



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

SEGMENTACE OPTICKÉHO DISKU V OBRAZOVÝCH DATECH SÍTNICE

SEGMENTATION OF OPTIC DISC IN RETINAL IMAGE DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Radek Juráček

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Odstrčilík, Ph.D.

BRNO 2022

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Radek Juráček

ID: 184397

Ročník: 3

Akademický rok: 2021/22

NÁZEV TÉMATU:

Segmentace optického disku v obrazových datech sítnice

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principem snímání očního pozadí pomocí experimentálního video oftalmoskopu a fundus kamery. 2) Provedte literární rešerši prací zabývajících se detekcí a segmentací optického disku v obrazových datech sítnice. Zaměřte se hlavně na metody, které jsou robustní vůči šumu a artefaktům v obraze. 3) Nastudujte nejméně 3 metody segmentace optického disku a proveďte jejich implementaci v programovém prostředí MATLAB. 4) Implementované algoritmy otestujte a případně rozšířte za účelem dosažení co nejvyšší úspěšnosti segmentace a následně vyhodnoťte na dostupných datech. 5) Provedte diskusi dosažených výsledků a zhodnoťte účinnost a využitelnost aplikovaného řešení. 6) Vytvořené programové funkce přehledně okomentujte.

DOPORUČENÁ LITERATURA:

[1] THAKUR, N., et al. Survey on segmentation and classification approaches of optic cup and optic disc for diagnosis of glaucoma. Biomedical Signal Processing and Control, 2018, roč. 42, č. 4, s. 162-189.

[2] ALMAZROA, A., et al. Optic Disc and Optic Cup Segmentation Methodologies for Glaucoma Image Detection: A Survey. Journal of Ophthalmology, 2015.

Termín zadání: 7.2.2022

Termín odevzdání: 27.5.2022

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

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Tato bakalářská práce se zabývá návrhem a realizací algoritmu automatické detekce optického disku v retinálních snímcích. Stručně popisuje anatomii lidského oka a principy snímání očního pozadí. Dále jsou popsány metody segmentace optického disku. Vybrané metody jsou implementovány v prostředí MATLAB a optimalizovány pomocí genetického algoritmu. Celkem pět metod bylo představeno a optimalizováno na HRF datasetu a dvou experimentálních datasetech.

KLÍČOVÁ SLOVA

retina, optický disk, segmentace, evoluční algoritmus, genetický algoritmus, netopýří algoritmus, morfologické operace, kruhová Houghova transformace, prahování obrazu

ABSTRACT

This bachelor thesis is focused on the algorithm of automatic detection of the optic disc in retinal images. It briefly describes the anatomy of the human eye and the principles of scanning the ocular background. The following describes the optical disk segmentation methods. Selected methods are implemented in MATLAB and optimized using a genetic algorithm. A total of five methods were introduced and optimized on the HRF dataset and two experimental datasets.

KEYWORDS

retina, optic disc, segmentation, evolutionary algorithm, genetic algorithm, bat algorithm, morphological operations, circular Hough transform, image thresholding

JURÁČEK, Radek. *Segmentace optického disku v obrazových datech sítnice*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Department of Biomedical Engineering, 2022, 97 s. Bakalářská práce. Vedoucí práce: Ing. Jan Odstrčilík, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Radek Juráček
VUT ID autora: 184397
Typ práce: Bakalářská práce
Akademický rok: 2021/22
Téma závěrečné práce: Segmentace optického disku v obrazových datech sítnice

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval svému vedoucímu bakalářské práce panu Ing. Jan Odstrčilíkovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	21
1 Snímky očního pozadí	25
1.1 Metody snímání očního pozadí	25
1.2 Oční pozadí	26
1.3 Kritéria hodnocení	28
1.4 Databáze retinálních snímků	31
1.4.1 HFR	31
1.4.2 Experimentální video-ofthalmoskop	31
2 Metody segmentace optického disku	33
3 Implementované metody segmentace	39
3.1 Optimalizace genetickým algoritmem	39
3.2 Implementace segmentačních metod	41
3.3 Segmentace optického disku pomocí prahování	42
3.4 Segmentace optického disku pomocí kruhové Houghovy transformace	44
3.5 Kruhová Houghova transformace s potlačením krevního řečiště	47
3.6 Segmentace s využitím netopýřího algoritmu pro stanovení prahu . .	49
3.7 Segmentace s využitím metody narůstání oblasti	52
4 Výsledky implementovaných metod	55
5 Diskuze	57
Závěr	65
Literatura	67
Seznam symbolů a zkratk	73
Seznam příloh	75
A Tabulky - Metriky jednotlivých snímků	77

Seznam obrázků

1	Anatomie lidského oka [3]	22
1.1	Znázornění principu přímé oftalmoskopie [5]	25
1.2	Znázornění principu nepřímé oftalmoskopie [9]	26
1.3	Schéma optického aparátu fundus kamery [8]	27
1.4	Schéma osvětlení sítnice [8]	27
1.5	Vyznačení diagnosticky zajímavých struktur na snímku sítnice [14]	28
1.6	Příklad peripapilární atrofie [10]	29
1.7	Na levém snímku optický disk zdravého oka, na pravém snímku optický disk se zvětšeným pohárkem oka postiženého glaukomem [13]	29
1.8	Kritérium hodnocení segmentace [15]	30
1.9	HRF snímek zdravého pacienta [18]	31
1.10	Snímek pořízený experimentálním oftalmoskopem [16]	32
3.1	Obecný genetický algoritmus	40
3.2	Postup segmentace prahováním	44
3.3	Implementovaný postup kruhové Houghovy transformace	45
3.4	Detekce kružnice [37]	46
3.5	Implementovaný postup prosté kruhové Houghovy transformace	48
3.6	Implementovaný postup využívající netopýří algoritmus	50
3.7	Implementovaný postup využívající narůstání oblasti	53
5.1	Boxplot DICE metriky HRF datasetu	57
5.2	Boxplot DICE metriky STUDY_01 datasetu	58
5.3	Boxplot DICE metriky STUDY_02 datasetu	58
5.4	Graf učicí fáze HRF datasetu	59
5.5	Graf učicí fáze STUDY_01 datasetu	59
5.6	Graf učicí fáze STUDY_02 datasetu	60
5.7	Ukázka segmentace snímku pomocí prahování	61
5.8	Ukázka maskování krevního řečiště pomocí lineárního strukturního elementu	62
5.9	Ukázka maskování krevního řečiště pomocí diskového strukturního elementu	63

Seznam tabulek

3.1	Optimalizované parametry prahovací metody	43
3.2	Optimalizované parametry metody Houghovy transformace	47
3.3	Optimalizované parametry metody Houghovy transformace s potlačením krevního řečiště	49
3.4	Optimalizované parametry metody netopýřího algoritmu	52
3.5	Optimalizované parametry narůstání oblasti	53
4.1	Tabulka DICE metrik všech metod na HRF	55
4.2	Tabulka DICE metrik všech metod na STUDY_01	55
4.3	Tabulka DICE metrik všech metod na STUDY_02	56
5.1	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na HRF	60
5.2	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na HRF	63
A.1	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování HRF	78
A.2	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování STUDY_01	78
A.3	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování STUDY_02	78
A.4	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na STUDY_01	79
A.5	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na STUDY_02	79
A.6	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na HRF	79
A.7	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na STUDY_01	80
A.8	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na STUDY_02	80
A.9	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na STUDY_01	80
A.10	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na STUDY_02	81
A.11	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na HRF	81
A.12	Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na STUDY_01	81

A.13 Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na STUDY_02	81
A.14 Tabulka překryvů všech metod na HRF	82
A.15 Tabulka překryvů všech metod na STUDY_01	82
A.16 Tabulka překryvů všech metod na STUDY_02	82
A.17 Tabulka výsledků prahování na HRF dataset	83
A.18 Tabulka výsledků prahování na STUDY01 dataset	84
A.19 Tabulka výsledků prahování na STUDY02 dataset	85
A.20 Tabulka výsledků Houghovy transformace na HRF datasetu	86
A.21 Tabulka výsledků Houghovy transformace s morfologií na STUDY01 datasetu	87
A.22 Tabulka výsledků Houghovy transformace na STUDY01 datasetu	88
A.23 Tabulka výsledků Houghovy transformace na STUDY02 datasetu	89
A.24 Tabulka výsledků Houghovy transformace s morfologií na HRF datasetu	90
A.25 Tabulka výsledků Houghovy transformace s morfologií na STUDY02 datasetu	91
A.26 Tabulka výsledků narůstání oblasti na HRF datasetu	92
A.27 Tabulka výsledků narůstání oblasti na STUDY01 datasetu	93
A.28 Tabulka výsledků narůstání oblasti na STUDY02 datasetu	94
A.29 Tabulka výsledků netopýřího algoritmu na HRF datasetu	95
A.30 Tabulka výsledků netopýřího algoritmu na STUDY01 datasetu	96
A.31 Tabulka výsledků netopýřího algoritmu na STUDY02 datasetu	97

Seznam výpisů

Úvod

Včasná diagnostika a léčba je doposud jediným způsobem, jak zabránit nevratné ztrátě zraku způsobené nejčastěji glaukomem, věkem, podmíněnou makulární degenerací, angiopatií, retinopatií či jiným onemocněním postihujícím sítnici a zrakový nerv. Vyšetření spočívá ve vizuální kontrole očního pozadí a extrakci diagnosticky důležitých oblastí zadního segmentu oka. Tradiční metoda, kdy odborník manuálně značí scénu očního pozadí, je pro efektivní screening populace časově náročná a zatížená lidským faktorem. Naštěstí se s příchodem digitalizace snímků nabízí možnost algoritmizace tohoto procesu s cílem rychlejší a přesnější segmentace vedoucí ke včasější diagnóze, což je náplní této práce. [1]


Anatomie oka

Následující odstavce jsou věnovány elementárnímu popisu anatomických struktur oka a převodnímu systému zrakové dráhy s cílem seznámení se s problematikou. Lidské oko je párový kulovitý smyslový orgán uložený uvnitř očnice, reagující na světlo o vlnových délkách v rozsahu přibližně 380 až 760 nm. Vnější slupku tvoří bílá tuhá vazivová blána zvaná bělima (*sclera*), na které jsou upnuty okoohybné svaly. Světlo dopadající na světlolámající rohovku (*cornea*) prochází skrz duhovku (*iris*) kruhovým otvorem zvaný zornice (*pupila*), který pomocí hladkého svalstva mění svůj průměr a množství procházejícího světla. Prošlé světlo je fokusováno na zadní stěnu pomocí pružné bikonvexní čočky (*lens crystallina*), kterou dle potřeb zakřivuje řasnaté tělísko (*corpus ciliare*) z hladké svaloviny. Na zadní stěně paprsky dopadají na narůžovělou světločivnou blánu zvanou sítnice (*retina*), kterou krví zásobuje cévnatka (*choroidea*). Světločivná vrstva zadního segmentu oka je protnuta zrakovým nervem a krevním řečištěm. Dutina je vyplněna rosolovitým sklivcem (*corpus vitreum*), který společně s nitrooční tekutinou (*humor aquosus*) udržuje tonus bulvy. Popsané struktury lze názorně vidět na obr. 1. [2, 3]

Udržování fyziologických rozmezí nitroočního tlaku mezi 10 až 20 mmHg (1,3 až 2,9 kPa) je nezbytné pro výživu oka, a jeho patologicky vysoké hodnoty jsou považovány za jeden z hlavních rizikových faktorů pro rozvoj glaukomu. Dalšími rizikovými faktory vzniku glaukomu jsou systémová hypertenze, diabetes mellitus, myopie, genetické predispozice či pokročilý věk. Onemocnění probíhá asymptomaticky a progresivně, a vede k postupnému zúžení zorného pole až k úplné ztrátě zraku. Na snímku očního pozadí lze pozorovat změny v oblasti zrakového nervu, které jsou způsobeny jeho exkavací. [2, 4]

Vzhledem k tomu, že optický aparát oka je za fyziologických podmínek transparentní, ve snímku očního pozadí pozorujeme struktury sítnice. Sítnice (*pars optica retinae*) je světločivná, strukturně hustá blána obsahující dva odlišné typy fotoreceptorů. Mají specifickou strukturu i funkci, a lze je tak dělit na buňky čípkové a tyčinkové. Tyčinky reagují na tlumené světlo a poskytují nám šedotónové vidění – rozlišují pouze intenzitu světla, nikoliv vlnovou délku. Čípky oproti tyčinkám potřebují podstatně více světla a díky odlišnému pigmentu v receptorech nám umožňují rozlišit červené, zelené a modré světlo.

Dalším článkem zrakové dráhy je systém bipolárních, gangliových a amakrinních buněk obstarávající konvergenci a částečné zpracování informace získané fotoreceptory. Na sítnici dohromady najdeme cca 120 milionů tyčinkových receptorů, 6 milionů čípkových receptorů a 1,5 milionu gangliových buněk. Konvergence se na celé sítnici neprojevuje stejně, v periferních oblastech je nejvyšší, zatímco v oblasti nejvyšší zrakové ostrosti je poměr receptorová:bipolární:gangliová buňka 1:1:1. Tento poměr se nachází uvnitř jamky žluté skvrny (*fovea centralis*). [2, 3]



Obr. 1: Anatomie lidského oka [3]

Onemocnění postihující zadní segment sítnice

Další řádky této kapitoly stručně popisují onemocnění nejčastěji odhalená při vyšetření očního pozadí, kterými jsou glaukom a věkem podmíněná makulární degenerace.

Glaukom, též známý jako zelený zákal, je skupina onemocnění různé etiologie postihující zrakový nerv, která je ve většině případů spojena s patologicky zvýšeným nitroočním tlakem. Dalšími rizikovými faktory jsou systémová hypertenze, diabetes mellitus, myopie, genetické predispozice či pokročilý věk. Onemocnění probíhá asymptomaticky a progresivně, vede ke zúžení zorného pole až k úplné ztrátě zraku. Tím se glaukom stává po kataraktě druhou nejčastější příčinou ztráty zraku, a na rozdíl od katarakty je tato ztráta zatím nevratná. V případě glaukomu lze na snímku očního pozadí pozorovat vyblednutí či prohloubení v oblasti optického disku (OD; *Optic Disc*), které je způsobeno exkavací zrakového nervu. Měříme tedy *Cup to Disc ratio* (CDR), s progresí onemocnění dochází k další exkavaci zrakového nervu. [2, 4]

Věkem podmíněná makulární degenerace bývá nejčastější příčinou praktické slepoty vyskytující se u jedinců starších 60 let a je způsobena úbytkem kapilár v oblasti žluté skvrny. Kvůli nedostatečné látkové výměně dochází k velmi rychlému úbytku neuronů v této oblasti a ztrátě zrakové ostrosti. Rozlišujeme suchou a vlhkou formu. Suchá (atrofická) forma je způsobena zánikem kapilár. Příčinou vlhké formy je novotvorba cévek v cévnatce a jejich prorůstání do dalších vrstev, které vede k narušení jednotlivých vrstev sítnice. [2, 4]


1 Snímky očního pozadí

Jelikož je optická dráha transparentní, lze za pomoci soustavy čoček pozorovat anatomické struktury zadního segmentu oka, které jsou zodpovědné za detekci dopadajícího světla a jeho další zpracování. V následujících podkapitolách jsou stručně popsány metody snímání společně s popisem snímku a měřenými parametry, dále datasey použité pro tuto práci a kritéria hodnocení segmentace snímku.

1.1 Metody snímání očního pozadí

Inspekci a pořízení snímku očního pozadí lze provést několika metodami, kdy je výstup ovlivněn především vlastnostmi a parametry zařízení. K nahlédnutí do zadního segmentu oční bulvy slouží nízkovýkonový mikroskop zvaný oftalmoskop. Při oftalmoskopickém vyšetření oka osvětlujeme zkoumaný oddíl pomocí viditelného světla a sledujeme paprsky odražené od sítnice. Odražené paprsky lze pozorovat jen za podmínky, že osa pozorování je alespoň přibližně stejná jako osa osvětlení. Oftalmoskopem obecně chápeme ruční optický přístroj s vlastním zdrojem světla a optickým aparátem, tvořeným polopropustným zrcadlem či odrazivým hranolem a soustavou optických čoček. Oftalmoskopii dále dělíme na přímou a nepřímou.


Přímý oftalmoskop se skládá z polopropustného zrcadla, zdroje světla a optických čoček. Zdroj světla svítí na polopropustné zrcadlo, od kterého je světlo odraženo do vyšetřovaného oka. Světlo odražené od sítnice prochází zpětnou cestou přes polopropustné zrcadlo přímo do oka pozorovatele (obr. 1.1). Pozorování sítnice probíhá pouze jedním okem z velmi krátké vzdálenosti (jednotky cm), a získáváme přibližně 16x zvětšený obraz oblasti sítnice o průměru 2 mm, pro pozorování jiných oblastí je nutno měnit úhel pozorování.



Obr. 1.1: Znázornění principu přímé oftalmoskopie [5]

Nepřímý oftalmoskop má v ohniskové vzdálenosti pacientova oka navíc spojovou vyšetřovací čočku, a zdroj světla je umístěn na hlavě vyšetřujícího (obr. 1.2).

Lze tak pomocí obou očí pozorovat převrácený, 4-6x zvětšený obraz sítnice ze vzdálenosti až 50 cm, kdy zorné pole je až 45°.




Obr. 1.2: Znázornění principu nepřímé oftalmoskopie [9]


Fundus kamera (obr. 1.3) vychází z konstrukce nepřímého oftalmoskopu. Průměrná sítnice odrazí zpět pouze 10 % světla, fundus kamera proto využívá slabšího zdroje světla pro zaměření vyšetřované oblasti a výkonného impulzního zdroje bílého světla pro snímání. Dále je doplněna o soustavu čoček pro korigování refrakčních vad optického aparátu vyšetřovaného oka. Světlo do vyšetřovaného oka proniká při okrajích *pupily* a je zpět odraženo jejím středem, jak lze vidět na obr. 1.4. Elektronická část obsahuje, kromě zdroje světla, snímací prvek v podobě *Charge-Coupled Device* (CCD) čipu a výpočetní jednotku pro analýzu obrazu a nastavení vhodných parametrů měření, jako je například nalezení středu očního pozadí či vhodné nastavení intenzity osvětlení sítnice při snímání. Hlavním parametrem spjatým se zvětšením obrazu je zorné pole snímání sítnice, které je v rozsahu 15° až 140°, nejčastěji však okolo 30°. Pro zvýraznění určitých struktur sítnice lze použít barevné filtry, a to nejčastěji červený (640 nm), zelený (540 nm) či modrý (450 nm). Dále je nutno dosáhnout dilatace zornice, dle toho dělíme fundus kamery na mydriatické, kdy musí pacient použít mydriatika ve formě očních kapek, a nemydriatické, kdy vyšetření probíhá v zatemněné místnosti a zaměření vyšetřované oblasti je provedeno v oblasti infračerveného záření. [7, 6, 8]

1.2 Oční pozadí

Jak bylo nastíněno v předešlých odstavcích, očním pozadím chápeme povrch sítnice v zadním segmentu oka, na kterém se nachází charakteristické oblasti, které je



Obr. 1.3: Schéma optického aparátu fundus kamery [8]




Obr. 1.4: Schéma osvětlení sítnice [8]

nutné rozlišit pro další zpracování a diagnostiku. Jak lze vidět na obr. 1.5, oční pozadí má v nativním stavu narůžovělou barvu a jeho odstín je ovlivněn pigmentem vyšetřované osoby.

Nejvýraznějším útvarem se jeví optický disk, který má světlou, mírně nažloutlou barvu a kruhový až eliptický tvar. Optický disk, někdy nazývaný jako slepá skvrna, je oblast bez světločivných buněk ležící 3-4 mm nazálně od centrální jamky s horizontálním průměrem $1,76 \pm 0,3$ mm a vertikálním průměrem $1,92 \pm 0,3$ mm. V tomto

místě se sbíhají vlákna gangliových buněk ve zrakový nerv, který společně s krevním zásobením vnitřního prostoru oka protíná bělimu.


Uvnitř optického disku lze rozlišit prohloubený oválný útvar zvaný pohárek (obr. 1.7), jehož velikost je vázána exkavací zrakového nervu. Poměr průměru pohárku ku optickému disku, tzv. CDR, je významným hodnotícím kritériem v diagnostice glaukomu. Fyziologické hodnoty se pohybují v oblasti do 0,5, s rozdílem mezi pravým a levým okem nanejvýš 0,2. [10, 11] Další výraznou strukturou na snímku očního pozadí je žlutá skvrna, což je shluk čípkových receptorů v zorné ose oka s centrální jamkou (*foveola centralis retinae*) uprostřed. Pokud exkavace zrakového nervu přesáhne hranici optického disku, hovoříme o peripapilární atrofii, kterou lze vidět na obr. 1.6. Dále lze rozlišit světlejší a užší tepénky a tmavší a silnější žilky, které se ze čtyř hlavních větví sbíhají do optického disku. [2, 3, 12, 10]




Obr. 1.5: Vyznačení diagnosticky zajímavých struktur na snímku sítnice [14]

1.3 Kritéria hodnocení

5 Pro optimalizaci a vyhodnocení je nutné zvolit vhodné kritérium úspěšnosti. Jak lze vidět na obrázku 1.8, při vyhodnocení úspěšnosti segmentace rozlišujeme oblast *True Positive* (TP), jež představuje množinu pixelů správně detekovaných jako OD. Dále oblast *True Negative* (TN), která představuje množinu pixelů opravdu nenáležících OD.



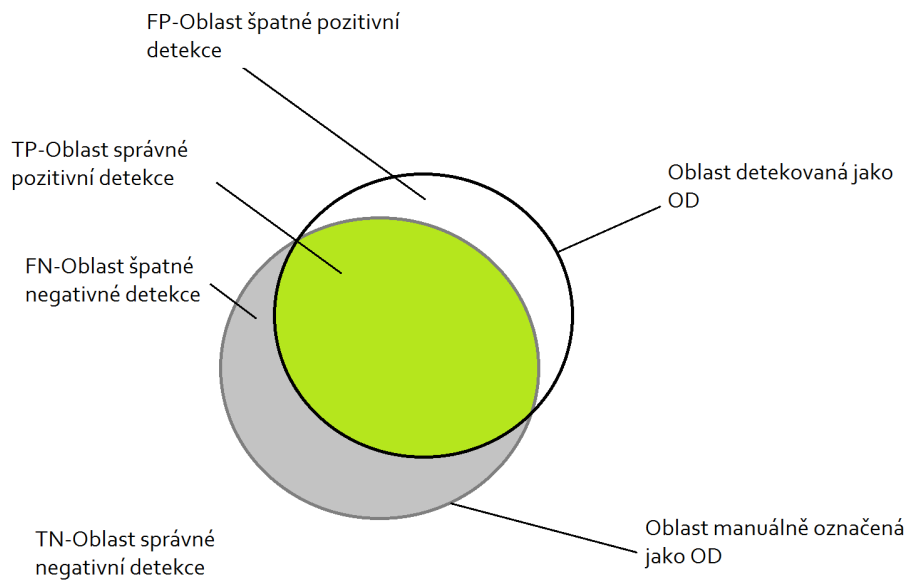
Obr. 1.6: Příklad peripapilární atrofie [10]



Obr. 1.7: Na levém snímku optický disk zdravého oka, na pravém snímku optický disk se zvětšeným pohárkem oka postiženého glaukomem [13]

Oblast *False Positive* (FP) byla chybně detekována jako OD (chyba 1. typu) a *False Negative* (FN) oblast byla chybně detekována jako oblast mimo OD (chyba 2. typu). [15]

Z takto klasifikovaného snímku lze dále vypočítat senzitivitu (1.1), která reflektuje citlivost vůči chybě 2. typu, a specifitu (1.2), která reflektuje citlivost vůči chybě 1. typu. Dále počítáme překryv (1.4), který zohledňuje chybu obou typů a je citlivější než přesnost (1.3), jeví se tak jako ideální kritérium hodnocení. Nápodobně vhodnou metrikou je *Sørensen–Dice koeficient* (DICE) (1.5) nebo v literatuře frekventovaně používaná euklidovská vzdálenost centoidů.



Obr. 1.8: Kritérium hodnocení segmentace [15]

$$SN = \frac{TP}{TP + FN} \quad (1.1)$$

$$SP = \frac{TN}{TN + FP} \quad (1.2)$$

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (1.3)$$

$$OL = \frac{TP}{TP + FN + FP} \quad (1.4)$$


$$DICE = \frac{2 \cdot TP}{(TP + FN) + (TP + FP)} \quad (1.5)$$

Z výše uvedených parametrů se pro hodnocení jako nejvhodnější jeví překryv (1.4), který, na rozdíl od senzitivity a specificity, zohledňuje FN i FP. Přesnost je nevhodná kvůli TN oblasti, je tedy necitlivá a má pouze malou výpovědní hodnotu. Překryv je tudíž jediným parametrem, jenž má výpovědní hodnotu bez přihlídnutí k ostatním parametrům.

1.4 Databáze retinálních snímků

1.4.1 HFR

Vhodným datasetem je veřejně dostupný set *High-Resolution Fundus* (HRF) z práce [18] obsahující 15 snímků zdravých pacientů, 15 snímků pacientů s diabetickou retinopatií a 15 snímků pacientů postižených glaukomem. Jak lze vidět na obr. 1.9, jedná se o RGB snímky o rozměrech 3504 x 2336 pixelů pořízené zařízením CANON CF-60UVi. K datasetu jsou dostupné binární snímky definující zlatý standard segmentace krevního řečiště, dále masky definující *Field Of View* (FOV) a souřadnice kruhové aproximace OD. Zlatý standard je určen skupinou expertů zabývajících se analýzou retinálních snímků ve spolupráci s oftalmologickou klinikou.




Obr. 1.9: HRF snímek zdravého pacienta [18]

1.4.2 Experimentální video-ofthalmoskop

Experimentální video-ofthalmoskop dle [16] pracuje s LED zdrojem světla o vlnové délce 575 nm s *Full width at Half Maximum* (FWHM) 25 nm, které má absorpční maximum při 578 nm a zvýrazňuje krevní řečiště bohaté na oxyhemoglobin s cílem jeho precizní segmentace pro výpočet hemodynamických parametrů. Při vyšetření není nutné, aby pacient použil mydriatika k dilataci *pupily*. Relativně malé zorné pole 20 × 15 napomáhá potlačit rušivé odrazy. Použitá monochromatická CCD kamera má rozlišení 640 × 480 se vzorkovací frekvencí 25 Hz. Kalibrační faktor (velikost

sítnice/pixel) je tedy $9,3 \mu\text{m}/\text{pixel}$. Jak lze vidět na obr.1.10, takto získané šedotónové snímky se vyznačují často nerovnoměrným rozložením světla, malým kontrastem, neostrotí snímku způsobenou pohybem nebo světlým mezikružím vzniklým při osvětlení očního pozadí. [16, 17]



Obr. 1.10: Snímek pořízený experimentálním oftalmoskopem [16]

2 Metody segmentace optického disku

Segmentací rozumíme rozdělení scény na oblasti odpovídající skutečným objektům ve scéně. S příchodem digitalizace snímků očního pozadí a rozvojem výpočetní techniky vznikla spousta algoritmů zabývajících se segmentací anatomických struktur ve snímku očního pozadí s cílem predikovat, detekovat a sledovat vývoj patologických jevů postihujících zrak. Tato kapitola je věnována rešerši metod segmentace optického disku s přihlédnutím k jejich přednostem i limitacím, a s cílem implementace vhodné metody segmentace pro data získaná experimentálním oftalmoskopem. Cílem je tedy získat přesnou hranici mezi optickým diskem a sítnicí, výstup tak bude tvořit křivka nebo binární reprezentace optického disku ve snímku očního pozadí. To znesnadňuje husté krevní řečiště překrývající optický disk, neostré hrany optického disku a vliv patologické papilární atrofie. [19, 20, 21]

Obecně lze rozdělit způsoby segmentace na metody založené na úrovni jasu a prahování, dále na metody využívající hranové detekce v obraze a na metody využívající vlastností specifické oblasti obrazu. Jedním z historicky prvních a často využívaných principů segmentace OD je Houghova transformace pro kružnici, jejímž vstupem je snímek reprezentující výrazné hrany v obraze.

Blanco a kol. [23] využil vysokých hodnot jasu v oblasti OD pro lokalizaci disku tak, že hledá největší možný shluk pixelů s nejvyššími hodnotami jasu. Vybere tak 1 % pixelů s nejvyšším jasnem, kdy následně každý z těchto pixelů považuje za cluster s vlastním centroidem. Jestliže je Euklidovská vzdálenost nižší než daný práh, jsou clustery sloučeny v jeden, a je vypočítán nový centroid. Pomocí clusteru s nejvyšším počtem pixelů je označena obdélníková oblast zájmu (ROI; *Region Of Interest*) o velikosti odvozené z rozměrů snímků. V oblasti zájmu je provedena detekce hran pomocí Cannyho operátoru, na jejíž výstup je aplikován *Multilocal Level Set Extrinsic Curvature based on the Structure Tensor* (MLSECST) operátor detekující záhyby nacházející se uvnitř krevního řečiště. Výsledkem je tak linka reprezentující danou žilku či tepénku. Hrany detekované okolo těchto linek jsou odstraněny, čímž dojde k potlačení vlivu krevního řečiště. Na takto upravený snímek reprezentující hrany je použita fuzzy Houghova transformace, která bere v potaz i hrany mimo poloměr kružnice s váhou odpovídající vzdálenosti od kružnice. Tímto postupem byl OD úspěšně detekován v 98 % případů.

Aquino a kol. [22] navrhl tři nezávislé metody lokalizace optického disku ve snímku. Společným znakem všech tří metod je využití zeleného kanálu barevného obrazu, který se vyznačuje nejvyšším kontrastem. První metoda vychází z předpokladu, že optický disk je nejsvětlejší oblastí snímku. Lokalizace je tedy realizována transformací snímku do frekvenční oblasti, kde je následně aplikován Gaussovský filtr s mezní frekvencí 25 Hz. Snímek je zpětně transformován do prostorové oblasti,

a pixel s nejvyšší hodnotou jasu je brán jako kandidát oblasti optického disku.

Druhý algoritmus vychází z předpokladu, že oblast optického disku je částečně překryta tmavým krevním řečištěm, lze tedy předpokládat, že diference zde bude nejvyšší z celého snímku. Nejprve je snímek upraven mediánovým filtrem o velikosti okna W , a následně je vypočtena diference pro každý pixel s velikostí okna W . Pixel s nejvyšší hodnotou v diferenci snímku je považován za dalšího kandidáta oblasti optického disku. Poslední metoda vychází ze stejného předpokladu jako předchozí, s tím rozdílem, že využívá variance v daném okně. Dále je získán binární snímek z modrého kanálu barevného snímku pomocí Otsu prahování. Oblast optického disku je stanovena jako oblast s nejvyšší variancí a alespoň 10 světlými pixely v okolí z binárního snímku. Finální oblast je vybrána pomocí rozhodovacího pravidla, tedy pokud jsou všichni kandidáti blíže než maximální průměr optického disku, oblast je stanovena jako oblast zájmu. Pokud vzdálenost splňují pouze dva kandidáti, oblast zájmu je brána jako jejich průměr, a pokud kritérium nesplňuje ani jeden kandidát, je vybrána metoda maximální variance, která se ukázala jako nejspolehlivější. Dalším krokem je odstranění krevního řečiště v oblasti zájmu za pomoci rotujícího morfologického lineárního operátoru, kterým aproximujeme krátký úsek žíly. Pokud se délka, šířka a orientace shoduje s úsekem krevního řečiště, bude mezi tímto výstupem operátoru a výstupem operátoru otočeného o 90° nejvyšší možná diference. Tímto způsobem je dosaženo potlačení vlivu krevního řečiště a optický disk je následně aproximován Houghovou transformací pro detekci kružnice. Algoritmus tak dosáhl 99% úspěšnosti lokalizace OD a 86% úspěšnosti segmentace OD.

Joshi a kol. [27] pro lokalizaci OD využil červenou složku RGB snímku, u které lineární transformací normalizoval hodnoty jasu v rozsahu 0 až 1. Jako ROI je vybrána oblast s nejpočetnějším shlukem pixelů, které mají intenzitu vyšší než 0,95. V ROI je pomocí morfologické bottom-hat transformace potlačeno rušivé krevní řečiště, kdy je použit rotující morfologický operátor s délkou větší, než je tloušťka hlavních cév a žil. Výstupní snímek reprezentující krevní řečiště tak tvoří nejvyšší hodnoty na dané pozici ve snímku z obdržené 3D matice, potlačení je provedeno odečtením snímku krevního řečiště od původního. Přesná hranice OD je získána pomocí aktivní kontury, což je metoda využívající specifické vlastnosti oblasti obrazu, kdy jsou segmentované oblasti ohraničeny svíjející se křivkou tak, aby došlo k minimalizaci rozptylu jasu daných oblastí a křivosti křivky.

Priyadharshini a kol. [24] využil k segmentaci OD metodu narůstání oblastí. Prvně je snímek převeden na šedotónový obraz, a adaptivní ekvalizací je upraven histogram. Následně je v zelené složce obrazu zvýrazněno krevní řečiště pomocí rozdílu dvou snímků morfologického uzavření s kruhovým strukturálním elementem o dvou různých poměrech. Vzniklý snímek krevního řečiště je poté odečten od šedotónového ekvalizovaného snímku a vyhlazen mediánovým filtrem. Na takto upravený

snímek bez krevního řečiště je aplikován algoritmus narůstání oblastí.

Khalil a kol. [25] se ve své práci zabývá detekcí optického disku a pohárku za cílem určení CDR. Při segmentaci OD bylo využito červené složky RGB snímku, která měla nejviditelnější disk. Následuje průměrovací a mediánová filtrace s cílem potlačit šum, který by rušil při segmentaci pomocí prahování. Původní záměr použít Otsu metodu [26] pro stanovení prahu byl při implementaci překonán fixním prahem o hodnotě 0,4 jasové intenzity. Výstupem je tak binární snímek kandidátních pixelů, OD, na který je aplikováno morfologické otevření s kruhovým strukturním elementem s cílem odstranění rušivých shluků kandidátních pixelů mimo OD, a vyplnění mezer způsobených tmavým krevním řečištěm. Dále jsou odstraněny shluky pixelů o ploše menší než 20 000 pixelů, a na oblast OD je aplikována metoda konvexního obalu s cílem získat hladké ohraničení, vyplnit mezery a vypočítat plochu OD.

Balabrish a kol. [28] představil metodu využívající *Neighboring Differential Clustering* (NDC) shlukování a *Intensity Variation Masking* (IVM) segmentaci. V rámci předzpracování potlačili šum pomocí Gaussovy filtrace, a na takto upravený snímek použili shlukovací metodu využívající rozdílu sousedních pixelů, která je založena na konceptu mapování a výpočtu vzdálenosti. Zmíněný algoritmus vyniká rychlým shlukováním a efektivním potlačením šumu bez nutnosti stanovit fixní práh. Následuje segmentace na základě podobnosti a nesouvislosti pixelů, která je rychlá, flexibilní a generuje segmenty se souvislou hranicí.

Maheshwari a kol. [29] využil pro segmentaci OD iterativní variační dekompozice. Nejdříve rozměry zelené složky snímku bikubicky interpolovali na požadované rozlišení a pomocí adaptivní úpravy histogramu zvýšili kontrast. Následně použili 2D iterativní variační dekompozici, aby extrahovali příznaky na základě entropie a fraktálních rozměrů, které dále normalizovali a seřadili pro další zpracování pomocí *Support Vector Machine* (SVM) za použití metody nejmenších čtverců.

Koh a kol. [30] využili *Pyramid Histogram of Oriented Gradients* (PHOG) a *Speeded Up Robust Features* (SURF) deskriptoru pro extrakci příznaků, které po vyvážení, fúzi a selekci použili pro klasifikaci pomocí *k-Nearest Neighbor* (kNN) sítě. Při předzpracování je pomocí *Contrast Limited Adaptive Histogram Equalization* (CLAHE) optimalizován jas a šum zelené složky RGB snímku, na který je následně aplikován PHOG a SURF deskriptor. PHOG deskriptor popisuje distribuci a orientaci hran v obrazu získaném pomocí Cannyho detektoru hran, zatímco SURF deskriptor pomocí Haarovy vlnkové transformace zachycuje změny intenzity v obraze. Nerovnováha mezi příznaky ze dvou různých deskriptorů je vyvážena adaptivním syntetickým vzorkováním AdaSyn, které generuje příznaky na základě distribuce minoritních příznaků s využitím Euklidovské vzdálenosti. Příznaky z obou datasetů jsou následně sloučeny pomocí kánonické korelační analýzy na základě podobnosti a dále selektovány pomocí *Partical Swarm Optimization* (PSO).

Rehman a kol. [31] navrhl postup využívající segmentace superpixelu za použití prostého lineárního iterativního shlukování. Nejdříve potlačili šum ve snímku bilaterální filtrací a vliv krevního řečiště morfologickou dilatací s kruhovým strukturním elementem. Dále stanovili práh pro binarizaci adaptivním prahováním a oblast zájmu určili podle centroidu shluku s nejnižší excentricitou. Rušivý vliv pozadí snímku je potlačen odečtením odhadu pozadí a snímek je dále normalizován přizpůsobením histogramu. Snímek je následně segmentován metodou, kdy jsou pixely s podobnými vlastnostmi sloučeny do superpixelu, lze tak pro každý superpixel stanovit příznaky pro další zpracování. Bylo stanoveno celkem 17 příznaků, které vystihují intenzitu pixelů v superpixelu, jeho texturu pomocí banky Gaborových filtrů a přítomnost hran. Normalizované neredundantní příznaky jsou dále využity pro klasifikační metody s učitelem, ze kterých se ukázaly jako nejefektivnější metody náhodného lesu a RusBoost, které překonaly výsledky metody AdaBoost i podpůrného strojového učení. Takto obdržená silueta je v posledním kroku aproximována elipsou.

Unver a kol. [32] představil segmentační metodu založenou na kruhové Houghově transformaci, kdy pro detekci hran využil upravené statistické metody robustního pořadí. Jas zelené složky RGB snímku je vylepšen pomocí modifikované CLAHE, která bere v potaz i okolní regiony s cílem zamezit nadměrnému kontrastu v homogenních regionech. Dále je vypočítána průměrná intenzita pixelů ve snímku, kterou jsou nahrazeny pixely o nižší hodnotě, čímž dojde k potlačení vlivu krevního řečiště na detekci. Detekce hran je provedena pomocí lokálního operátoru využívajícího modifikované metody robustního pořadí založené na principu nicotné nulové hypotézy. Obdržená hranová reprezentace je tak vstupem do kruhové Houghovy transformace, která kružnicí aproximuje obrys optického disku.

Abdullah a kol. [33] navrhl postup využívající heuristického algoritmu pro prahování. V rámci předzpracování, a s cílem potlačit vliv řečiště na tvar optického disku, aplikovali na šedotónový snímek morfologické uzavření s plochým strukturním elementem ve tvaru disku a průměrem větším, než byla tloušťka cév překrývající optický disk. Z histogramu předzpracovaného snímku je pomocí heuristického algoritmu, který popisuje chování netopýrů při echolokaci, stanoven práh s optimální variací jasu. Obdržená nepravidelná linie je dále aproximována elipsou pomocí metody nejmenších čtverců.

Marin a kol. [34] představil metodu předzpracování snímku pomocí morfologického otevření a uzavření s cílem potlačit vliv krevního řečiště. To je na snímek opakovaně aplikováno s narůstajícím poloměrem strukturního elementu. Na takto upraveném snímku je nalezen přibližný okraj optického disku pomocí kruhové Houghovy transformace. Prezentovaný postup předzpracování byl využit i u výše zmíněné metody [33].

Vzhledem k obsáhlosti tématu je výše vypsán jen stručný přehled metod použí-

vaných při segmentaci OD v retinálních snímcích. Vybrané metody jsou implementovány v následující kapitole.

3 Implementované metody segmentace

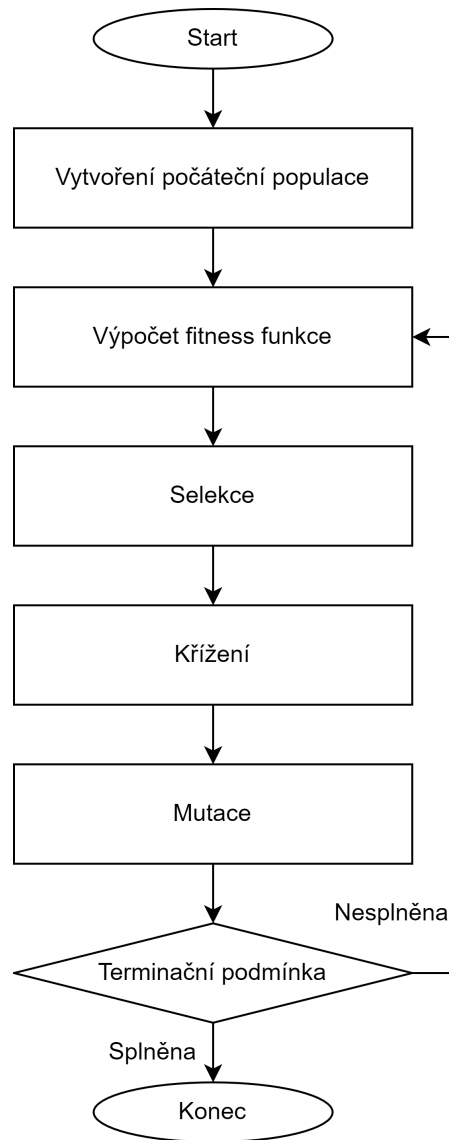
Tato kapitola je věnována praktické implementaci vybraných algoritmů segmentace OD zmíněných v předešlé rešerši. Všechny vybrané postupy segmentace jsou optimalizovány pomocí genetického algoritmu (GA; *Genetic Algorithm*), na který se zaměřuje následující podkapitola. Algoritmy jsou realizovány v prostředí MATLAB 2020b a výpočty byly provedeny na zařízení s procesorem Intel(R) Core(TM) i5-8400 CPU 2.80 GHz s operační pamětí 16 GB.

3.1 Optimalizace genetickým algoritmem

Při implementaci výše zmíněných metod segmentace je třeba stanovit celou řadu konstant, proto se jeví namísto využít křížové validace a genetického algoritmu pro obdržení testovacích konstant pro každou podmnožinu datasetu. V případě každého datasetu bylo použito 45 snímků očního pozadí, které byly rozděleny do pěti skupin. Na každý trénovací set zvlášť byl použit populační meta-heuristický genetický algoritmus, který se řadí mezi evoluční algoritmy. Genetický algoritmus se jeví jako vhodný pro řešení problémů nelineárního charakteru s vymezeným parametrickým prostorem. [42, 43, 44] Obecně jej lze rozdělit do pěti kroků dle vývojového diagramu 3.1. V prvním kroku je nejdříve nutné inicializovat počáteční populaci jedinců, kteří představují jednotlivá možná řešení. Hledané parametry představují geny jedince, které jsou generovány náhodně v mezích prohledávaného parametrického prostoru. V případě prezentované práce je součástí 50 členné počáteční populace i jedinec X_0 , jehož geny byly zvoleny empiricky s cílem rychlejší konvergence k hledanému řešení. Druhým krokem je výpočet ohodnocující *fitness* funkce každého i jedince v n početné populaci. Tím je v případě implementovaných algoritmů překryv masky segmentace a masky zlatého standardu, který může nabývat hodnot v rozsahu 0 až 1. Na základě *fitness* úspěšnosti jedince se zvyšuje jeho šance *prob* na selekci při reprodukci dle 3.1. V případě implementovaného postupu byla konstanta β empiricky nastavena na hodnotu 2 vzhledem k možným výstupům zvolené *fitness* funkce. Vektor pravděpodobností všech jedinců *prob* je následně dělen jeho sumou tak, aby byla dodržena podmínka, že suma všech pravděpodobností je rovna jedné. [42, 43, 44]

$$prob_i = \frac{e^{\beta \cdot fitness_i}}{\sum_i^n e^{\beta \cdot fitness_i}} \quad (3.1)$$

Ve třetím kroku jsou z populace vybráno pět dvojic jedinců na základě jejich šance na reprodukci *prob*. Tyto dvojice představují rodiče následující populace. Pro výběr byla využita metoda rulety, kdy jednotlivé šance představují šířku pole na ruletě.



Obr. 3.1: Obecný genetický algoritmus

Metoda rulety byla vybrána pro svou jednoduchost, nízkou výpočetní náročnost, rychlou konvergenci a zachování diversity populace oproti výběru rankováním, soutěžením nebo Boltzmannovou metodou. Nevýhodou metody je riziko předčasné konvergence. [43, 44]

Čtvrtým krokem je křížení, při kterém dva potomci *offspring* dostávají kombinaci genů svých rodičů *parent* dle 3.2. Vzhledem k povaze optimalizovaného problému bylo využito uniformního křížení, které je aplikovatelné na velké podmnožiny hledání. Uniformní křížení má vysoký rekombinační potenciál za cenu méně diverzní populace řešení.

Vektor α nabývá hodnot ze spojitého rovnoměrného rozložení v rozsahu 0 až 1.

$$offspring = \alpha \cdot parent_1 + (1 - \alpha) \cdot parent_2 \quad (3.2)$$

V pátém kroku dojde k mutaci každého genu potomka s pravděpodobností rovné konstantě μ , kdy míra mutace je v parametrickém prostoru stanovena krokem σ . Konstanta σ byla v implementovaném postupu empiricky nastavena na 0,3. Jako pravděpodobnost mutace μ se osvědčila hodnota 0,1, která byla zvolena s ohledem na relativně malou populaci, nízký počet iterací a riziko předčasné konvergence řešení. Následně je vypočtena *fitness* funkce 10 nových jedinců, a ti jsou podle úspěšnosti zařazeni do původní populace při zachování velikosti populace. Do další generace přežívá 50 nejúspěšnějších jedinců a opakuje se výpočet nové populace potomků od třetího kroku. V implementovaném postupu je provedena iterace celkem 20 generací a výstupem je nejúspěšnější jedinec z celého pokusu. [42, 43, 44]

3.2 Implementace segmentačních metod

V následujících podkapitolách budou představeny implementované postupy segmentace a jejich optimalizované parametry. Prvním a společným krokem všech metod je předzpracování, kdy je v případě datasetu obsahujícího RGB snímky provedena konverze červené *Red* a zelené *Green* složky na šedotónový snímek *G*. 3.3 Hodnoty poměru složek byly nastaveny dle metod z literární rešerše, kde se empiricky osvědčily. Zvolený poměr složek lépe aproximuje kontrast mezi OD a krevním řečištěm, jako je to u datasetu snímků pořízených experimentálním video-ofthalmoskopem, který je pro prezentovanou práci stěžejní.

$$G(x, y) = 0,75 \times Red(x, y) + 0,25 \times Green(x, y) \quad (3.3)$$

Dále je zmenšen rozměr šedotónového snímku z důvodu menší výpočetní náročnosti a lepší reproducibility. V případě HRF datasetu je rozměr zmenšeného snímku 389 x 584 pixelů tak, aby byla velikost zorného pole stejná, jako je uvedeno v [22], ze které tento rozměr následně převzalo více navazujících publikací. U experimentálních datasetů byla velikost snímku stanovena na 96 x 128 pixelů tak, aby byla zachována přibližně stejná velikost optického disku. Rozdíl velikostí je snímků je dán různým FOV každého datasetu. Rušivý vliv nerovnoměrného osvětlení snímku je dle 3.4 potlačen odečtením aproximace pozadí BG_{approx} od zmenšeného šedotónového snímku *G* podle metody prezentované Marinem a kol. [40]. Výstupem této operace je rozdílový snímek *Diff*.

$$Diff(x, y) = G(x, y) - BG_{approx}(x, y) \quad (3.4)$$

Aproximace pozadí je získána pomocí průměrovacího filtru s Gaussovským rozložením. Použitý Gaussův filtr odstraní vyšší frekvence v obraze a lze ho realizovat konvolucí v prostorové oblasti i frekvenční oblasti získané Furierovou transformací.

V prostorové oblasti využíváme konvoluce s konvolučním jádrem, jehož váhové koeficienty odpovídají Gaussovu rozložení vyjádřenému rovnicí 3.5, kde $h(x, y)$ je konvoluční jádro, A je amplituda, x a y jsou indexy prvků konvolučního jádra, μ je střed Gaussovy křivky a σ je rozptyl.

$$h(x, y) = A \cdot e^{\frac{-(\sqrt{x^2+y^2}-\mu)^2}{\sigma^2}} \quad (3.5)$$

O míře potlačení šumu rozhoduje, stejně jako u průměrovacích masek, velikost masky, a to za předpokladu, že střední odchylka je závislá na velikosti masky. Filtrací vyšších frekvencí dochází ke ztrátě informace o hranách, a dostáváme tak pouze informaci o přibližném rozložení jasu. [37, 36, 38] V případě všech datasetů byla empiricky stanovena velikost konvoluční masky a to 69 pixelů, stejně jako v publikaci [40].

Jasové hodnoty rozdílového snímku *Diff* musí být, vzhledem k povaze operace, kdy mohou vznikat i záporné hodnoty jasu, normalizovány v rozpětí 0-255. Normalizovaný snímek N je dále upraven dle rovnice 3.6 s cílem homogenizace osvětlení snímků. Z histogramu je získána nejfrekventovanější hodnota jasu $Hist_{max}$, která reprezentuje úroveň jasu v pozadí snímku. Výstupem je tak snímek I_{homo} , který má přibližně stejnou úroveň jasu v pozadí snímku v celém datasetu. [40]

$$I_{homo} = N + 128 - Hist_{max} \quad (3.6)$$

3.3 Segmentace optického disku pomocí prahování

První implementovaná metoda je založena na prahování, přesný postup zpracování snímků je inspirován [25]. Na normalizovaný snímek jsou aplikovány lokální operátory průměrovacího a mediánového filtru s cílem potlačit vliv krevního řečiště a šum, který by při prahování vedl k nepravidelným okrajům. Průměrovací filtr používá konvoluční masku s váhovými koeficienty, které jsou stejné a upravené tak, aby celková energie operátoru byla rovna jedné. Zmíněný mediánový filtr je také lokálním operátorem, jen s tím rozdílem, že výstupní hodnota je rovna mediánu hodnot v okně operátoru. Na rozdíl od předešlých dvou filtrů se jedná o nelineární operaci s vyšší výpočetní náročností. [37, 36, 38] Binární snímek hrubě reprezentující OD je získán s fixním prahem, a je dále morfologicky otevřen s operátorem ve tvaru disku s cílem potlačit rušivé shluky pixelů mimo OD a vyplnit vzniklé mezery po krevním řečišti. Morfologické otevření dostaneme aplikací dilatace na již erodovaný obraz za použití stejného strukturního elementu. Jsou tak ovlivněny především objekty menší než strukturní element, aniž by byla zásadně ovlivněna velikost a tvar

objektů větších než strukturní element.

$$O \circ S = (B \otimes S) \oplus S \quad (3.7)$$

Kde O je otevřený obraz, B je vstupní obraz a S je strukturní element. Jak bylo zmíněno, prvním krokem při morfologickém otevření je eroze. Eroze skládá dvě bodové množiny s využitím vektorového rozdílu, je tedy duální k dilataci, nikoliv inverzní. Dochází ke zjednodušení tmavých struktur objektu v obraze, objekty o jednotkové tloušťce zaniknou. Obrýs objektu můžeme najít odečtením erodovaného obrazu od originálu, lze tak použít morfologické operace místo detektoru hran na bázi konvoluce.

$$E = B \otimes S = \{(x, y) | S_{xy} \subseteq B\} \quad (3.8)$$

Kde E je výsledný erodovaný obraz, B je vstupní obraz a S je strukturní element. Jak bylo uvedeno výše, na erodovaný obraz je poté aplikována dilatace. Dilatace skládá body dvou množin pomocí vektorového součtu. Tmavé objekty v obraze jsou po provedení dilatace zvětšeny o jednu vrstvu, kterou lze chápat jako pomyslnou slupku dilatovaného objektu na úkor světlejšího pozadí snímku.

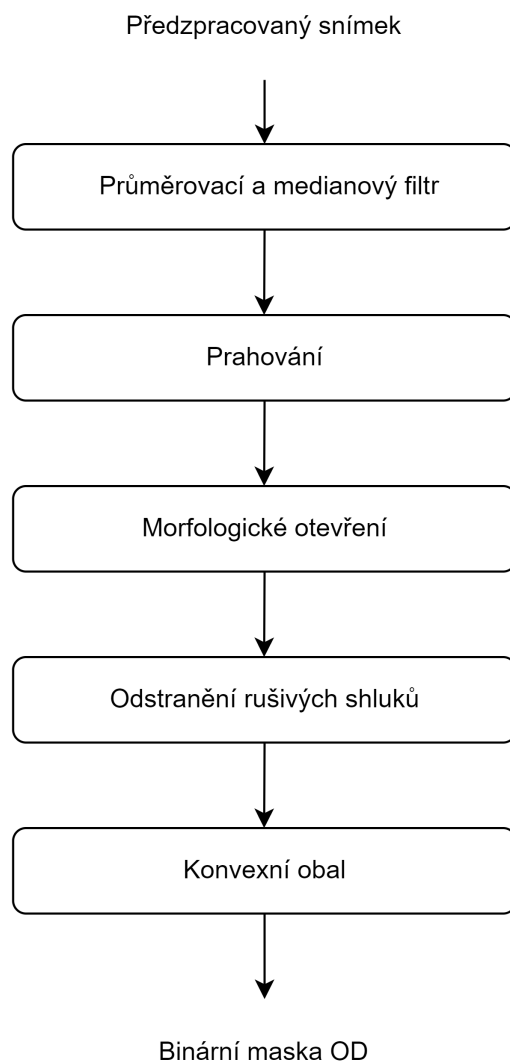
$$D = B \oplus S = \{(x, y) | S_{xy} \cap B \neq \emptyset\} \quad (3.9)$$

Kde D je výsledný dilatovaný obraz, B je vstupní obraz a S je strukturní element. [37, 36, 38]

Dále je stanoven počet shluků kandidátních pixelů a jejich spojitost. Pokud snímek obsahuje více než jeden shluk, jsou nadbytečné rušivé shluky pixelů odstraněny na základě informace o jejich ploše. Na takto upravený snímek je aplikován konvexní obal, díky kterému dojde k vyhlazení hran a vyplnění záhybů a mezer v oblasti označené jako OD. Popsaný postup je znázorněn vývojovým diagramem na obrázku 3.2. V tabulce 3.1 jsou uvedeny optimalizované parametry GA, včetně mezí prostoru a výchozího jedince X_0 .

Tab. 3.1: Optimalizované parametry prahovací metody

Optimalizovaný parametr	Spodní hranice	Horní hranice	X_0
Velikost masky průměrovacího filtru	3	30	10
Velikost masky mediánového filtru	3	30	20
Práh	0	1	0.6
Velikost masky binárního otevření	3	30	10
Minimální plocha shluku	100	2000	200

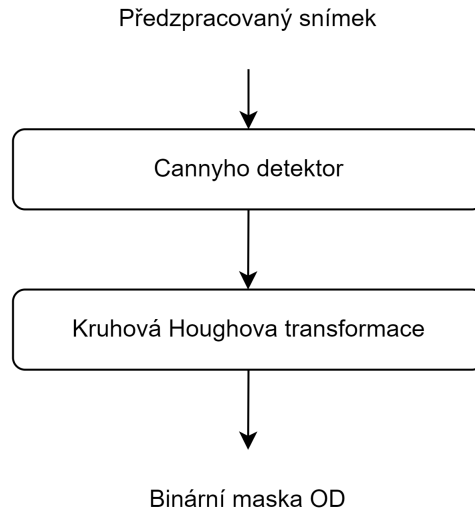


Obr. 3.2: Postup segmentace prahováním

3.4 Segmentace optického disku pomocí kruhové Houghovy transformace

Další implementovanou metodou je segmentace pomocí Houghovy kruhové transformace. Z předzpracovaného snímku je za použití Cannyho operátoru odtržena binární hranová reprezentace, ve které jsou detekovány kružnice. Schéma navrženého postupu segmentace je na obr. 3.3.

Cannyho detektor je víceúrovňový algoritmus, jehož výstupem je binární reprezentace hran v obraze. Tradiční provedení Cannyho detektoru v prvním kroce potlačuje vyšší frekvence v obraze pomocí Gaussovského filtrování, kdežto moderní implementace často využívá adaptivního filtrování.



Obr. 3.3: Implementovaný postup kruhové Houghovy transformace

Na filtrovaný snímek je použit jeden z možných gradientních operátorů, nejčastěji Sobelův (3.13), Prewittův (3.14) nebo Robertsův (3.12) operátor. Dále z gradientního snímku vypočte absolutní hodnotu (3.10), úhel gradientů (3.11) a práh pro segment pomocí Otsu metody, kde jeden práh odpovídá silným hranám a druhý jemným. Detekované hrany jsou ztenčovány na základě znalosti úhlu gradientu, a informace o jemných hranách může být nápomocná při spojování hran silných. Výstupem je pak binární hranová reprezentace tvořená souvislými křivkami o tloušťce jednoho pixelu. [37, 36, 38]

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2} \quad (3.10)$$

$$\Theta_{i,k} = \arctan \frac{\nabla_x f_{i,k}}{\nabla_y f_{i,k}} \quad (3.11)$$

$$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} \quad (3.12)$$

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (3.13)$$

$$\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad (3.14)$$

Na obdrženou binární hranovou reprezentaci je dále použit algoritmus kruhové Houghovy transformace. Kruhová Houghova transformace je oblíbená díky své robustnosti i za přítomnosti šumu, okluze či měnícího se osvětlení. Obecná rovnice kružnice je:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (3.15)$$


kterou lze vyjádřit parametricky:

$$x = a + r \cos \varphi \quad (3.16)$$

$$y = b + r \sin \varphi \quad (3.17)$$

Kde a a b jsou souřadnice středu kružnice, r je poloměr a x, y jsou souřadnice libovolného bodu ležícího na kružnici. Dostaneme tak 3D parametrický prostor, kde osy x a y odpovídají pozici pixelu v originálním obrazu a osa z poloměru r .

Jak lze vidět na obrázku 3.4, kružnice jednotlivých bodů, ležících na kružnici daného pixelu se stejným poloměrem, se ve středu protínají. Prokládáme tedy středy jednotlivých pixelů kružnicemi o stejném poloměru, který postupně měníme. Tím dostáváme třírozměrnou matici. Souřadnice pixelu s nejvyšší kumulací hlasů odpovídají souřadnicím středu kružnice a jejího poloměru. [37, 36, 38]



Obr. 3.4: Detekce kružnice [37]

V tabulce 3.2 jsou uvedeny optimalizované parametry GA včetně mezí prostoru a výchozího jedince X_0 .

Tab. 3.2: Optimalizované parametry metody Houghovy transformace

Optimalizovaný parametr	Spodní hranice	Horní hranice	X_0
Sigma Cannyho detektoru	1	20	6
Spodní limit hledaného rádia	10	50	20
Horní limit hledaného rádia	10	50	40
Krok hledaného rádia	1	5	2

3.5 Kruhová Houghova transformace s potlačením krevního řečiště

Vzhledem k negativnímu vlivu krevního řečiště na segmentaci OD pomocí kruhové Houghovy transformace byl implementován postup potlačení krevního řečiště inspirovaný [22]. Histogram předzpracovaného snímku je omezen v daném rozsahu, a na upravený snímek je aplikováno šedotónové morfologické uzavření s rotujícím lineárním strukturním elementem. Tak vznikne 3D matice uzavřených snímků s různou orientací strukturního elementu. Dále je vypočtena variace mezi snímky se vzájemně kolmými strukturními elementy, a je získán úhel, při kterém variace na daném pixelu dosahuje maxima. Výstup potlačení řečiště je roven vyšší hodnotě na daném pixelu z uzavřeného snímku se strukturním elementem o získaném úhlu a z uzavřeného snímku se strukturním elementem kolmým k získanému úhlu. V takto předzpracovaném snímku bez krevního řečiště jsou dále detekovány hrany pomocí Cannyho detektoru, a obdržená hranová reprezentace vstupuje do klasické kruhové Houghovy transformace, výstupem je opět binární snímek reprezentující OD. Schéma navrženého postupu segmentace je na obr. 3.5.

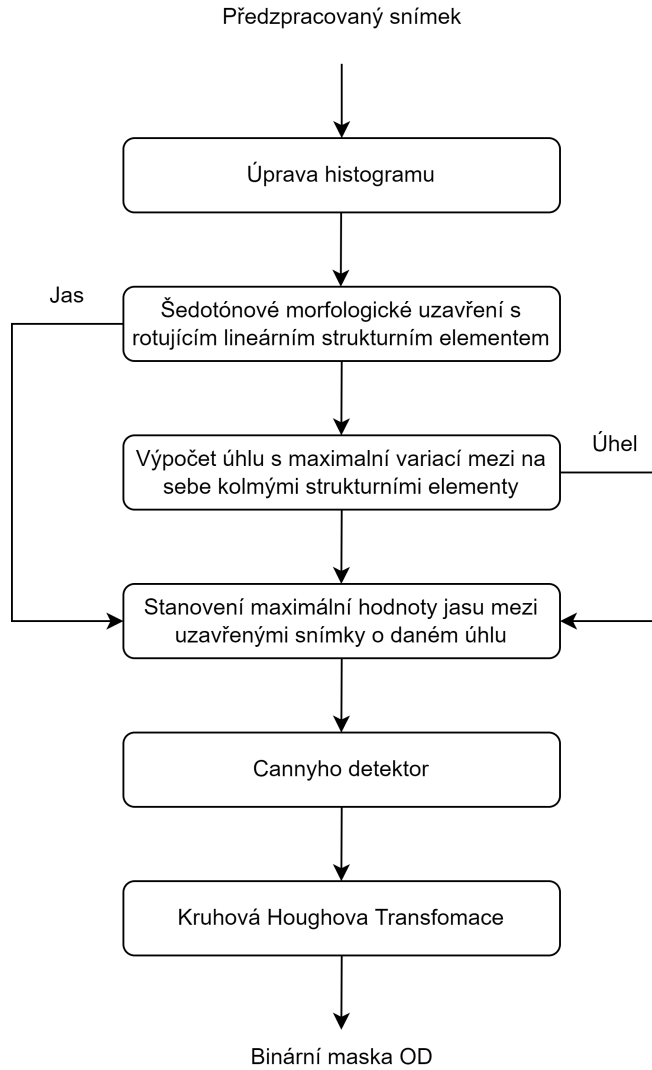
Proces předzpracování lze formulovat jako rovnici 3.18, kde I_v je výstupní snímek bez řečiště.

$$I_v(i, j) = I_{B_r}^{max}(i, j) \quad (3.18)$$

Kde $I_{B_r}^{max}$ je morfologicky uzavřený snímek s lineárním operátorem o rotaci r , která odpovídá maximu ze dvou na sebe kolmých lineárních operátorů s nejvyšší variancí, jak říká 3.19.

$$r = \arg_k(\max\{I_{B_r}^{var}(i, j); k = 1, 2, \dots, 12\}) \quad (3.19)$$

Délka lineárního operátoru L musí být delší než nejtlustší žíly ve snímku tak, aby se projevila variance mezi morfologickým uzavřením se strukturním elementem o úhlu kolmém a podélném ke směru žíly.



Obr. 3.5: Implementovaný postup prosté kruhové Houghovy transformace

Aby bylo možné šedotónové množinové operace zobecnit, je nutné šedotónový obraz vyjádřit jako množinu binárních obrazů, k čemuž slouží tzv. prahová dekompozice šedotónového obrazu. [37, 38] Zmíněné šedotónové morfologické uzavření ψ_B s plochým strukturálním elementem (3.20) lze chápat jako erozi šedotónové dilatace s plochým strukturálním elementem.

$$\psi_B(X) = X \circ Y = (X \ominus B) \oplus B \quad (3.20)$$

Šedotónová dilatace v 1D průřezu

$$(I \otimes S)(x) = \sup_{y \in Y} f(y) + g(x - y) \quad (3.21)$$

Šedotónová eroze v 1D průřezu

$$(I \ominus S)(x) = \inf_{y \in Y} f(y) - g(x - y) \quad (3.22)$$

Kde f je vstupní snímek a g je plochý strukturní element. V tabulce 3.3 jsou uvedeny optimalizované parametry GA, včetně mezí prostoru a výchozího jedince X_0 .

Tab. 3.3: Optimalizované parametry metody Houghovy transformace s potlačením krevního řečiště

Optimalizovaný parametr	Spodní hranice	Horní hranice	X_0
Spodní limit omezení histogramu	0	255	128
Horní limit omezení histogramu	0	255	190
Délka lineárního strukturního elementu	5	50	15
Sigma Cannyho detektoru	1	20	6
Spodní limit hledaného rádia	10	60	20
Horní limit hledaného rádia	10	60	40
Krok hledaného rádia	1	5	2

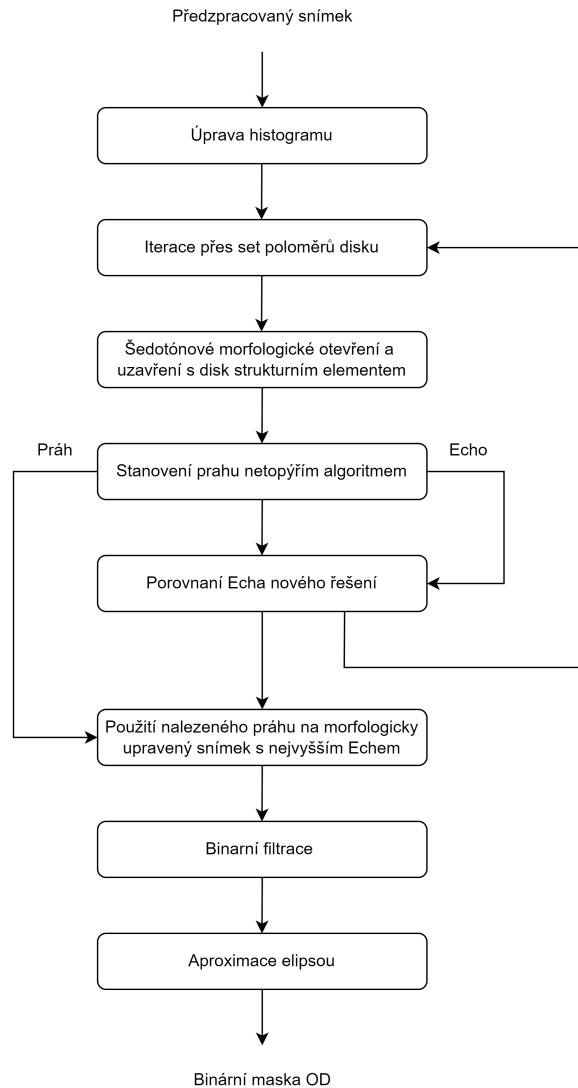
3.6 Segmentace s využitím netopýřího algoritmu pro stanovení prahu

Následující postup je inspirován metodou navrženou Abdullahem a kol. [33] Histogram předzpracovaného snímku je omezen v daném rozsahu, a na upravený snímek je, dle metody převzaté z [34], aplikována série morfologického uzavření a otevření s narůstající velikostí strukturního elementu s cílem potlačit vliv krevního řečiště.

Každý výstup otevření a uzavření snímku z této série je zpracován za pomoci *Bat Algorithm* (BA) s cílem stanovit práh s optimální variancí jasu. Pro další zpracování je poté vybrán morfologický snímek s nejvyšším echem v netopýřím algoritmu. Na nalezený morfologický snímek je použit práh optimálního řešení s cílem získat binární snímek. Ten je následně filtrován na základě plochy shluků, kdy je ponechán pouze shluk s největší plochou, případné otvory uvnitř shluku jsou vyplněny. Nalezený shluk je ve výstupní masce následně aproximován elipsou pomocí metody nejmenších čtverců. Schéma popsaného postupu lze vidět na obrázku 3.6.

Netopýří algoritmus

Pro stanovení optimálního prahu při segmentaci byl použit meta-heuristický netopýří algoritmus.



Obr. 3.6: Implementovaný postup využívající netopýří algoritmus

Meta-heuristický algoritmus publikovaný Xin-She Yangem [39] v roce 2010 popisuje chování mikronetopýřů při hledání potravy. BA je založen na faktu, že netopýří využívají echolokaci k rozlišení kořisti od bariéry. Netopýří létají s náhodnou rychlostí a polohou, s nepravidelnou frekvencí, hlasitostí i pulzně emisním poměrem. Kroky společnými pro implementaci tohoto algoritmu jsou:

Formulace objektové funkce $T_{max}(X)$ pro optimalizaci $X = X_1, X_2, X_2, \dots, X_t$, kde X je populace netopýřů a t je počet optimalizačních parametrů. Zápis 3.23 vyjadřuje optimalizovanou funkci pro stanovení prahu s optimální variací.

$$T_{max}(X) = \omega_0(X) \cdot \omega_1(X) [\mu_0(X) - \mu_1(X)]^2 \quad (3.23)$$

Za předpokladu, že pixely snímku na základě prahu rozdělíme do dvou tříd, ω udává pravděpodobnost příslušnosti ke třídě, kdy μ je průměr třídy.

Dále jsou stanoveny počáteční parametry BA, přesněji polohy počáteční populace netopýrů X_m , jejich rychlost V_m a frekvence f_m , kde $(m = 1, 2, 3, \dots, y)$, kde y je celkový počet netopýrů v populaci. Stanoven je i počáteční pulzně frekvenční poměr P_m , hlasitostní faktor R_m a maximální počet iterací $Iter_{max}$.

Následně je započata iterace n do splnění podmínky $n < Iter_{max}$ a formulace nového řešení populace. Na základě nejlepšího řešení a náhodně generované frekvence z 3.24 je v 3.25 vypočtena rychlost každého netopýra a jeho nová poloha X_m^n jako v 3.26.

$$f_m = f_{min} + (f_{max} - f_{min})\gamma \quad (3.24)$$

$$V_m^n = V_m^{n-1} + (X_m^{n-1} - X_{best})f_m \quad (3.25)$$

$$X_m^n = X_m^{n-1} + V_m^n \quad (3.26)$$

V_m^n je nová rychlost netopýra, X_m^n je poloha nového řešení, γ je náhodný vektor v rozsahu 0 až 1 a X_{best} je současné nejlepší řešení. Doporučený rozsah frekvencí $[f_{min}, f_{max}]$ každého netopýra je 0 až 2.

Pokud je náhodná normovaná veličina vyšší než pulzně frekvenční poměr P_m , je realizován náhodný lokální pohyb podle rovnice:

$$X_{new} \rightarrow X_{old} = \epsilon R^n \quad (3.27)$$

kde ϵ je náhodné číslo od -1 do 1 a R^n je průměrná hlasitost všech netopýrů. V dané poloze je vypočteno nové echo, a pokud je nové řešení lepší než současné a zároveň je náhodná normovaná veličina nižší než hlasitostní faktor R_m , je přijato nové nejlepší řešení. Pokud tak nastalo, je dle 3.28 redukován hlasitostní faktor R_m a zvýšen pulzně emisní poměr P_m dle 3.29.

$$R_m^{n+1} = \beta R_m^n \quad (3.28)$$

$$P_m^{n+1} = P_m^0(1 - \epsilon^{(-\sigma^n)}) \quad (3.29)$$

Konstanta β náleží na intervalu 0 až 1 a konstanta σ je větší než 0. Za standardních podmínek je β rovno σ . V navrženém algoritmu jsou tyto konstanty rovny 0,9 dle původní publikace. Tyto parametry se empiricky osvědčily. S ukončením iterace je

jako výstup algoritmu vybráno nejlepší nalezené řešení a jeho echo. Morfologicky upravený snímek je binarizován dle nalezeného prahu a binární snímek je filtrován na základě velikosti tak, aby zůstal pouze největší shluk pixelů. Obdržená maska je nakonec aproximována elipsou za pomoci metody nejmenších čtverců. V tabulce 3.4 jsou uvedeny optimalizované parametry GA včetně mezí prostoru a výchozího jedince X_0 .

Tab. 3.4: Optimalizované parametry metody netopýřího algoritmu

Optimalizovaný parametr	Spodní hranice	Horní hranice	X_0
Spodní limit histogramu	0	255	128
Horní limit histogramu	0	255	190
Spodní limit rádia morfologie	4	22	4
Horní limit rádia morfologie	4	22	16
Krok rádia morfologie	4	18	4

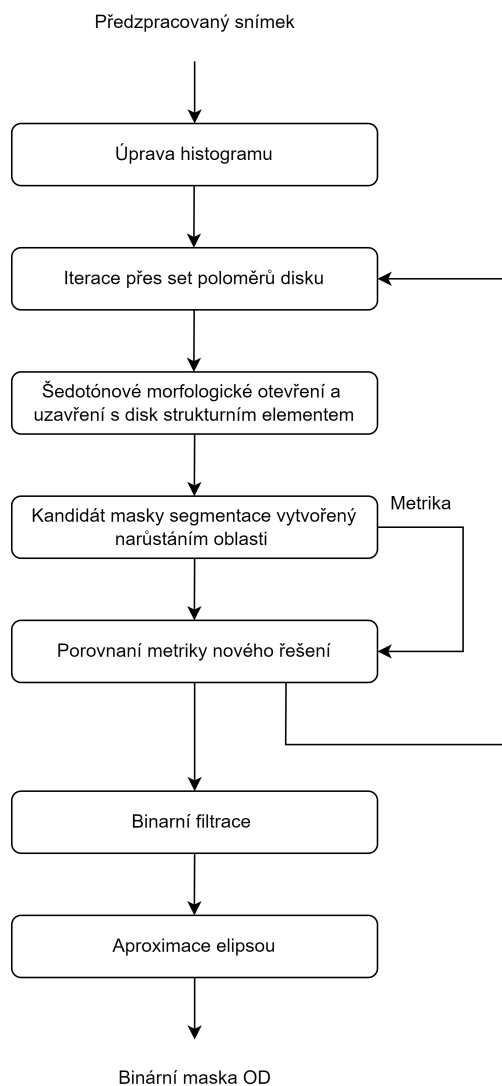
3.7 Segmentace s využitím metody narůstání oblasti

Další implementovanou metodou je regionově orientované narůstání oblasti. Postup dle 3.7 zahrnuje maskování krevního řečiště během iterace operací morfologických operátorů otevření a uzavření stejně jako u předešlé metody využívající netopýří algoritmus, s tím rozdílem, že oblast kandidátních pixelů masky je obdržena pomocí narůstání oblasti namísto prahování snímku. [37, 38]

Metrika M úspěšnosti maskování krevního řečiště je převzata z netopýřího algoritmu dle 3.30, kde za předpokladu, že pixely snímku na základě masky rozdělíme do dvou tříd, ω udává pravděpodobnost příslušnosti ke třídě a μ je průměr třídy.

$$M = \omega_0 \cdot \omega_1 [\mu_0 - \mu_1]^2 \quad (3.30)$$

Narůstání oblasti lze obecně rozdělit do čtyř fází. Prvně je inicializován počáteční bod narůstání, což je v případě implementovaného algoritmu pozice s nejvyšší hodnotou jako v morfologicky upraveném snímku. Druhým krokem je nalezení okolních pixelů narůstající oblasti ve všech osmi směrech. Ve třetím kroku je rozhodnuto zda sousední pixel náleží do hledané oblasti na základě optimalizované váhy prahu. Pokud je hodnota jasouzeného pixelu vyšší než součin adaptivní váhy a hodnoty výchozího pixelu, je pixel přijat do hledané oblasti. Pokud je splněna podmínka, že oblast už nemá kam dále narůstat, je v rámci poslední fáze algoritmus ukončen. Obdržená maska je nakonec aproximována elipsou za pomoci metody nejmenších čtverců. V tabulce 3.5 jsou uvedeny optimalizované parametry GA včetně mezí prostoru a výchozího jedince X_0 .



Obr. 3.7: Implementovaný postup využívající narůstání oblasti

Tab. 3.5: Optimalizované parametry narůstání oblasti

Optimalizovaný parametr	Spodní hranice	Horní hranice	X_0
Spodní limit histogramu	0	255	128
Horní limit histogramu	0	255	190
Váha adaptivního prahování	0.05	0.95	0.2
Spodní limit rádia morfologie	4	22	4
Horní limit rádia morfologie	4	22	16
Krok rádia morfologie	4	18	4

Výsledky výše uvedených implementovaných metod jsou popsány a zhodnoceny v následující kapitole.

4 Výsledky implementovaných metod

Následující kapitola obsahuje stručný popis dosažených výsledků celkem pěti implementovaných metod. Ty byly pro srovnání aplikovány na veřejně dostupný dataset popsany v podkapitole 1.4.1 a snímky pořízené experimentálním video-ofthalmoskopem z podkapitoly 1.4.2.

Metoda využívající segmentaci pomocí prahování dle tabulky 4.1 dosáhla na HRF datasetu nejnižšího průměrného DICE koeficientu 78,2 % a překryvu 65,3 % s centroidy vzdálenými 5,4 pixelu. Dle tabulky 4.2 v případě STUDY_01 datasetu si prahování vedlo lépe s průměrným překryvem 56,7 % a DICE koeficientem 71,4 % s centroidy vzdálenými 8 pixelů. Na STUDY_02 datasetu dosáhla metoda průměrného překryvu 52,2 % a 66,6 % DICE koeficientu s centroidy vzdálenými 13,5 pixelu. Výsledky dosažené na tomto datasetu jsou prezentovány v tabulce 4.3.

Tab. 4.1: Tabulka DICE metrik všech metod na HRF

Metoda	Průměr	Medián	Odchylka
Prahování	0.782	0.792	0.106
Houghova transformace	0.713	0.892	0.366
Upravená Houghova transformace	0.8	0.854	0.226
Narůstání oblasti	0.816	0.855	0.156
Netopýří algoritmus	0.769	0.807	0.192

Implementace Houghovy transformace dosáhla na HRF datasetu průměrného překryvu 64,9 % a DICE koeficientu 71,3 % s centroidy vzdálenými 38,2 pixelu. V případě STUDY_01 datasetu činil průměrný překryv 75,9 % a DICE koeficient 84,4 % s centroidy vzdálenými 4,5 pixelu, obdobně tomu bylo u STUDY_02 datasetu, kdy byl průměrný překryv 81,1 % a DICE koeficient 89,1 % s centroidy vzdálenými 3,1 pixelu.

Tab. 4.2: Tabulka DICE metrik všech metod na STUDY_01

Metoda	Průměr	Medián	Směrodatná odchylka
Prahování	0.714	0.757	0.118
Houghova transformace	0.844	0.915	0.177
Upravená Houghova transformace	0.812	0.916	0.248
Narůstání oblasti	0.533	0.58	0.169
Netopýří algoritmus	0.524	0.566	0.162

Tab. 4.3: Tabulka DICE metrik všech metod na STUDY_02

Metoda	Průměr	Medián	Směrodatná odchylka
Prahování	0.666	0.712	0.186
Houghova transformace	0.891	0.912	0.079
Upravená Houghova transformace	0.837	0.88	0.12
Narůstání oblasti	0.543	0.536	0.135
Netopýří algoritmus	0.527	0.526	0.138

Zmíněná Houghova transformace byla doplněna o maskování krevního řečiště pomocí maximální variance uzavření s rotujícím lineárním strukturním elementem. Dosáhla tak na HRF datasetu průměrného DICE koeficientu 80 % a 70,5 % překryvu. Vzdálenost centroidů činila 18,5 pixelu. Dle tabulky 4.2 v případě STUDY_01 datasetu dosahovala implementace průměrně 81,2 % DICE koeficientu, 73,5 % překryvu a 6,1 pixelu vzdálenosti centroidů. Na STUDY_02 datasetu činil průměrný překryv 73,6 % a DICE koeficient 83,7 % s centroidy vzdálenými 4,7 pixelu.

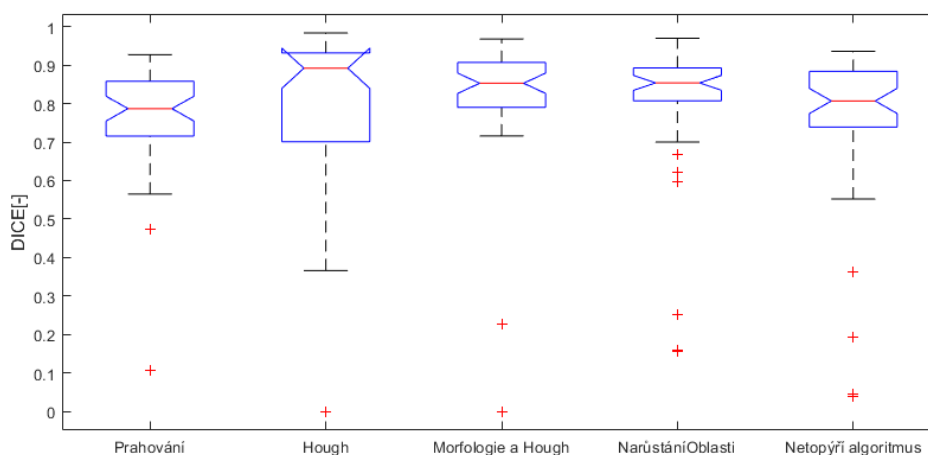
V případě HRF datasetu si dobře vedla metoda narůstání oblasti s průměrem 81,6 % DICE koeficientu, 71,2 % překryvu a 6,82 pixelu vzdálenými centroidy. Na STUDY_01 činil průměrný DICE koeficient 53,3 % a překryv 37,9 %. Průměrná vzdálenost centroidů byla 12,6 pixelu. Na STUDY_02 metoda dosáhla průměrně 54,3 % DICE koeficientu a 38,5 % překryvu. Průměrná vzdálenost centroidů byla 11,4 pixelu.

Nepříliš dobře si vedl netopýří algoritmus na datech z HRF s průměrným DICE koeficientem 76,9 % a překryvem 65,3 % s centroidy vzdálenými 12,13 pixelu. Obdobně tomu bylo i v případě STUDY_01 datasetu, kdy průměr DICE koeficientu činil 52,4 % a 37 % překryvu. Průměrná vzdálenost centroidů činila 11,8 pixelu. V případě STUDY_02 datasetu metoda dosáhla průměrně 52,7 % DICE koeficientu a 37 % překryvu s centroidy vzdálenými 11 pixelů.

Konkrétní výsledky každého snímku všech prezentovaných metod jsou k nahlédnutí v příloze A. Dále v jsou součástí přílohy i tabulka A.14 obsahující hodnoty překryvů všech metod na HRF datasetu a optimalizované parametry jednotlivých podmnožin křížové validace každé z metod. Obdobně se statistiky překryvů STUDY_01 datasetu nachází v tabulce A.15, hodnoty překryvů STUDY_02 datasetu jsou v tabulce A.16.

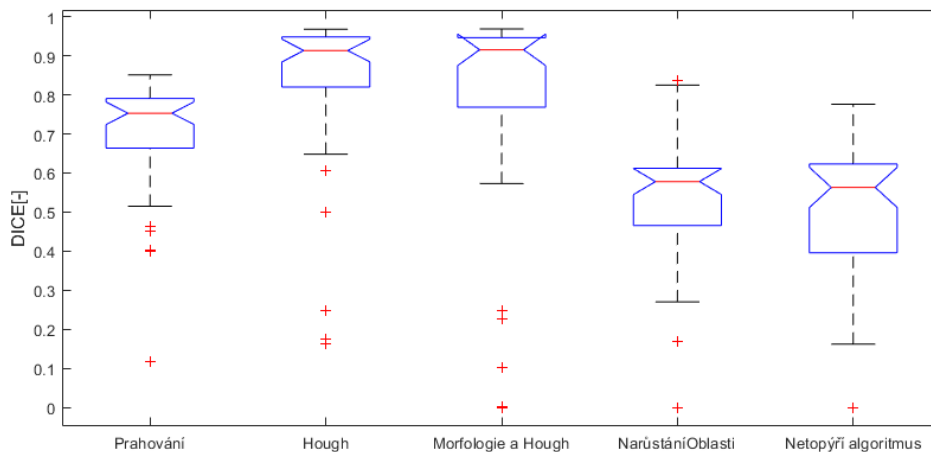
5 Diskuze

V následujících odstavcích budou diskutovány a analyzovány výsledky implementace metod z předešlé kapitoly. Nejdříve jsou porovnány výsledky jednotlivých metod v závislosti na použitých datech. Následuje seznámení se s průběhem trénovací fáze genetického algoritmu, které je nutno brát ve spojitosti s úspěšností segmentace. Při vzájemném porovnání boxplotů DICE metriky HRF datasetu (graf 5.1) oproti boxplotům obou STUDY datasetů (grafy 5.2 a 5.3) lze pozorovat rozdíl v úspěšnosti metod využívajících tradičních morfologických operací. Ten je způsoben především vyšší mírou šumu a nerovnoměrného osvětlení u experimentálních snímků. Lze z toho vyvodit závěr, že je v případě takto specifické situace vhodnější využít především informaci o hranách snímku, jelikož úrovně jasu jsou v případě experimentálních dat zkreslené.




Obr. 5.1: Boxplot DICE metriky HRF datasetu

Jako hlavní sledovaná metrika učící fáze segmentace byl zvolen průměr překryvů všech snímků v trénovací podmnožině datasetu. Jak bylo popsáno v úvodní podkapitole věnované možným kriteriím hodnocení úspěšnosti segmentace, překryv lze považovat za nejcitlivější vhodnou metriku při segmentaci optického disku. Na průběhu učící fáze HRF datasetu 5.4, STUDY_01 datasetu 5.5 a STUDY_02 5.6 lze pozorovat, že empiricky stanovený počáteční jedinec X_0 by ve většině případů vhodně zvolen, jelikož již nedocházelo k razantnímu nárůstu hodnotící funkce. V případě metody Houghovy transformace doplněné o morfologické maskování krevního řečiště tomu tak nebylo. Počáteční jedinec nebyl zvolen tak přesně jako u ostatních metod, a lze pozorovat, jak metoda z počátku rychle konverguje k optimálnímu řešení a následně se postupně zlepšuje jako ostatní metody.




Obr. 5.2: Boxplot DICE metriky STUDY_01 datasetu



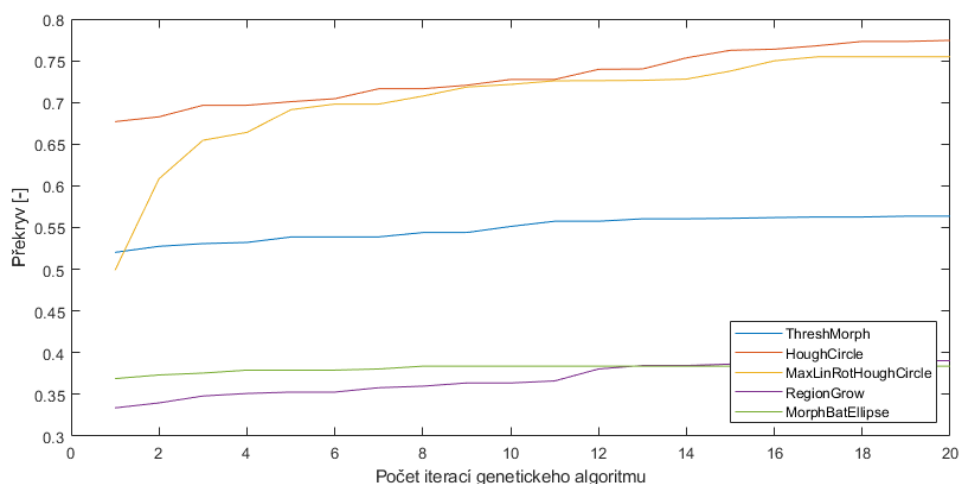
Obr. 5.3: Boxplot DICE metriky STUDY_02 datasetu

Z grafů je zřejmé, že by bývalo bylo vhodnější použít vyšší počet generací GA, jelikož v posledních iteracích lze stále pozorovat mírná zlepšení. To by pravděpodobně vedlo k obecně lepším výsledkům, jelikož je nízkým počtem iterací limitována i schopnost mutace genetického algoritmu nalézat nová optimálnější řešení mimo lokální maximum hodnotící funkce.

Metoda založená na prahování snímku si vedla na snímcích z experimentálního video-ofthalmoskopu hůře, avšak pokles přesnosti segmentace nebyl tak znatelný jako v případě metody netopýřího algoritmu a narůstání oblasti. Tato metoda má přiřazeně hned dvě limitace. První limitací je závislost na kvalitě předzpracování snímku, kdy se nerovnoměrné rozložení jasu pozadí snímku způsobené osvětlením negativně projeví na prvním binárním snímku po prahování.




Obr. 5.4: Graf učící fáze HRF datasetu



Obr. 5.5: Graf učící fáze STUDY_01 datasetu

V takovém případě nemůže vést další práce s binárním snímkem k uspokojivým výsledkům. Druhou limitací je přítomnost stínu krevního řečiště, která negativně ovlivňuje segmentaci okrajů optického disku, které mají často podobnou úroveň jasu jako pozadí snímku. Ukázkou postupu segmentace krok po kroku je vyobrazena na obrázku 5.7, kde můžeme vidět předzpracovaný snímek, dále snímek po aplikaci průměrovací masky následovaný snímkem mediánové filtrace, a binární masku po prahování, která je v dalším kroce filtrována o nežádoucí oblasti. Zelená line v posledním snímku představuje zlatý standard a červená line oblast obdrženu segmentací.




Obr. 5.6: Graf učící fáze STUDY_02 datasetu

Tab. 5.1: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na HRF

Set	Sigma Canny	Dolní limit poloměru	Horní limit poloměru	Krok poloměru	Průměr překryvu	Průměr času
1.	5	28	32	4	0.737	0.124
2.	5	28	34	2	0.749	0.232
3.	4	32	34	2	0.533	0.137
4.	5	28	40	4	0.75	0.221
5.	5	29	34	3	0.475	0.123


Metoda založená na použití Houghovy transformace si vedla na všech třech datasetech nejlépe, což je pravděpodobně dáno faktem, že využívá pouze informace o přítomnosti hran ve snímku. Její úspěšnost je závislá na míře Gaussova rozostření v prvním kroku Cannyho detektoru a stanovení rozpětí hledaného poloměru. Z tabulky optimalizovaných parametrů trénovací fáze 5.1 si lze povšimnout, jak limity poloměrů hledaných Houghovou transformací spolu s krokem přímo ovlivňují přesnost i výpočetní náročnost segmentace.

Metoda aplikující Houghovu transformaci na snímek upravený pomocí rotujícího lineárního operátoru maximální variance morfologického uzavření si vedla lépe než ostatní metody využívající morfologie. Snímek 5.8 ukazuje schopnost operátoru potlačit krevní řečiště bez snížení jasu v okolí maskované cévy, jako se tomu děje při použití diskového strukturního elementu.




Obr. 5.7: Ukázka segmentace snímku pomocí prahování

Metoda narůstání oblasti je, podobně jako metoda netopýřího algoritmu, závislá na kvalitě maskování krevního řečiště diskovým strukturním elementem. Ukázku takto předzpracovaného snímku lze vidět na obrázku 5.9. Nevýhody použité metody maskování krevního řečiště jsou specifikovány v následujícím odstavci věnovaném netopýřímu algoritmu.



Obr. 5.8: Ukázka maskování krevního řečiště pomocí lineárního strukturního elementu

Oproti předpokladům si metoda využívající netopýří algoritmus vedla hůře než ostatní implementované postupy a překonala pouze metodu prahování na snímcích HRF datasetu. Tak se dělo i v případě snímků z HRF datasetu. V tabulce 5.2 si lze povšimnout, že netopýří algoritmus dosahoval nejlepších výsledků s parametry 4. trénovací podmnožiny, tedy při použití pouze dvou průměrů poloměru, což odporuje původní myšlence hledat optimální poloměr z předem zadaného setu více jak 2 poloměrů, která je prezentována v [33]. Nutno dodat, že uvedená metoda je oproti ostatním prezentovaným metodám značně výpočetně náročná, což je zapříčiněno její neoptimalizovanou implementací. Připadá v úvahu i zvážit použití jiné hodnotící funkce, která by lépe evaluovala kvalitu potlačení krevního řečiště morfologickými operacemi. Zbylé tabulky optimalizovaných parametrů jsou obsaženy v příloze A.



Obr. 5.9: Ukázka maskování krevního řečiště pomocí diskového strukturního elementu

Tab. 5.2: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na HRF

Set	Dolní limit histogramu	Horní limit histogramu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	127	154	5	22	4	0.625	4.947
2.	123	175	4	18	10	0.694	1.942
3.	120	167	5	16	14	0.55	1.053
4.	126	167	4	16	16	0.755	1.048
5.	123	180	4	18	8	0.597	1.976

Závěr

Cílem této bakalářské práce bylo seznámit se s problematikou segmentace optického disku ve snímku očního pozadí, dále vybrat vhodné metody segmentace a ty následně implementovat v prostředí MATLAB. Úvodní část práce stručně popisuje anatomii lidského oka, patologie viditelné na snímku očního pozadí, metody snímání očního pozadí a oblasti na něm viditelné. Dále je zmíněn veřejně dostupný HRF dataset snímků a dva datasey získané experimentálním video-oftalmoskopem, které jsou pro tuto práci stěžejní. Zmíněny jsou i možné metriky a jejich vhodnost pro validaci segmentace optického disku. V následující kapitole práce najdeme literární rešerši metod segmentace optického disku vhodných pro šedotónové snímky, která má za cíl nastínit možnosti implementace. Rešerše byla v rámci bakalářské práce rozšířena o další metody. Vybrané metody jsou v bakalářské práci aplikovány na data získaná experimentálním video-oftalmoskopem [16], proto bylo třeba vybrat metodu dostatečně robustní vůči šumu, nevhodné expozici, nerovnoměrnému osvětlení a rozostření způsobenému pohybem pacienta.

Byla implementována metoda využívající meta-heuristický netopýří algoritmus, ale také metoda prosté kruhové Houghovy transformace a její modifikace s morfologickým předzpracováním snímku. Dále implementace obsahuje metodu založenou na prahování a metodu využívající narůstání oblasti. Zvolené postupy segmentace byly optimalizovány pomocí meta-heuristického genetického algoritmu s cílem najít vhodné parametry pro každou podmnožinu snímků křížové validace.

Vzhledem k výsledkům je nutno konstatovat, že jedinou metodou vhodnou k segmentaci specifických snímků z experimentálního zařízení byla Houghova transformace, která využívá pouze informace o poloze hran ve snímku. Lepších výsledků by pravděpodobně bylo možné dosáhnout při jiné konfiguraci genetického algoritmu a navýšení počtu jedinců i počtu iterací. Vzhledem k výpočetní náročnosti zvolené metody optimalizace i metody segmentace využívající šedotónových morfologických operací by bylo vhodnější přistupovat k řešenému problému zcela odlišně. Namísto práce s celým snímkem by bylo vhodné použít pouze vektor příznaků a v případě dostatečného počtu trénovacích snímků použít umělé neuronové sítě.

Literatura

- [1] QUIGLEY, H A. *The number of people with glaucoma worldwide in 2010 and 2020. British Journal of Ophthalmology [online]. 2006, 90(3), 262-267 [cit. 2020-11-30]. DOI: 10.1136/bjo.2005.081224. ISSN 0007-1161. Dostupné z: <http://bjo.bmj.com/cgi/doi/10.1136/bjo.2005.081224>*
- [2] ROZSÍVAL, Pavel. *Oční lékařství. Praha: Galén, c2006. ISBN 80-7262-404-0.*
- [3] WARD, Jeremy P. T. a R. W. A. LINDEN. *Základy fyziologie. Praha: Galén, c2010. ISBN 978-80-7262-667-0.*
- [4] SVOZÍLKOVÁ, Petra, Jarmila HEISSIGEROVÁ a Pavel DIBLÍK. *Diferenciální diagnostika v oftalmologii v obrazech. Praha: Mladá fronta, 2015. Aeskulap. ISBN 978-80-204-3393-0.*
- [5] K. KAISER, Peter. *The Joy of Visual Perception [online]. York: York University, c1996-2005 [cit. 2020-07-07]. Dostupné z URL: <<http://www.yorku.ca/eye/ophthal.htm>>*
- [6] PAPOUR, Asael, et al. *Imaging autofluorescence temporal signatures of the human ocular fundus in vivo. Journal of Biomedical Optics, 2015, 20.11: 110505.*
- [7] HLOŽÁNEK, Martin a Blanka BRŮNOVÁ. *Přístrojová technika v oftalmologii. 1. vyd. Praha: Univerzita Karlova, 2. lékařská fakulta, 2006, 28 s. ISBN 80-902-1609-9. Dostupné z URL: <<https://anzdoc.com/queue/pistrojova-technika-v-oftalmologii.html>>*
- [8] YANOFF, Myron; DUKER, Jay S. *Ophthalmology. 3rd ed. Kidlington: Mosby, 2009. 1552 s. ISBN 978-0-323-04332-8.*
- [9] *Community Eye Health Journal Community Eye Health Journal [online]. Copyright © International Centre for Eye Health, London School of Hygiene [cit. 2020-07-07]. Dostupné z URL: <<https://www.cehjournal.org/article/understanding-and-caring-for-an-indirect-ophthalmoscope/>>*
- [10] CIVIT-MASOT, Javier, Francisco LUNA-PEREJON, Saturnino VICENTE-DIAZ, Jose Maria RODRIGUEZ CORRAL a Anton CIVIT. *TPU Cloud-Based Generalized U-Net for Eye Fundus Image Segmentation. IEEE Access [online]. 2019, 7, 142379-142387 [cit. 2020-12-01]. DOI: 10.1109/ACCESS.2019.2944692. ISSN 2169-3536. Dostupné z: <https://ieeexplore.ieee.org/document/8853235/>*

- [11] *The Eye Digest*. [online]. Illinois: The University of Illinois Eye and Ear Infirmary., 2012 [cit. 2020-11-27]. Dostupné z: <https://web.archive.org/web/20120708075410/http://www.agingeye.net/glaucoma/glaucomainform>
- [12] Sadun, A., Glaser, J. a Bose, S. *Anatomy of the Visual Sensory System* [online]. 2006, Updated July 10 2016. Dostupné z URL: <<https://entokey.com/anatomy-of-the-visual-sensory-system/>>
- [13] Dwarikanath Mahapatra, *Automatic Optic Cup and Optic Disc Segmentation for Glaucoma Diagnosis* [online]. 2018 [cit. 2021-05-18] Dostupné z URL: <<http://www.ise.inf.ethz.ch/education/studentprojects/completedprojects/automatic-optic-cup-and-optic-disc-segmentation-for-glaucoma-dia0.html>>
- [14] Mahwish Arshad - *Ocular manifest of systemic disease* [online]. [cit. 2017-12-28]. Dostupné z URL: <<https://ocularmanifestofsystemicdisease.weebly.com/anatomy.html>>
- [15] CHRÁSTEK, R., M. WOLF, K. DONATH, et al. *Automated segmentation of the optic nerve head for diagnosis of glaucoma*. *Medical Image Analysis* [online]. 2005, 9(4), 297-314 [cit. 2021-12-01]. DOI: 10.1016/j.media.2004.12.004. ISSN 13618415. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1361841505000101>
- [16] TORNOW, Ralf P.; KOLÁŘ, Radim; ODSTRČILÍK, Jan. *Non-mydratic video ophthalmoscope to measure fast temporal changes of the human retina*. In: *European Conference on Biomedical Optics*. Optical Society of America, 2015. p. 954006.
- [17] KOLAR, Radim, et al. *Registration of retinal sequences from new video-ophthalmoscopic camera*. *Biomedical engineering online*, 2016, 15.1: 57.
- [18] BUDAI, A., R. BOCK, A. MAIER, J. HORNEGGER a G. MICHELSON. *Robust Vessel Segmentation in Fundus Images*. *International Journal of Biomedical Imaging* [online]. 2013, 2013, 1-11 [cit. 2021-12-29]. ISSN 1687-4188. Dostupné z: [doi:10.1155/2013/154860](https://doi.org/10.1155/2013/154860)
- [19] THAKUR, N., et al. *Survey on segmentation and classification approaches of optic cup and optic disc for diagnosis of glaucoma*. *Biomedical Signal Processing and Control*, 2018, roč. 42, č. 4, s. 162-189.

- [20] ALMAZROA, A., et al. *Optic Disc and Optic Cup Segmentation Methodologies for Glaucoma Image Detection: A Survey*. Journal of Ophthalmology, 2015, Article ID 180972, s. 28.
- [21] ALLAM, Ali, Aliaa YOUSSEF a Atef GHALWASH. *Automatic Segmentation of Optic Disc in Eye Fundus Images: A Survey* Electronic Letters on Computer Vision and Image Analysis [online]. 2015, 2015(1-20), 20 [cit. 2020-12-29]. Dostupné z: <http://elcvia.cvc.uab.es/article/view/680>
- [22] AQUINO, Arturo, Manuel Emilio GEGÚNDEZ-ARIAS a Diego MARÍN. *Detecting the Optic Disc Boundary in Digital Fundus Images Using Morphological, Edge Detection, and Feature Extraction Techniques*. IEEE Transactions on Medical Imaging [online]. 2010, 29(11), 1860-1869 [cit. 2021-11-20]. DOI: 10.1109/TMI.2010.2053042. ISSN 0278-0062. Dostupné z: <http://ieeexplore.ieee.org/document/5487392/>
- [23] Blanco M., Penedo M.G., Barreira N., Penas M., Carreira M.J. *Localization and Extraction of the Optic Disc Using the Fuzzy Circular Hough Transform*. ICAISC 2006. Lecture Notes in Computer Science, vol 4029. Springer, Berlin, Heidelberg. [cit. 2020-11-26] <https://doi.org/10.1007/1178523174>
- [24] PRIYADHARSHINI, Lydia a L. ANITHA. *A Region Growing Method of Optic Disc Segmentation in Retinal Images* [online]. 2014 [cit. 2020-11-26]. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=6892618>
- [25] KHALIL, Tehmina, Muhammad USMAN AKRAM, Samina KHALID a Amina JAMEEL. *Improved automated detection of glaucoma from fundus image using hybrid structural and textural features*. IET Image Processing [online]. 2017, 11(9), 693-700 [cit. 2020-12-06]. ISSN 1751-9659. Dostupné z: [doi:10.1049/iet-ipr.2016.0812](https://doi.org/10.1049/iet-ipr.2016.0812)
- [26] OTSU, Nobuyuki. *A Threshold Selection Method from Gray-Level Histograms*. IEEE Transactions on Systems, Man, and Cybernetics [online]. 1979, 9(1), 62-66 [cit. 2020-12-06]. ISSN 0018-9472. Dostupné z: [doi:10.1109/TSMC.1979.4310076](https://doi.org/10.1109/TSMC.1979.4310076)
- [27] JOSHI, Gopal Datt, Jayanthi SIVASWAMY, Kundan KARAN a S. R. KRISHNADAS. *Optic disk and cup boundary detection using regional information*. In: 2010 IEEE International Symposium on Biomedical Imaging: From Nano to Macro [online]. IEEE, 2010, 2010, s. 948-951 [cit. 2021-12-22]. ISBN 978-1-4244-4125-9. Dostupné z: [doi:10.1109/ISBI.2010.5490144](https://doi.org/10.1109/ISBI.2010.5490144)

- [28] BALAKRISHNAN, Umarani. *NDC-IVM: An automatic segmentation of optic disc and cup region from medical images for glaucoma detection*. *Journal of Innovative Optical Health Sciences* [online]. 2017, 10(03) [cit. 2021-12-23]. ISSN 1793-5458. Dostupné z: doi:10.1142/S1793545817500079
- [29] MAHESHWARI, Shishir, Ram Bilas PACHORI, Vivek KANHANGAD, Sulatha V. BHANDARY a U. Rajendra ACHARYA. *Iterative variational mode decomposition based automated detection of glaucoma using fundus images*. *Computers in Biology and Medicine* [online]. 2017, 88, 142-149 [cit. 2021-12-23]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbiomed.2017.06.017
- [30] KOH, Joel E. W., Eddie Y. K. NG, Sulatha V. BHANDARY, Augustinus LAUDE a U. Rajendra ACHARYA. *Automated detection of retinal health using PHOG and SURF features extracted from fundus images*. *Applied Intelligence* [online]. [cit. 2021-12-25]. ISSN 0924-669X. Dostupné z: doi:10.1007/s10489-017-1048-3
- [31] REHMAN, Zaka Ur, Syed S. NAQVI, Tariq M. KHAN, Muhammad ARSALAN, Muhammad A. KHAN a M.A. KHALIL. *Multi-parametric optic disc segmentation using superpixel based feature classification*. *Expert Systems with Applications* [online]. 2019, 120, 461-473 [cit. 2021-12-23]. ISSN 09574174. Dostupné z: doi:10.1016/j.eswa.2018.12.008
- [32] ÜNVER, Halil, Yunus KÖKVER, Elvan DUMAN a Osman ERDEM. *Statistical Edge Detection and Circular Hough Transform for Optic Disk Localization*. *Applied Sciences* [online]. 2019, 9(2) [cit. 2021-12-26]. ISSN 2076-3417. Dostupné z: doi:10.3390/app9020350
- [33] ABDULLAH, Ahmad S., Yasa Ekşioğlu ÖZOK a Javad RAHEBI. *A novel method for retinal optic disc detection using bat meta-heuristic algorithm*. *Medical Biological Engineering Computing* [online]. 2018, 56(11), 2015-2024 [cit. 2022-4-25]. ISSN 0140-0118. Dostupné z: doi:10.1007/s11517-018-1840-1
- [34] MARIN, Diego, Manuel E. GEGUNDEZ-ARIAS, Angel SUERO a Jose M. BRAVO. *Obtaining optic disc center and pixel region by automatic thresholding methods on morphologically processed fundus images*. *Computer Methods and Programs in Biomedicine* [online]. 2015, 118(2), 173-185 [cit. 2022-05-10]. ISSN 01692607. Dostupné z: doi:10.1016/j.cmpb.2014.11.003
- [35] R. Fisher, S. Perkins, A. Walker , E. Wolfart .‘Intensity Histogram’. [cit. 2021-12-26] Dostupné z: <http://homepages.inf.ed.ac.uk/rbf/HIPR2/histogram.htm>

- [36] SOJKA, Eduard, Jan GAURA a Michal KRUMNIKL. *Matematické základy digitálního zpracování obrazu*. 2011.
- [37] VÁLEK, Petr, Martin LAMOŠ a Jiří JAN. *Analýza biomedicínských obrazů: Počítačová cvičení*. 2015. Brno: Vysoké učení technické v Brně Fakulta elektrotechniky a komunikačních technologií Ustav biomedicínského inženýrství, 2015. ISBN 978-80-214-4792-9.
- [38] HÁJOVSKÝ, Radovan, PUSTKOVÁ, Radka, KUTÁLEK, František: *Zpracování obrazu v měřicí a řídicí technice. Studijní materiály pro studijní obor Měřicí a řídicí technika, Elektronika, Fakulty elektrotechniky a informatiky*, 2012. ISBN 978-80-248-2596-0
- [39] YANG, Xin-She. *A New Metaheuristic Bat-Inspired Algorithm*. GONZÁLEZ, Juan R., David Alejandro PELTA, Carlos CRUZ, Germán TERRAZAS a Natalio KRASNOGOR, ed. *Nature Inspired Cooperative Strategies for Optimization (NICSO 2010) [online]*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, 2010, s. 65-74 [cit. 2021-4-25]. *Studies in Computational Intelligence*. ISBN 978-3-642-12537-9. Dostupné z: doi:10.1007/978-3-642-12538-6
- [40] MARÍN, D, A AQUINO, M E GEGUNDEZ-ARIAS a J M BRAVO. *A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and Moment Invariants-Based Features*. *IEEE Transactions on Medical Imaging [online]*. 2011, 30(1), 146-158 [cit. 2022-05-10]. ISSN 0278-0062. Dostupné z: doi:10.1109/TMI.2010.2064333
- [41] SALAZAR-GONZALEZ, Ana, Djibril KABA, YONGMIN LI a XIAOHUI LIU. *Segmentation of the Blood Vessels and Optic Disk in Retinal Images*. *IEEE Journal of Biomedical and Health Informatics [online]*. 2014, 18(6), 1874-1886 [cit. 2022-05-10]. ISSN 2168-2194. Dostupné z: doi:10.1109/JBHI.2014.2302749
- [42] Mostapha Kalami Heris, *Practical Genetic Algorithms in Python and MATLAB – Video Tutorial (URL: <https://yarpiz.com/632/ypga191215-practical-genetic-algorithms-in-python-and-matlab>)*, Yarpiz, 2020.
- [43] KATOCH, Sourabh, Sumit Singh CHAUHAN a Vijay KUMAR. *A review on genetic algorithm: past, present, and future*. *Multimedia Tools and Applications [online]*. 2021, 80(5), 8091-8126 [cit. 2022-05-10]. ISSN 1380-7501. Dostupné z: doi:10.1007/s11042-020-10139-6
- [44] TVRDÍK, J. *Evoluční algoritmy*, Ostravská univerzita, 2004, 73s

Seznam symbolů a zkratek

BA	Bat Algorithm
CCD	Charge-Coupled Device
CDR	Cup to Disc ratio
CLAHE	Contrast Limited Adaptive Histogram Equalization
DICE	Sørensen–Dice koeficient
FOV	Field Of View
FP	False Positive
FN	False Negative
FWHM	Full width at Half Maximum
GA	Genetic Algorithm
HRF	High-Resolution Fundus
IVM	Intensity Variation Masking
kNN	k-Nearest Neighbor
MLSECST	Multilocal Level Set Extrinsic Curvature based on the Structure Tensor
NDC	Neighboring Differential Clustering
OD	Optic Disc
PHOG	Pyramid Histogram of Oriented Gradients
PSO	Partical Swarm Optimalization
RGB	Red Green Blue parametrický prostor pro barevné snímky
ROI	Region of Interest
LED	Light-Emitting Diode
SURF	Speeded Up Robust Features
SVM	Support Vector Machine

TP	True Positive
TN	True Negative
USB	Universal Serial Bus
VMD	Variation Mode Decomposition

Seznam příloh

A Tabulky - Metriky jednotlivých snímků

77

A Tabulky - Metriky jednotlivých snímků

Tab. A.1: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování HRF

Set	Průměrovací maska	Mediánová maska	Práh	Poloměr otevření	Filtrovaná plocha	Průměr překryvu	Průměr času
1.	6	26	0.561	15	1296	0.576	0.045
2.	12	18	0.574	12	811	0.664	0.031
3.	4	20	0.599	11	537	0.601	0.031
4.	6	16	0.588	8	851	0.633	0.025
5.	4	20	0.603	11	481	0.617	0.031

Tab. A.2: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování STUDY_01

Set	Průměrovací maska	Mediánová maska	Práh	Poloměr otevření	Filtrovaná plocha	Průměr překryvu	Průměr času
1.	14	20	0.518	9	537	0.557	0.008
2.	20	18	0.514	13	197	0.536	0.007
3.	20	10	0.518	12	483	0.516	0.006
4.	22	18	0.525	12	439	0.597	0.006
5.	12	10	0.498	12	731	0.469	0.005

Tab. A.3: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace prahování STUDY_02

Set	Průměrovací maska	Mediánová maska	Práh	Poloměr otevření	Filtrovaná plocha	Průměr překryvu	Průměr času
1.	30	24	0.531	13	500	0.585	0.01
2.	28	26	0.537	4	756	0.54	0.007
3.	16	10	0.555	8	568	0.454	0.006
4.	24	16	0.531	17	578	0.429	0.007
5.	30	26	0.542	11	570	0.534	0.007

Tab. A.4: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na STUDY_01

Set	Sigma Canny	Dolní limit poloměru	Horní limit poloměru	Krok poloměru	Průměr překryvu	Průměr času
1.	1	19	37	1	0.861	0.111
2.	2	20	31	2	0.702	0.024
3.	2	20	36	2	0.721	0.027
4.	1	20	31	2	0.751	0.037
5.	1	20	36	2	0.78	0.054

Tab. A.5: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace na STUDY_02

Set	Sigma Canny	Dolní limit poloměru	Horní limit poloměru	Krok poloměru	Průměr překryvu	Průměr času
1.	2	20	35	2	0.736	0.026
2.	2	22	32	2	0.698	0.019
3.	2	20	34	2	0.767	0.023
4.	2	20	37	1	0.823	0.051
5.	1	21	26	2	0.795	0.021

Tab. A.6: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na HRF

Set	Dolní limit histogramu	Horní limit histogramu	Délka elementu	Sigma	Dolní limit rádia	Horní limit rádia	Krok rádia	Průměr překryvu	Průměr času
1.	122	209	20	20	29	35	4	0.685	0.108
2.	110	177	17	5	25	33	2	0.836	0.274
3.	126	229	22	20	29	36	3	0.696	0.108
4.	118	184	22	7	22	40	3	0.528	0.287
5.	125	219	20	20	29	35	3	0.715	0.107

Tab. A.7: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na STUDY_01

Set	Dolní limit histogramu	Horní limit histogramu	Délka elementu	Sigma	Dolní limit rádia	Horní limit rádia	Krok rádia	Průměr překryvu	Průměr času
1.	93	219	23	1	18	33	2	0.632	0.048
2.	131	220	24	1	19	39	1	0.779	0.086
3.	53	221	12	1	21	30	3	0.829	0.024
4.	74	208	22	1	18	35	3	0.55	0.038
5.	103	210	22	2	20	30	3	0.733	0.02

Tab. A.8: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace Houghovy transformace s předzpracováním na STUDY_02

Set	Dolní limit histogramu	Horní limit histogramu	Délka elementu	Sigma	Dolní limit rádia	Horní limit rádia	Krok rádia	Průměr překryvu	Průměr času
1.	45	223	20	1	19	31	3	0.737	0.032
2.	7	235	19	2	19	33	3	0.726	0.022
3.	29	229	19	2	19	31	5	0.754	0.018
4.	81	239	21	1	21	33	2	0.645	0.036
5.	56	234	19	2	20	32	3	0.779	0.024

Tab. A.9: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na STUDY_01

Set	Dolní limit histogramu	Horní limit histogramu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	56	217	4	16	18	0.417	0.305
2.	110	176	6	12	8	0.351	0.301
3.	68	187	4	14	12	0.323	0.303
4.	56	233	4	10	10	0.326	0.294
5.	97	212	4	10	10	0.459	0.296

Tab. A.10: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace netopýřího algoritmu na STUDY_02

Set	Dolní limit histogramu	Horní limit histogramu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	37	221	4	16	14	0.361	0.305
2.	85	224	4	12	10	0.349	0.293
3.	33	211	4	14	18	0.435	0.306
4.	54	233	4	10	8	0.37	0.306
5.	76	215	6	12	8	0.279	0.316

Tab. A.11: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na HRF

Set	Dolní limit histogramu	Horní limit histogramu	Váha adaptivního prahu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	16	198	0.557	5	11	10	0.768	0.027
2.	21	197	0.563	5	10	13	0.649	0.025
3.	15	198	0.579	5	11	10	0.722	0.024
4.	42	198	0.558	5	11	10	0.666	0.023
5.	21	198	0.566	5	10	12	0.727	0.025

Tab. A.12: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na STUDY_01

Set	Dolní limit histogramu	Horní limit histogramu	Váha adaptivního prahu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	76	165	0.249	6	17	13	0.441	0.008
2.	67	176	0.323	6	15	11	0.334	0.008
3.	60	184	0.359	4	20	18	0.493	0.006
4.	48	185	0.374	7	15	11	0.326	0.007
5.	114	188	0.364	7	15	13	0.346	0.006

Tab. A.13: Tabulka optimalizovaných parametrů a výsledků každého setu křížové validace metody narůstání oblasti na STUDY_02

Set	Dolní limit histogramu	Horní limit histogramu	Váha adaptivního prahu	Dolní limit morfologie	Horní limit morfologie	Krok morfologie	Průměr překryvu	Průměr času
1.	55	167	0.272	7	13	12	0.365	0.011
2.	85	195	0.384	5	12	10	0.421	0.006
3.	55	187	0.358	5	13	13	0.335	0.005
4.	87	178	0.318	6	15	18	0.41	0.006
5.	74	195	0.463	7	13	11	0.386	0.007

Tab. A.14: Tabulka překryvů všech metod na HRF

Metoda	Průměr [-]	Medián [-]	Směrodatná odchylka [-]
Prahování	0.653	0.655	0.138
Houghova transformace	0.649	0.806	0.341
Upravená Houghova transformace	0.705	0.745	0.214
Narůstání oblasti	0.71	0.753	0.184
Netopýří algoritmus	0.653	0.676	0.194

Tab. A.15: Tabulka překryvů všech metod na STUDY_01

Metoda	Průměr [-]	Medián [-]	Směrodatná odchylka [-]
Prahování	0.567	0.609	0.129
Houghova transformace	0.759	0.848	0.203
Upravená Houghova transformace	0.735	0.846	0.253
Narůstání oblasti	0.383	0.375	0.125
Netopýří algoritmus	0.379	0.409	0.144

Tab. A.16: Tabulka překryvů všech metod na STUDY_02

Metoda	Průměr [-]	Medián [-]	Směrodatná odchylka [-]
Prahování	0.522	0.553	0.176
Houghova transformace	0.811	0.839	0.115
Upravená Houghova transformace	0.736	0.786	0.156
Narůstání oblasti	0.385	0.366	0.132
Netopýří algoritmus	0.37	0.356	0.136

Tab. A.17: Tabulka výsledků prahování na HRF dataset

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
3	01_dr	0.993	0.484	0.653	9.737	0.03
2	01_g	0.997	0.78	0.876	3.136	0.034
3	01_h	0.997	0.779	0.876	2.874	0.032
4	02_dr	0.993	0.529	0.692	11.857	0.025
2	02_g	0.992	0.394	0.565	10.071	0.03
4	02_h	0.996	0.753	0.859	2.988	0.031
1	03_dr	0.96	0.206	0.342	87.537	0.042
4	03_g	0.994	0.63	0.773	5.345	0.024
2	03_h	0.995	0.713	0.832	4.723	0.031
1	04_dr	0.997	0.776	0.874	1.798	0.041
5	04_g	0.995	0.619	0.765	6.918	0.029
1	04_h	0.995	0.665	0.799	5.984	0.04
3	05_dr	0.994	0.451	0.622	11.245	0.029
4	05_g	0.995	0.587	0.74	2.303	0.022
2	05_h	0.991	0.494	0.662	7.147	0.031
5	06_dr	0.994	0.529	0.692	10.842	0.029
1	06_g	0.994	0.597	0.747	4.132	0.044
1	06_h	0.987	0	0	584	0.05
4	07_dr	0.996	0.754	0.86	4.928	0.029
4	07_g	0.714	0.041	0.08	204.323	0.023
4	07_h	0.995	0.723	0.839	6.808	0.024
1	08_dr	0.998	0.831	0.908	4.034	0.04
3	08_g	0.996	0.672	0.804	4.981	0.035
5	08_h	0.993	0.556	0.715	11.441	0.03
4	09_dr	0.999	0.885	0.939	0.663	0.023
3	09_g	0.996	0.668	0.801	6.128	0.03
3	09_h	0.994	0.612	0.759	6.702	0.033
4	10_dr	0.998	0.792	0.884	1.144	0.026
2	10_g	0.998	0.822	0.902	1.475	0.031
5	10_h	0.993	0.524	0.687	4.867	0.032
2	11_dr	0.997	0.781	0.877	3.216	0.033
2	11_g	0.995	0.677	0.807	2.365	0.031
3	11_h	0.992	0.415	0.586	7.862	0.028
5	12_dr	0.995	0.502	0.669	8.112	0.029
1	12_g	0.995	0.621	0.766	5.765	0.069
1	12_h	0.996	0.682	0.811	2.742	0.04
5	13_dr	0.996	0.581	0.735	3.307	0.036
1	13_g	0.998	0.803	0.891	1.283	0.042
5	13_h	0.998	0.803	0.891	1.981	0.03
3	14_dr	0.997	0.777	0.874	1.503	0.031
3	14_g	0.995	0.552	0.711	8.906	0.03
2	14_h	0.998	0.796	0.887	1.801	0.032
5	15_dr	0.998	0.799	0.889	2.356	0.032
2	15_g	0.993	0.521	0.685	11.63	0.03
5	15_h	0.996	0.642	0.782	2.577	0.031
-	Mean	0.988	0.618	0.742	24.345	0.033
-	Median	0.995	0.642	0.782	4.928	0.031
-	STD	0.042	0.192	0.191	91.129	0.008

Tab. A.18: Tabulka výsledků prahování na STUDY01 dataset

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
4	Study01_00001_002	0.965	0.736	0.848	2.542	0.006
1	Study01_00002_003	0.923	0.625	0.769	4.66	0.005
3	Study01_00003_001	0.956	0.679	0.809	6.476	0.006
1	Study01_00003_002	0.951	0.592	0.743	7.266	0.006
4	Study01_00003_003	0.96	0.691	0.817	6.168	0.006
1	Study01_00006_001	0.936	0.494	0.662	10.131	0.006
5	Study01_00007_001	0.925	0.532	0.695	10.883	0.005
2	Study01_00008_002	0.913	0.646	0.785	8.883	0.007
1	Study01_00008_003	0.906	0.645	0.784	9.272	0.006
3	Study01_00010_001	0.736	0.253	0.404	12.588	0.006
3	Study01_00010_002	0.779	0.297	0.458	15.107	0.006
5	Study01_00010_003	0.944	0.483	0.651	10.754	0.006
1	Study01_00016_002	0.934	0.55	0.71	11.144	0.005
5	Study01_00017_002	0.956	0.616	0.762	6.675	0.006
4	Study01_00019_002	0.924	0.324	0.489	13.929	0.006
1	Study01_00020_001	0.893	0.407	0.578	15.026	0.007
1	Study01_00022_001	0.951	0.564	0.721	7.842	0.028
3	Study01_00023_002	0.974	0.766	0.867	3.923	0.006
2	Study01_00025_003	0.935	0.639	0.78	8.441	0.007
4	Study01_00029_002	0.947	0.674	0.805	5.969	0.006
5	Study01_00030_002	0.874	0.292	0.451	18.655	0.006
4	Study01_00033_001	0.948	0.665	0.799	7.147	0.006
4	Study01_00033_002	0.955	0.693	0.818	6.063	0.007
2	Study01_00035_002	0.95	0.535	0.697	3.385	0.006
4	Study01_00037_001	0.955	0.623	0.768	7.135	0.006
5	Study01_00037_002	0.916	0.527	0.69	3.995	0.005
5	Study01_00037_003	0.803	0.31	0.474	19.325	0.005
5	Study01_00038_001	0.858	0.477	0.646	13.863	0.006
5	Study01_00038_002	0.887	0.497	0.664	12.532	0.005
2	Study01_00038_003	0.9	0.553	0.712	11.176	0.01
2	Study01_00043_002	0.915	0	0	128	0.009
2	Study01_00053_002	0.943	0.648	0.787	7.492	0.007
3	Study01_00054_002	0.841	0.324	0.489	17.737	0.006
2	Study01_00055_001	0.918	0.482	0.65	10.557	0.007
3	Study01_00055_002	0.915	0.476	0.645	11.115	0.006
1	Study01_00055_003	0.884	0.549	0.709	11.305	0.006
3	Study01_00068_001	0.96	0.741	0.851	3.23	0.006
2	Study01_00068_002	0.947	0.681	0.81	7.108	0.007
3	Study01_00068_003	0.958	0.728	0.842	5.47	0.006
4	Study01_00069_002	0.887	0.405	0.576	3.988	0.006
4	Study01_00070_002	0.941	0.565	0.722	9.198	0.006
1	Study01_00070_003	0.954	0.589	0.741	7.554	0.006
5	Study01_00071_001	0.927	0.489	0.657	9.989	0.005
2	Study01_00071_002	0.951	0.642	0.782	6.785	0.007
3	Study01_00071_003	0.835	0.383	0.554	10.977	0.007
-	Mean	0.916	0.535	0.682	11.81	0.007
-	Median	0.934	0.553	0.712	8.883	0.006
-	STD	0.051	0.157	0.159	18.178	0.003

Tab. A.19: Tabulka výsledků prahování na STUDY02 dataset

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
1	Study_02_00008_01_L	0.955	0.773	0.872	4.133	0.007
3	Study_02_00008_01_R	0.901	0.469	0.638	9.535	0.005
4	Study_02_00009_01_L	0.941	0.591	0.743	6.129	0.007
4	Study_02_00009_01_R	0.885	0.481	0.649	11.798	0.008
1	Study_02_00009_02_L	0.84	0.361	0.531	14.784	0.008
1	Study_02_00010_04_R	0.942	0.646	0.785	7.154	0.007
4	Study_02_00014_01_R	0.892	0	0	128	0.005
4	Study_02_00016_01_R	0.878	0	0	128	0.008
4	Study_02_00016_02_L	0.951	0.66	0.795	6.712	0.007
4	Study_02_00016_02_R	0.956	0.656	0.792	6.485	0.007
4	Study_02_00016_03_L	0.88	0	0	128	0.006
2	Study_02_00020_02_L	0.858	0.406	0.578	6.372	0.007
5	Study_02_00020_03_L	0.933	0.406	0.577	11.161	0.007
2	Study_02_00026_01_R	0.933	0.57	0.726	8.329	0.006
3	Study_02_00026_02_R	0.92	0.543	0.704	10.761	0.005
2	Study_02_00026_03_R	0.937	0.525	0.689	10.391	0.007
2	Study_02_00038_01_L	0.919	0.481	0.649	10.926	0.007
1	Study_02_00038_02_L	0.92	0.473	0.642	11.545	0.008
4	Study_02_00041_01_L	0.967	0.742	0.852	4.208	0.006
5	Study_02_00041_02_R	0.962	0.672	0.804	5.798	0.006
2	Study_02_00041_03_L	0.97	0.722	0.838	2.248	0.007
3	Study_02_00054_01_R	0.746	0.296	0.457	10.955	0.007
2	Study_02_00054_02_R	0.87	0.388	0.559	17.911	0.009
5	Study_02_00054_03_R	0.905	0.445	0.616	13.215	0.007
3	Study_02_00056_01_R	0.739	0.25	0.4	8.576	0.005
3	Study_02_00056_02_L	0.818	0.34	0.507	11.228	0.005
1	Study_02_00056_03_L	0.932	0.473	0.642	10.282	0.007
1	Study_02_00059_01_L	0.965	0.74	0.851	4.708	0.007
2	Study_02_00059_03_R	0.933	0.56	0.718	9.606	0.007
4	Study_02_00059_04_L	0.965	0.728	0.842	5.001	0.006
3	Study_02_00061_01_L	0.956	0.743	0.852	2.242	0.005
3	Study_02_00061_01_R	0.869	0.442	0.613	12.068	0.008
1	Study_02_00061_02_L	0.94	0.585	0.738	5.502	0.007
5	Study_02_00061_03_L	0.975	0.845	0.916	1.301	0.007
3	Study_02_00061_03_R	0.91	0.45	0.621	12.428	0.005
5	Study_02_00061_04_L	0.955	0.677	0.807	4.953	0.006
5	Study_02_00061_04_R	0.905	0.427	0.599	14.007	0.007
1	Study_02_00063_01_L	0.923	0.59	0.742	2.848	0.007
5	Study_02_00063_01_R	0.845	0.393	0.565	12.821	0.007
1	Study_02_00063_02_L	0.937	0.621	0.766	1.771	0.032
5	Study_02_00063_02_R	0.921	0.522	0.686	11.694	0.006
3	Study_02_00063_03_L	0.919	0.553	0.712	6.524	0.005
2	Study_02_00063_03_R	0.883	0.47	0.64	10.7	0.007
5	Study_02_00066_01_L	0.797	0.421	0.592	10.336	0.007
2	Study_02_00066_02_L	0.955	0.74	0.851	3.064	0.007
-	Mean	0.909	0.508	0.648	16.36	0.007
-	Median	0.921	0.522	0.686	9.606	0.007
-	STD	0.055	0.195	0.211	30.421	0.004

Tab. A.20: Tabulka výsledků Houghovy transformace na HRF datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
2	01_dr	1	0.968	0.984	0.686	0.19
4	01_g	0.998	0.872	0.932	0.971	0.204
3	01_h	0.998	0.898	0.946	2.481	0.142
5	02_dr	0.997	0.812	0.896	4.8	0.101
4	02_g	0.998	0.858	0.923	3.424	0.219
2	02_h	0.996	0.77	0.87	4.063	0.237
3	03_dr	0.998	0.842	0.914	4.088	0.118
1	03_g	0.997	0.805	0.892	4.384	0.084
2	03_h	0.997	0.843	0.915	2.158	0.166
4	04_dr	0.998	0.859	0.924	1.779	0.177
2	04_g	0.998	0.9	0.948	1.723	0.175
4	04_h	0.998	0.853	0.921	3.565	0.178
3	05_dr	0.994	0.623	0.767	8.201	0.114
3	05_g	0.996	0.777	0.874	5.333	0.112
3	05_h	0.997	0.818	0.9	4.133	0.13
1	06_dr	0.998	0.859	0.924	1.498	0.105
3	06_g	0.997	0.809	0.895	5.295	0.118
5	06_h	0.999	0.894	0.944	1.766	0.108
2	07_dr	0.996	0.748	0.856	3.857	0.194
4	07_g	0.999	0.943	0.971	1.397	0.229
5	07_h	0.973	0	0	89.766	0.097
1	08_dr	0.998	0.866	0.928	2.407	0.123
1	08_g	0.997	0.787	0.881	3.382	0.117
1	08_h	0.974	0	0	146.114	0.1
3	09_dr	0.974	0	0	144.546	0.113
1	09_g	0.999	0.883	0.938	2.366	0.107
5	09_h	0.995	0.706	0.827	7.312	0.097
5	10_dr	0.998	0.865	0.928	3.056	0.096
1	10_g	0.996	0.731	0.845	6.727	0.113
5	10_h	0.998	0.842	0.914	1.456	0.093
5	11_dr	0.998	0.851	0.92	2.533	0.097
5	11_g	0.973	0	0	267.073	0.119
4	11_h	0.994	0.615	0.762	10.612	0.215
2	12_dr	0.979	0	0	336.882	0.202
2	12_g	0.997	0.807	0.893	3.145	0.218
4	12_h	0.996	0.766	0.867	6.36	0.18
5	13_dr	0.995	0.624	0.769	4.877	0.102
1	13_g	0.979	0	0	69.358	0.134
4	13_h	0.999	0.898	0.946	1.27	0.207
3	14_dr	0.997	0.791	0.883	1.23	0.132
4	14_g	0.979	0	0	171.511	0.236
1	14_h	0.999	0.938	0.968	0.398	0.108
2	15_dr	0.999	0.89	0.942	2.278	0.209
3	15_g	0.998	0.848	0.918	4.064	0.112
2	15_h	0.974	0	0	350.33	0.156
-	Mean	0.994	0.677	0.741	37.881	0.146
-	Median	0.997	0.812	0.896	3.857	0.123
-	STD	0.009	0.327	0.352	86.357	0.048

Tab. A.21: Tabulka výsledků Houghovy transformace s morfologií na STUDY01 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
4	Study01_00001_002	0.991	0.917	0.957	0.38	0.034
4	Study01_00002_003	0.878	0.401	0.573	4.27	0.033
4	Study01_00003_001	0.961	0.706	0.827	5.704	0.041
3	Study01_00003_002	0.992	0.93	0.964	0.786	0.024
3	Study01_00003_003	0.994	0.946	0.972	0.425	0.023
4	Study01_00006_001	0.967	0.706	0.828	5.109	0.039
1	Study01_00007_001	0.947	0.598	0.748	6.537	0.039
1	Study01_00008_002	0.9	0.586	0.739	11.438	0.042
5	Study01_00008_003	0.876	0.452	0.622	3.729	0.018
1	Study01_00010_001	0.861	0.104	0.188	25.666	0.046
3	Study01_00010_002	0.944	0.618	0.764	6.341	0.023
4	Study01_00010_003	0.819	0.128	0.226	29.486	0.047
5	Study01_00016_002	0.985	0.859	0.924	2.292	0.02
1	Study01_00017_002	0.972	0.777	0.874	3.685	0.046
2	Study01_00019_002	0.988	0.879	0.936	1.084	0.077
2	Study01_00020_001	0.969	0.738	0.849	4.476	0.071
2	Study01_00022_001	0.987	0.878	0.935	1.99	0.081
5	Study01_00023_002	0.992	0.923	0.96	0.803	0.017
1	Study01_00025_003	0.991	0.94	0.969	0.723	0.047
1	Study01_00029_002	0.98	0.859	0.924	1.687	0.058
2	Study01_00030_002	0.98	0.846	0.916	1.209	0.093
2	Study01_00033_001	0.988	0.911	0.954	0.954	0.072
5	Study01_00033_002	0.971	0.774	0.872	3.665	0.021
3	Study01_00035_002	0.988	0.897	0.945	1.628	0.021
5	Study01_00037_001	0.994	0.944	0.971	0.694	0.021
4	Study01_00037_002	0.975	0.763	0.865	2.361	0.037
4	Study01_00037_003	0.811	0	0.001	38.362	0.034
3	Study01_00038_001	0.961	0.83	0.907	2.849	0.03
4	Study01_00038_002	0.96	0.78	0.876	4.311	0.043
3	Study01_00038_003	0.93	0.612	0.759	5.563	0.029
1	Study01_00043_002	0.854	0.068	0.127	27.774	0.063
3	Study01_00053_002	0.987	0.917	0.957	1.617	0.021
1	Study01_00054_002	0.993	0.922	0.959	0.273	0.047
2	Study01_00055_001	0.95	0.643	0.783	5.199	0.105
3	Study01_00055_002	0.986	0.91	0.953	1.356	0.026
2	Study01_00055_003	0.985	0.896	0.945	1.456	0.096
5	Study01_00068_001	0.983	0.886	0.94	1.845	0.021
4	Study01_00068_002	0.936	0.552	0.711	7.756	0.034
3	Study01_00068_003	0.97	0.802	0.89	3.545	0.022
2	Study01_00069_002	0.908	0.293	0.453	16.062	0.098
1	Study01_00070_002	0.983	0.83	0.907	1.84	0.043
2	Study01_00070_003	0.993	0.93	0.964	0.206	0.08
5	Study01_00071_001	0.984	0.858	0.923	2.441	0.021
5	Study01_00071_002	0.989	0.9	0.948	0.776	0.021
5	Study01_00071_003	0.694	0	0	48.848	0.021
-	Mean	0.95	0.705	0.785	6.649	0.043
-	Median	0.975	0.83	0.907	2.441	0.037
-	STD	0.062	0.277	0.268	10.64	0.025

Tab. A.22: Tabulka výsledků Houghovy transformace na STUDY01 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
3	Study01_00001_002	0.979	0.834	0.909	1.892	0.024
4	Study01_00002_003	0.917	0.595	0.746	7.249	0.038
2	Study01_00003_001	0.979	0.823	0.903	3.12	0.014
5	Study01_00003_002	0.981	0.831	0.908	2.966	0.055
1	Study01_00003_003	0.982	0.855	0.922	2.402	0.102
3	Study01_00006_001	0.976	0.794	0.885	3.668	0.033
4	Study01_00007_001	0.959	0.695	0.82	5.364	0.031
2	Study01_00008_002	0.894	0.491	0.659	3.509	0.028
5	Study01_00008_003	0.945	0.757	0.862	4.816	0.054
3	Study01_00010_001	0.894	0.334	0.501	16.025	0.029
2	Study01_00010_002	0.931	0.479	0.648	10.841	0.028
3	Study01_00010_003	0.925	0.433	0.605	11.958	0.035
5	Study01_00016_002	0.984	0.852	0.92	2.132	0.048
5	Study01_00017_002	0.991	0.911	0.953	0.8	0.06
3	Study01_00019_002	0.984	0.848	0.918	2.041	0.022
3	Study01_00020_001	0.982	0.833	0.909	2.135	0.022
3	Study01_00022_001	0.986	0.869	0.93	1.99	0.019
5	Study01_00023_002	0.992	0.926	0.962	0.894	0.033
1	Study01_00025_003	0.986	0.905	0.95	1.621	0.106
5	Study01_00029_002	0.971	0.802	0.89	3.837	0.05
1	Study01_00030_002	0.977	0.829	0.906	2.155	0.119
1	Study01_00033_001	0.978	0.85	0.919	2.391	0.102
3	Study01_00033_002	0.979	0.856	0.922	1.064	0.025
1	Study01_00035_002	0.992	0.926	0.962	0.828	0.113
4	Study01_00037_001	0.989	0.894	0.944	1.588	0.04
1	Study01_00037_002	0.992	0.929	0.963	0.364	0.101
2	Study01_00037_003	0.825	0.088	0.162	28.524	0.02
5	Study01_00038_001	0.911	0.535	0.697	7.154	0.071
2	Study01_00038_002	0.985	0.916	0.956	1.635	0.027
1	Study01_00038_003	0.93	0.61	0.758	7.205	0.131
4	Study01_00043_002	0.843	0.141	0.248	25.604	0.039
4	Study01_00053_002	0.987	0.917	0.957	1.617	0.028
4	Study01_00054_002	0.98	0.807	0.893	2.773	0.04
4	Study01_00055_001	0.981	0.863	0.927	1.523	0.041
1	Study01_00055_002	0.991	0.938	0.968	0.071	0.109
3	Study01_00055_003	0.955	0.691	0.817	4.673	0.034
4	Study01_00068_001	0.985	0.903	0.949	1.845	0.035
2	Study01_00068_002	0.989	0.926	0.962	0.494	0.02
5	Study01_00068_003	0.97	0.802	0.89	3.545	0.05
5	Study01_00069_002	0.951	0.608	0.756	5.339	0.066
2	Study01_00070_002	0.984	0.843	0.915	1.37	0.023
1	Study01_00070_003	0.991	0.906	0.951	1.098	0.118
4	Study01_00071_001	0.994	0.945	0.972	0.635	0.043
2	Study01_00071_002	0.98	0.845	0.916	2.413	0.027
2	Study01_00071_003	0.989	0.903	0.949	1.115	0.03
-	Mean	0.964	0.763	0.846	4.362	0.051
-	Median	0.98	0.843	0.915	2.155	0.038
-	STD	0.039	0.206	0.177	5.906	0.033

Tab. A.23: Tabulka výsledků Houghovy transformace na STUDY02 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
2	Study_02_00008_01_L	0.966	0.819	0.9	3.506	0.023
2	Study_02_00008_01_R	0.919	0.533	0.696	3.404	0.026
3	Study_02_00009_01_L	0.986	0.867	0.929	0.216	0.025
4	Study_02_00009_01_R	0.982	0.849	0.918	1.887	0.037
2	Study_02_00009_02_L	0.967	0.737	0.848	3.188	0.014
5	Study_02_00010_04_R	0.992	0.943	0.971	0.377	0.021
3	Study_02_00014_01_R	0.939	0.548	0.708	9.409	0.023
3	Study_02_00016_01_R	0.977	0.814	0.898	2.462	0.024
1	Study_02_00016_02_L	0.981	0.856	0.922	2.573	0.029
4	Study_02_00016_02_R	0.976	0.79	0.882	3.81	0.067
3	Study_02_00016_03_L	0.966	0.732	0.845	4.762	0.026
2	Study_02_00020_02_L	0.978	0.822	0.902	2.926	0.016
1	Study_02_00020_03_L	0.984	0.85	0.919	1.641	0.039
5	Study_02_00026_01_R	0.985	0.872	0.932	1.985	0.018
1	Study_02_00026_02_R	0.98	0.826	0.905	2.936	0.016
3	Study_02_00026_03_R	0.98	0.821	0.902	2.909	0.016
3	Study_02_00038_01_L	0.93	0.605	0.754	9.121	0.033
4	Study_02_00038_02_L	0.943	0.698	0.822	4.502	0.068
3	Study_02_00041_01_L	0.972	0.807	0.893	1.77	0.015
2	Study_02_00041_02_R	0.91	0.465	0.634	12.24	0.011
4	Study_02_00041_03_L	0.943	0.573	0.729	8.637	0.034
3	Study_02_00054_01_R	0.982	0.838	0.912	2.792	0.024
2	Study_02_00054_02_R	0.875	0.296	0.457	18.598	0.014
4	Study_02_00054_03_R	0.989	0.907	0.951	1.517	0.047
1	Study_02_00056_01_R	0.879	0.219	0.359	19.583	0.026
1	Study_02_00056_02_L	0.991	0.916	0.956	1.034	0.022
4	Study_02_00056_03_L	0.989	0.899	0.947	1.062	0.045
2	Study_02_00059_01_L	0.976	0.819	0.9	3.252	0.017
4	Study_02_00059_03_R	0.992	0.936	0.967	0.846	0.049
1	Study_02_00059_04_L	0.952	0.652	0.789	6.807	0.021
4	Study_02_00061_01_L	0.987	0.912	0.954	1.439	0.064
2	Study_02_00061_01_R	0.982	0.881	0.937	1.738	0.027
5	Study_02_00061_02_L	0.984	0.891	0.942	1.769	0.02
5	Study_02_00061_03_L	0.982	0.881	0.937	2.014	0.021
1	Study_02_00061_03_R	0.963	0.731	0.844	3.314	0.026
2	Study_02_00061_04_L	0.986	0.909	0.952	1.456	0.02
4	Study_02_00061_04_R	0.977	0.842	0.914	1.708	0.049
5	Study_02_00063_01_L	0.99	0.917	0.957	1.357	0.023
5	Study_02_00063_01_R	0.915	0.445	0.616	12.93	0.025
5	Study_02_00063_02_L	0.987	0.882	0.937	1.34	0.019
1	Study_02_00063_02_R	0.969	0.749	0.857	4.727	0.032
1	Study_02_00063_03_L	0.978	0.823	0.903	1.546	0.025
5	Study_02_00063_03_R	0.91	0.434	0.605	13.442	0.023
3	Study_02_00066_01_L	0.978	0.872	0.932	0.988	0.02
5	Study_02_00066_02_L	0.982	0.889	0.942	1.814	0.017
-	Mean	0.966	0.764	0.853	4.252	0.028
-	Median	0.978	0.823	0.903	2.573	0.024
-	STD	0.03	0.175	0.137	4.608	0.014

Tab. A.24: Tabulka výsledků Houghovy transformace s morfologií na HRF datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
2	01_dr	0.996	0.738	0.85	6.645	0.107
4	01_g	0.996	0.708	0.829	7.858	0.101
3	01_h	0.997	0.769	0.869	2.305	0.106
5	02_dr	0.992	0.558	0.716	13.879	0.116
4	02_g	0.993	0.577	0.731	12.53	0.104
2	02_h	0.997	0.819	0.9	2.391	0.274
3	03_dr	0.998	0.861	0.925	2.897	0.284
1	03_g	0.994	0.67	0.803	1.322	0.101
2	03_h	0.995	0.691	0.817	3.921	0.108
4	04_dr	0.998	0.859	0.924	1.204	0.323
2	04_g	0.994	0.602	0.752	11.535	0.105
4	04_h	0.996	0.726	0.841	4.084	0.112
3	05_dr	0.995	0.651	0.789	9.169	0.109
3	05_g	0.994	0.514	0.679	5.333	0.233
3	05_h	0.995	0.684	0.812	3.424	0.287
1	06_dr	0.995	0.648	0.786	9.889	0.12
3	06_g	0.996	0.739	0.85	6.425	0.106
5	06_h	0.994	0.61	0.758	11.275	0.105
2	07_dr	0.996	0.736	0.848	6.489	0.135
4	07_g	0.999	0.918	0.957	1.397	0.296
5	07_h	0.998	0.887	0.94	3.175	0.227
1	08_dr	0.999	0.892	0.943	2.469	0.25
1	08_g	0.996	0.704	0.826	7.861	0.105
1	08_h	0.995	0.667	0.8	8.966	0.106
3	09_dr	0.998	0.83	0.907	2.638	0.269
1	09_g	0.998	0.871	0.931	3.148	0.293
5	09_h	0.997	0.774	0.873	0.614	0.106
5	10_dr	0.998	0.812	0.896	3.204	0.254
1	10_g	0.997	0.788	0.882	2.73	0.291
5	10_h	0.994	0.638	0.779	10.214	0.105
5	11_dr	0.995	0.673	0.805	8.925	0.099
5	11_g	0.996	0.745	0.854	3.385	0.104
4	11_h	0.998	0.83	0.907	3.267	0.105
2	12_dr	0.997	0.701	0.824	6.942	0.285
2	12_g	0.98	0	0	177.964	0.311
4	12_h	0.998	0.884	0.938	2.953	0.261
5	13_dr	0.993	0.561	0.719	9.961	0.104
1	13_g	0.981	0	0	222.529	0.343
4	13_h	0.998	0.817	0.899	4.585	0.108
3	14_dr	0.997	0.77	0.87	5.849	0.114
4	14_g	0.983	0	0	141.209	0.318
1	14_h	0.999	0.952	0.975	1.118	0.249
2	15_dr	0.997	0.802	0.89	4.975	0.107
3	15_g	0.995	0.693	0.819	7.734	0.104
2	15_h	0.997	0.767	0.868	6.002	0.113
-	Mean	0.995	0.692	0.791	17.253	0.177
-	Median	0.996	0.736	0.848	5.333	0.113
-	STD	0.004	0.213	0.225	45.112	0.088

Tab. A.25: Tabulka výsledků Houghovy transformace s morfologií na STUDY02 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
3	Study_02_00008_01_L	0.949	0.719	0.837	6.192	0.018
3	Study_02_00008_01_R	0.939	0.501	0.667	10.111	0.021
4	Study_02_00009_01_L	0.977	0.793	0.885	1.168	0.036
4	Study_02_00009_01_R	0.984	0.873	0.932	2.07	0.028
5	Study_02_00009_02_L	0.981	0.822	0.902	2.877	0.022
2	Study_02_00010_04_R	0.993	0.944	0.971	0.377	0.022
1	Study_02_00014_01_R	0.958	0.65	0.788	6.122	0.029
2	Study_02_00016_01_R	0.97	0.751	0.858	2.462	0.021
5	Study_02_00016_02_L	0.976	0.804	0.891	2.968	0.026
3	Study_02_00016_02_R	0.98	0.82	0.901	2.81	0.02
5	Study_02_00016_03_L	0.974	0.793	0.885	3.168	0.022
5	Study_02_00020_02_L	0.992	0.923	0.96	0.903	0.025
3	Study_02_00020_03_L	0.991	0.91	0.953	0.639	0.017
3	Study_02_00026_01_R	0.965	0.697	0.821	5.531	0.017
4	Study_02_00026_02_R	0.879	0.292	0.452	18.612	0.031
4	Study_02_00026_03_R	0.982	0.843	0.915	2.166	0.033
4	Study_02_00038_01_L	0.794	0.1	0.182	30.892	0.049
5	Study_02_00038_02_L	0.876	0.31	0.474	18.63	0.031
1	Study_02_00041_01_L	0.98	0.845	0.916	2.552	0.028
1	Study_02_00041_02_R	0.937	0.51	0.675	9.862	0.032
2	Study_02_00041_03_L	0.983	0.863	0.926	1.203	0.023
5	Study_02_00054_01_R	0.977	0.799	0.888	3.341	0.019
5	Study_02_00054_02_R	0.981	0.836	0.911	2.545	0.019
2	Study_02_00054_03_R	0.97	0.747	0.855	3.969	0.019
4	Study_02_00056_01_R	0.907	0.407	0.579	13.335	0.04
1	Study_02_00056_02_L	0.982	0.828	0.906	2.013	0.024
1	Study_02_00056_03_L	0.981	0.823	0.903	1.783	0.049
3	Study_02_00059_01_L	0.969	0.738	0.849	3.906	0.017
3	Study_02_00059_03_R	0.967	0.733	0.846	3.788	0.017
2	Study_02_00059_04_L	0.955	0.654	0.791	5.899	0.022
3	Study_02_00061_01_L	0.989	0.925	0.961	1.165	0.019
5	Study_02_00061_01_R	0.981	0.868	0.929	2.449	0.027
1	Study_02_00061_02_L	0.983	0.893	0.943	1.067	0.033
5	Study_02_00061_03_L	0.978	0.855	0.922	2.433	0.023
4	Study_02_00061_03_R	0.968	0.773	0.872	3.523	0.034
1	Study_02_00061_04_L	0.95	0.642	0.782	5.062	0.03
1	Study_02_00061_04_R	0.959	0.746	0.855	4.504	0.026
4	Study_02_00063_01_L	0.985	0.873	0.932	2.241	0.035
2	Study_02_00063_01_R	0.967	0.718	0.836	5.028	0.023
3	Study_02_00063_02_L	0.972	0.745	0.854	4.502	0.017
2	Study_02_00063_02_R	0.962	0.69	0.817	5.725	0.026
4	Study_02_00063_03_L	0.982	0.848	0.917	2.111	0.04
1	Study_02_00063_03_R	0.963	0.7	0.823	4.973	0.038
2	Study_02_00066_01_L	0.941	0.609	0.757	4.012	0.019
2	Study_02_00066_02_L	0.932	0.561	0.719	8.197	0.019
-	Mean	0.961	0.728	0.828	5.086	0.026
-	Median	0.972	0.773	0.872	3.341	0.024
-	STD	0.036	0.179	0.153	5.644	0.008

Tab. A.26: Tabulka výsledků narůstání oblasti na HRF datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
2	01_dr	0.996	0.738	0.85	6.645	0.107
4	01_g	0.996	0.708	0.829	7.858	0.101
3	01_h	0.997	0.769	0.869	2.305	0.106
5	02_dr	0.992	0.558	0.716	13.879	0.116
4	02_g	0.993	0.577	0.731	12.53	0.104
2	02_h	0.997	0.819	0.9	2.391	0.274
3	03_dr	0.998	0.861	0.925	2.897	0.284
1	03_g	0.994	0.67	0.803	1.322	0.101
2	03_h	0.995	0.691	0.817	3.921	0.108
4	04_dr	0.998	0.859	0.924	1.204	0.323
2	04_g	0.994	0.602	0.752	11.535	0.105
4	04_h	0.996	0.726	0.841	4.084	0.112
3	05_dr	0.995	0.651	0.789	9.169	0.109
3	05_g	0.994	0.514	0.679	5.333	0.233
3	05_h	0.995	0.684	0.812	3.424	0.287
1	06_dr	0.995	0.648	0.786	9.889	0.12
3	06_g	0.996	0.739	0.85	6.425	0.106
5	06_h	0.994	0.61	0.758	11.275	0.105
2	07_dr	0.996	0.736	0.848	6.489	0.135
4	07_g	0.999	0.918	0.957	1.397	0.296
5	07_h	0.998	0.887	0.94	3.175	0.227
1	08_dr	0.999	0.892	0.943	2.469	0.25
1	08_g	0.996	0.704	0.826	7.861	0.105
1	08_h	0.995	0.667	0.8	8.966	0.106
3	09_dr	0.998	0.83	0.907	2.638	0.269
1	09_g	0.998	0.871	0.931	3.148	0.293
5	09_h	0.997	0.774	0.873	0.614	0.106
5	10_dr	0.998	0.812	0.896	3.204	0.254
1	10_g	0.997	0.788	0.882	2.73	0.291
5	10_h	0.994	0.638	0.779	10.214	0.105
5	11_dr	0.995	0.673	0.805	8.925	0.099
5	11_g	0.996	0.745	0.854	3.385	0.104
4	11_h	0.998	0.83	0.907	3.267	0.105
2	12_dr	0.997	0.701	0.824	6.942	0.285
2	12_g	0.98	0	0	177.964	0.311
4	12_h	0.998	0.884	0.938	2.953	0.261
5	13_dr	0.993	0.561	0.719	9.961	0.104
1	13_g	0.981	0	0	222.529	0.343
4	13_h	0.998	0.817	0.899	4.585	0.108
3	14_dr	0.997	0.77	0.87	5.849	0.114
4	14_g	0.983	0	0	141.209	0.318
1	14_h	0.999	0.952	0.975	1.118	0.249
2	15_dr	0.997	0.802	0.89	4.975	0.107
3	15_g	0.995	0.693	0.819	7.734	0.104
2	15_h	0.997	0.767	0.868	6.002	0.113
-	Mean	0.995	0.692	0.791	17.253	0.177
-	Median	0.996	0.736	0.848	5.333	0.113
-	STD	0.004	0.213	0.225	45.112	0.088

Tab. A.27: Tabulka výsledků narůstání oblasti na STUDY01 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
1	Study01_00001_002	0.92	0.408	0.58	13.053	0.006
2	Study01_00002_003	0.885	0.437	0.608	9.504	0.008
1	Study01_00003_001	0.933	0.454	0.624	9.84	0.006
2	Study01_00003_002	0.935	0.445	0.616	8.949	0.006
5	Study01_00003_003	0.934	0.428	0.6	8.784	0.005
1	Study01_00006_001	0.921	0.349	0.517	12.916	0.006
2	Study01_00007_001	0.848	0.302	0.464	20.884	0.009
3	Study01_00008_002	0.9	0.561	0.719	10.922	0.008
5	Study01_00008_003	0.878	0.473	0.642	7.803	0.006
2	Study01_00010_001	0.592	0.18	0.305	13.176	0.016
5	Study01_00010_002	0.736	0.236	0.382	22.159	0.009
1	Study01_00010_003	0.943	0.53	0.693	11.909	0.017
3	Study01_00016_002	0.94	0.442	0.613	7.838	0.006
4	Study01_00017_002	0.898	0.33	0.496	12.726	0.006
4	Study01_00019_002	0.926	0.265	0.419	13.079	0.005
4	Study01_00020_001	0.469	0.146	0.255	22.653	0.016
2	Study01_00022_001	0.942	0.474	0.644	8.567	0.006
4	Study01_00023_002	0.945	0.476	0.645	5.894	0.005
4	Study01_00025_003	0.912	0.42	0.592	11.304	0.006
3	Study01_00029_002	0.931	0.543	0.704	5.971	0.005
5	Study01_00030_002	0.893	0.236	0.382	15.578	0.005
5	Study01_00033_001	0.911	0.357	0.526	12.947	0.005
5	Study01_00033_002	0.912	0.342	0.51	12.569	0.005
3	Study01_00035_002	0.915	0.207	0.343	9.193	0.004
5	Study01_00037_001	0.94	0.437	0.608	7.871	0.005
3	Study01_00037_002	0.971	0.752	0.858	1.862	0.008
1	Study01_00037_003	0.955	0.653	0.79	4.733	0.007
3	Study01_00038_001	0.788	0.404	0.575	16.839	0.008
1	Study01_00038_002	0.895	0.441	0.612	11.36	0.008
5	Study01_00038_003	0.853	0.425	0.596	18.346	0.007
2	Study01_00043_002	0.913	0.247	0.396	16.994	0.007
4	Study01_00053_002	0.914	0.429	0.6	8.729	0.006
4	Study01_00054_002	0.786	0.217	0.356	25.908	0.007
3	Study01_00055_001	0.901	0.324	0.489	11.61	0.004
1	Study01_00055_002	0.889	0.279	0.436	14.455	0.007
4	Study01_00055_003	0.89	0.256	0.408	12.979	0.005
1	Study01_00068_001	0.911	0.428	0.6	9.106	0.006
4	Study01_00068_002	0.91	0.396	0.567	11.224	0.005
3	Study01_00068_003	0.952	0.649	0.787	6.141	0.005
2	Study01_00069_002	0.945	0.335	0.501	9.134	0.005
3	Study01_00070_002	0.949	0.558	0.716	7.761	0.005
1	Study01_00070_003	0.938	0.427	0.598	10.38	0.006
5	Study01_00071_001	0.847	0.181	0.306	18.594	0.006
2	Study01_00071_002	0.847	0.269	0.424	14.407	0.009
2	Study01_00071_003	0.837	0.316	0.481	16.196	0.01
-	Mean	0.886	0.388	0.546	12.063	0.007
-	Median	0.912	0.408	0.58	11.36	0.006
-	STD	0.092	0.133	0.138	4.97	0.003

Tab. A.28: Tabulka výsledků narůstání oblasti na STUDY02 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
4	Study_02_00008_01_L	0.926	0.603	0.752	9.479	0.006
5	Study_02_00008_01_R	0.944	0.575	0.73	9.161	0.006
4	Study_02_00009_01_L	0.564	0.169	0.29	26.538	0.01
1	Study_02_00009_01_R	0.767	0.337	0.504	16.716	0.011
5	Study_02_00009_02_L	0.95	0.497	0.664	7.662	0.005
2	Study_02_00010_04_R	0.928	0.445	0.616	2.326	0.005
4	Study_02_00014_01_R	0.925	0.336	0.503	10.727	0.005
2	Study_02_00016_01_R	0.926	0.407	0.579	7.885	0.008
1	Study_02_00016_02_L	0.888	0.361	0.531	17.62	0.008
5	Study_02_00016_02_R	0.937	0.433	0.605	7.335	0.005
3	Study_02_00016_03_L	0.921	0.389	0.56	10.32	0.005
5	Study_02_00020_02_L	0.609	0.21	0.347	8.992	0.013
2	Study_02_00020_03_L	0.921	0.174	0.297	12.7	0.005
5	Study_02_00026_01_R	0.933	0.382	0.553	8.809	0.005
1	Study_02_00026_02_R	0.599	0.215	0.354	17.602	0.024
4	Study_02_00026_03_R	0.937	0.396	0.567	7.782	0.005
4	Study_02_00038_01_L	0.892	0.397	0.568	15.352	0.006
1	Study_02_00038_02_L	0.903	0.428	0.6	14.44	0.007
2	Study_02_00041_01_L	0.924	0.36	0.529	3.677	0.005
3	Study_02_00041_02_R	0.942	0.425	0.597	4.951	0.004
3	Study_02_00041_03_L	0.937	0.411	0.583	3.098	0.004
2	Study_02_00054_01_R	0.936	0.454	0.625	8.542	0.006
1	Study_02_00054_02_R	0.937	0.518	0.682	9.926	0.008
4	Study_02_00054_03_R	0.932	0.472	0.641	9.84	0.005
3	Study_02_00056_01_R	0.521	0.153	0.266	11.068	0.011
5	Study_02_00056_02_L	0.607	0.208	0.344	9.101	0.013
1	Study_02_00056_03_L	0.884	0.295	0.455	19.981	0.008
3	Study_02_00059_01_L	0.919	0.315	0.479	8.662	0.005
5	Study_02_00059_03_R	0.921	0.366	0.536	10.849	0.005
3	Study_02_00059_04_L	0.921	0.375	0.545	7.824	0.005
5	Study_02_00061_01_L	0.904	0.35	0.518	10.993	0.005
5	Study_02_00061_01_R	0.885	0.453	0.623	17.272	0.007
2	Study_02_00061_02_L	0.894	0.266	0.42	11.381	0.005
3	Study_02_00061_03_L	0.895	0.283	0.441	12.185	0.004
4	Study_02_00061_03_R	0.908	0.373	0.543	12.26	0.005
3	Study_02_00061_04_L	0.898	0.288	0.447	12.765	0.004
4	Study_02_00061_04_R	0.896	0.285	0.444	16.056	0.005
2	Study_02_00063_01_L	0.961	0.67	0.802	3.505	0.006
3	Study_02_00063_01_R	0.925	0.375	0.546	11.644	0.005
4	Study_02_00063_02_L	0.959	0.658	0.794	4.363	0.006
1	Study_02_00063_02_R	0.917	0.354	0.522	12.609	0.006
2	Study_02_00063_03_L	0.96	0.656	0.793	4.144	0.006
2	Study_02_00063_03_R	0.92	0.355	0.524	11.358	0.005
1	Study_02_00066_01_L	0.635	0.292	0.452	12.43	0.016
1	Study_02_00066_02_L	0.872	0.481	0.65	7.792	0.009
-	Mean	0.873	0.383	0.543	10.66	0.007
-	Median	0.921	0.375	0.545	10.32	0.005
-	STD	0.117	0.125	0.13	4.814	0.004

Tab. A.29: Tabulka výsledků netopýřího algoritmu na HRF datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
2	01_dr	0.996	0.738	0.85	6.645	0.107
4	01_g	0.996	0.708	0.829	7.858	0.101
3	01_h	0.997	0.769	0.869	2.305	0.106
5	02_dr	0.992	0.558	0.716	13.879	0.116
4	02_g	0.993	0.577	0.731	12.53	0.104
2	02_h	0.997	0.819	0.9	2.391	0.274
3	03_dr	0.998	0.861	0.925	2.897	0.284
1	03_g	0.994	0.67	0.803	1.322	0.101
2	03_h	0.995	0.691	0.817	3.921	0.108
4	04_dr	0.998	0.859	0.924	1.204	0.323
2	04_g	0.994	0.602	0.752	11.535	0.105
4	04_h	0.996	0.726	0.841	4.084	0.112
3	05_dr	0.995	0.651	0.789	9.169	0.109
3	05_g	0.994	0.514	0.679	5.333	0.233
3	05_h	0.995	0.684	0.812	3.424	0.287
1	06_dr	0.995	0.648	0.786	9.889	0.12
3	06_g	0.996	0.739	0.85	6.425	0.106
5	06_h	0.994	0.61	0.758	11.275	0.105
2	07_dr	0.996	0.736	0.848	6.489	0.135
4	07_g	0.999	0.918	0.957	1.397	0.296
5	07_h	0.998	0.887	0.94	3.175	0.227
1	08_dr	0.999	0.892	0.943	2.469	0.25
1	08_g	0.996	0.704	0.826	7.861	0.105
1	08_h	0.995	0.667	0.8	8.966	0.106
3	09_dr	0.998	0.83	0.907	2.638	0.269
1	09_g	0.998	0.871	0.931	3.148	0.293
5	09_h	0.997	0.774	0.873	0.614	0.106
5	10_dr	0.998	0.812	0.896	3.204	0.254
1	10_g	0.997	0.788	0.882	2.73	0.291
5	10_h	0.994	0.638	0.779	10.214	0.105
5	11_dr	0.995	0.673	0.805	8.925	0.099
5	11_g	0.996	0.745	0.854	3.385	0.104
4	11_h	0.998	0.83	0.907	3.267	0.105
2	12_dr	0.997	0.701	0.824	6.942	0.285
2	12_g	0.98	0	0	177.964	0.311
4	12_h	0.998	0.884	0.938	2.953	0.261
5	13_dr	0.993	0.561	0.719	9.961	0.104
1	13_g	0.981	0	0	222.529	0.343
4	13_h	0.998	0.817	0.899	4.585	0.108
3	14_dr	0.997	0.77	0.87	5.849	0.114
4	14_g	0.983	0	0	141.209	0.318
1	14_h	0.999	0.952	0.975	1.118	0.249
2	15_dr	0.997	0.802	0.89	4.975	0.107
3	15_g	0.995	0.693	0.819	7.734	0.104
2	15_h	0.997	0.767	0.868	6.002	0.113
-	Mean	0.995	0.692	0.791	17.253	0.177
-	Median	0.996	0.736	0.848	5.333	0.113
-	STD	0.004	0.213	0.225	45.112	0.088

Tab. A.30: Tabulka výsledků netopýřího algoritmu na STUDY01 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
4	Study01_00001_002	0.931	0.384	0.555	9.324	0.287
1	Study01_00002_003	0.876	0.393	0.565	7.777	0.304
2	Study01_00003_001	0.934	0.438	0.61	8.385	0.285
5	Study01_00003_002	0.934	0.443	0.614	9.049	0.295
3	Study01_00003_003	0.937	0.466	0.636	8.83	0.279
4	Study01_00006_001	0.92	0.279	0.436	11.454	0.293
3	Study01_00007_001	0.541	0.217	0.356	13.645	0.281
2	Study01_00008_002	0.901	0.567	0.724	10.92	0.274
5	Study01_00008_003	0.901	0.582	0.736	9.315	0.293
5	Study01_00010_001	0.605	0.184	0.311	13.999	0.336
4	Study01_00010_002	0.653	0.212	0.349	16.934	0.335
5	Study01_00010_003	0.951	0.494	0.661	9.971	0.268
3	Study01_00016_002	0.941	0.438	0.609	7.522	0.31
3	Study01_00017_002	0.826	0.308	0.471	17.241	0.323
5	Study01_00019_002	0.933	0.327	0.493	10.566	0.324
4	Study01_00020_001	0.931	0.352	0.521	11.186	0.271
1	Study01_00022_001	0.942	0.465	0.634	8.225	0.316
5	Study01_00023_002	0.945	0.472	0.641	5.874	0.294
1	Study01_00025_003	0.912	0.417	0.589	10.561	0.269
1	Study01_00029_002	0.909	0.378	0.549	9.632	0.307
1	Study01_00030_002	0.925	0.568	0.724	10.235	0.311
3	Study01_00033_001	0.912	0.371	0.542	12.888	0.301
3	Study01_00033_002	0.913	0.36	0.529	12.589	0.303
2	Study01_00035_002	0.41	0.154	0.268	14.387	0.316
1	Study01_00037_001	0.942	0.439	0.611	7.375	0.35
5	Study01_00037_002	0.963	0.664	0.798	3.454	0.286
1	Study01_00037_003	0.933	0.382	0.553	7.74	0.27
2	Study01_00038_001	0.868	0.437	0.608	15.381	0.31
2	Study01_00038_002	0.894	0.435	0.607	11.582	0.277
5	Study01_00038_003	0.899	0.456	0.626	10.609	0.265
4	Study01_00043_002	0.583	0.17	0.29	24.239	0.343
4	Study01_00053_002	0.9	0.309	0.472	6.122	0.286
2	Study01_00054_002	0.784	0.221	0.362	25.921	0.274
1	Study01_00055_001	0.531	0.229	0.373	7.349	0.352
2	Study01_00055_002	0.888	0.265	0.419	14.612	0.353
3	Study01_00055_003	0.743	0	0	39.821	0.324
2	Study01_00068_001	0.903	0.382	0.553	9.883	0.324
1	Study01_00068_002	0.926	0.484	0.652	8.689	0.266
5	Study01_00068_003	0.935	0.513	0.678	8.925	0.301
3	Study01_00069_002	0.47	0.126	0.224	19.697	0.274
4	Study01_00070_002	0.947	0.448	0.619	8.004	0.261
3	Study01_00070_003	0.96	0.625	0.769	6.47	0.331
4	Study01_00071_001	0.927	0.371	0.541	9.274	0.266
2	Study01_00071_002	0.844	0.26	0.413	14.508	0.298
4	Study01_00071_003	0.931	0.405	0.576	8.444	0.302
-	Mean	0.852	0.375	0.53	11.747	0.3
-	Median	0.912	0.384	0.555	9.971	0.298
-	STD	0.144	0.139	0.159	6.181	0.026

Tab. A.31: Tabulka výsledků netopýřího algoritmu na STUDY02 datasetu

Set	Název	Přesnost[-]	Překryv[-]	DICE[-]	Vzdálenost centroidů[-]	Čas[s]
4	Study_02_00008_01_L	0.927	0.573	0.729	4.07	0.333
2	Study_02_00008_01_R	0.941	0.593	0.745	8.602	0.309
2	Study_02_00009_01_L	0.565	0.17	0.29	26.545	0.311
4	Study_02_00009_01_R	0.825	0.377	0.547	18.194	0.328
3	Study_02_00009_02_L	0.589	0.182	0.309	28.923	0.288
2	Study_02_00010_04_R	0.797	0.077	0.142	41.665	0.279
5	Study_02_00014_01_R	0.67	0.087	0.16	41.646	0.343
2	Study_02_00016_01_R	0.929	0.428	0.6	7.635	0.311
1	Study_02_00016_02_L	0.921	0.394	0.565	10.045	0.314
3	Study_02_00016_02_R	0.939	0.456	0.626	7.687	0.311
5	Study_02_00016_03_L	0.921	0.394	0.565	10.687	0.326
4	Study_02_00020_02_L	0.636	0.222	0.364	9.932	0.281
1	Study_02_00020_03_L	0.926	0.367	0.537	12.541	0.338
3	Study_02_00026_01_R	0.932	0.355	0.524	7.565	0.312
5	Study_02_00026_02_R	0.604	0.217	0.357	18.334	0.33
4	Study_02_00026_03_R	0.932	0.335	0.502	7.811	0.321
1	Study_02_00038_01_L	0.891	0.386	0.557	15.429	0.293
5	Study_02_00038_02_L	0.903	0.436	0.607	14.398	0.316
5	Study_02_00041_01_L	0.917	0.299	0.46	2.294	0.291
3	Study_02_00041_02_R	0.939	0.398	0.569	4.132	0.346
1	Study_02_00041_03_L	0.929	0.337	0.504	1.248	0.32
2	Study_02_00054_01_R	0.599	0.21	0.348	10.277	0.276
2	Study_02_00054_02_R	0.941	0.487	0.655	8.692	0.303
2	Study_02_00054_03_R	0.93	0.424	0.595	9.835	0.294
4	Study_02_00056_01_R	0.396	0.126	0.223	17.234	0.304
1	Study_02_00056_02_L	0.597	0.204	0.338	9.632	0.286
5	Study_02_00056_03_L	0.468	0.168	0.287	11.569	0.331
4	Study_02_00059_01_L	0.926	0.365	0.535	6.541	0.266
3	Study_02_00059_03_R	0.928	0.418	0.59	8.716	0.29
1	Study_02_00059_04_L	0.923	0.378	0.549	6.502	0.292
5	Study_02_00061_01_L	0.9	0.295	0.455	10.946	0.324
2	Study_02_00061_01_R	0.885	0.465	0.635	17.447	0.267
5	Study_02_00061_02_L	0.893	0.259	0.412	11.7	0.299
4	Study_02_00061_03_L	0.895	0.277	0.434	11.196	0.309
1	Study_02_00061_03_R	0.909	0.349	0.517	11.258	0.332
2	Study_02_00061_04_L	0.9	0.289	0.449	12.02	0.286
1	Study_02_00061_04_R	0.897	0.291	0.451	16.034	0.282
3	Study_02_00063_01_L	0.968	0.733	0.846	2.102	0.276
3	Study_02_00063_01_R	0.925	0.37	0.54	11.527	0.343
4	Study_02_00063_02_L	0.965	0.7	0.824	3.768	0.312
4	Study_02_00063_02_R	0.919	0.354	0.523	12.068	0.296
3	Study_02_00063_03_L	0.966	0.708	0.829	3.368	0.301
5	Study_02_00063_03_R	0.92	0.355	0.523	11.599	0.287
3	Study_02_00066_01_L	0.644	0.297	0.459	12.876	0.286
1	Study_02_00066_02_L	0.927	0.539	0.701	7.43	0.285
-	Mean	0.841	0.359	0.511	12.083	0.305
-	Median	0.919	0.355	0.524	10.687	0.304
-	STD	0.151	0.151	0.162	8.55	0.022