | 100it., pop.200 | Medián 3x3 | 0.2961 | 0.7578 | 0.5163 |
| K-means | 5 | 100it., pop.200 | Prům. 9x9 | 0.2364 | 2.5394 | 1.2859 |
| Otsu | 8 | 200it., pop.500 | Prům. 9x9 | 0.3742 | 4.5125 | 1.9405 |

Tab. 13: Objektivní srovnání výsledků SSIM nejlepších nastavení Fuzzy-ABC, K-means a Otsu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | SSIM ABC | SSIM K-means | SSIM Otsu |
|-----------|---------------|---------------------|----------------------|----------|--------------|-----------|
| Fuzzy-ABC | 3 | 100it., pop.200 | Prům. 3x3 | 0.9833 | 0.9676 | 0.9792 |
| K-means | 5 | 100it., pop.200 | Medián. 9x9 | 0.9876 | 0.9004 | 0.9504 |
| Otsu | 8 | 200it., pop.500 | Prům. 9x9 | 0.9873 | 0.8408 | 0.9426 |









Původní obraz

Fuzzy-ABC; 200it.,
pop.500, avg. agr. 9x9

Otsu

K-means







Obr. 74: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd.



(A)

(B)

Obr. 75: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 3 segmentační třídy, mediánová agregace, Gaussovský šum. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.




(A)


(B)

Obr. 76: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 5 segmentačních tříd, mediánová agregace, Gaussovský šum. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.


Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a K-means segmentace




Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a Otsu segmentace




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a K-means segmentace




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a Otsu segmentace



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a K-means segmentace



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a Otsu segmentace



(A)

(B)

Obr. 77: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 8 segmentačních tříd, mediánová agregace, Gaussovský šum. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.

V Tab. 11, Tab. 12 a Tab. 13 je možné vidět nejlepší výsledky metod Fuzzy-ABC, K-means a Otsuovy metody v rámci zpracování obrazů zašuměných Gaussovským šumem v datasetu MRI. S výjimkou rozložení obrazů do 3 regionů dosáhla metoda Fuzzy-ABC v rámci korelace nejlepších výsledků při zpracování MRI obrazů zašuměných Gaussovským šumem. Nejhorších výsledků všech evaluačních parametrů dosáhla metoda K-means.

Při rozkladu obrazu do 3 regionů dosáhla u metody Fuzzy-ABC nejlepších výsledků průměrová agregace rozměru 3x3 a nastavení 100 iterací a populace 200.

Při rozkladu do 5 regionů se dvou ze tří evaluačních parametrů nejvíce osvědčila průměrová agregace, a to o rozměru 5x5 a 9x9 při nastavení 100 iterací a populace 200.

Při rozkladu do 8 regionů se nejvíce osvědčila průměrová agregace, a to o rozměru 9x9 při nastavení 200 iterací a populace 500.

Na Obr. 74 je možné pozorovat segmentované výstupy jednotlivých metod při rozložení obrazu do 8 segmentačních tříd (regionů). Metoda Fuzzy-ABC sice dosáhla nejlepších výsledků vůči svému zlatému standardu a došlo k potlačení šumu, ale při úkolu vyextrahovat z obrazu nádor by neuspěla. Nádorové ložisko splývá s velkou částí mozku, který byl klasifikován do stejného regionu. Ze stejného důvodu by neuspěla ani metoda K-means. V Otsuově metodě je přítomné velké množství šumu, ale provedení extrakce by přineslo kvalitnější výsledky.

Na Obr. 75, Obr. 76 a Obr. 77 je možné vidět srovnání průběhu hodnot evaluačních parametrů analyzovaných obrazů pomocí Fuzzy-ABC, K-means a Otsuovy metody při 10 úrovních zašumění v rámci počtu regionů 3, 5 a 8. Je zde patrné, že efektivita Fuzzy-ABC se zvyšuje s rostoucím počtem regionů. V grafech je možné také orientačně vidět výsledky různých nastavení algoritmu.

6.1.2 Šum Salt&Pepper

Tab. 14: Objektivní srovnání výsledků korelace nejlepších nastavení K-means, Otsu a Fuzzy-ABC algoritmu.


| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | Kor. ABC | Kor. K-means | Kor. Otsu |
|-----------|---------------|---------------------|----------------------|---------------|---------------|---------------|
| Fuzzy-ABC | 3 | 200it., pop.500 | Prům. 3x3 | 0.6712 | 0.6971 | 0.7998 |
| K-means | 5 | 50it., pop.100 | Medián 5x5 | 0.8867 | 0.7656 | 0.8143 |
| Otsu | 8 | 50it., pop.100 | Prům. 3x3 | 0.9565 | 0.7710 | 0.7811 |

Tab. 15: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | MSE ABC | MSE K-means | MSE Otsu |
|-----------|---------------|---------------------|----------------------|---------------|---------------|---------------|
| Fuzzy-ABC | 3 | 200it., pop.500 | Medián 3x3 | 0.4352 | 0.5739 | 0.2648 |
| K-means | 5 | 50it., pop.100 | Medián 5x5 | 0.5574 | 0.9575 | 0.6780 |
| Otsu | 8 | 50it., pop.100 | Prům. 3x3 | 0.2111 | 1.2838 | 1.4022 |

Tab. 16: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | SSIM ABC | SSIM K-means | SSIM Otsu |
|-----------|---------------|---------------------|----------------------|---------------|---------------|---------------|
| Fuzzy-ABC | 3 | 200it., pop.500 | Medián 3x3 | 0.9660 | 0.9736 | 0.9723 |
| K-means | 5 | 50it., pop.100 | Medián 15x15 | 0.9723 | 0.9606 | 0.9552 |
| Otsu | 8 | 50it., pop.100 | Prům. 3x3 | 0.9933 | 0.9552 | 0.9943 |









Původní obraz

Fuzzy-ABC; 200it.,
pop.500, prům. agr.
3x3

Otsu

K-means







Obr. 78: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd.



(A)

(B)







Obr. 79: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 3 segmentační třídy, mediánová agregace, šum Salt&Pepper. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.



(A)

(B)

Obr. 80: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 5 segmentačních tříd, mediánová agregace, šum Salt&Pepper. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.



(A)

(B)

Obr. 81: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 8 segmentačních tříd, mediánová agregace, šum Salt&Pepper. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.

V Tab. 14, Tab. 15 a Tab. 16 je možné vidět nejlepší výsledky metod Fuzzy-ABC, K-means a Otsuovy metody v rámci zpracování obrazů zašuměných šumem Salt&Pepper v datasetu MRI.

Obecně nejlepších evaluačních parametrů dosáhla metoda Fuzzy-ABC. Z hlediska korelace dosáhla nejlepších výsledků při nastavení 5 a 8 regionů. Při nastavení 3 regionů byla nejefektivnější Otsuova metoda. Stejně výsledky je možné pozorovat také u parametru MSE. Z hlediska SSIM dosáhla nejhorších výsledků metoda K-means.

Při nastavení 3 regionů se u Fuzzy-ABC algoritmu nejlépe jevílo nastavení 200 iterací a populace 500 a nastavení mediánové agregace rozměru 3x3. Výsledky průměrové agregace ale byly velice podobné. Při nastavení 5 regionů se nejlépe jevílo nastavení 50 iterací a populace 100 s mediánovou agregací rozměru 5x5 a při nastavení 8 regionů nastavení 50 iterací a populace 100 a průměrová agregace rozměru 3x3.

Na Obr. 78 je možné vidět segmentované výstupy jednotlivých metod při rozložení obrazu do 8 segmentačních tříd (regionů). Metoda Fuzzy-ABC dosáhla nejlepších výsledků vůči svému zlatému standardu a došlo k dobrému potlačení šumu. Nádorové ložisko by bylo možné efektivně vyextrahovat. Extrakce by byla možná i u K-means a Otsuovy metody. U těchto metod by ale byly výsledné segmentační masky negativně ovlivněny šumem a projevíly by se tzv. blind spots, které by se projevíly jako černé „díry“ ve výsledné segmentační masce.

Na Obr. 79, Obr. 80 a Obr. 81 je možné vidět srovnání průběhu hodnot evaluačních parametrů analyzovaných obrazů pomocí Fuzzy-ABC, K-means a Otsuovy metody při 10 úrovních zašumění v rámci počtu regionů 3, 5 a 8. I zde platí, že efektivita různých nastavení Fuzzy-ABC algoritmu se se zvyšujícím počtem regionů prudce zlepšuje. Největší rozdíl je zřetelný mezi 3 a 5 regiony. Zejména u nastavení 5 regionů je možné u Fuzzy-ABC vidět velké fluktuace výstupních hodnot. Ve srovnáním s Otsuovou metodou je možné tvrdit, že Fuzzy-ABC je vůči rostoucí intenzitě šumu méně robustní.

6.1.3 Šum Speckle

Tab. 17: Objektivní srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.


| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | Kor. ABC | Kor. K-means | Kor. Otsu |
|-----------|---------------|---------------------|----------------------|----------|---------------|---------------|
| Fuzzy-ABC | 3 | 200it., pop.500 | Prům. 9x9 | 0.8502 | 0.6689 | 0.9109 |
| K-means | 5 | 50it., pop.100 | Prům. 5x5 | 0.9145 | 0.8338 | 0.9334 |
| Otsu | 8 | 50it., pop.100 | Prům. 5x5 | 0.9344 | 0.8708 | 0.9358 |

Tab. 18: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | MSE ABC | MSE K-means | MSE Otsu |
|-----------|---------------|---------------------|----------------------|---------------|---------------|----------|
| Fuzzy-ABC | 3 | 200it., pop.500 | Medián 9x9 | 0.0201 | 0.6185 | 0.1647 |
| K-means | 5 | 100it., pop.200 | Prům. 9x9 | 0.0703 | 0.8957 | 0.2871 |
| Otsu | 8 | 50it., pop.100 | Prům. 5x5 | 0.2318 | 0.7690 | 0.4366 |

Tab. 19: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Agregace u Fuzzy-ABC | SSIM ABC | SSIM K-means | SSIM Otsu |
|-----------|---------------|---------------------|----------------------|---------------|---------------|-----------|
| Fuzzy-ABC | 3 | 100it., pop.200 | Medián 9x9 | 0.9990 | 0.9707 | 0.9952 |
| K-means | 5 | 100it., pop.200 | Prům. 9x9 | 0.9973 | 0.9659 | 0.9939 |
| Otsu | 8 | 200it., pop.500 | Prům. 5x5 | 0.9944 | 0.9659 | 0.9918 |



Původní obraz


Fuzzy-ABC; 50it.,
pop.100, prům. agr.
5x5

Otsu


K-means

Obr. 82: Nativní snímek a obrazové výstupy jednotlivých metod, 8 seg. tříd.


Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a K-means segmentace 3 seg. třídy, Šum Speckle, Dataset MRI




Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a Otsu segmentace 3 seg. třídy, Šum Speckle, Dataset MRI




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a K-means segmentace 3 seg. třídy, Šum Speckle, Dataset MRI




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a Otsu segmentace 3 seg. třídy, Šum Speckle, Dataset MRI



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a K-means segmentace 3 seg. třídy, Šum Speckle, Dataset MRI









Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a Otsu segmentace 3 seg. třídy, Šum Speckle, Dataset MRI



(A)

(B)

Obr. 83: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 3 segmentační třídy, mediánová agregace, šum Speckle. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.




(A)


(B)

Obr. 84: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 5 segmentačních tříd, mediánová agregace, šum Speckle. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.


Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a K-means segmentace 8 seg. tříd, Šum Speckle, Dataset MRI




Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a Otsu segmentace 8 seg. tříd, Šum Speckle, Dataset MRI




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a K-means segmentace 8 seg. tříd, Šum Speckle, Dataset MRI




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a Otsu segmentace 8 seg. tříd, Šum Speckle, Dataset MRI



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a K-means segmentace 8 seg. tříd, Šum Speckle, Dataset MRI



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a Otsu segmentace 8 seg. tříd, Šum Speckle, Dataset MRI



(A)

(B)

Obr. 85: Grafická srovnání výsledků metod K-means, Otsu a nastavení Fuzzy-ABC algoritmu pro 8 segmentačních tříd, mediánová agregace, šum Speckle. (A) – srovnání Fuzzy-ABC a K-means, shora: korelace, MSE a SSIM; (B) – srovnání Fuzzy-ABC a Otsu, shora: korelace, MSE a SSIM.

V Tab. 17, Tab. 18 a Tab. 19 je možné vidět nejlepší výsledky metod Fuzzy-ABC, K-means a Otsuovy metody v rámci zpracování obrazů zašuměných šumem Speckle v datasetu MRI.

Obecně nejlepších evaluačních parametrů dosáhla metoda Fuzzy-ABC. Z hlediska korelace dosáhla nejlepších výsledků při nastavení Otsuova metoda. Z hlediska MSE dosáhla nejlepších výsledků Fuzzy-ABC a totéž platí pro SSIM. Celkově nejhorší ve všech parametrech vyšla metoda K-means.

Při nastavení 3 regionů se u Fuzzy-ABC algoritmu nejlépe jevílo nastavení 200 iterací a populace 500 a nastavení mediánové agregace rozměru 9x9. Výsledky průměrové agregace ale byly velice podobné. Při nastavení 5 regionů se nejlépe jevílo nastavení 50 iterací a populace 100 s mediánovou agregací rozměru 5x5 a při nastavení 8 regionů nastavení 50 iterací a populace 100 a průměrová agregace rozměru 3x3.

Na Obr. 82 je možné vidět segmentované výstupy jednotlivých metod při rozložení obrazu do 8 segmentačních tříd (regionů). Metoda Fuzzy-ABC dosáhla na základě evaluačních parametrů nejlepších výsledků vůči svému zlatému standardu. Z obrazových výstupů je patrné, že šum Speckle představuje pro metodu Fuzzy-ABC problém. Metoda nedokáže tento typ šumu zpracovat tak, jako Gaussovský šum a šum Salt&Pepper a dochází tak k rozmazání, které připomíná malbu štětcem. I přes tento fenomén by bylo možné tumor vyextrahovat, byť ne příliš kvalitně. Otsuova metoda a K-means by měly při extrakci problémy shodné s problémy u šumu Salt&Pepper.

Na Obr. 83, Obr. 84 a Obr. 85 je možné vidět srovnání průběhu hodnot evaluačních parametrů analyzovaných obrazů pomocí Fuzzy-ABC, K-means a Otsuovy metody při 10 úrovních zašumění v rámci počtu regionů 3, 5 a 8. I zde platí, že efektivita různých nastavení Fuzzy-ABC algoritmu se se zvyšujícím počtem regionů prudce zvyšuje. Největší rozdíl je zřetelný mezi 3 a 5 regiony. Zejména u nastavení 5 regionů je možné u Fuzzy-ABC vidět velké fluktuace výstupních hodnot. Ve srovnáním s Otsuovou metodou je možné tvrdit, že Fuzzy-ABC je vůči rostoucí intenzitě šumu méně robustní.

6.2 Srovnání nejlepších nastavení výsledků Fuzzy-ABC a F-FCM algoritmu podle počtu regionů v datasetu MRI

6.2.1 Gaussovský šum, Srovnání nejlepších nastavení metod v rámci počtu regionů

Tab. 20: Objektivní srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Typ agregace: | Velikost agr. | Korelace |
|-----------|---------------|---------------------|---------------|---------------|---------------|
| F-FCM | 3 | - | průměrová | 15x15 | 0.9741 |
| | 5 | - | průměrová | 9x9 | 0.9571 |
| | 8 | - | průměrová | 9x9 | 0.9511 |
| Fuzzy-ABC | 3 | 100it., pop.200 | průměrová | 3x3 | 0.7280 |
| | 5 | 50it., pop.100 | průměrová | 5x5 | 0.8470 |
| | 8 | 200it., pop.500 | průměrová | 5x5 | 0.9127 |


Tab. 21: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| | Počet regionů | Nastavení Fuzzy-ABC | | Velikost agr. | MSE |
|-----------|---------------|---------------------|-----------|---------------|---------------|
| F-FCM | 3 | - | průměrová | 15x15 | 0.0224 |
| | 5 | - | průměrová | 9x9 | 0.1422 |
| | 8 | - | průměrová | 5x5 | 0.5574 |
| Fuzzy-ABC | 3 | 100it., pop.200 | průměrová | 3x3 | 0.2961 |
| | 5 | 100it., pop.200 | mediánová | 5x5 | 0.2364 |
| | 8 | 100it., pop.200 | průměrová | 9x9 | 0.3742 |


Tab. 22: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| | Počet regionů | Nastavení Fuzzy-ABC | | Velikost agr. | SSIM |
|-----------|---------------|---------------------|-----------|---------------|---------------|
| F-FCM | 3 | - | průměrová | 15x15 | 0.9993 |
| | 5 | - | mediánová | 5x5 | 0.9962 |
| | 8 | - | průměrová | 5x5 | 0.9879 |
| Fuzzy-ABC | 3 | 100it., pop.200 | průměrová | 3x3 | 0.9833 |
| | 5 | 100it., pop.200 | mediánová | 9x9 | 0.9876 |
| | 8 | 200it., pop.500 | průměrová | 9x9 | 0.9873 |


Srovnání výsledků korelace metod mediánové agregace ABC-Fuzzy a Fuzzy-FCM segmentaci




Srovnání výsledků korelace metod průměrové agregace ABC-Fuzzy a Fuzzy-FCM segmentaci




Srovnání výsledků MSE metod mediánové agregace ABC-Fuzzy a Fuzzy-FCM segmentace




Srovnání výsledků MSE metod průměrové agregace ABC-Fuzzy a Fuzzy-FCM segmentace



Srovnání výsledků SSIM metod mediánové agregace ABC-Fuzzy a Fuzzy-FCM segmentace




Srovnání výsledků SSIM metod průměrové agregace ABC-Fuzzy a Fuzzy-FCM segmentace



(A)

(B)

Obr. 86: Grafická srovnání výsledků metod F-FCM a Fuzzy-ABC algoritmu (nastavení 200 it., pop500) pro 8 segmentačních tříd, Gaussovský šum. (A) – srovnání výsledků mediánové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM; (B) – srovnání výsledků průměrové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM.



Nativní zašuměný obraz

Fuzzy-ABC; 200it., pop 500,
průměrová agregace 9x9

F-FCM; průměrová agregace
5x5

Obr. 87: Nativní zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM při 8 seg. třídách.

Z Tab. 20, Tab. 21 a Tab. 22 je možné vidět nejlepší výsledky metod Fuzzy-ABC a F-FCM v rámci zpracování obrazů zašuměných Gaussovským šumem v datasetu MRI.

Je patrné, že nejlepších výsledků dosáhla metoda F-FCM, a to ve všech počtech regionů oproti Fuzzy-ABC algoritmu s různým nastavením.

U F-FCM se při nastavení 3 regionů nejlépe jeví nastavení průměrové agregace rozměru 15x15, při nastavení 5 regionů nastavení mediánové agregace rozměru 9x9 a při nastavení 8 regionů nastavení průměrové agregace rozměru 5x5.

Jako nejefektivnější se však u Fuzzy-ABC algoritmu jeví při 3 regionech nastavení 100 iterací a populace 200 a mediánová agregace rozměru 3x3, při 5 regionech nastavení 100 iterací, populace 200 a mediánové agregace 5x5 nebo 9x9 a při nastavení 8 regionů nastavení 200 iterací, populace 200 a průměrové agregace rozměru 9x9.

Na Obr. 86 je možné vidět grafický výstup evaluačních metod pro metody Fuzzy-ABC a F-FCM, kde je možné vidět jak porovnání Fuzzy-ABC a F-FCM, tak srovnání mediánové a průměrové agregace při nastavení 8 regionů. Je patrné, že F-FCM dosahuje lepší robustnosti vůči rostoucí úrovni zašumění. Také je možné vidět, že efektivita Fuzzy-ABC má klesavou tendenci, zatímco efektivita F-FCM je přibližně konstantní.

Na Obr. 87 jsou obrazové segmentační výstupy obou výše zmíněných metod. Z hlediska extrakce tumoru je navzdory objektivním evaluačním parametrům možné říct, že extrakcí příslušných tříd, které definují tumor, by bylo dosaženo lepšího výsledku při použití metody Fuzzy-ABC. U F-FCM algoritmu by došlo při extrakci i k extrakci okolí tumoru.

6.2.2 Šum Salt&Pepper, Srovnání nejlepších nastavení metod v rámci počtu regionů

Tab. 23: Objektivní srovnání výsledků korelace nastavení F-FCM a Fuzzy-ABC algoritmu.







| Metoda | Počet regionů | Nastavení Fuzzy-ABC | Typ agregace: | Velikost agr. | Korelace |
|-----------|---------------|---------------------|---------------|---------------|---------------|
| F-FCM | 3 | - | mediánová | 3x3 | 0.9819 |
| | 5 | - | průměrová | 3x3 | 0.9748 |
| | 8 | - | průměrová | 3x3 | 0.9818 |
| Fuzzy-ABC | 3 | 200it., pop.500 | průměrová | 3x3 | 0.6712 |
| | 5 | 50it., pop.100 | mediánová | 5x5 | 0.8867 |
| | 8 | 50it., pop.100 | průměrová | 3x3 | 0.9565 |

Tab. 24: Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| | Počet regionů | Nastavení Fuzzy-ABC | | Velikost agr. | MSE |
|-----------|---------------|---------------------|-----------|---------------|---------------|
| F-FCM | 3 | - | mediánová | 3x3 | 0.0153 |
| | 5 | - | průměrová | 5x5 | 0.0882 |
| | 8 | - | průměrová | 5x5 | 0.1828 |
| Fuzzy-ABC | 3 | 200it., pop.500 | mediánová | 3x3 | 0.4352 |
| | 5 | 50it., pop.100 | mediánová | 5x5 | 0.5574 |
| | 8 | 50it., pop.100 | průměrová | 3x3 | 0.2111 |

Tab. 25: Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.


| | Počet regionů | Nastavení Fuzzy-ABC | | Velikost agr. | SSIM |
|-----------|---------------|---------------------|-----------|---------------|---------------|
| F-FCM | 3 | - | mediánová | 3x3 | 0.9995 |
| | 5 | - | průměrová | 3x3 | 0.9973 |
| | 8 | - | průměrová | 3x3 | 0.9951 |
| Fuzzy-ABC | 3 | 200it., pop.500 | mediánová | 3x3 | 0.9660 |
| | 5 | 50it., pop.100 | mediánová | 15x15 | 0.9723 |
| | 8 | 50it., pop.100 | průměrová | 3x3 | 0.9933 |



(A)

(B)

Obr. 88: Grafická srovnání výsledků metod F-FCM a Fuzzy-ABC algoritmu (nastavení 200 it., pop500) pro 8 segmentačních tříd, šum Salt&Pepper. (A) – srovnání výsledků mediánové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM; (B) – srovnání výsledků průměrové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM.



Nativní zašuměný obraz

Fuzzy-ABC; 50it., pop 100,
průměrová agregace 3x3

F-FCM; průměrová agregace
3x3

Obr. 89: Nativní zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM při 8 seg. třídách

Z Tab. 23, Tab. 24 a Tab. 25 je možné vidět nejlepší výsledky metod Fuzzy-ABC a F-FCM v rámci zpracování obrazů zašuměných šumem Salt&Pepper v datasetu MRI.

I zde je patrné, že nejlepších výsledků dosáhla metoda F-FCM, a to ve všech počtech regionů oproti Fuzzy-ABC algoritmu s různým nastavením.

U F-FCM se při nastavení 3 regionů nejlépe jeví nastavení mediánové agregace rozměru 3x3, při nastavení 5 regionů nastavení průměrové agregace rozměru 3x3 a při nastavení 8 regionů nastavení průměrové agregace rozměru taktéž 3x3.

Jako nejefektivnější se však u Fuzzy-ABC algoritmu jeví při 3 regionech nastavení 200 iterací a populace 500 a mediánová agregace rozměru 3x3, při 5 regionech nastavení 500 iterací, populace 200 a mediánové agregace 5x5 a při nastavení 8 regionů nastavení 50 iterací, populace 100 a průměrové agregace rozměru 3x3.

Na Obr. 88 je možné vidět grafický výstup evaluačních metod pro metody Fuzzy-ABC a F-FCM, kde je možné vidět jak porovnání Fuzzy-ABC a F-FCM, tak srovnání mediánové a průměrové agregace při nastavení 8 regionů. Je patrné, že F-FCM dosahuje mnohem lepší efektivity vůči rostoucí úrovni zašumění. Také je možné vidět, že efektivita Fuzzy-ABC se vyznačuje vysokou hodnotou variačního rozpětí, zatímco efektivita F-FCM je přibližně konstantní a dosahuje tak mnohem vyšší robustnosti.

Na Obr. 89 jsou obrazové segmentační výstupy obou výše zmíněných metod. Z hlediska extrakce tumoru je možné říct, že extrakcí příslušných tříd, které definují tumor, by bylo dosaženo obdobného výsledku při použití obou metod.

6.2.3 Šum Speckle, Srovnání nejlepších nastavení metod v rámci počtu regionů

Tab. 26: Objektivní srovnání výsledků korelace nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.







| Metoda | Počet regionů: | Nastavení Fuzzy-ABC | Typ agregace: | Velikost agr. | Korelace |
|-----------|----------------|---------------------|---------------|---------------|----------|
| F-FCM | 3 | - | průměrová | 9x9 | 0.9844 |
| | 5 | - | průměrová | 9x9 | 0.9727 |
| | 8 | - | průměrová | 5x5 | 0.9606 |
| Fuzzy-ABC | 3 | 200it., pop.500 | průměrová | 9x9 | 0.8502 |
| | 5 | 50it., pop.100 | průměrová | 5x5 | 0.9145 |
| | 8 | 50it., pop.100 | průměrová | 5x5 | 0.9344 |

Tab. 27 Objektivní srovnání výsledků MSE nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.

| Metoda | Počet regionů: | Nastavení Fuzzy-ABC | Typ agregace: | Velikost agr. | MSE |
|-----------|----------------|---------------------|---------------|---------------|--------|
| F-FCM | 3 | - | průměrová | 9x9 | 0.0135 |
| | 5 | - | průměrová | 5x5 | 0.0844 |
| | 8 | - | průměrová | 5x5 | 0.3532 |
| Fuzzy-ABC | 3 | 200it., pop.500 | průměrová | 9x9 | 0.0201 |
| | 5 | 100it., pop.200 | mediánová | 9x9 | 0.0703 |
| | 8 | 50it., pop.100 | průměrová | 5x5 | 0.2318 |

Tab. 28 Objektivní srovnání výsledků SSIM nejlepších nastavení F-FCM a Fuzzy-ABC algoritmu.


| Metoda | Počet regionů: | Nastavení Fuzzy-ABC | Typ agregace: | Velikost agr. | SSIM |
|-----------|----------------|---------------------|---------------|---------------|--------|
| F-FCM | 3 | - | průměrová | 9x9 | 0.9997 |
| | 5 | - | průměrová | 5x5 | 0.9981 |
| | 8 | - | průměrová | 3x3 | 0.9934 |
| Fuzzy-ABC | 3 | 200it., pop.500 | průměrová | 9x9 | 0.9990 |
| | 5 | 100it., pop.200 | mediánová | 9x9 | 0.9973 |
| | 8 | 50it., pop.100 | průměrová | 5x5 | 0.9944 |



(A)

(B)

Obr. 90: Grafická srovnání výsledků metod F-FCM a Fuzzy-ABC algoritmu (nastavení 200 it., pop500) pro 8 segmentačních tříd, šum Speckle. (A) – srovnání výsledků mediánové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM; (B) – srovnání výsledků průměrové agregace F-FCM a Fuzzy-ABC, shora: korelace, MSE a SSIM.



Nativní zašuměný obraz

Fuzzy-ABC; 50it., pop 100,
průměrová agregace 3x3

F-FCM; průměrová agregace
3x3

Obr. 91: Nativní zašuměný obraz a obrazové výstupy Fuzzy-ABC a F-FCM při 8 seg. třídách

Z Tab. 26, Tab. 27 a Tab. 28 je možné vidět nejlepší výsledky metod Fuzzy-ABC a F-FCM v rámci zpracování obrazů zašuměných šumem Speckle v datasetu MRI.

Metoda F-FCM dosáhla opět obecně lepších výsledků než Fuzzy-ABC ve většině evaluačních parametrů.

U F-FCM se při nastavení 3 regionů nejlépe jeví nastavení průměrové agregace rozměru 9x9, při nastavení 5 regionů nastavení průměrové agregace rozměru 5x5 a při nastavení 8 regionů nastavení průměrové agregace rozměru taktéž 5x5.

Jako nejefektivnější se u Fuzzy-ABC algoritmu jeví při 3 regionech nastavení 200 iterací a populace 500 a průměrová agregace rozměru 9x9, při 5 regionech nastavení 100 iterací, populace 200 a mediánové agregace 9x9 a při nastavení 8 regionů nastavení 50 iterací, populace 100 a průměrové agregace rozměru 5x5. U parametru SSIM vyšly hodnoty obou metod velice podobně.


Na Obr. 90 je možné vidět grafický výstup evaluačních metod pro metody Fuzzy-ABC a F-FCM, kde je možné vidět jak porovnání Fuzzy-ABC a F-FCM, tak srovnání mediánové a průměrové agregace při nastavení 8 regionů. Je patrné, že F-FCM dosahuje mnohem lepší efektivity vůči rostoucí úrovni zašumění. Na rozdíl od případu u předchozího šumu zde u mediánové agregace nedochází k tak významné fluktuaci hodnot, ale u průměrové agregace jsou tyto fluktuace stále docela významné. I zde platí, že F-FCM algoritmus se vyznačuje vyšší robustností vůči rostoucí úrovni zašumění.

Na Obr. 91 jsou obrazové segmentační výstupy obou výše zmíněných metod. Z hlediska extrakce tumoru je možné říct, že extrakcí příslušných tříd, které definují tumor, by bylo dosaženo lepších výsledků jednoznačně použitím metody F-FCM.

6.3 Dataset UZV a dataset Retina


Z důvodu velkého množství výsledků, které vzešly ze všech provedených analýz, byly podrobně demonstrovány pouze výsledky datasetů MRI. Datasety UZV a Retina budou pouze shrnuty v rámci diskuse. Veškeré výsledky jsou k práci připojeny ve formě příloh (Příloha I.), ve kterých je možné si všechny výsledky prohlédnout ve formě excel tabulky s názvem „Databáze“ a také prostřednictvím srovnávacích grafů (složka „Grafická srovnání“ ve složce příslušného datasetu).

6.4 Výpočetní náročnost algoritmů



Obr. 92: Grafické zobrazení průměrné výpočetní náročnosti K-means a Otsuovy metody při různém počtu regionů.

Vzhledem k tomu, že při testování Fuzzy-ABC bylo využito 50 obrazů oproti 200 u ostatních metod, byl průměrný čas u této metody vynásoben 4, aby byly časy porovnatelné.



Obr. 93: Grafické zobrazení průměrné výpočetní náročnosti Fuzzy-ABC a F-FCM při různém počtu regionů.

Z grafu na Obr. 92 je patrné, že Otsuova metoda je signifikantně výpočetně méně náročná, než metoda K-means.

Při srovnání s Obr. 93 je také patrné, že Otsuova metoda (nastavení 3 regionů) je nejen rychlejší oproti K-means, ale také je nejrychlejší napříč všemi testovanými metodami, a to v poměru 1:55 vůči druhé nejrychlejší metodě se stejným nastavením (F-FCM při nastavení 3 regionů).

U metody K-means se výpočetní čas [25, 41, 59 sec] s rostoucím nastavením regionů prodlužuje a to o 42 % mezi nastavením 3 a 5 a o 31 % mezi nastaveními 5 a 8. U Otsuovy metody se výpočetní čas s rostoucím počtem regionů zvyšuje jen málo [5, 5.1, 5.21 sec].

U F-FCM (mediánová agregace) dochází mezi nastavením 3 a 5 regionů k prodloužení výpočetního času o 63 % a mezi 5 a 8 o 47 %.

U Fuzzy-ABC (mediánová agregace) je časové rozpětí výpočetní náročnosti nejširší. Zde se mimo počtu regionů významně projevují také nastavení počtu iterací a populace.

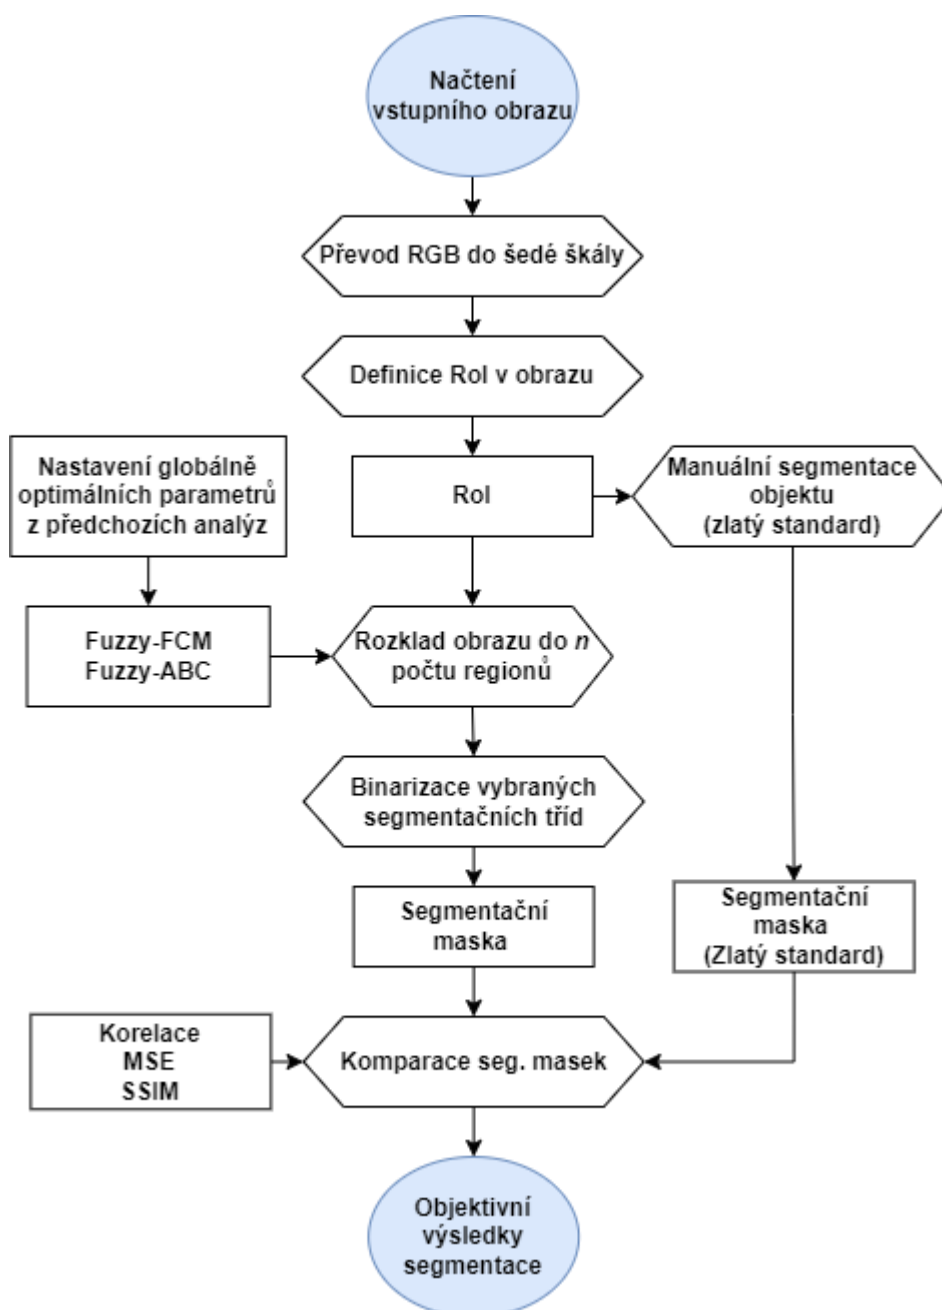
- 50 iterací, populace 100
 - Mezi nastavením 3 a 5 regionů dochází k prodloužení výpočetního času o 25 % a při nastavení 5 a 8 o 27 %.
- 100 iterací, populace 200
 - Mezi nastavením 3 a 5 regionů dochází k prodloužení výpočetního času o 30 % a při nastavení 5 a 8 o 30 %.
- 200 iterací, populace 500
 - Mezi nastavením 3 a 5 regionů dochází k prodloužení výpočetního času o 32 % a při nastavení 5 a 8 o 32 %.

Parametry výpočetního systému (Lenovo Legion 5-15ARH05H):

- AMD Ryzen 5 4600H – 3000 MHz, boost 4000 MHz
- 2x16 GB RAM (DDR4) – 1600 MHz,
- NVIDIA GeForce RTX 2060 6 GB

7 Segmentace vybraných objektů zájmu vybraných algoritmů

Nastavení parametrů Fuzzy-ABC i F-FCM bylo podřízeno výsledkům předchozích analýz efektivity obou algoritmů při zpracování obrazů zasažených variabilními typy šumů s dynamickou intenzitou. U Fuzzy-ABC algoritmu byla nastavena velikost populace na 500 a 200 iterací. Velikost agregací u F-FCM algoritmu byly taktéž nastaveny podle předchozích výsledků. Blokové vyjádření jednotlivých kroků při řešení této praktické části je na Obr. 94.




Obr. 94: Blokové schéma řešení segmentace konkrétních objektů z medicínských obrazů.

Původní obrazy byly převedeny do šedého spektra (256 jasových hodnot) a pomocí aplikace Image Segmenter z prostředí MATLAB byly definovány RoI, kde byly ze snímků MRI a CT odstraněny kosti. Ve snímcích UZV nebyla definice RoI provedena. V každém datasetu bylo segmentaci podrobena celkem 5 snímků, ve kterých byla provedena manuální segmentace objektu zájmu. Tato segmentace později sloužila jako zlatý standard (reference) pro ohodnocení kvality segmentace pomocí obou testovaných algoritmů.

Segmentace byla vždy provedena při nastavení 8 regionů. Z výsledných segmentovaných obrazů byly vždy vybrány ty třídy, které nejlépe definovaly požadovaný objekt zájmu a pomocí binarizace těchto tříd byl tento objekt vyextrahován. Výsledná segmentační maska byla následně porovnána se segmentační maskou zlatého standardu a ohodnocena pomocí korelace, MSE a SSIM.

Pro demonstraci efektivity segmentace byly obě segmentační masky překryty s původním vstupním RoI obrazu, čímž vznikl původní obraz s vyznačeným objektem zájmu.

7.1 Segmentace objektů pomocí Fuzzy-ABC algoritmu, Průměrová agregace rozměru 5x5, 8 seg. tříd (regionů), dataset CT



Obr. 95: Ukázky segmentace v datasetu CT; Sloupec (A) – Segmentace pomocí Fuzzy-ABC algoritmu, (B) – Manuální segmentace (zlatý standard), Sloupec (C) – Binarizovaný segmentační model (Fuzzy-ABC), (D) – Binarizovaný segmentační model (zlatý standard), (E) – Nativní CT snímek

Tab. 29: Výsledky segmentací objektů; Fuzzy-ABC algoritmu vůči zlatému standardu v datasetu CT


| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.9456 | 1.16E+03 | 0.9725 |
| 2 | 0.6077 | 6.53E+02 | 0.974668 |
| 3 | 0.8645 | 1.55E+03 | 0.963155 |
| 4 | 0.6917 | 1.91E+03 | 0.937363 |
| 5 | 0.5427 | 7.09E+02 | 0.945124 |

Segmentace vybraných objektů z medicínských CT snímků založená na Fuzzy-ABC dosáhla na 5 testovaných obrazech výsledků, které je možné vidět na Obr. 95. Výstupy evaluačních metod pro tyto obrazy, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 29.

Globálně je možné říct, že zásadním vlivem na kvalitu výstupu segmentace má kontrast mezi jednotlivými objekty. Vlivem nedostatečného kontrastu dochází k nepřesnostem při klasifikaci pixelů do jednotlivých regionů a ve výsledku není možné dosáhnout segmentačních výstupů, které by obsahovaly pouze požadovaný objekt zájmu. Testované CT snímky příliš dobrým kontrastem nedisponují a objevují se tak ve výstupních segmentačních maskách chyby.

Celkově je možné pomocí Fuzzy-ABC algoritmu v datasetu CT detekovat tumory v mozkové tkáni, byť většinou se nepodařilo dosáhnout hranic tumoru, které bývají o něco tmavší než zbytek útvaru.

7.2 Segmentace objektů pomocí Fuzzy-ABC algoritmu, Průměrová agregace rozměru 9x9, 8 seg. tříd (regionů), dataset MRI



Obr. 96: Ukázky segmentace v datasetu MRI; (A) – Seg. pomocí Fuzzy-ABC algoritmu, (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní MRI snímek

Tab. 30: Výsledky segmentací objektů; Fuzzy-ABC algoritmu vůči zlatému standardu v datasetu MRI.


| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.8903 | 1.01E+03 | 0.9751 |
| 2 | 0.748 | 1.14E+03 | 0.952 |
| 3 | 0.8425 | 833.4135 | 0.9745 |
| 4 | 0.8141 | 1.33E+03 | 0.9588 |
| 5 | 0.909 | 812.1019 | 0.9687 |

Segmentace vybraných objektů z medicínských MRI snímků založená na Fuzzy-ABC dosáhla na 5 testovaných obrazech výsledků, které je možné vidět na Obr. 96. Výstupy evaluačních metod pro tyto obrazy, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 30.

I zde platí, že zásadním vliv na kvalitu výstupu segmentace má kontrast mezi jednotlivými objekty v obraze. Vlivem nedostatečného kontrastu může docházet k nepřesnostem při klasifikaci pixelů do jednotlivých regionů a ve výsledku tak není možné dosáhnout segmentačních výstupů, které by obsahovaly pouze požadovaný objekt zájmu. Testované MRI snímky disponují relativně vysokým kontrastem, takže je kvalita výsledné segmentace ve většině případů dobrá.

Celkově je možné říct, že pomocí Fuzzy-ABC algoritmu v datasetu MRI detekovat tumory v mozkové tkáni. U jednodušších dobře ohraničených objektů je kvalita segmentace velmi dobrá. U obrazů 2 je patrné, že u složitějších a jednoznačně neohraničených útvarů mohou výsledky dosahovat horší, ale stále uspokojivé kvality.

7.3 Segmentace objektů pomocí Fuzzy-ABC algoritmu, Průměrová agregace rozměru 5x5, 8 seg. tříd (regionů), dataset UZV



Obr. 97: Ukázky segmentace v datasetu UZV; (A) – Seg. pomocí Fuzzy-ABC algoritmu, (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní UZV snímek

Tab. 31: Výsledky segmentací objektů; Fuzzy-ABC algoritmu vůči zlatému standardu v datasetu UZV.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.1231 | 1.84E+04 | 0.6247 |
| 2 | 0.1558 | 1.50E+04 | 0.7396 |
| 3 | 0.1146 | 1.79E+04 | 0.6783 |
| 4 | 0.0907 | 2.31E+04 | 0.5131 |
| 5 | 0.1455 | 2.43E+04 | 0.5426 |

Segmentace vybraných objektů z medicínských UZV snímků založená na Fuzzy-ABC dosáhla na 5 testovaných obrazech výsledků, které je možné vidět na Obr. 97. Výstupy evaluačních metod pro tyto obrazy, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 31.


U této série obrazů je na první pohled patrné, že segmentace rozhodně není možné označit za úspěšnou. Vlivem velkého množství šumu a nízkého kontrastu nebylo většinou možné extrahovat požadovaný objekt zájmu z obrazu.

Celkově je možné říct, že pomocí Fuzzy-ABC algoritmu není možné provádět obrazovou segmentaci typu dat, které byly testovány v rámci této kapitoly. Nádory, které se v obraze projevují jako tmavé skvrny, mají tendenci splývat s hlubšími (tmavšími) vrstvami tkáně. Lepších výsledků by bylo dosaženo, kdyby byla před testováním provedena extrakce RoI (Region of interest), ale vzhledem k cíli, kterým bylo zjištění efektivity lokalizace nádoru v tkáni, by se jednalo o zásadní ovlivnění celého testování.

Na základě obrazových výstupů i výstupů evaluačních metod lze vyhodnotit efektivitu segmentace Fuzzy-ABC algoritmem v datasetu UZV jako neúspěšnou.


7.4 Segmentace objektů pomocí F-FCM algoritmu, dataset CT

7.4.1 Průměrová agregace rozměru 5x5, 8 seg. tříd (regionů)



Obr. 98: Ukázky segmentace v datasetu CT; (A) – Seg. pomocí F-FCM algoritmu (průměrová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní CT snímek

7.4.2 Mediánová agregace rozměru 5x5, 8 seg. tříd (regionů)



Obr. 99: Ukázky segmentace v datasetu CT; (A) – Seg. pomocí F-FCM algoritmu (mediánová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní CT snímek

Tab. 32: Výsledky segmentací objektů F-FCM algoritmu (průměrová agregace) vůči zlatému standardu v datasetu CT.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.8239 | 3.60E+03 | 0.9115 |
| 2 | 0.6631 | 4.95E+02 | 0.9736 |
| 3 | 0.8818 | 1.66E+03 | 0.9571 |
| 4 | 0.6967 | 2.30E+03 | 0.917 |
| 5 | 0.5317 | 1.17E+03 | 0.9102 |

Tab. 33: Výsledky segmentací objektů F-FCM algoritmu (mediánová agregace) vůči zlatému standardu v datasetu CT.


| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.8119 | 3.50E+03 | 0.912 |
| 2 | 0.6607 | 5.07E+02 | 0.9721 |
| 3 | 0.8874 | 1.64E+03 | 0.9586 |
| 4 | 0.6897 | 2.33E+03 | 0.9144 |
| 5 | 0.5132 | 1.16E+03 | 0.9076 |

Na Obr. 98 a Obr. 99 lze vidět obrazové výstupy pro průměrovou a mediánovou agregaci F-FCM algoritmu. Výstupy evaluačních metod pro tyto obrazy, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 32 a Tab. 33.

Pohledem na obrazové výstupy obou agregací je patrné, že obě nastavení dosáhly podobných výsledků. Byť mají snímky z datasetu CT daleko k ideálnímu kontrastu, u obou nastavení F-FCM metoda dokázala nalézt objekty zájmu. Celkově obě nastavení dosáhly dobrých objektivních výsledků (Tab. 32 a Tab. 33). Objektivně lepších výsledků dosáhlo nastavení průměrové agregace.


7.5 Segmentace objektů pomocí F-FCM algoritmu, dataset MRI

7.5.1 Průměrová agregace rozměru 9x9, 8 seg. tříd (regionů)



Obr. 100: Ukázky segmentace v datasetu MRI; (A) – Seg. pomocí F-FCM algoritmu (průměrová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní MRI snímek

7.5.2 Mediánová agregace rozměru 3x3, 8 seg. tříd (regionů)



Obr. 101: Ukázky segmentace v datasetu MRI; (A) – Seg. pomocí F-FCM algoritmu (mediánová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní MRI snímek

Tab. 34: Výsledky segmentací objektů; F-FCM algoritmu (průměrová agregace) vůči zlatému standardu v datasetu MRI.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.9282 | 1.10E+03 | 0.9748 |
| 2 | 0.751 | 1.13E+03 | 0.9577 |
| 3 | 0.9296 | 1.07E+03 | 0.9716 |
| 4 | 0.8273 | 1.33E+03 | 0.9618 |
| 5 | 0.9412 | 772.3593 | 0.9787 |

Tab. 35: Výsledky segmentací objektů; F-FCM algoritmu (mediánová agregace) vůči zlatému standardu v datasetu MRI.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.9495 | 1.16E+03 | 0.9729 |
| 2 | 0.7621 | 1.15E+03 | 0.957 |
| 3 | 0.932 | 1.04E+03 | 0.9726 |
| 4 | 0.8189 | 1.31E+03 | 0.9617 |
| 5 | 0.9396 | 745.4327 | 0.9781 |


Na Obr. 100 a Obr. 101 lze vidět obrazové výstupy pro průměrovou a mediánovou agregaci F-FCM algoritmu. Výstupy evaluačních metod pro tyto obrázky, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 34 a Tab. 35.

V tomto datasetu (MRI) byla segmentace relativně úspěšná pro obě nastavení algoritmu. Díky dobrému kontrastu a ohraničení hledaných útvarů došlo většinou k extrakci segmentační masky velmi podobné zlatému standardu. To potvrzují i výsledky evaluačních parametrů v Tab. 34 a Tab. 35, kdy parametr SSIM dosáhl ve všech případech alespoň hodnoty 0.95.

Byť okem obě nastavení dosáhla prakticky totožných výsledků, v kontextu objektivního hodnocení na základě Tab. 34 a Tab. 35 dosáhlo lepších výsledků nastavení mediánové agregace.


7.6 Segmentace objektů pomocí F-FCM algoritmu, dataset UZV

7.6.1 Průměrová agregace rozměru 9x9, 8 seg. tříd (regionů)



Obr. 102: Ukázky segmentace v datasetu UZV; (A) – Seg. pomocí F-FCM algoritmu (průměrová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní UZV snímek

7.6.2 Mediánová agregace rozměru 3x3, 8 seg. tříd (regionů)



Obr. 103: Ukázky segmentace v datasetu UZV; (A) – Seg. pomocí F-FCM algoritmu (mediánová agregace), (B) – Manuální segmentace (zlatý standard), (C) – Binarizovaný segmentační model, (D) – Binarizovaný seg. model (zlatý standard), (E) – Nativní UZV snímek

Tab. 36: Vyhodnocení srovnání segmentací objektu pomocí F-FCM algoritmu (průměrová agregace) vůči zlatému standardu v datasetu UZV.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.1331 | 7.12E+03 | 0.8099 |
| 2 | 0.1697 | 9.35E+03 | 0.8122 |
| 3 | 0.1096 | 1.17E+04 | 0.7625 |
| 4 | 0.1961 | 3.22E+04 | 0.3967 |
| 5 | 0.2308 | 3.04E+04 | 0.4478 |

Tab. 37: Vyhodnocení srovnání segmentací objektu pomocí F-FCM algoritmu (mediánová agregace) vůči zlatému standardu v datasetu UZV.

| Číslo snímku: | Korelace (-) | MSE (-) | SSIM (-) |
|---------------|--------------|----------|----------|
| 1 | 0.0426 | 2.26E+04 | 0.5467 |
| 2 | 0.1590 | 1.82E+04 | 0.6603 |
| 3 | 0.1017 | 2.19E+04 | 0.5773 |
| 4 | 0.1024 | 2.31E+04 | 0.4584 |
| 5 | 0.0852 | 2.15E+04 | 0.5273 |

Na Obr. 102 a Obr. 103 lze vidět obrazové výstupy pro průměrovou a mediánovou agregaci F-FCM algoritmu. Výstupy evaluačních metod pro tyto obrazy, kdy byly binární segmentační masky porovnávány s manuálně segmentovanými maskami sloužící jako zlatý standard, jsou znázorněny v Tab. 36 a Tab. 37

U této série obrazů je na první pohled patrné, že segmentace rozhodně není možné označit za úspěšnou. Vlivem velkého množství šumu a nízkého kontrastu nebylo většinou možné extrahovat požadovaný objekt zájmu z obrazu.

Celkově ale metoda F-FCM dosáhla lepších výsledků, než Fuzzy-ABC algoritmus. Z hlediska nastavení mediánové a průměrové agregace dosáhla na základě objektivních hodnotících parametrů lepších výsledků průměrová agregace.

Nádory, které se v obraze projevují jako tmavé skvrny, mají tendenci splývat s hlubšími (tmavšími) vrstvami tkáně. Lepších výsledků by bylo dosaženo, kdyby byla před testováním provedena extrakce RoI (Region of interest), ale vzhledem k cíli, kterým bylo zjištění efektivity lokalizace nádoru v tkáni, by se jednalo o zásadní ovlivnění celého testování.

8 Diskuse

Cílem práce byla analýza efektivity vybraných optimalizačních algoritmů při segmentaci obrazu zasaženého variabilními typy šumu s dynamickou intenzitou. Celkem byly otestovány tři datasety obsahující snímky MRI, fundus kamery a ultrazvuku. Otestovány byly tři typy šumu, a to Gaussovský šum, šum Salt&Pepper a Speckle. Každé metoda s výjimkou Fuzzy-ABC (50 snímků) byla otestována pomocí 200 snímků. Tento počet vždy zahrnuje 20 snímků, z nichž každý byl zašuměn 10 úrovněmi šumu od každého typu. U Fuzzy-ABC bylo z důvodu vysoké předpokládané výpočetní náročnosti otestováno jen 5 snímků a každý byl opět zašuměn 10 úrovněmi od každého typu šumu. K evaluaci byly využity MSE, korelace a SSIM.

Konkrétně byly testovány a hodnoceny algoritmy K-means, Otsuova metoda prahování, fuzzy algoritmus založený na algoritmu ABC a algoritmus založený na principu FCM (F-FCM). Testování bylo rozděleno do několika částí, kdy v první z nich (kapitola 5) byly globálně posouzeny efektivity všech algoritmů vůči sobě na základě zprůměrování výsledků jednotlivých metod v rámci typu šumu a datasetu MRI. Tímto byl získán hrubý pohled na to, jak jsou jednotlivé algoritmy efektivní při segmentaci obrazových dat MRI zasažených různými typy šumu. V druhé části (kapitola 6) byly vůči sobě porovnávány Otsuova metoda, K-means a Fuzzy-ABC algoritmus. Nastavení Fuzzy-ABC i F-FCM algoritmu bylo v rámci každého šumu a počtu regionů přizpůsobeno na základě nejlepších výsledků vzešlých z analýzy.

Ve třetí části (druhá polovina kapitoly 6) byly srovnávány pouze Fuzzy-ABC algoritmus a F-FCM, jejichž nastavení bylo opět provedeno pomocí nejlepších výsledků vzešlých z analýz. Jednalo se o nastavení typu agregace (mediánová, průměrová) a jejího rozměru (3x3, 5x5, 9x9, 15x15). U Fuzzy-ABC algoritmu se ještě navíc nastavoval počet iterací a velikost populace. U Fuzzy-ABC i F-FCM algoritmu bylo pro různé počty regionů (3, 5, 8) měněno nastavení v závislosti na tom, které z nastavení dosáhlo v rámci daného počtu regionů a typu šumu nejlepších výsledků v rámci analýz.

V poslední části, které byla vyhrazena vlastní 7. kapitola, byla řešena problematika efektivity extrakce objektu zájmu ze snímků MRI, CT a UZV. Extrakce byly provedeny pomocí Fuzzy-ABC s průměrovou agregací a F-FCM algoritmem, u kterého byly otestovány oba typy agregace. Nastavení každé z metod bylo provedeno opět podle výstupů analýz. Vybrané obrazy byly rozděleny do 8 regionů, z kterých byly vybrány třídy nejlépe reprezentující požadovaný objekt zájmu. Tyto třídy byly následně binarizovány, čímž vznikla výsledná segmentační maska, která byla porovnávána se segmentační maskou vytvořenou pomocí manuální segmentace. Výsledné hodnocení bylo provedeno na základě evaluačních parametrů, ale byly zmíněny i některé subjektivní postřehy.

Obecně je možné říct, že všechny metody dosahují nejvyšší efektivity při nastavení 8 regionů. Existují však výjimky, kdy to neplatí. Týká se to například datasetu Retina u šumu Speckle, kdy korelace dosahuje u všech metod nejlepších výsledků při nastavení 5 regionů a MSE i SSIM jsou nejlepší při nastavení 3 regionů. Další příklady je možné nalézt také v datasetu UZV a Gaussovského šumu i šumu Speckle. Dále bylo zjištěno, že vyšší nastavení iterací i populace u Fuzzy-ABC algoritmu automaticky neznamená, že bude dosažena vyšší efektivita. Co je možné tvrdit s jistotou je však to, že významně vzroste výpočetní náročnost. Při nastavení 8 regionů je nárůst výpočetního času nejvyššího nastavení Fuzzy-ABC oproti nejnižšímu zhruba 26krát vyšší. Nejnižší nastavení Fuzzy-ABC algoritmu (50 iterací, populace 100) při segmentaci obrazu do 8 regionů bylo v porovnání s Otsuovou metodou průměrně 108krát časově náročnější.

Dále bylo zjištěno, že F-FCM algoritmus vykazuje mnohem lepší robustnost vůči rostoucí úrovni zašumění. V rámci datasetu MRI dosahuje F-FCM algoritmus prakticky vždy lepších výsledků než Fuzzy-ABC algoritmu, u kterého je možné v grafech v mnoha případech pozorovat výrazné fluktuace efektivity při segmentaci obrazů do různého počtu segmentačních tříd. U tohoto jevu je však možné říct, že se zvyšujícím se počtem regionů se tyto fluktuace stávají méně významnými.

Z hlediska porovnání efektivity Fuzzy-ABC algoritmu a F-FCM je možné tvrdit, že F-FCM dosahuje ve všech datasetech u většiny evaluačních parametrů v rámci všech typů šumu i segmentačních tříd lepších výsledků. V případech, kde Fuzzy-ABC dosahuje lepších hodnot jsou zpravidla hodnoty obou metod velice blízké. Z hlediska porovnání efektivnějšího typu agregace u F-FCM algoritmu v drtivé většině případů dosahuje lepších výsledků průměrová agregace. U všech datasetů platí, že lepších výsledků dosahují u průměrové agregace při zpracování snímků s Gaussovským šumem a šumem Speckle spíše vyšší rozměry agregační masky (9x9, 15x15). Naopak u šumu Salt&Pepper dosahují v datasetech UZV a MRI lepších výsledků menší rozměry agregace (3x3, 5x5). U datasetu Retina jsou nastavení 5x5 a 9x9 nejlepší i pro zpracování snímků zasažených tímto šumem.

Ve srovnání s konvenčními metodami Fuzzy-ABC většinou dosahuje lepších výsledků, ale jsou i případy, kdy je metoda Otsu na základě evaluačních parametrů lepší. K-means lze vyhodnotit jako globálně nejméně efektivní metodu.

Obecně je možné říct, že průměrová agregace dosahuje lepších nebo obdobných výsledků než mediánová agregace. Kromě případu v datasetu MRI u Gaussovského šumu se však nestává, že by mediánová agregace dosahovala významně lepších výsledků.

Důležitým faktem je, že po dvojím zpracování téhož obrazu pomocí Fuzzy-ABC nikdy nedostaneme dva stejné výsledky. Tento fenomén je daný náhodností počáteční množiny řešení, které jsou následně na základě principu ABC algoritmu zpracovávány. Tento fakt má velký vliv na rozkolísanost například na Obr. 78. Tento jev může být částečně způsoben také nedostatečným prohledáním prostoru všech řešení z důvodu nedostatečného nastavení iterací a populace.

Při extrakci vybraných objektů zájmu se ukázaly všechny testované algoritmy (Fuzzy-ABC a obě agregace algoritmu F-FCM) jako obdobně efektivní. Významný vliv zde ale má náhoda, jelikož opět platí, že dvakrát nelze získat stejný výsledek. Rozdíly hodnot evaluačních parametrů se tak při dvou pokusech mohou lišit i o desetiny. Na základě rešerše i výsledků této práce je však možné tvrdit, že oba testované algoritmy je možné použít relativně efektivně pro segmentování objektů z medicínských obrazových dat. Bylo by však dobré k tomuto účelu využít postprocessingu k odstranění nežádoucích struktur, které byly chybně segmentovány společně s objektem zájmu.

Na základě celého testování a analýz s přihlédnutím k výstupům evaluačních parametrů je možné tvrdit, že byt' jsou tyto objektivní výstupy určitě velmi důležité pro srovnání efektivity různých metod, ne vždy lepší hodnota indikuje skutečně lepší výsledek.

Nebylo v možnostech této práce otestovat zvláště změny počtu iterací při neměnicí se velikosti populace a naopak. Je však možné na základě výsledků tvrdit, že výsledné hodnoty evaluačních parametrů se při změnách těchto otestovaných nastavení ve většině případů významně nemění. Tato práce tak nabízí potenciál pro rozšíření právě o analýzu vlivu různých nastavení Fuzzy-ABC algoritmu, ale také by mohly být otestovány podstatně vyšší nastavení tohoto algoritmu. Pravděpodobně by k tomu muselo být využito například pronájmu výpočetní kapacity superpočítačového centra, protože i pro nastavené hodnoty v rámci této práce byla výpočetní náročnost obrovská.

9 Závěr

Cílem práce byla analýza vybraných metod při obrazové segmentaci vybraných medicínských snímků s rostoucí intenzitou různých typů parazitních šumů. První část práce se zabývá teorií, kde jsou popsány základní principy segmentace obrazu vybrané metody, které se při regionální segmentaci nejčastěji používají. Následující část teorie se zabývá popisem a základní funkčností evolučních algoritmů a popisem některých z nich. Následující rešeršní část se zabývá přímo tématem aplikací různých evolučních algoritmů za účelem obrazové segmentace.

Na pomezí mezi teoretickou částí a praktickou částí je kapitola 4, která se zabývá tvorbou testovací báze, popisem použitých typů šumu, popisem využitých evaluačních parametrů a popisem principu testování.

Praktická část začíná kapitolou 5, ve které jsou testované metody globálně porovnány mezi sebou pro všechny typy šumu. Na konci této kapitoly jsou také grafická zobrazení výpočetní náročnosti a popis výpočetního systému, na kterém byla práce realizována. Dále praktická část pokračuje kapitolou 6, jejíž první části jsou porovnány nejlepší výsledky metod Fuzzy-ABC, Otsuovy metody a K-means při počtu regionů 8 pro všechny typy šumu. V druhé části této kapitoly jsou porovnávány nejlepší výsledky nejlepších nastavení Fuzzy-ABC algoritmu a F-FCM algoritmu taktéž pro všechny typy šumu. Nejpodstatnější výsledky byly okomentovány v rámci diskuse. Poslední kapitola 7 se zabývá extrakcí vybraných objektů zájmu z medicínských snímků pomocí metod Fuzzy-ABC s průměrovou agregací a F-FCM s průměrovou i mediánovou agregací. Zde bylo zjištěno, že obě metody dosahují obdobných výsledků a je možné je využít pro extrakci objektu zájmu z medicínských snímků.

10 Literatura a jiné zdroje:

- [1] MAINTZ, J.B. Antoine a Max A. VIERGEVER. A survey of medical image registration. *Medical Image Analysis* [online]. 1998, **2**(1), 1–36. ISSN 13618415. Dostupné z: doi:10.1016/S1361-8415(01)80026-8
- [2] NOROUZI, Alireza, Mohd Shafry Mohd RAHIM, Ayman ALTAMEEM, Tanzila SABA, Abdolvahab Ehsani RAD, Amjad REHMAN a Mueen UDDIN. Medical Image Segmentation Methods, Algorithms, and Applications. *IETE Technical Review* [online]. 2014, **31**(3), 199–213. ISSN 0256-4602, 0974-5971. Dostupné z: doi:10.1080/02564602.2014.906861
- [3] SHARMA, Neeraj, AmitK RAY, Kk SHUKLA, Shiru SHARMA, Satyajit PRADHAN, Arvind SRIVASTVA a LalitM AGGARWAL. Automated medical image segmentation techniques. *Journal of Medical Physics* [online]. 2010, **35**(1), 3. ISSN 0971-6203. Dostupné z: doi:10.4103/0971-6203.58777
- [4] CASTRO, F.J.S., C. POLLO, R. MEULI, P. MAEDER, O. CUISENAIRE, M.B. CUADRA, J.-G. VILLEMURE a J.-P. THIRAN. A Cross Validation Study of Deep Brain Stimulation Targeting: From Experts to Atlas-Based, Segmentation-Based and Automatic Registration Algorithms. *IEEE Transactions on Medical Imaging* [online]. 2006, **25**(11), 1440–1450. ISSN 0278-0062, 1558-254X. Dostupné z: doi:10.1109/TMI.2006.882129
- [5] SARADHI, G.V., G. GOPALAKRISHNAN, A.S. ROY, R. MULLICK, R. MANJESHWAR, K. THIELEMANS a U. PATIL. A framework for automated tumor detection in thoracic FDG pet images using texture-based features. In: *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro (ISBI): 2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro* [online]. Boston, MA, USA: IEEE, 2009, s. 97–100 [vid. 2021-11-01]. ISBN 978-1-4244-3931-7. Dostupné z: doi:10.1109/ISBI.2009.5192992
- [6] ROGOWSKA, Jadwiga. Overview and Fundamentals of Medical Image Segmentation. In: *Handbook of Medical Imaging* [online]. B.m.: Elsevier, 2000 [vid. 2021-11-01], s. 69–85. ISBN 978-0-12-077790-7. Dostupné z: doi:10.1016/B978-012077790-7/50009-6
- [7] BANKMAN, I.N., T. NIZIALEK, I. SIMON, O.B. GATEWOOD, I.N. WEINBERG a W.R. BRODY. Segmentation algorithms for detecting microcalcifications in mammograms. *IEEE Transactions on Information Technology in Biomedicine* [online]. 1997, **1**(2), 141–149. ISSN 10897771. Dostupné z: doi:10.1109/4233.640656
- [8] LIM, Kelvin O. a Adolf PFEFFERBAUM. Segmentation of MR Brain Images into Cerebrospinal Fluid Spaces, White and Gray Matter: *Journal of Computer Assisted Tomography* [online]. 1989, **13**(4), 588–593. ISSN 0363-8715. Dostupné z: doi:10.1097/00004728-198907000-00006
- [9] KUBÍČEK, Jan, SLEZSKÁ UNIVERZITA, a ÚSTAV FYZIKY. *Zpracování medicínských obrazových dat*. Opava: Slezská univerzita v Opavě, Filozoficko-přírodovědecká fakulta, Ústav fyziky, 2014. ISBN 978-80-7248-941-1.
- [10] DOUGHERTY, Geoff. *Digital image processing for medical applications*. Cambridge, UK ; New York: Cambridge University Press, 2009. ISBN 978-0-521-86085-7.
- [11] NOMURA, Atsushi, Makoto ICHIKAWA, Rismon H. a Hidetoshi MIIKE. Reaction-Diffusion Algorithm for Vision Systems. In: Goro OBINATA a Ashish DUTT, ed. *Vision Systems: Segmentation and Pattern Recognition* [online]. B.m.: I-Tech Education and Publishing, 2007 [vid. 2021-11-06]. ISBN 978-3-902613-05-9. Dostupné z: doi:10.5772/4954

- [12] FERMÜLLER, Cornelia a Marc POLLEFEYS. Edge detection. In: [online]. B.m. Dostupné z: <https://www.ics.uci.edu/~majumder/DIP/classes/EdgeDetect.pdf>
- [13] VALOŠEK, Jan. *Software pro vizualizaci a kvantitativní vyhodnocení cévních kalcifikací* [online]. Ostrava, 2017. Diplomová práce. Vysoká škola báňská – Technická univerzita Ostrava. Dostupné z: <http://hdl.handle.net/10084/119119>
- [14] OLIVER, Arnau, Jordi FREIXENET, Joan MARTÍ, Elsa PÉREZ, Josep PONT, Erika R.E. DENTON a Reyer ZWIGGELAAR. A review of automatic mass detection and segmentation in mammographic images. *Medical Image Analysis* [online]. 2010, 14(2), 87–110. ISSN 13618415. Dostupné z: doi:10.1016/j.media.2009.12.005
- [15] *Simple single-seeded region growing* [online]. 2012. Dostupné z: <https://uk.mathworks.com/matlabcentral/fileexchange/35269-simple-single-seeded-region-growing>
- [16] MITTAL, Himanshu, Avinash Chandra PANDEY, Mukesh SARASWAT, Sumit KUMAR, Raju PAL a Garv MODWEL. A comprehensive survey of image segmentation: clustering methods, performance parameters, and benchmark datasets. *Multimedia Tools and Applications* [online]. 2021 [vid. 2021-11-07]. ISSN 1380-7501, 1573-7721. Dostupné z: doi:10.1007/s11042-021-10594-9
- [17] VISWARUPAN, Niruhan. K-Means Data Clustering [online]. 2017, 2017. Dostupné z: <https://towardsdatascience.com/k-means-data-clustering-bce3335d2203>
- [18] COHEN, David, Theodore LEE a David SKLAR. *Precalculus: a problems-oriented approach*. 6th ed. Belmont, CA: Thomson-Brooks/Cole, 2005. ISBN 978-0-534-40212-9.
- [19] Euclidean Distance. *ROSALIND* [online]. Dostupné z: <http://rosalind.info/glossary/euclidean-distance/>
- [20] VERMA, Hanuman, Deepa VERMA a Pawan Kumar TIWARI. A population based hybrid FCM-PSO algorithm for clustering analysis and segmentation of brain image. *Expert Systems with Applications* [online]. 2021, 167, 114121. ISSN 09574174. Dostupné z: doi:10.1016/j.eswa.2020.114121
- [21] KUBICEK, PENHAKER, AUGUSTYNEK, CERNY, a OCZKA. Segmentation of Articular Cartilage and Early Osteoarthritis based on the Fuzzy Soft Thresholding Approach Driven by Modified Evolutionary ABC Optimization and Local Statistical Aggregation. *Symmetry* [online]. 2019, 11(7), 861. ISSN 2073-8994. Dostupné z: doi:10.3390/sym11070861
- [22] VOLNÁ, Eva. *EVOLUČNÍ ALGORITMY A NEURONOVÉ SÍŤE* [online]. B.m.: Ostravská univerzita v Ostravě. 2012. Dostupné z: https://web.osu.cz/~Volna/Evolucni_algoritmy_a_neuronove_site.pdf
- [23] MOZDREN, Karel, Tomas BURIANEK, Jan PLATOS a Václav SNÁŠEL. Evolutionary Techniques for Image Segmentation. In: Pavel KÖMER, Ajith ABRAHAM a Václav SNÁŠEL, ed. *Proceedings of the Fifth International Conference on Innovations in Bio-Inspired Computing and Applications IBICA 2014* [online]. Cham: Springer International Publishing, 2014 [vid. 2021-11-07], *Advances in Intelligent Systems and Computing*, s. 291–300. ISBN 978-3-319-08155-7. Dostupné z: doi:10.1007/978-3-319-08156-4_29
- [24] BEVILACQUA, Vitoantonio a Giuseppe MASTRONARDI. Image Segmentation Using a Genetic Algorithm. In: Andrea BONARINI, Francesco MASULLI a Gabriella PASI, ed. *Soft*

- Computing Applications* [online]. Heidelberg: Physica-Verlag HD, 2003 [vid. 2021-11-07], s. 115–126. ISBN 978-3-7908-1544-3. Dostupné z: doi:10.1007/978-3-7908-1768-3_11
- [25] HYNEK, Josef. *Genetické algoritmy a genetické programování*. Praha: Grada, 2008. ISBN 978-80-247-2695-3.
- [26] FARADONBEH, Roohollah Shirani, Mahdi HASANIPANAH, Hassan Bakhshandeh AMNIEH, Danial Jahed ARMAGHANI a Masoud MONJEZI. Development of GP and GEP models to estimate an environmental issue induced by blasting operation. *Environmental Monitoring and Assessment* [online]. 2018, 190(6), 351. ISSN 0167-6369, 1573-2959. Dostupné z: doi:10.1007/s10661-018-6719-y
- [27] VILLAFANEZ, Juan P. *Un algoritmo genético: una breve introducción* [online]. 2019. Dostupné z: <https://ahorasomos.izertis.com/solidgear/un-algoritmo-genetico-una-breve-introduccion/>
- [28] PARK, Kendall. *Approximation with Genetic Algorithms* [online]. 2014. Dostupné z: <https://github.com/KendallPark/genetic-algorithm>
- [29] SHERRY, A. 2D Image segmentation by Hybridization of PSO and BBO. *International Journal of Engineering Research and General Science* [online]. 2017. ISSN 2091-2730. Dostupné z: <https://www.semanticscholar.org/paper/2-D-Image-segmentation-by-Hybridization-of-PSO-and-Sherry/39c641a944ae7c07cde8115a50ca8df7541be043>
- [30] HAMD AOUI, Fayçal, Anis LADGHAM, Anis SAKLY a Abdellatif MTIBAA. A new images segmentation method based on modified particle swarm optimization algorithm. *International Journal of Imaging Systems and Technology* [online]. 2013, 23(3), 265–271. ISSN 08999457. Dostupné z: doi:10.1002/ima.22060
- [31] SIVANANDAM, S. N. a S. N. DEEPA. *Introduction to Genetic Algorithms*. Guildford Boulder: Springer London NetLibrary, Inc. [distributor], nedatováno. ISBN 978-3-540-73190-0.
- [32] LOKHANDE, Netra M. a Ramachandra V. PUJERI. Novel Image Segmentation Using Particle Swarm Optimization. In: *the 2018 8th International Conference: Proceedings of the 2018 8th International Conference on Biomedical Engineering and Technology - ICBET '18* [online]. Bali, Indonesia: ACM Press, 2018, s. 46–50 [vid. 2021-11-09]. ISBN 978-1-4503-6369-3. Dostupné z: doi:10.1145/3208955.3208962
- [33] LIU, Shuo, Kang ZHOU, Huaqing QI a Jiangrong LIU. Improved hybrid particle swarm optimisation for image segmentation. *International Journal of Parallel, Emergent and Distributed Systems* [online]. 2021, 36(1), 44–50. ISSN 1744-5760, 1744-5779. Dostupné z: doi:10.1080/17445760.2019.1689568
- [34] LIN, Zhengchun, Zhiyan WANG a Yanqing ZHANG. Image Thresholding Using Particle Swarm Optimization. In: *2008 International Conference on MultiMedia and Information Technology (MMIT): 2008 International Conference on MultiMedia and Information Technology* [online]. Three Gorges, China: IEEE, 2008, s. 245–248 [vid. 2021-11-09]. ISBN 978-0-7695-3556-2. Dostupné z: doi:10.1109/MMIT.2008.43
- [35] ZHU, Xia. Image Segmentation Research Based on Particle Swarm Optimization. *Advanced Materials Research* [online]. 2011, 403–408, 1644–1647. ISSN 1662-8985. Dostupné z: doi:10.4028/www.scientific.net/AMR.403-408.1644
- [36] YONG-FENG, Xu a Zhang SHU-LING. Fuzzy Particle Swarm Clustering of Infrared Images. In: *2009 Second International Conference on Information and Computing Science: 2009 Second International Conference on Information and Computing Science* [online]. Manchester, England,

- UK: IEEE, 2009, s. 122–124 [vid. 2021-11-09]. ISBN 978-0-7695-3634-7. Dostupné z: doi:10.1109/ICIC.2009.139
- [37] Particle Swarm Optimization (PSO). *esa.github.io* [online]. Dostupné z: <https://esa.github.io/pagmo2/docs/cpp/algorithms/pso.html>
- [38] KUBÍČEK, Jan, Marek PENHAKER, Martin AUGUSTINEK, Martin ČERNÝ a David OCZKA. *Intelligent information and database systems: 10th Asian Conference, ACIIDS 2018, Dong Hoi City, Vietnam, March 19-21, 2018: proceedings. Part 2*. Cham: Springer, 2018. Lecture notes in computer science Lecture notes in artificial intelligence, 10752. ISBN 978-3-319-75420-8.
- [39] THOMAZ, R. L., R. ANASTÁCIO, T. A. A. MACEDO, A. C. PATROCINIO a A. B. SOARES. Non-deterministic optimization using Differential Evolution algorithm to launch seeds for liver segmentation in MDCT. In: David A. JAFFRAY, ed. *World Congress on Medical Physics and Biomedical Engineering, June 7-12, 2015, Toronto, Canada* [online]. Cham: Springer International Publishing, 2015 [vid. 2021-11-20], IFMBE Proceedings, s. 78–81. ISBN 978-3-319-19386-1. Dostupné z: doi:10.1007/978-3-319-19387-8_20
- [40] FAN, Yuling, Peizhong LIU, Jianeng TANG, Yanmin LUO a Yongzhao DU. Fuzzy entropy based on differential evolution for breast gland segmentation. *Australasian Physical & Engineering Sciences in Medicine* [online]. 2018, 41(4), 1101–1114. ISSN 0158-9938, 1879-5447. Dostupné z: doi:10.1007/s13246-018-0672-5
- [41] ÖZTÜRK, Şaban, Rehan AHMAD a Nadeem AKHTAR. Variants of Artificial Bee Colony algorithm and its applications in medical image processing. *Applied Soft Computing* [online]. 2020, 97, 106799. ISSN 15684946. Dostupné z: doi: 10.1016/j.asoc.2020.106799
- [42] HASSANIEN, Aboul Ella, E. EMARY a Hossam M. ZAWBAA. Retinal blood vessel localization approach based on bee colony swarm optimization, fuzzy c-means and pattern search. *Journal of Visual Communication and Image Representation* [online]. 2015, 31, 186–196. ISSN 10473203. Dostupné z: doi: 10.1016/j.jvcir.2015.06.019
- [43] ALI, Ahmed Fouad, Abdalla MOSTAFA, Gehad Ismail SAYED, Mohamed Abd ELFATTAH a Aboul Ella HASSANIEN. Nature Inspired Optimization Algorithms for CT Liver Segmentation. In: Nilanjan DEY, Vikrant BHATEJA a Aboul Ella HASSANIEN, ed. *Medical Imaging in Clinical Applications* [online]. Cham: Springer International Publishing, 2016 [vid. 2021-12-02], Studies in Computational Intelligence, s. 431–460. ISBN 978-3-319-33791-3. Dostupné z: doi:10.1007/978-3-319-33793-7_19
- [44] ZHAO, Yanqiao, Xiaoyang YU, Haibin WU, Yong ZHOU, Xiaoming SUN, Shuang YU, Shuchun YU a He LIU. A Fast 2-D Otsu lung tissue image segmentation algorithm based on improved PSO. *Microprocessors and Microsystems* [online]. 2021, 80, 103527. ISSN 01419331. Dostupné z: doi: 10.1016/j.micpro.2020.103527
- [45] ZHAO, Juan juan, Guo hua JI, Yong XIA a Xiao long ZHANG. Cavitory nodule segmentation in computed tomography images based on self-generating neural networks and particle swarm optimisation. *International Journal of Bio-Inspired Computation* [online]. 2015, 7(1), 62. ISSN 1758-0366, 1758-0374. Dostupné z: doi:10.1504/IJBIC.2015.067999
- [46] VIKRAM, K., Hema P. MENON a Dhanya M. DHANALAKSHMY. Segmentation of Brain Parts from MRI Image Slices Using Genetic Algorithm. In: D. Jude HEMANTH a S. SMYS, ed. *Computational Vision and Bio Inspired Computing* [online]. Cham: Springer International Publishing, 2018 [vid. 2021-12-03], Lecture Notes in Computational Vision and Biomechanics, s. 457–465. ISBN 978-3-319-71766-1. Dostupné z: doi:10.1007/978-3-319-71767-8_38

- [47] YONG FAN, TIANZI JIANG a D.J. EVANS. Volumetric segmentation of brain images using parallel genetic algorithms. *IEEE Transactions on Medical Imaging* [online]. 2002, 21(8), 904–909. ISSN 0278-0062. Dostupné z: doi:10.1109/TMI.2002.803126
- [48] MÜHLENBEIN, H., M. SCHOMISCH a J. BORN. The parallel genetic algorithm as function optimizer. *Parallel Computing* [online]. 1991, 17(6–7), 619–632. ISSN 01678191. Dostupné z: doi:10.1016/S0167-8191(05)80052-3
- [49] HUANG, Peng, Huizhi CAO a Shuqian LUO. An artificial ant colonies approach to medical image segmentation. *COMPUTER METHODS AND PROGRAMS IN BIOMEDICINE* [online]. 2008, 2008(3). Dostupné z: 10.3233/THC-140845
- [50] SELMANI, Anissa, Hassene SEDDIK a Ezzedine BEN BRAIEK. A novel ant colonies approach to medical image segmentation. In: *2017 14th International Multi-Conference on Systems, Signals & Devices (SSD): 2017 14th International Multi-Conference on Systems, Signals & Devices (SSD)* [online]. Marrakech: IEEE, 2017, s. 22–26 [vid. 2021-12-04]. ISBN 978-1-5386-3175-1. Dostupné z: doi:10.1109/SSD.2017.8167012
- [51] BÍLEK, Petr. *Aplikace zpracování biomedicínských obrazů na základě Wavelet transformace*. Ostrava, 2020. Vysoká škola báňská – Technická univerzita Ostrava.
- [52] LOIZOU, Christos P a Constantinos S PATTICHIS. *Despeckle filtering algorithms and software for ultrasound imaging*. S.l.: Morgan & Claypool, 2008. ISBN 978-1-59829-621-1.
- [53] ISTEPANIAN, R. S. H., N. PHILIP, M. G. MARTINI, N. AMSO a P. SHORVON. Subjective and objective quality assessment in wireless teleultrasonography imaging. In: *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society: 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. Vancouver, BC: IEEE, 2008, s. 5346–5349 [vid. 2022-03-11]. ISBN 978-1-4244-1814-5. Dostupné z: doi:10.1109/IEMBS.2008.4650422

Seznam příloh

Příloha I. – Tato příloha v elektronické podobě obsahuje všechny MATLAB skripty, s kterými bylo v rámci řešení práce pracováno. Jednotlivé složky jsou pojmenovány tak, aby bylo možné se v nich intuitivně vyznat. Součástí přílohy je také hlavičkový PDF soubor popisující jednotlivé části přílohy. Přílohy obsahují složky s datasey, které obsahují obsahují podsložky:

- ABC algoritmus – uvnitř této složky jsou skripty pro řešení zpracování vybraných obrazů pomocí Fuzzy-ABC algoritmu.
- Grafická srovnání – 351 grafů pro každý dataset vyobrazující průběhy srovnávaných metod a jejich příslušných nastavení. Názvy grafů jsou voleny s ohledem na intuitivní zorientování.
- Výsledná data jednotlivých metod a vytvoření grafů – tato složka vždy obsahuje všechna raw data, která byla vytvořena zpracováním obrazů v příslušném datasetu. Na základě skriptů v této složce byly spočítány z výsledků průměry, mediány, směrodatné odchylky. Tyto spočtené hodnoty byly dále využity právě pro tvorbu grafů.
- Klasifikace – tyto složky obsahují skripty využité pro segmentaci vybraných objektů zájmu z obrazu. Nachází se zde také obrazové výstupu uložené v příslušných složkách.