



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

REGISTRACE OBRAZOVÝCH DAT SÍTNICE POMOCÍ EVOLUČNÍCH ALGORITMŮ

REGISTRATION OF RETINAL IMAGE DATA USING EVOLUTIONARY ALGORITHMS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Šimon Matoušek

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jan Odstrčilík, Ph.D.

BRNO 2024

Diplomová práce

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

Ústav biomedicínského inženýrství

Student: Bc. Šimon Matoušek

ID: 211676

Ročník: 2

Akademický rok: 2023/24

NÁZEV TÉMATU:

Registrace obrazových dat sítnice pomocí evolučních algoritmů

POKyny PRO VYPRACOVÁNÍ:

1) Seznamte se s obecnými principy evolučních výpočetních technik a zaměřte se na jejich využití v oblasti optimalizace. 2) Proveďte literární rešerši používaných evolučních metod a jejich využití zejména pro registraci obrazu. 3) Navrhněte a implementujte vybrané metody založené na použití evolučních algoritmů pro účely registrace zadaných retinálních obrazových dat. 4) Implementované metody otestujte na dostupných retinálních datech a srovnajte s jinými publikovanými přístupy. 5) Proveďte diskusi dosažených výsledků a zhodnoťte účinnost a využitelnost aplikovaných řešení.

DOPORUČENÁ LITERATURA:

[1] SIMON, D. Evolutionary optimization algorithms. Wiley, 2013, New Jersey, ISBN 978-0-470-93741-9.

[2] BIERLAIRE, M. Optimization: Principles and Algorithms. CRC Press, 2015, ISBN 978-1-4822-0345-5.

Termín zadání: 5.2.2024

Termín odevzdání: 9.8.2024

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

prof. Ing. Valentine Provazník, Ph.D.

předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Tato diplomová práce se věnuje problematice registrace snímků oční sítnice. Nejprve je v úvodní kapitole formou literární rešerše shrnuta teorie týkající se evolučních algoritmů a jejich praktického využití, poté jsou popsány různé přístupy registrace obrazu sítnice a transformace obrazu. Zároveň je stručně představena anatomie oka jakožto orgánu klíčového pro vnímání zrakových vjemů. Prostřednictvím programového prostředí MATLAB je v praktické části práce realizována metoda registrace statických a poté i dynamických retinálních snímků, závěrem jsou porovnány výsledky jednotlivých přístupů.

KLÍČOVÁ SLOVA

registrace obrazu, optimalizace, evoluční algoritmus, sítnice, oko, transformace obrazu

ABSTRACT

This thesis deals with the registration of retinal images. Firstly, the introductory chapter summarizes the theory related to evolutionary algorithms and their practical application in the form of a literature search, then different approaches of retinal image registration and image transformation are described. At the same time, the anatomy of the eye as a key organ for visual perception is briefly introduced. In the practical part of the thesis, the method of registration of static and then dynamic retinal images is implemented using MATLAB software environment, and finally the results of different approaches are compared.

KEYWORDS

image registration, optimization, evolutionary algorithm, retina, eye, image transformation

MATOUŠEK, Šimon. *Registrace snímků sítnice pomocí evolučních algoritmů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024, 57 s. Diplomová práce. Vedoucí práce: Ing. Jan Odstřčilík, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora:	Bc. Šimon Matoušek
VUT ID autora:	211676
Typ práce:	Diplomová práce
Akademický rok:	2023/24
Téma závěrečné práce:	Registrace snímků sítnice pomocí evolučních algoritmů

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 vedoucímu diplomové práce panu Ing. Janu Odstrčilíkovi, Ph.D. za odborné vedení, konzultace a podnětné návrhy k práci. Pevnou a spolehlivou oporu nejen při studiu pro mě představuje moje nejbližší rodina, bez jejíhož přispění by tato práce nemohla vzniknout.

Obsah

Úvod	10
1 Genetické a evoluční algoritmy	11
1.1 Historie vývoje evolučních algoritmů	11
1.2 Evoluční algoritmy	11
1.3 Princip genetických algoritmů	12
1.3.1 Selektce	12
1.3.2 Křížení	14
1.3.3 Mutace	15
1.4 Rojové algoritmy	15
1.4.1 Algoritmus mravenčí kolonie	15
1.4.2 Světluškový algoritmus	16
1.4.3 Algoritmus optimalizace hejnem částic	17
2 Registrace obrazů	19
2.1 Princip registrace obrazu	19
2.2 Geometrické transformace obrazů	19
2.2.1 Rigidní transformace	19
2.2.2 Pružné transformace	21
2.3 Použité metriky	21
2.3.1 Podobnostní kritéria	22
2.3.2 Vzdálenostní kritérium	22
2.3.3 Evaluační kritéria	23
2.4 Využití evolučních algoritmů při registraci obrazových dat	24
3 Testovací sada dat	25
3.1 Přístrojové vybavení	25
3.1.1 Fundus kamera	25
3.1.2 Videooftalmoskop	27
4 Praktická aplikace evolučních algoritmů pro registraci obrazů	29
4.1 Genetický algoritmus	29
4.1.1 Popis implementovaného algoritmu	29
4.1.2 Návod k aplikaci genetického algoritmu	30
4.2 Algoritmus mravenčí kolonie	32
4.2.1 Popis implementovaného algoritmu	32
4.2.2 Návod k aplikaci ACO algoritmu	32
4.3 Světluškový algoritmus	34

4.3.1	Popis implementovaného algoritmu	34
4.3.2	Návod k aplikaci světluškového algoritmu	34
4.4	Algoritmus PSO	35
4.4.1	Popis implementovaného algoritmu	35
4.4.2	Návod k aplikaci PSO algoritmu	36
5	Výsledky registrace obrazů	37
5.1	Genetický algoritmus	37
5.2	Algoritmus mravenčí kolonie	41
5.3	Světluškový algoritmus	44
5.4	Algoritmus PSO	47
5.5	Srovnání získaných výsledků s jinými studii	50
	Závěr	51
	Literatura	53

Seznam obrázků

1.1	Schematické znázornění pojmů gen, chromozom, populace.	13
1.2	Jednobodové křížení.	14
1.3	Mravenčí algoritmus - volba trasy před a po několika iteracích.	16
2.1	Schéma procesu registrace obrazů.	20
2.2	Rigidní transformace.	21
3.1	Ukázka statického snímku sítnice oka - záznam č.6.	26
3.2	Ukázka zprůměrovaného snímku sítnice oka - záznam č.6.	26
3.3	Fundus kamera.	27
3.4	Videooftalmoskop.	28
4.1	Ukázka testovacího obrazce - trojúhelníku.	29
4.2	Ukázka testovacího obrazce - rovnoběžníku.	30
4.3	Blokové schéma registrace statických obrazů.	31
4.4	Blokové schéma registrace dynamických obrazů - mravenčí algoritmus.	33
4.5	Blokové schéma registrace dynamických obrazů - světluškový algoritmus.	35
4.6	Blokové schéma registrace dynamických obrazů - PSO algoritmus.	36
5.1	Ukázka registrace fixního a modifikovaného obrazu - záznam č.4.	38
5.2	Ukázka registrace fixního a transformovaného obrazu - záznam č.2.	38
5.3	Šachovnicové zobrazení - záznam č.1.	39
5.4	Šachovnicové zobrazení - záznam č.2.	39
5.5	Šachovnicové zobrazení - záznam č.3.	42
5.6	Šachovnicové zobrazení - záznam č.9.	42
5.7	Šachovnicové zobrazení - záznam č.3.	43
5.8	Šachovnicové zobrazení - záznam č.9.	43
5.9	Šachovnicové zobrazení - záznam č.8.	45
5.10	Šachovnicové zobrazení - záznam č.2.	45
5.11	Šachovnicové zobrazení - záznam č.8.	46
5.12	Šachovnicové zobrazení - záznam č.2.	46
5.13	Šachovnicové zobrazení - záznam č.7.	48
5.14	Šachovnicové zobrazení - záznam č.6.	48
5.15	Šachovnicové zobrazení - záznam č.7.	49
5.16	Šachovnicové zobrazení - záznam č.6.	49

Úvod

Registrace obrazu představuje možnost, jak provést zpracování obrazů, v daném případě zarovnání dvou či vícero obrazů. Hlavní význam registrace spočívá v možnosti vzájemně tyto obrazy porovnat a podrobněji je analyzovat. Praktické využití registrace nalézá například při zpracování medicínských obrazů nasnímaných různými modalitami - počítačovou tomografií (CT), magnetickou rezonancí (MRI) či pozitronovou emisní tomografií (PET). Umožňuje tak pozorovat struktury jednotlivých tkání, stejně tak například vývoj onemocnění v těle pacienta. Registrace obrazů nalézá využití i v nemedicínských aplikacích, například při porovnávání satelitních snímků povrchu Země nasnímaných v různých letech, což umožňuje monitorovat změny v krajině vzniklé například lidskou činností. [9]

Principem samotné registrace je nalezení vhodné prostorové transformace obrazových dat. Transformace mohou být lineární, ale také nelineární, což činí proces transformace složitějším. Jedním ze způsobů, jež je možné při registraci aplikovat, jsou genetické, respektive evoluční algoritmy. Zatímco genetické algoritmy simulují evoluční procesy pomocí operací selekce, křížení a mutace, evoluční algoritmy jsou inspirovány přírodní evolucí. Vstupní populace v časovém vývoji (v iteracích) absoluuje určité změny.

Genetické a evoluční algoritmy mají široké využití díky své schopnosti řešit složité optimalizační problémy. Jejich výhodou je schopnost efektivně prohledávat velký prostor řešení dané úlohy, oproti běžným optimalizačním metodám jsou odolnější vůči nežádoucímu uvíznutí v lokálním minimu.

V rámci této práce jsou aplikovány za účelem zpracování a registrace statických a dynamických snímků oční sítnice nasnímaných různými modalitami. Tento přístup umožňuje dosáhnout přesnějšího zarovnání obrazů, což umožňuje lepší analýzu obrazů, případně i diagnostiku očních onemocnění.

1 Genetické a evoluční algoritmy

1.1 Historie vývoje evolučních algoritmů

Koncepce evolučních algoritmů se datuje do poloviny 20. století a vychází ze snahy řešit složité optimalizační problémy napodobováním procesů, k nimž přirozeně dochází v rámci evoluce.

Vývoj evolučních algoritmů probíhal od 50.let minulého století, v 60.letech je pak patrná diverzifikace do jednotlivých podskupin evolučních algoritmů. Jednu z těchto podskupin představují genetické algoritmy, na jejichž vývoji se angažoval John Holland. Tento americký vědec a profesor na Michiganské univerzitě byl fascinován myšlenkou využití počítačových simulací ke studiu biologických jevů. V rámci studia adaptace přírodních a umělých systémů vyvinul tyto první algoritmy a položil tak základy toho, co se později stalo významným odvětvím umělé inteligence a strojového učení. [30]

Souběžně s Hollandovou prací vyvinuli v 60. letech 20. století Ingo Rechenberg a Hans-Paul Schwefel, dva němečtí vědci, evoluční strategie. Jejich přístup se zaměřil na optimalizaci spojitých proměnných s reálnou hodnotou a zpočátku byl aplikován na optimalizaci tvaru křídel letounů. Pomocí experimentů v aerodynamickém tunelu byly testovány různé tvary křídel a výsledky těchto testů poté posloužily k opětovným úpravám tvarů křídel. Tento proces tak v podstatě věrně napodoboval činnost evolučních mechanismů, kdy každá generace návrhů představovala určitou modifikaci nevhodnějších návrhů z předchozí generace. [2]

V této době se zároveň Fogel a kol. angažovali ve vývoji další podskupiny evolučních algoritmů zvané evoluční programování, v 80.letech byl poté Johnem Kozou představen podobor zvaný genetické programování. [1] [20]

Začátek 21. století pak představuje možnost širokého využití evolučních a genetických algoritmů v mnoha oborech. Dnes jsou nedílnou součástí různých složitých optimalizačních úloh v oblasti strojového učení, umělé inteligence a datové vědy a nadále se vyvíjejí a přizpůsobují vlivům okolního prostředí, stejně jako přírodní procesy, které napodobují. Svou schopností nalézt řešení i pro složité optimalizační úlohy z nich činí důležité nástroje, které je možné uplatnit na poli ekonomie, strojírenství, biomedicíny a biologie, stejně tak v oblasti umění a designu. [26] [18]

1.2 Evoluční algoritmy

Evoluční algoritmy představují širokou skupinu optimalizačních a vyhledávacích metod inspirovaných principy evoluce v přírodě. Hlavním cílem těchto algoritmů je nalezení nejlepšího řešení problému prostřednictvím simulace evolučních procesů.

Často jsou využívány při optimalizaci funkcí, které nejsou dostatečně známé nebo jsou jen obtížně řešitelné analytickými postupy.[29]

Skládají se z populace jedinců, reprezentujících potenciální řešení. Na tyto jedince působí jednotlivé operace simulující činnost evolučních mechanismů (selekce, křížení, mutace) - dochází k vývoji populace. S ohledem na fakt, že se jedinci vyskytují v prostředí s omezenými zdroji, mají jedinci, kteří se v tomto prostředí nejvhodněji adaptují, vyšší šanci na přežití a předání svých informací (genů) do dalších generací (iterací). Míra adaptace na dané prostředí je vyjadřována pomocí účelové funkce (často označované pojmem fitness), cílem je provést maximalizaci (či minimalizaci) této funkce. Činnost evolučních algoritmů je členěna do postupně navazujících kroků, jimiž jsou inicializace populace, stanovení kvality jedinců dané populace a vytvoření populace nové. Dané kroky probíhají periodicky do splnění ukončující podmínky. [17]

1.3 Princip genetických algoritmů

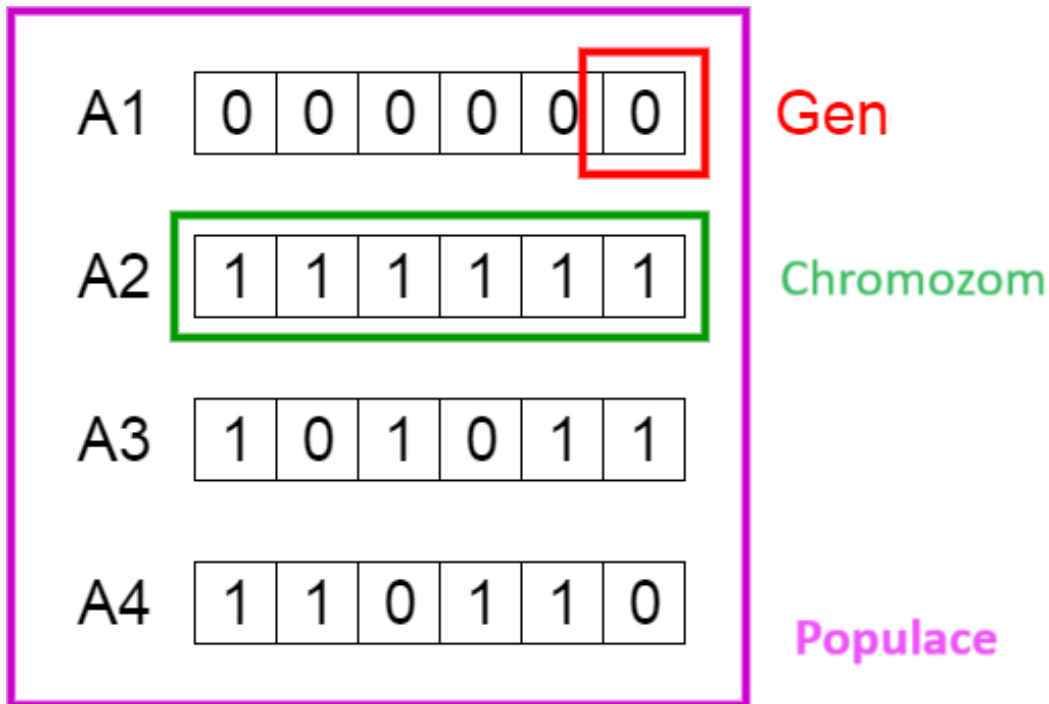
Genetické algoritmy využívají určitých operátorů, tyto operátory jsou aplikovány na prvky množiny (jedince populace). Populace sestává z chromozomů (genotypů) - jde o řetězce bitů, které jsou zpracovány. Jednotlivé bity představují určité geny, jak je znázorněno na obrázku 1.1. [26]

Chromozomy mohou být zastoupeny v binární reprezentaci - v tom případě sestávají z jednotlivých bitů a pomocí genetických operátorů dochází k aplikaci bitových operací. Stejně tak je možné využít reprezentace celočíselné - v tom případě jsou využity aritmetické operace ke změně hodnot těchto čísel. Jednotlivé geny také mohou být kódovány formou reálných čísel s desetinnou čárkou.

Podstatným parametrem je také velikost populace. Počet jedinců populace má vliv na efektivitu a rychlost nalezení optimálního řešení. V případě příliš malé populace může nastat riziko příliš nízké rozdílnosti mezi jednotlivými jedinci. V tom případě může nalezení optimálního řešení představovat poměrně velkou překážku. Oproti tomu vysoce početná populace představuje problém z výpočetního a časového hlediska.

1.3.1 Selektce

Operace selektce zajišťuje vývoj kvality populace v jednotlivých generacích. Přitom však nedochází ke změně počtu jedinců v populaci. V rámci selektce jsou vybírání jedinci, kteří následně podstoupí křížení. Existuje několik možných způsobů, jakými je možné realizovat selektci, mezi nejčastější patří ruletová selektce, případně turnajová selektce. Selektce také může být založena na náhodném principu, tento jev však



Obr. 1.1: Schematické znázornění pojmů gen, chromozom, populace.

Převzato z [23], modifikováno.

není vhodný, neboť je ignorována rozdílná kvalita různých jedinců.

V případě ruletové selekce má každý jedinec stanovenou určitou pravděpodobnost výběru, tato pravděpodobnost vychází z jeho kvality. Tato pravděpodobnost je stanovena pomocí následující rovnice [28]:

$$P_i = \frac{F_i}{\sum_{j=1}^N F_j}, \quad (1.1)$$

kde F_i je individuální kvalita jedince, N je velikost populace. Poté lze stanovit hodnoty kumulativní pravděpodobnosti.

$$C_i = \sum_{j=1}^i P_j. \quad (1.2)$$

Poté je náhodně generováno číslo U v rozmezí $(0, 1)$. Tato hodnota je porovnána s jednotlivými intervaly kumulativní pravděpodobnosti:

$$C_{i-1} < U \leq C_i \quad (1.3)$$

Do výstupní populace je následně propsán jedinec s hodnotou hodnota C_i . [28]

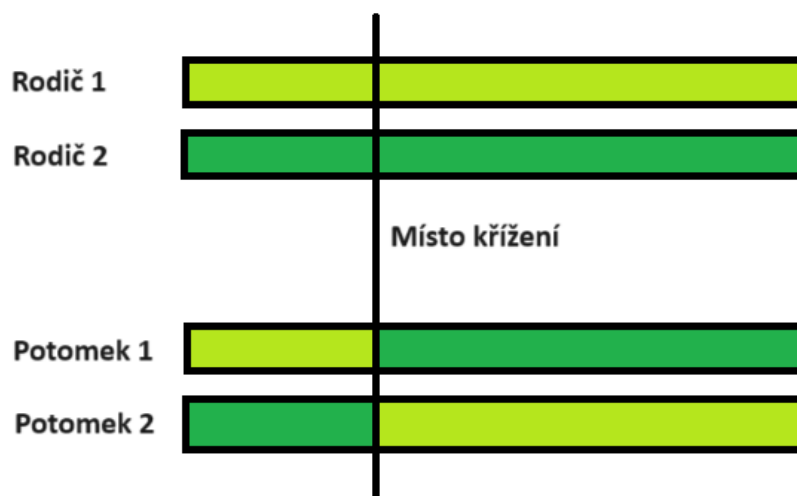
V případě, že je hodnota fitness funkce u určitého jedince příliš vysoká oproti jedincům ostatním, existuje riziko, že geny tohoto jedince se propíší do celé populace a jiní kvalitní jedinci nebudou vybráni vůbec.

Turnajová selekce využívá principu podmnožin. Každá podmnožina (skupina jedinců) mezi sebou soutěží, vítěz turnaje (jedinec s nejvyšší hodnotou fitness funkce) je následně zvolen jako rodič. Parametry počtu jedinců, kteří tvoří skupinu, a počtu postupujících jedinců do další generace mohou být variabilní. V závislosti na jejich stanovení lze měnit míru konvergence. [13]

Při selekci dle hodnoty fitness funkce také může být využitý elitismus. Ten zajišťuje přežití jednoho či více nejlepších jedinců do nové generace. Díky tomu budou v následující generaci zachována dosud nejlepší nalezená řešení.

1.3.2 Křížení

Úkolem této operace je zajišťovat obměnu populace. Při rekombinaci genetické informace od rodičů dochází ke vzniku potomků. Křížení může být jednobodové či vícebodové - tento parametr určuje, kolik bodů bude dělit chromozomy obou rodičů na určité části. Tyto části jsou následně přenášeny do další generace formou jejich kombinace - jsou porovnány geny od otce a matky a následně potomkovi předány ty s vyšší kvalitou. Pozice dělicího bodu je náhodně iniciována. Ukázka jednobodového křížení je znázorněna na obrázku 1.2.



Obr. 1.2: Jednobodové křížení.

Převzato z [10], modifikováno.

1.3.3 Mutace

V rámci této operace dochází k náhodným změnám částí chromozomu. Cílem těchto změn je zajistit vyšší míru diverzity v populaci - tím je předcházeno možnému uvíznutí algoritmu v lokálním minimu. S ohledem na uchování dosud nejlepších nalezených řešení je nutné vhodně zvolit hodnotu mutační konstanty. Mutace může ovlivnit jeden nebo více genů jedince. [26]

1.4 Rojové algoritmy

Rojové algoritmy představují skupinu algoritmů sloužících k popisu chování kolektivu zvířat (např. mravenci, ryby, ptáci, vlci, včely,...). Jednotliví jedinci mezi sebou určitým způsobem interagují a předávají si informace, přitom často dochází k jejich přesunu a shlukování do skupin (analogie k procesu hledání optimálního řešení). Existují mnohé varianty rojových algoritmů, v rámci této práce budou podrobněji popsány 3 algoritmy - algoritmus mravenčí kolonie, světluškový algoritmus a algoritmus optimalizace hejnem částic.

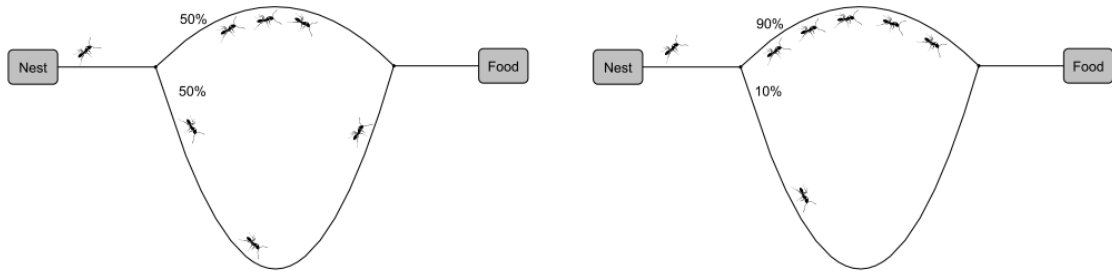
1.4.1 Algoritmus mravenčí kolonie

Mravenčí algoritmus byl navržen v 90. letech minulého století, přitom se inspiroval chováním společenství mravenců při shromažďování potravy, zejména jejich metodou hledání nejkratší cesty z kolonie ke zdroji potravy. Mravenci mezi sebou komunikují pomocí feromonů (chemických stop, které zanechávají na zemi). Každý mravenec náhodně prozkoumává oblast, po nalezení potravy se vrací do kolonie a zároveň zanechává feromonové stopy. Ostatní mravenci budou s vyšší mírou pravděpodobnosti následovat silnější feromonové stopy, čímž se úspěšné cesty časem posílí. Zároveň trasy, které nebudou až tak frekventované, budou postupně feromonovou stopou ztrácet (proběhne její vypařování). Kromě feromonové stopy algoritmus ještě zohledňuje samotnou vzdálenost trasy, někdy je tento parametr také označován pojmem atraktivita tahu. Při volbě trasy jednotliví mravenci zohledňují oba tyto faktory. [8]

V závislosti na množství uložených feromonů jsou postupně aktualizovány pravděpodobnosti průchodu danou hranou dle vztahu:

$$p_{ij}^k = \frac{\tau_{ij}(t)^\alpha \eta_{ij}^\beta}{\sum_{j \in N^k(i)} \tau_{ij}(t)^\alpha \eta_{ij}^\beta} \quad (1.4)$$

kde p_{ij}^k značí pravděpodobnost průchodu hranou spojující vrcholy i a j , $\tau_{ij}(t)$ značí množství feromonové stopy, parametr η_{ij}^β stanovuje heuristickou informaci a $N^k(i)$ představuje uzly, které může daný mravenec (značený k) navštívit.



Obr. 1.3: Mravenčí algoritmus - volba trasy před a po několika iteracích.

Převzato z [8], modifikováno.

Parametry α , β a ρ představují konstantní hodnoty. Množství feromonu, které se nachází na jednotlivých hranách mezi uzly, je průběžně aktualizováno a lze stanovit s využitím následující rovnice:

$$\tau_{ij}(t + 1) = (1 - \rho) \cdot \tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (1.5)$$

kde ρ představuje míru vypařování feromonu a $\Delta\tau_{ij}(t)$ značí množství feromonu na spojnici vrcholů i a j . Toto množství je stanovené v závislosti na kvalitě řešení nalezených celou mravenčí kolonií. [8]

1.4.2 Světluškový algoritmus

Algoritmus světlušek je metaheuristický optimalizační algoritmus inspirovaný přírodou, který v roce 2007 vyvinul Dr. Xin-She Yang. Tento algoritmus, který čerpá inspiraci z chování světlušek, se používá k řešení složitých optimalizačních problémů. Světlušky používají bioluminiscenci k lákání partnerů a kořisti. Intenzita světla vydávaného světluškami se mění se vzdáleností konkrétního jedince. Tento přírodní jev je aplikován v rámci vyhledávací strategie, kde jsou řešení optimalizačního problému reprezentována světluškami a jejich jas odpovídá vhodnosti řešení.[40]

Algoritmus světlušek funguje na třech klíčových principech:

1. Všechny světlušky jsou jednopohlavní - jedna světluška bude přitahována jinými světluškami bez ohledu na jejich pohlaví.
2. Atraktivita jedince je úměrná jasu světlušek - světlušky se navzájem přitahují na základě své jasnosti, která se snižuje s rostoucí vzdáleností mezi nimi.
3. Jasnost ovlivňuje pohyb: Méně jasná světluška se bude pohybovat směrem k jasnější světlušce. Pokud není přítomna žádná jasnější světluška, bude se světluška pohybovat náhodně. [22]

V rámci inicializace se nejprve náhodně vygeneruje populace světlušek. Intenzita světla každé světlušky se vyhodnotí pomocí účelové funkce. Každá světluška se pohybuje směrem k jasnějším

světluškám v populaci. Atraktivita jednotlivých světlušek klesá se vzájemnou vzdáleností. Při pohybu světlušek a jejich interakci algoritmus aktualizuje jejich pozice a hodnoty jejich atraktivity, tím tak simuluje objevování nových a potenciálně lepších řešení. Tento děj probíhá v rámci stanoveného počtu iterací, případně do ukončení stanoveného kritéria. Světlušky postupně konvergují k jasnějším řešením, což v ideálním případě vede k objevení globálního optima. [40] [22]

Atraktivitu světlušek β lze vyjádřit pomocí následující rovnice:

$$\beta = \beta_0 e^{-\gamma r^2} \quad (1.6)$$

kde β_0 značí atraktivitu světlušky pro nulovou vzdálenost ($r = 0$). [40]

Vzdálenost mezi dvěma světluškami i a j na jejich pozicích \mathbf{x}_i a \mathbf{x}_j odpovídá Euklidovské vzdálenosti:

$$r_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2}, \quad (1.7)$$

kde $x_{i,k}$ značí k -tou složku prostorové souřadnice \mathbf{x}_i i -té světlušky. Pro dvourozměrný prostor by rovnice nabývala tohoto tvaru:

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (1.8)$$

Pohyb světlušek lze vyjádřit s využitím této rovnice:

$$\mathbf{x}_i^{t+1} = \mathbf{x}_i^t + \beta_0 e^{-\gamma r_{ij}^2} (\mathbf{x}_j - \mathbf{x}_i) + \alpha \epsilon_i^t \quad (1.9)$$

kde první člen rovnice odpovídá předchozí pozici světlušky, druhý její atraktivitě $\beta = \beta_0 e^{-\gamma r_{ij}^2}$, třetí člen pak plní funkci tzv. náhodného kroku - určité nenulové hodnoty, který je přičtena k předchozím dvěma členům. Pokud parametr $\gamma \rightarrow 0$, poté je atraktivita $\beta = \beta_0 e^{-\gamma r_{ij}^2} \rightarrow \beta_0$ a viditelnost světlušek je ideální v celém prohledávaném prostoru. Pokud $\gamma \rightarrow \infty$, $\beta \rightarrow \delta(r)$ (nulová viditelnost), poté se světlušky pohybují zcela náhodně. Parametr α ovlivňuje velikost náhodných kroků, ta by měla v průběhu iterací klesat. [40]

1.4.3 Algoritmus optimalizace hejnem částic

Tento algoritmus je inspirován chováním skupiny zvířat (například ptáků), podstatným prvkem je vzájemná interakce mezi jedinci. Jedinci, často označovaní jako částice, si vzájemně předávají informace o pozici a rychlosti. Oproti dříve představeným evolučním algoritmům v tomto případě nedochází k souboji částic mezi sebou, ale ke vzájemné kooperaci za účelem nalezení nejlepšího řešení. Na počátku jsou generovány náhodně pozice všech částic a je také stanovena nejlepší pozice. Následně je vypočtena hodnota fitness funkce pro každou částici, nejvyšší z těchto hodnot je

určena jako globální maximum. Posléze jsou v rámci iterativního procesu přepočítány hodnoty polohy a rychlosti dle následujících rovnic [24].

Rychlost i -té částice lze stanovit následovně:

$$v_i(t+1) = v_i(t) + c_1(p_i - x_i(t))R_1 + c_2(g - x_i(t))R_2 \quad (1.10)$$

kde p_i je “lokální maximum” částice - nejlepší dosud získané řešení daným jedincem, zatímco g určuje “globální maximum” - nejlepší dosud nalezené řešení v rámci hejna. Dále jsou zavedeny koeficienty reálných čísel c_1 a c_2 , obvykle v rozmezí $0 \leq c_1, c_2 \leq 4$, takzvaný “kognitivní koeficient” and “sociální koeficient”, mají vliv na délku kroku, který částice vykoná při přesunu ke svému lokálnímu, resp. globálnímu maximu. Dále jsou zavedeny matice náhodných čísel generovaných z normálního rozložení $[0, 1]$, R_1 a R_2 , které zavádí stochasticitu u kognitivního a sociálního koeficientu. Částice proto konají pohyb, který není zcela deterministický a nese částečně prvky náhodnosti. Poloha určité částice může být stanovena následně:

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (1.11)$$

kde t a $t+1$ značí 2 následující iterace algoritmu a v_i představuje vektor rychlostí i -té částice napříč D dimenzemi. Vektor rychlostí je tvořen 3 složkami: momentem - určitá nenulová hodnota, která zamezuje příliš velké změně směru díky tomu, že si pamatuje předchozí směr pohybu, dále kognitivním a sociálním koeficientem, které byly popsány výše. [24]

Daný proces probíhá iterativně, dokud není splněná koncová podmínka, následovně: nejprve je aktualizována rychlost částice, poté její pozice, poté je stanovena hodnota fitness funkce každé částice. Pokud je nová pozice částice výhodnější než dosud nejlepší (tzn. její lokální maximum), stává se tato pozice jejím novým lokálním maximem. Stejně tak platí, že pokud je nová pozice lepší než stávající globální maximum, stává se novým globálním maximem. Po ukončení iterativního procesu představuje dané globální maximum nejlepší řešení.[24]

2 Registrace obrazů

2.1 Princip registrace obrazu

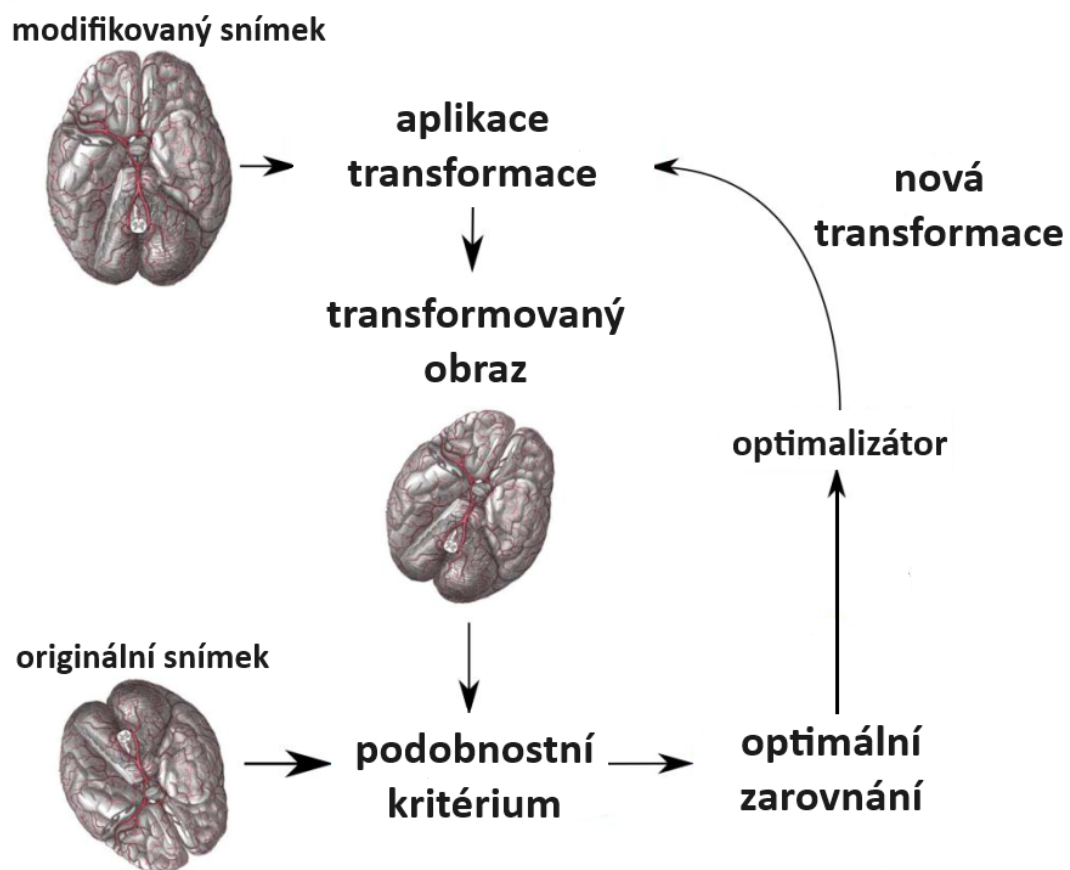
Registrace obrazu představuje iterativní proces, jehož cílem je provést zarovnání dvou či více obrazů stejné scény, které byly pořízeny v různém časovém okamžiku, stejně tak mohly být nasnímány různými modalitami či pod různým úhlem. Po zarovnání mohou být oba obrazy vzájemně porovnány, v případě většího počtu snímků z nich také lze vytvořit např. videosekvenci. V rámci procesu registrace je klíčové nalézt vhodnou geometrickou transformaci, která převádí body jednoho obrazu na odpovídající body v druhém obrazu, aby došlo k co nejlepšímu překrytí obrazů. Konkrétními příklady transformací, jež mohou být aplikovány, jsou translace, rotace, škálování, zkosení, případně další, složitější transformace.[36] Proces registrace je schematicky znázorněn na snímku 2.1. Na vstupu procesu jsou k dispozici 2 snímky, tzv. modelový (originální) snímek a modifikovaný snímek, který bude podstupovat proces transformace. Na modifikovaný snímek jsou aplikovány jednotlivé transformační operace vyjádřené ve formě transformační matice (podrobněji popsány v následující části práce), čímž je získán transformovaný obraz. Poté je stanoveno podobnostní kritérium, které vyjadřuje, do jaké míry se transformovaný snímek shoduje vůči originálnímu snímku. Proces registrace dále pokračuje v případě, že není splněna stanovená podmínka (například prahová hodnota pro dané kritérium). V daném případě jsou upraveny parametry transformační matice, obraz je opět transformován, je stanoveno podobnostní kritérium atd.

2.2 Geometrické transformace obrazů

Proces transformace zahrnuje modifikaci souřadnic pohyblivého obrazu s ohledem na souřadnice obrazu originálního. Transformace mohou být lokální, kdy dochází k aplikaci transformačních parametrů na vybranou část obrazu, případně globální, kdy se transformační parametry vztahují na celý obraz. V závislosti na tom, zda nastává změna tvaru obrazu či nikoliv, dělíme transformace na rigidní a flexibilní. [16] [21]

2.2.1 Rigidní transformace

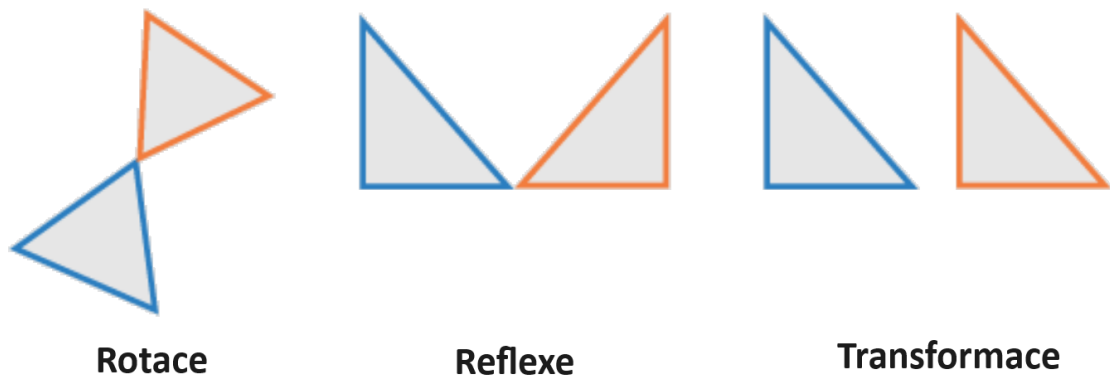
Charakteristickým znakem rigidních transformací je tendence zachovávat proporce obrazu, pouze dochází k úpravě prostorových souřadnic. Patří k nejjednodušším formám transformace, řadíme sem rotaci, translaci a zrcadlení, znázorněné na obrázku



Obr. 2.1: Schéma procesu registrace obrazů.

Převzato z [36], modifikováno.

2.2. Pro rotaci je typické násobení původních prostorových souřadnic obrazu určitou maticí, označovanou jako transformační matice. V případě translace jsou k původním souřadnicím x a y přičteny hodnoty Δx a Δy , tzn. dojde k posunu o určitou diskrétní vzdálenost. Pokud aplikujeme zrcadlení, získáme z původního vzoru nový obraz vytvořený pomocí osové souměrnosti, kde osa odděluje obrazovou a předmětovou rovinu.[16] [27] [21]



Obr. 2.2: Rigidní transformace.

Převzato z [34], modifikováno.

2.2.2 Pružné transformace

Dalším typem možných transformací jsou transformace pružné. Při nich dochází k deformaci vzdáleností mezi body obrazu v jeho určitých částech. Typickým zástupcem pružných transformací je škálování (*scaling*), případně zkosení (*shearing*). Při zkosení dochází k posunu obrazu podél určité hrany, u některých hran k posunu nedochází. Dalšími zástupci pružných transformací jsou tenze (*tension*) a komprese (*compression*), torze, případně ohyb (*bending*). [27] [21]

2.3 Použité metriky

Pro vyhodnocení úspěšnosti registrace byly využity podobnostní vzdálenostní a evaluační kritéria. Zatímco podobnostní kritéria vyhodnocují, jak jsou si určité objekty podobné, jejich obor hodnot se obvykle pohybuje od -1 do 1 (případně od 0 do

1), vzdálenostní kritéria mají obor hodnot od 0 po nekonečno (teoreticky) a vypovídají o vzdálenosti daných objektů. V případě podobnostních kritérií značí vyšší hodnoty větší podobnost, u vzdálenostních kritérií je tomu naopak, ideální jsou hodnoty blízké nule (či přímo nulové). Evaluační kritéria mohou sloužit jako informace o úspěšnosti provedené registrace obrazu.

2.3.1 Podobnostní kritéria

Kosinové kritérium

Kosinové kritérium stanovuje úhel mezi dvěma vektory v příznakovém prostoru, což umožňuje vyjádřit podobnost dvou obrazů na základě orientace jejich pixelů. Hodnota kosinového kritéria se pohybuje v rozmezí od -1 do 1, kde 1 značí úplnou podobnost, 0 značí žádnou (nulovou) podobnost a -1 značí úplnou nepodobnost. Vyšší hodnoty kosinové podobnosti indikují vyšší podobnost mezi dvěma obrazy, což značí úspěšnější registraci. Kosinové kritérium lze stanovit dle následující rovnice:

$$kriterium = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}} \quad (2.1)$$

kde A a B jsou vektory hodnot pixelů dvou obrazů.

Normalizovaná křížová korelace

Normalizovaná křížová korelace (NCC) je metrika, která měří podobnost mezi dvěma obrazy pomocí korelace jejich pixelů. Tato metrika se používá k nalezení nejlepšího zarovnání mezi dvěma obrazy tím, že porovnává intenzity jejich pixelů. Její rozmezí se pohybuje na úrovni od 0 do 1, kde 1 značí perfektní shodu a 0 žádnou shodu. Vyšší hodnoty NCC indikují lepší kvalitu registrace a vyšší podobnost mezi registrovaným a referenčním obrazem. Normalizovanou křížovou korelaci lze stanovit dle následující rovnice:

$$NCC(u, v) = \frac{\sum_{x,y} [A(x, y) - \bar{A}][B(x - u, y - v) - \bar{B}]}{\sqrt{\sum_{x,y} [A(x, y) - \bar{A}]^2} \sqrt{\sum_{x,y} [B(x - u, y - v) - \bar{B}]^2}} \quad (2.2)$$

kde A a B jsou obrazy, \bar{A} a \bar{B} jsou průměrné hodnoty pixelů v obrazech, a u a v jsou posuny obrazů ve vertikálním a horizontálním směru.

2.3.2 Vzdálenostní kritérium

Střední kvadratická odchylka

Střední kvadratická odchylka (MSE) představuje jedno z měřítek při vyhodnocení kvality registrace obrazu (respektive videosekvence). Kvantifikuje rozdíl mezi dvěma

obrazy na základě jednotlivých pixelů. MSE se vypočítá jako průměr kvadrátů rozdílů mezi odpovídajícími hodnotami pixelů obou porovnávaných obrazů. Nižší hodnoty MSE znamenají menší celkovou chybu a vyšší přesnost registrace jednotlivých obrazů. Střední kvadratickou chybu je možné stanovit dle následující rovnice, kde hodnoty M,N značí rozměry obrazu, $g(x, y)$ a $\hat{g}(x, y)$ originální a registrovaný obraz: [31]

$$MSE = \frac{1}{MN} \sum_{n=0}^M \sum_{m=1}^N [\hat{g}(n, m) - g(n, m)]^2 \quad (2.3)$$

2.3.3 Evaluační kritéria

Špičkový poměr signálu ku šumu

Tato metrika, často označovaná zkratkou PSNR, slouží k měření kvality rekonstruovaného obrazu ve srovnání s jeho původní verzí. Je zvláště užitečná pro hodnocení výkonnosti různých technik komprese a obnovy obrazu. Při jejím výpočtu je stanovena střední kvadratická odchylka (MSE) mezi původním a registrovaným obrazem, stejně tak maximální hodnota pixelu u daného obrazu, tzn. například pro osmibitový obraz by taková hodnota činila 255. Vyšší hodnoty PSNR obvykle značí lepší výslednou kvalitu registrace. Hodnota PSNR bývá stanovena v decibelech (dB). [31]

$$PSNR = 10 \log_{10} \left(\frac{peakval^2}{MSE} \right) \quad (2.4)$$

kde *peakval* značí maximální hodnotu v obrazu, například pro osmibitový obraz tato hodnota činí 255. [6]

SSIM index

Index strukturální podobnosti (SSIM index) je metrika používaná k měření podobnosti mezi dvěma obrazy. V rámci výpočtu SSIM je porovnávána průměrná úroveň jasu obou obrazů, kontrast (ten je stanoven vyhodnocením směrodatných odchylek intenzity jednotlivých pixelů u obou obrazů) a korelační koeficient (porovnání struktury u obou obrazů). Hodnota SSIM indexu se pohybuje v rozmezí -1 až +1, přičemž -1 značí celkovou neshodu, +1 celkovou shodu. [31]

Index SSIM lze stanovit dle následující rovnice:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (2.5)$$

kde μ_x a μ_y značí průměrné intenzity obou obrazů (x,y).

2.4 Využití evolučních algoritmů při registraci obrazových dat

Cílem této části práce je popsat publikace, které byly v minulosti zpracovány různými autory za účelem zpracování obrazových dat. S ohledem na zaměření této práce byly voleny publikace zaměřené na zpracování medicínských dat.

Autoři Troglia a kol. využívají ke zpracování snímků oční sítnice genetický algoritmus obsahující všechny bloky - selekci (autoři využívají turnajovou selekci), křížení a mutaci. Zároveň je také implementován elitismus. Jakožto kritériální funkce slouží vzájemně korelační funkce. Jsou zpracovávány šedotónové záznamy (získané spektrofotometricky) a záznamy barevné, pořízené fundus kamerou. Registrace je prováděna manuálně (pomocí výběru korespondujících bodů) a také automaticky. [35]

Autoři Gupta a kol. využívají k registraci dat nasnímaných pomocí magnetické rezonance. Po předzpracování, které spočívá v aplikaci gamma korekce a aplikace Gaussovského filtru, je aplikován mravenčí algoritmus. K vyhodnocení jsou následně využity metriky špičkového poměru signálu k šumu, entropie a střední kvadratické odchylky.[12]

Zpracování medicínských záznamů se věnuje i další studie, publikovaná kolektivem autorů Wachowiak a kol. Autoři využívají optimalizaci rojem částic (PSO), jakožto podobnostní kritérium slouží normalizovaná vzájemná informace. V práci jsou využita data pořízená pomocí 3 různých modalit (ultrazvuk, CT, magnetická rezonance). Autoři porovnávají několik modifikací PSO algoritmu, stejně tak aplikují i různé varianty evoluční strategie.[38] Autoři Martínez-Río a kol. se taktéž věnují registraci medicínských dat pořízených angiograficky. Jsou využity 2 různé modalitty, fluorescenční angiografie a optická koherenční tomografická angiografie. Algoritmus autorů využívá několika na sebe navazujících fází, jednou z nich je také evoluční algoritmus využívající diferenciální evoluce. [25] Další z publikovaných přístupů využívá evoluční algoritmus - umělou včelí kolonii. Tento algoritmus popisuje chování včel při hledání zdroje potravy. Včely postupně v závislosti na zdrojích potravy konvergují k určitému řešení, využity jsou 2 druhy včel - včely nacházející se v místě, kde je potrava (lokální optimum) a včely pozorovatelky - ty prohledávají okolí za cílem nalezení vhodnějšího řešení. Autoři provádějí registraci medicínských i nemedicínských dat (letecké snímky, snímky objektů). [15] Autoři Valsecchi a kol. se v publikovaném článku zaměřují na porovnání různých registračních technik - kromě genetického algoritmu využívají také několik metod založených na gradientním poklesu (sestup). Testování algoritmů probíhá na datech pořízených magnetickou rezonancí, nejpříznivějších výsledků je dosaženo při použití genetického algoritmu. [37]

3 Testovací sada dat

V rámci praktické části byly nejprve využity modelové snímky geometrických útvarů (rovnoběžníku, trojúhelníku a čtverce). Účelem těchto snímků bylo ověření funkčnosti procesu registrace v programovém prostředí Matlab, a to pomocí manuálního výběru korespondujících bodů u obou snímků. V tomto případě byla vždy zpracována dvojice snímků, a to originálního a modifikovaného. Na snímky byla v těchto případech aplikována pouze rotace či translace, případně jejich kombinace.

V návaznosti na tato modelová data byla následně podrobněji zpracovávána databáze snímků oční sítnice obsahující celkem 19 záznamů, každý ze snímků je nasnímán pro různé vlnové délky (470, 525, 580, 595 a 660 nm). Kromě toho jsou u všech záznamů zaznamenány základní údaje pacientů, jako je věk, pohlaví, systolický či diastolický krevní tlak. Také byly zaznamenány hodnoty EKG záznamu (tepová frekvence a pozice R kmitů), obrazová data (vysegmentované optické disky a oční sítnice, obojí pomocí automatické a manuální segmentace), ty však v této práci nebyly dále využity.


V této diplomové práci byly využity statické snímky pořízené fundus kamerou a dynamické snímky zachycené videooftalmoskopem pro vlnovou délku 470 nm. Celkem bylo využito 10 videosekvencí (záznamy č. 1 - 10). Videosekvence byly převedeny do formátu mp4 z důvodu příliš velkých vstupních souborů. Vstupní dynamické sekvence mají délku v rozmezí 12 - 17 sekund, vzorkovací frekvence činí 25 snímků za sekundu, rozměry jednotlivých snímků jsou 1224 x 970 pixelů. Při registraci dynamických snímků byl využit průměrný obraz, získaný formou zprůměrování jednotlivých snímků videosekvence. Ukázka zprůměrovaného obrazu je uvedena na obrázku 3.2.

3.1 Přístrojové vybavení


V rámci praktické části práce byly zpracovány snímky pořízené fundus kamerou a videooftalmoskopem v laboratoři Ústavu biomedicínského inženýrství. Ačkoliv při tvorbě samotné práce tato zařízení nebyla využita, je vhodné obě zařízení alespoň ve stručnosti představit.

3.1.1 Fundus kamera

Laboratoř je vybavena fundus kamerou výrobce Canon, konkrétně modelem CR-1. Obrázek 3.3 znázorňuje daný model fundus kamery. Předností daného modelu je možnost pořizovat snímky ve vysokém rozlišení s důrazem na jednotlivé detaily,




Obr. 3.1: Ukázka statického snímku sítnice oka - záznam č.6.



Obr. 3.2: Ukázka zprůměrovaného snímku sítnice oka - záznam č.6.

což poté umožňuje snazší detekci očních nemocí (např. glaukomu). Ovládání samotného fotoaparátu je zajištěno pomocí joysticku, díky němuž je možné provést centrování snímku. Samotný výběr vhodné oblasti lze ovlivnit pomocí šipek klávesnice. Zorný úhel dosahuje hodnoty až 45 stupňů. Detailnější snímání oční sítnice je možné uskutečnit při aktivovaném módu 2X, kdy je automaticky oříznuta okrajová část snímku. Také je možné nastavovat jas snímku, pořízení snímku lze uskutečnit stisknutím tlačítka joysticku. Zařízení je rovněž vybaveno dioptrickou korekcí (v závislosti na nastavené pozici ovladače - je možné vybírat mezi pozicemi značenými 0, - a +). V závislosti na výšce vyšetřované osoby je možné pomocí ovládacího panelu upravit výšku opěrky, na níž se přikládá brada. Zařízení umožňuje nastavit 10 režimů intenzity záblesků pro pořizování snímků. Čip určený na pozorování sítnice je typu CCD, obraz je přenášen na LCD monitor o velikosti 5,7 palce. Hmotnost celého zařízení činí 21,5 kilogramů. [3]




Obr. 3.3: Fundus kamera.

Převzato z [3].

3.1.2 Videooftalmoskop

Při tvorbě záznamů oční sítnice byl taktéž využit videooftalmoskop. Zařízení je schopné pořizovat snímky v rozlišení 1224 x 970 pixelů, zorné pole činí 20 x 17

stupňů, což odpovídá ploše 6 x 5 milimetrů s axiální délkou 24 milimetrů. Snímkovací frekvence činí 25 snímků za sekundu, expoziční čas 40 milisekund. Vlnová délka, na níž je možné uskutečnit měření, závisí na použitém zdroji světla, obecně činí 400 - 700 nanometrů. Světelný zdroj je vybaven sestavou 16 led diod s různými vlnovými délkami, autoři studie využili celkem 5 těchto diod. Schéma použitého videooftalmoskopu je zobrazeno na obrázku 3.4.



Obr. 3.4: Videooftalmoskop.


Převzato z [19], modifikováno.

4 Praktická aplikace evolučních algoritmů pro registraci obrazů

V rámci této části práce jsou podrobněji popsány jednotlivé algoritmy, které byly poté prakticky realizovány.

4.1 Genetický algoritmus


V praktické části práce byl realizován optimalizační algoritmus založený na registraci dvojici obrazů pořízených fundus kamerou a videooftalmoskopem. Pro ověření funkčnosti algoritmu byla nejprve prováděna registrace pomocí uměle vytvořených geometrických útvarů (rovnoběžník, trojúhelník a čtverec), jak je znázorněno na obrázcích 4.1 a 4.2. Teprve poté byly využity snímky oční sítnice.



Obr. 4.1: Ukázka testovacího obrazce - trojúhelníku.

4.1.1 Popis implementovaného algoritmu

Algoritmus je implementován v matlabovském souboru *GA.m*. Na počátku tohoto algoritmu je nejprve aplikováno předzpracování - pokud je vstupní snímek barevný, je převeden do šedotónového formátu, stejně tak je formát obrazu upraven na typ double. Taktéž je aplikován padding - operace, kdy jsou okraje obrazů doplněny nulami z důvodu korektního výpočtu podobnostního kritéria. Poté jsou definovány

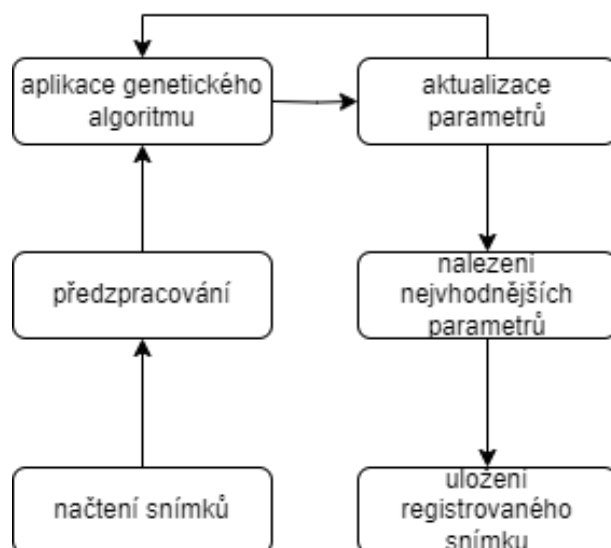


Obr. 4.2: Ukázka testovacího obrazce - rovnoběžníku.

jednotlivé parametry genetického algoritmu - velikost populace, počet generací, je vymezen prohledávací prostor (rozmezí posunu, případně úhlu rotace). Při příliš širokém rozpětí hodnot (velkém vstupním prostoru) nedochází k efektivní konvergenci algoritmu v daném čase (počtu iterací), v případě volby malého rozmezí algoritmus nemusí vůbec optimální hodnotu nalézt. Následně je inicializována matice populace (jednotlivých jedinců) a jejich funkčních hodnot. Na jedince jsou aplikované operace selekce (využita je ruletová selekce), křížení (použito dvoubodové křížení) a mutace. Za účelem udržení diverzity populace je v každé generaci přidáno do populace malé množství náhodných jedinců. Následně proběhne vyhodnocení dané populace, případně aktualizace hodnoty skóre. Za účelem eliminace rizika uvíznutí v lokálním minimu nejlepší jedinec v dané generaci prohledává své nejbližší okolí, k tomuto účelu je využito algoritmu simulovaného žíhání. Podobnostní kritérium, jímž je normalizovaná křížová korelace, je stanoveno v menším výřezu obrazu - tento výřez je soustředěn na centrální část obrazu, okrajové části, které jsou při transformaci často znehodnoceny, nejsou zohledňovány. Výstup algoritmu je kromě výpisu v příkazové řádce také vyobrazen graficky překrytím dané dvojice obrazů. Blokové schéma 4.3 znázorňuje jednotlivé kroky algoritmu. [18]

4.1.2 Návod k aplikaci genetického algoritmu

Algoritmus obsahuje řadu parametrů, které je možné modifikovat dle potřeby. Mezi tyto parametry patří následující:



Obr. 4.3: Blokové schéma registrace statických obrazů.

- **okraje** - tento parametr určuje velikost okrajů (počet nulových pixelů přidány na okraj obrazů). V současné době je hodnota nastavena na 50.
- **populace** - počet jedinců vstupujících do genetického algoritmu - při příliš nízké hodnotě nemusí dojít ke komplexnímu prohledání okolí, příliš vysoká hodnota způsobí nárůst výpočetní náročnosti. Nyní nastavena na hodnotu 60 jedinců.
- **maxgenerace** - Parametr stanovující počet generací, během nichž probíhá činnost genetického algoritmu. Opět platí, že při příliš nízké hodnotě nemusí dojít ke komplexnímu prohledání okolí, příliš vysoká hodnota způsobí nárůst výpočetní náročnosti. Nyní nastavena na hodnotu 50 generací.
- **uhelrozmezi** - vymezení prohledávaného prostoru; rozmezí stanoveno ve stupních. Nyní nastaveno v rozmezí -45 až +45 stupňů.
- **trXrozmezi/trYrozmezi** - vymezení prohledávaného prostoru; rozmezí stanoveno pro obě osy v pixelech. Nyní nastaveno v rozmezí -50 až +50 pixelů.
- **elitismus** - určuje počet jedinců, kteří jsou zachováni (přeneseni do další generace), aniž by byli modifikováni. Jde o nejlepší jedince (z hlediska nalezeného řešení) v dané generaci. Aktuálně nastaveno na hodnotu 1 jedince.
- **mutacnikonst** - určuje pravděpodobnost, že dojde k mutaci některého z genů daného jedince. Aktuálně nastavena na hodnotu 0,05 (pravděpodobnost 5 procent).

4.2 Algoritmus mravenčí kolonie

4.2.1 Popis implementovaného algoritmu

Dalším implementovaným algoritmem byl algoritmus založený na optimalizaci pomocí mravenčí kolonie (ACO). Algoritmus se nachází v matlabovském souboru *ACO.m*. Metoda je navržena tak, aby zarovнала sérii snímků videa s referenčním snímkem, eliminovala případné pohyby scény a zlepšila stabilitu videa.[33]

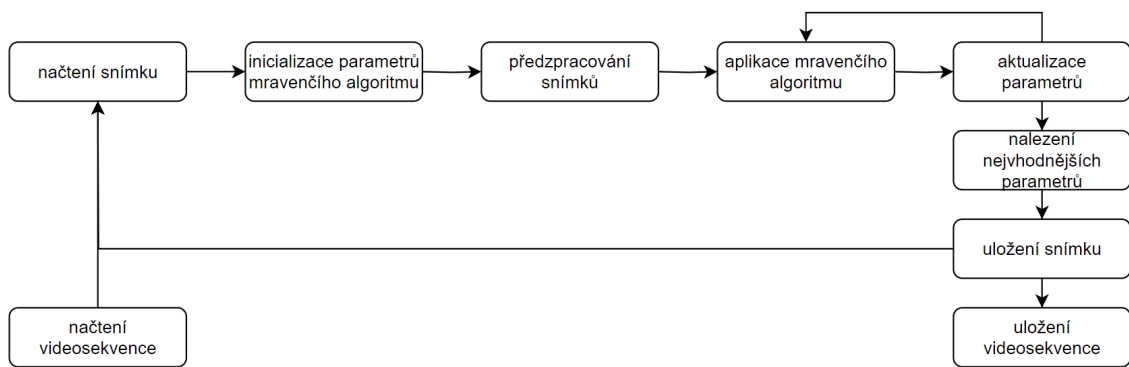
Po načtení videozáznamu je první snímek (frame) nastaven jako referenční, na něhož pak probíhá registrace následujících snímků až do stanoveného maximálního počtu snímků (v daném případě do konce videosekvence). Po nastavení parametrů mravenčího algoritmu (počet jedinců a iterací, vliv feromonové a heuristické informace, míra vypařování a ukládání feromonu) jsou inicializovány vektory stanovující jednotlivé metriky (SSIM, PSNR, kosinové kritérium, normalizovaná křížová korelace). Výpočet těchto kritérií je, s ohledem na aplikované transformace obrazu, realizován v menším okně. Okno je umístěné v centrální části obrazu, v místě předpokládaného výskytu optického disku. Stejně tak je inicializována matice, do níž jsou ukládány parametry transformace. Posléze jsou náhodně inicializovány pozice jednotlivých mravenců a proměnné, do nichž budou ukládány hodnoty nejlepšího nalezeného skóre jedinců.

Po stanovený počet iterací následně mravenci vykonávají pohyb a aktualizují své souřadnice. Pohyb mravenců závisí na množství feromonu a také určité heuristické informaci. Za účelem zlepšování kvality řešení se mravenci pohybují směrem k nejlepšímu jedinci, velikost jejich pohybu je váhovaná číselným koeficientem. Pro každého mravence jsou stanoveny hodnoty translace a rotace. Daný proces probíhá po stanovený počet generací, přičemž se na počátku další generace náhodně vygenerují noví jedinci, z předchozí generace je ponechán pouze nejlepší jedinec. Následně je vzniklá videosekvence uložena. Následující blokové schéma 4.4 zobrazuje jednotlivé části procesu registrace pomocí mravenčího algoritmu:

4.2.2 Návod k aplikaci ACO algoritmu

Před spuštěním algoritmu je možné provést modifikaci určitých parametrů algoritmu:

- **mravenci** - Tento parametr určuje počet mravenců použitých v algoritmu ACO. Každý mravenec představuje potenciální řešení a prohledává okolí, snaží se nalézt vhodné parametry transformace. Vyšší počet mravenců umožňuje



Obr. 4.4: Blokové schéma registrace dynamických obrazů - mravenčí algoritmus.

získat přesnější řešení, avšak na úkor složitější výpočetní náročnosti algoritmu. V současnosti parametr nastaven na hodnotu 50 mravenců.

- **iterace** - Počet iterací, které každý mravenec v procesu hledání podstoupí. Více iterací umožňuje podrobnější prohledávání, zvyšuje však výpočetní náročnost algoritmu. V rámci každé iterace daný mravenec zkoumá nové pozice na základě hladiny feromonů, tyto feromony přispívají k nalezení optimálnějšího řešení. V současnosti parametr nastaven na hodnotu 30 iterací.
- **alfa** - Nastavení parametru feromonové stopy. Tento parametr ovlivňuje sílu feromonových stop. Při vyšší hodnotě tohoto parametru budou mravenci využívat trasy s vyšším obsahem feromonu. Parametr je nyní nastaven na hodnotu 1.
- **beta** - Parametr stanovující, jaký vliv bude mít heuristická informace (což může být například vzdálenost k cíli). Vyšší hodnoty přispívají k pravděpodobnějšímu průzkumu nových tras. Parametr je nyní nastaven na hodnotu 2.
- **ro** - Rychlost odpařování feromonové stopy. Pokud je rychlost odpařování příliš velká, dochází k postupnému snižování atraktivity tzv. starších (dřívějších) tras. Parametr nastaven na hodnotu 0,4.
- **Q** - Parametr určující množství uložené feromonové stopy. V závislosti na kvalitě řešení nalezeného daným mravencem dojde k uložení adekvátního množství feromonové stopy. Při vyšších hodnotách tohoto parametru jsou podporována lepší řešení - trasy, po nichž se vydali úspěšní jedinci, jsou posléze atraktivnější pro další mravence. Parametr je nyní nastaven na hodnotu 1.
- **maxsnimek** - Počet snímků, na něž je aplikován algoritmus. Nyní je zpracovávána celá videosekvence.

Dále je možné uživatelsky přizpůsobit velikost okna, v němž probíhá výpočet kritérií (nyní nastaveno na rozmezí 500 x 500 pixelů).

4.3 Světluškový algoritmus

4.3.1 Popis implementovaného algoritmu

Dalším z vytvořených evolučních algoritmů je světluškový algoritmus, který je implementován v matlabovském souboru *FA.m*. Světluškový algoritmus vychází z představy chování světlušek v přírodě. Simuluje jejich chování, přitom zohledňuje určitá zjednodušení oproti reálnému stavu. Všechny světlušky mají stejné pohlaví, tzn. se jedinci vzájemně přitahují bez ohledu na jejich pohlaví. Stejně tak je atraktivita světlušek úměrná jejich jasu. Světluška se pohybuje náhodně pouze za předpokladu, že se v jejím okolí nevyskytuje žádná světluška, která by byla jasnější než ona sama. Pokud existuje rozdíl jasů u dvou (či vícero) světlušek, platí, že se méně jasná přibližuje k jasnější. Jas světlušky přitom souvisí s hodnotou účelové funkce v místě, kde se světluška právě nachází. Jasnější světlušky dosahují nižší hodnoty účelové funkce (při minimalizačních problémech, v případě maximalizace platí opačná zákonitost). Pomocí jasů je možné vyjádřit atraktivitu světlušky. S rostoucí vzdáleností od jiné světlušky klesá její atraktivita. [5]

Implementovaný algoritmus na počátku inicializuje pozice světlušek náhodně, jejich intenzita je nastavena na nekonečnou hodnotu. Poté jsou inicializovány jednotlivé metriky (PSNR, NCC, kosinové kritérium, SSIM). Následně světlušky prozkoumávají své okolí - pohyb vykonávají v závislosti na přitažlivosti k dalším jedincům. Kromě přitažlivosti má na pohyb vliv i náhodná složka, která zabraňuje uvíznutí v lokálním minimu. Po stanovení parametrů transformace každé světlušky je v závislosti na jejich intenzitě a vzdálenosti od jiných jedinců upravena jejich pozice. Na základě parametrů světlušky s nejvýhodnější pozicí (s nejnižší hodnotou kritériální funkce) dojde k registraci daného snímku videosekvence na snímek předchozí. Daný proces probíhá po stanovený počet generací, přičemž se na počátku další generace náhodně vygenerují noví jedinci, z předchozí generace je ponechán pouze nejlepší jedinec. Následně je vzniklá videosekvence uložena. Blokové schéma 4.5 znázorňuje jednotlivé prvky světluškového algoritmu.

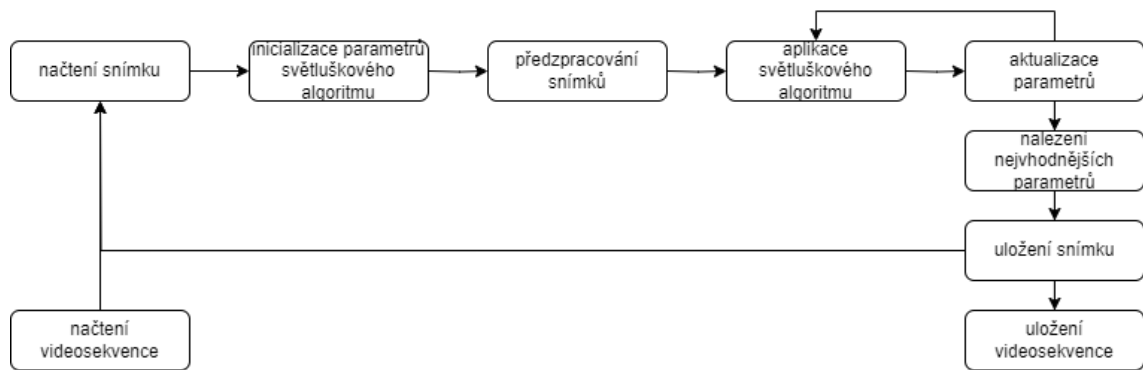
4.3.2 Návod k aplikaci světluškového algoritmu

Na vstupu algoritmu jsou nastavovány následující parametry:

- **svetlusk** - parametr vypovídající o počtu nastavených světlušek. Daný počet světlušek má vliv na pokrytí prohledávaného prostoru v rámci procesu registrace snímků, každá světluška prohledává určitou část prostoru řešení. Vyšší

počet světlušek umožňuje získat přesnější řešení, avšak na úkor vyšší výpočetní náročnosti algoritmu. V současnosti parametr nastaven na hodnotu 50 světlušek.

- **iterace** - počet iterací, které každý mravenec v procesu hledání podstoupí. Více iterací umožňuje podrobnější prohledávání, avšak zvyšuje výpočetní náročnost algoritmu. V současnosti parametr nastaven na hodnotu 30 iterací.
- **beta0** a **alpha** - atraktivita světlušek na začátku (beta0) je nastavena na 1 a faktor náhodnosti (alpha) je 0.2, což umožňuje světluškám prozkoumat širší spektrum potenciálních řešení.
- **gamma** - parametr stanovující míru poklesu atraktivity světlušky v závislosti na její vzdálenosti. Nyní je parametr nastaven na hodnotu 1.
- **maxsnimek** - Počet snímků, na něž je aplikován algoritmus. Nyní je zpracována celá videosekvence.



Obr. 4.5: Blokové schéma registrace dynamických obrazů - světluškový algoritmus.

4.4 Algoritmus PSO

4.4.1 Popis implementovaného algoritmu

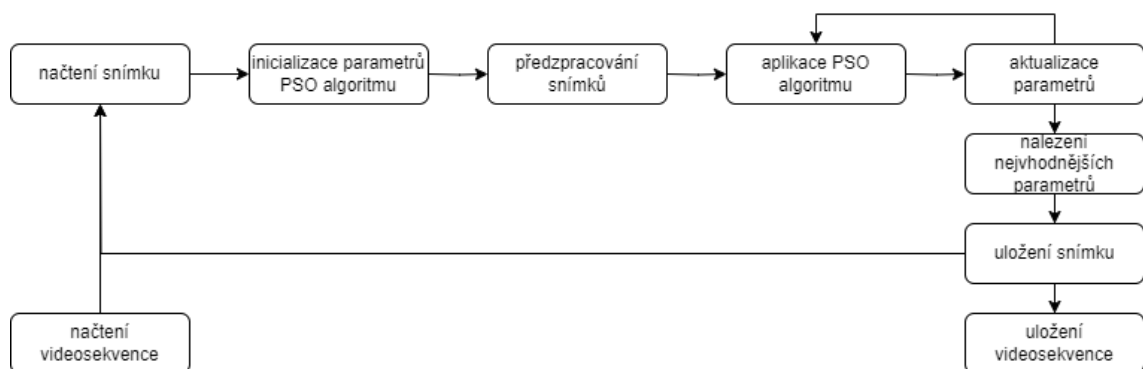
Čtvrtým, závěrečným algoritmem, je algoritmus PSO, který je implementován v matlabovském souboru *PSO.m*. Algoritmus PSO nejprve nastavuje jednotlivé parametry. Následně inicializuje náhodně pozice a rychlosti jednotlivých částic. Poté jsou inicializovány jednotlivé metriky (PSNR, NCC, kosinové kritérium, SSIM). V rámci hlavního cyklu dochází k aktualizaci pozice a rychlosti každé z částic, přitom je využita kognitivní a sociální komponenta. V závislosti na stanovených hodnotách transformačních parametrů dochází k registraci nového snímku na snímek stávající. Daný proces probíhá po stanovený počet generací, přičemž se na počátku další

generace náhodně vygenerují noví jedinci, z předchozí generace je ponechán pouze nejlepší jedinec. Následně je vzniklá videosekvence uložena. Blokové schéma 4.6 znázorňuje jednotlivé části algoritmu.

4.4.2 Návod k aplikaci PSO algoritmu

Na vstupu algoritmu jsou nastavovány následující parametry:

- **castice** - Parametr udávající počet částic v roji. Větší počet částic může vést k lepšímu prozkoumání prostoru řešení, ale zvyšuje výpočetní náročnost. V současnosti parametr nastaven na hodnotu 50 částic.
- **iterace** - Udává počet iterací, které algoritmus provede. Více iterací umožňuje částicím lépe prozkoumat prostor a potenciálně najít lepší řešení. V současnosti parametr nastaven na hodnotu 30 iterací.
- **w, c1, c2** - Parametry řídící dynamiku roje: w je váhový faktor určující schopnost částic neměnit svůj předchozí směr pohybu (tzv. inerce), $c1$ je kognitivní komponenta (váha vlastních zkušeností daného jedince), a $c2$ je tzv. sociální komponenta (váha zkušeností celého roje). Parametr w je nastaven na hodnotu 0,7, parametr $c1$ na hodnotu 1,5, parametr $c2$ na hodnotu 1,5.



Obr. 4.6: Blokové schéma registrace dynamických obrazů - PSO algoritmus.

5 Výsledky registrace obrazů

V této kapitole jsou představeny výsledky jednotlivých algoritmů. Vyhodnocení probíhalo třemi způsoby: v rámci subjektivního vyhodnocení bylo vytvořeno tzv. šachovnicové zobrazení. Takové zobrazení umožňuje vizuálně vyhodnotit ostrost obrazu. Dvojice obrazů je rozdělena na síť menších čtverců (či obdélníků). Jednotlivá pole, vizuálně připomínající šachovnici, reprezentují kombinaci obou obrazů - jeden z obrazů je reprezentován světlými segmenty, druhý tmavšími. Objektívni vyhodnocení proběhlo stanovením kritérií NCC, PSNR, SSIM a kosinového kritéria, u vybraných záznamů také porovnáním získaných parametrů transformace s předem dostupnými parametry získanými metodou fázové korelace. Objektívni vyhodnocení proběhlo s využitím 4 metrik (v případě genetického algoritmu pouze jednou metrikou - NCC). Algoritmy využívající evolučních principů obsahují stochastické prvky, proto se získané výsledky mohou při opětovném spuštění mírně lišit od výsledků uvedených v této práci. K tvorbě dílčích částí algoritmů byl využit nástroj ChatGPT ve verzi 4, a to v rozsahu specifikovaném v jednotlivých skriptech. Veškeré algoritmy byly vytvořeny v programovém prostředí Matlab ve verzi 2023b.


5.1 Genetický algoritmus

Statické snímky byly vyhodnoceny pomocí normalizované křížové korelace (NCC). Pro každý z 10 snímků algoritmus našel hodnotu rotace (v radiánech), translace ve směru osy X a osy Y (v pixelech) tak, aby bylo dosaženo co nejlepšího zarovnání obou obrazů. Výsledky byly zobrazeny vizuálně pro subjektivní vyhodnocení, následně také zaneseny do tabulky.

Následující dvojice obrázků 5.2, 5.1 a zachycují výsledky registrace. Zatímco v případě obrázku 5.1 (záznam č.2), bylo dosaženo poměrně dobré vizuální kvality registrace, vyskytly se také případy, kdy algoritmus nedosahoval zcela přesných výsledků. U záznamu č.4, znázorněném na obrázku 5.2, byla registrace úspěšná pouze zčásti, v určitých částech snímku je patrná diskontinuita v návaznosti v oblasti optického disku i cév. Vybraná místa jsou znázorněna červenými šipkami.


Dále bylo realizováno výše popsané šachovnicové zobrazení. Obrázky 5.3 a 5.4 znázorňují překryv snímků získaných fundus kamerou a videooftalmoskopem. Zatímco na obrázku 5.3 je patrná poměrně dobrá návaznost cév (ačkoliv se také objevují oblasti, kde návaznost není ideální), v případě obrázku 5.4 je takových oblastí mnoho (opět znázorněny červenými šipkami) - v daných oblastech neproběhla registrace snímků zcela ideálně. Co se týká vyhodnocení objektívniho, výsledky jsou shrnuty v tabulce 5.1.

Překryv originálního a transformovaného obrazu - záznam č.4




Obr. 5.1: Ukázka registrace fixního a modifikovaného obrazu - záznam č.4.

Překryv originálního a transformovaného obrazu - záznam č.2




Obr. 5.2: Ukázka registrace fixního a transformovaného obrazu - záznam č.2.

Šachovnicové zobrazení



Obr. 5.3: Šachovnicové zobrazení - záznam č.1.

Šachovnicové zobrazení



Obr. 5.4: Šachovnicové zobrazení - záznam č.2.

Č. snímku	Rot. [rad]	Tr. X [px]	Tr. Y [px]	NCC [-]
1	-0,033	46,046	48,430	0,9544
2	-0,051	47,526	44,505	0,8441
3	-0,187	43,490	44,294	0,8803
4	1,027	38,507	41,773	0,9369
5	0,236	50,706	46,368	0,8683
6	-0,029	46,399	35,036	0,9112
7	0,5897	36,991	51,896	0,9526
8	0,281	48,265	46,929	0,9596
9	1,709	47,366	45,164	0,8985
10	0,093	40,049	50,158	0,9232

Tab. 5.1: Parametry transformace u jednotlivých snímků nalezené genetickým algoritmem, výsledné hodnoty NCC.

Zaokrouhlené hodnoty kritéria NCC se pohybovaly v rozmezí 0,84 - 0,95. Nejnižší hodnoty, a to 0,8411, bylo dosaženo u záznamu č.2, nejvyšší (0,9544) pak u záznamu č.1. Při porovnání nalezených parametrů transformace jsou patrně poměrně velké rozptyly hodnot rotace (která nabývá kladných i záporných hodnot - uvedena v radiánech). V případě translace se nejnižší a nejvyšší hodnota liší cca o 15 pixelů. Nalezené parametry (včetně hodnoty NCC) se však mohou při opětovném spuštění algoritmu mírně lišit.

5.2 Algoritmus mravenčí kolonie

Následující snímky 5.5 a 5.6 ukazují porovnání zprůměrovaných snímků videosekvencí před a po provedené registraci. Zatímco v případě záznamu č.3 byly poměrně dobře patrné vizuální návaznosti polí šachovnice, u záznamu č.9 vznikl rozostřený obraz, který téměř znemožňuje jakoukoliv podrobnější analýzu, přesto jsou však v určitých částech dobře pozorovatelné návaznosti cév.

Také bylo provedeno šachovnicové zarovnání zprůměrovaného snímku se snímkem, který byl získán pomocí referenční registrační metody (fázové korelace). Pro srovnání byly opět zvoleny záznamy č.3 a č.9 (na snímcích 5.7 a 5.8). U záznamu č.9 je však návaznost vinou rozostřeného zprůměrovaného snímku z ACO algoritmu velmi málo patrná.


Následně byly vyhodnoceny jednotlivé metriky, výsledky byly shrnuty opět formou tabulky 5.2.

Č. videa	PSNR [dB]	SSIM [-]	kosinové kritérium [-]	NCC [-]
1	26,772	0,971	0,993	0,927
2	19,362	0,946	0,993	0,928
3	25,943	0,970	0,993	0,911
4	27,900	0,964	0,989	0,955
5	29,661	0,972	0,991	0,929
6	24,771	0,961	0,989	0,904
7	27,653	0,963	0,986	0,946
8	26,093	0,969	0,990	0,917
9	18,770	0,911	0,988	0,844
10	29,687	0,975	0,991	0,927

Tab. 5.2: Výsledné hodnoty kritérií u ACO algoritmu.


Ze získaných hodnot lze usoudit tyto závěry: hodnoty kritéria PSNR se pohybují v rozmezí od 18,77 dB u záznamu č.2 po 29,69 dB u záznamu č.10. Kritérium SSIM má rozpětí od minima 0,911 u záznamu č.9 po 0,975 u záznamu č.10. Záznam č.10 dosahoval poměrně vysokých hodnot i u kosinového kritéria a maxima normalizované křížové korelace, kde tyto hodnoty činí 0,991 a 0,927. V případě kosinového kritéria byly získány ještě mírně vyšší hodnoty, a to 0,993, shodně u záznamů č.1, 2 a 3. Hodnota maxima normalizované křížové korelace pak činila 0,955 u záznamu č.4. Nejnižších hodnot u sledovaných parametrů bylo dosaženo v případě záznamu č.9.

Šachovnicové zobrazení



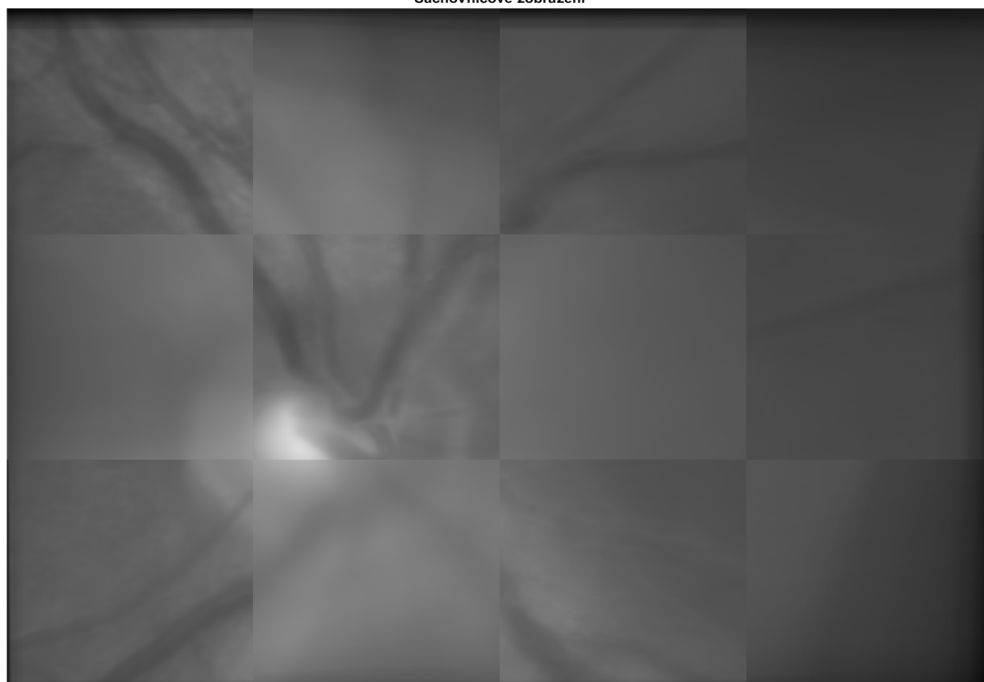
Obr. 5.5: Šachovnicové zobrazení - záznam č.3.

Šachovnicové zobrazení




Obr. 5.6: Šachovnicové zobrazení - záznam č.9.

Šachovnicové zobrazení



Obr. 5.7: Šachovnicové zobrazení - záznam č.3.

Šachovnicové zobrazení



Obr. 5.8: Šachovnicové zobrazení - záznam č.9.

5.3 Světluškový algoritmus

Následující snímky 5.9 a 5.10 ukazují porovnání zprůměrovaných snímků videosekvencí před a po provedené registraci. V případě záznamu č.8 byly vizuální návaznosti polí šachovnice patrné poměrně dobře navzdory tmavším sekvencím, u záznamu č.2, kde bylo dosaženo horších kvantitativních parametrů, je návaznost periferních cév také poměrně dobře patrná.

Také u tohoto algoritmu bylo provedeno šachovnicové zarovnání zprůměrovaného snímku se snímkem, který byl získán pomocí referenční registrační metody (fázové korelace). Vybrány byly záznamy č.2 a 8, znázorněné na snímcích 5.11 a 5.12.

V případě tohoto porovnání je vizuálně patrnější kvalitnější výsledek registrace záznamů s využitím fázové korelace. Navzdory tomu je u obou záznamů, a to i u tmavšího záznamu č.8, poměrně dobře patrná návaznost v oblasti optického disku i periferních cév.


Následně byly vyhodnoceny jednotlivé metriky, výsledky byly shrnuty opět formou tabulky 5.3.

Č. videa	PSNR [dB]	SSIM [-]	kosinové kritérium [-]	NCC [-]
1	25,838	0,978	0,999	0,995
2	17,559	0,933	0,998	0,972
3	24,249	0,969	0,998	0,968
4	27,408	0,965	0,996	0,989
5	33,160	0,978	0,997	0,986
6	24,099	0,961	0,996	0,968
7	27,441	0,962	0,993	0,985
8	24,828	0,972	0,999	0,995
9	17,518	0,896	0,993	0,901
10	39,413	0,991	0,999	0,997

Tab. 5.3: Výsledné hodnoty kritérií u světluškového algoritmu.


Při pohledu na tabulku je patrné, že nejvyšších hodnot u sledovaných parametrů se podařilo dosáhnout v případě záznamu č.5 a 10. Nízkých hodnot kritérií pak u záznamů č.2 a 9. Hodnoty kritéria PSNR se pohybují v rozmezí od 17,51 dB u záznamu č.9 po 39,41 dB u záznamu č.10. Kritérium SSIM má rozpětí od minima 0,896 u záznamu č.9 po 0,991 u záznamu č.10. Záznam č.10 dosahoval opět vysokých hodnot i u kosinového kritéria a maxima normalizované křížové korelace, kde tyto hodnoty činí 0,999 a 0,997. U kosinového kritéria i maxima normalizované křížové korelace bylo dosaženo (až na jednu výjimku u záznamu č.9) vždy hodnot nad 0,96.

Šachovnicové zobrazení




Obr. 5.9: Šachovnicové zobrazení - záznam č.8.

Šachovnicové zobrazení




Obr. 5.10: Šachovnicové zobrazení - záznam č.2.

Šachovnicové zobrazení



Obr. 5.11: Šachovnicové zobrazení - záznam č.8.

Šachovnicové zobrazení



Obr. 5.12: Šachovnicové zobrazení - záznam č.2.

5.4 Algoritmus PSO

Následující snímky 5.13 a 5.14 ukazují porovnání zprůměrovaných snímků video-sequencí před a po provedené registraci. V případě těchto záznamů byly vizuální návaznosti polí šachovnice patrné jen velmi málo z důvodu velkého rozostření obou obrazů.

Také bylo provedeno šachovnicové zarovnání zprůměrovaného snímku se snímkem, který byl získán pomocí referenční registrační metody (fázové korelace). Vybrány byly opět záznamy č.7 a 6, znázorněné na snímcích 5.15 a 5.16.


Z vizuálního zhodnocení obou šachovnicových zobrazení vyplývá, že u obou záznamů bylo opět dosaženo kvalitnějších výsledků s využitím fázové korelace. Záznam č.7 je sice tmavší, ale přesto jsou na něm poměrně dobře patrné návaznosti retinálních cév. Návaznost optického disku tentokrát není příliš dobrá. U záznamu č.6 v některých místech retinální cévy nenavazují přesně, optický disk v místě kontaktu polí taktéž příliš nenavazuje. Následně byly vyhodnoceny jednotlivé metriky, výsledky byly shrnuty opět formou tabulky.

Č. videa	PSNR [dB]	SSIM [-]	kosinové kritérium [-]	NCC [-]
1	29,687	0,975	0,991	0,927
2	17,724	0,930	0,996	0,968
3	23,041	0,959	0,996	0,959
4	26,240	0,955	0,991	0,990
5	31,285	0,977	0,995	0,978
6	23,014	0,955	0,992	0,954
7	26,606	0,959	0,991	0,982
8	24,291	0,967	0,998	0,991
9	17,77	0,900	0,985	0,962
10	37,495	0,989	0,999	0,995

Tab. 5.4: Výsledné hodnoty kritérií u PSO algoritmu.


Ze získaných výsledků je patrné rozmezí, v němž se pohybovaly jednotlivé koeficienty. V případě koeficientu PSNR činí rozmezí od 17,72 dB (u záznamu č.2) do 37,49 dB (u záznamu č.10). Index SSIM se pohybuje v rozmezí od 0,930 po 0,989, kosinové kritérium činí u všech záznamů (vyjma záznamu č.9) více než 0,99 a hodnoty normalizované křížové korelace se pohybují v rozmezí od 0,927 po 0,995. Při celkovém pohledu na všechny záznamy je patrné, že nejpriznivějších výsledků napříč sledovanými parametry se podařilo dosáhnout u záznamů 1, 5 a 10, nejnižších opět u záznamů č.2 a 9.

Šachovnicové zobrazení




Obr. 5.13: Šachovnicové zobrazení - záznam č.7.

Šachovnicové zobrazení




Obr. 5.14: Šachovnicové zobrazení - záznam č.6.

Šachovnicové zobrazení



Obr. 5.15: Šachovnicové zobrazení - záznam č.7.

Šachovnicové zobrazení



Obr. 5.16: Šachovnicové zobrazení - záznam č.6.

5.5 Srovnání získaných výsledků s jinými studii

V rámci této práce bylo také realizováno srovnání dosažených výsledků s jinými studii, které se zaměřují na zpracování snímků oční sítnice. Jedna z těchto studií, založená na využití neuronových sítí (typu GAN) s aktivační funkcí typu ReLU, popisuje zpracování snímků oční sítnice za účelem detekce změn na sítnici. Autoři studie data testují na několika různých datasetech, k vyhodnocení používají metriky PSNR a SSIM, porovnávají přitom jejich metodu s již existujícími metodami (například bikubickou interpolační metodou). Hodnoty PSNR se u jednotlivých metod pohybují v rozmezí od 36,8 do 38,2 decibelů, hodnoty SSIM v rozmezí od 0,964 po 0,978.[7]

Autoři další studie provádí úpravy snímků oční sítnice pomocí modifikace kontrastu. Realizují metodu ekvalizace histogramu (HE) a kontrastně limitované ekvalizace histogramu (CLAHE). Snímky jsou zpracovány v RGB a poté i LAB prostoru. Vyhodnocení provádí na sadě 1200 snímků, opět stanovují průměrné PSNR a SSIM. U klasické ekvalizace histogramu činí průměrné PSNR přibližně 25,8 (v obou prostorech, RGB i LAB), u CLAHE dosahuje průměrné PSNR hodnoty 8,7 v RGB prostoru, 9,5 v LAB prostoru. Průměrné hodnoty SSIM činí 0,5 (RGB), respektive 0,6 (LAB) u klasické ekvalizace histogramu, u CLAHE pak 0,3 u RGB i LAB prostoru.[11]

Za zmínku stojí také studie, která používá klasický genetický algoritmus a metodu PSO. Autoři provádí optimalizaci záznamů pomocí různých druhů entropií (Rényiho, Masiho, Shannonovy). Vyhodnocení je realizováno pomocí metrik PSNR, SSIM a FSIM, a to na dvaceti záznamech. Také je využito prahování do několika tříd (autoři ve studii používají 2 - 7 prahů) za účelem zlepšení kvality segmentace. Po použití nejvyššího počtu prahů je dosaženo těchto výsledků: PSNR činí průměrně 25,5 dB u genetického algoritmu a 29 dB u PSO algoritmu, SSIM 0,77 u genetického algoritmu a 0,79 u PSO algoritmu. Pro úplnost je vhodné doplnit i výsledné hodnoty FSIM, ta se pohybuje na úrovni 0,88 u genetického algoritmu a 0,89 u PSO algoritmu.[14] Při porovnání výsledků získaných v rámci této diplomové práce s výsledky publikovanými ve výše zmíněných publikacích je patrné, že se pro určité snímky podařilo dosáhnout podobné úspěšnosti. Dané srovnání je však potřebné brát s určitou rezervou, záleží vždy na použitém datasetu a konkrétní modifikaci dané metody.

Závěr

Cílem této diplomové práce bylo formou literární rešerše představit teoretické informace spojené s tématem evolučních algoritmů, prozkoumat praktické využití evolučních technik pro optimalizační úlohy a v návaznosti také pro praktický část práce - registraci oční sítnice.

Úvodní část práce popisuje využití evolučních technik při řešení různých problémů a simulaci dějů v přírodě. Podkapitola zaměřená na konkrétní evoluční metody popisuje různé optimalizační přístupy, které byly navrženy a prakticky realizovány.

Následně se práce zaměřuje na různé druhy geometrických transformací obrazů. Kromě samotného popisu jsou jednotlivé varianty transformace doplněny i názornými ukázkami. Poté je stručně čtenáři práce popsána anatomie oka, jsou představeny jednotlivé části oka.

Dále jsou zachyceny různé metody, které byly využity k registraci obrazu oční sítnice s využitím odlišných kritérií, například maximální věrohodnost, optimalizaci s využitím hejna částic nebo konvenční evoluční algoritmus.

V kapitole věnované praktické části je navržena metoda registrace statických snímků s využitím genetického algoritmu, vyhodnocení probíhá pomocí metriky normalizovaná křížová korelace. Výsledky této metody jsou shrnuty v příložené tabulce, u vybraných dvojic snímků jsou taktéž graficky vyobrazeny. Pro určité záznamy se podařilo dosáhnout poměrně slušných výsledků registrace, u jiných záznamů byla úspěšnost registrace nižší.

V rámci praktické části byla také realizována trojice algoritmů (světluškový algoritmus, algoritmus mravenčí kolonie a algoritmus hejna částic) za účelem registrace dynamických snímků. Registrace probíhala formou výběru prvního snímku z dané videosekvence, na něhož byly postupně registrovány snímky následující. Tyto metody byly hodnoceny nejprve subjektivně - šachovnicovým zarovnáním, posléze objektivně pomocí metrik SSIM, PSNR, kosinového kritéria a normalizované křížové korelace (NCC).

Při vzájemném porovnání tabulek jednotlivých metod je patrné, že nejvyšších hodnot SSIM indexu a PSNR bylo dosaženo u světluškového a PSO algoritmu. Co se týká maxima normalizované křížové korelace a kosinového kritéria, tyto parametry dosahovaly (až na lokální výjimky) poměrně vyrovnaných hodnot. Algoritmu mravenčí kolonie naopak vykazoval mírně vyrovnanější hodnoty PSNR a SSIM, ačkoliv i v tomto případě se vyskytla odlehlejší minima a maxima. Komplexní zhodnocení algoritmů z hlediska nejvyšší úspěšnosti představuje složitou otázku i s ohledem na fakt, že vstupní záznamy nepocházely od jednoho jedince, některé záznamy byly znehodnoceny určitými artefakty (prudší pohyb scény, případně výskyt krátké sekvence

bílých snímků u některých záznamů).

Na základě subjektivního (vizuálního) i objektivního zhodnocení je patrné, že se jednotlivým algoritmům algoritmu podařilo provést registraci snímků s poměrně dobrou úspěšností. Nejpříznivějších hodnot se podařilo dosáhnout u záznamů č. 5 a 10, vyskytly se však i případy, u nichž byla patrná nižší účinnost registrace. Typicky se jednalo o záznamy č.2 a 9, které vykazovaly vyšší parametry translace a rotace mezi jednotlivými snímky, což proces registrace příliš neulehčovalo.

Celkovou kvalitu registrace snímků ovlivňuje řada parametrů, které bezprostředně s daným algoritmem souvisí, jako je velikost populace, počet cyklů, během nichž je algoritmus spuštěn, další parametry konkrétních algoritmů (jako je např. míra vypařování feromonové stopy), vliv má samozřejmě i konkrétní kritériální funkce, podmínky ukončení činnosti algoritmu atd. Určitými modifikacemi (zvýšením počtu iterací, počtu jedinců, úpravou dalších parametrů algoritmů) je možné dosáhnout kvalitnějších výsledků registrace včetně vizuálního vzhledu videosekvence (hladších přechodů mezi jednotlivými snímky), často ovšem na úkor zvýšené časové a výpočetní náročnosti.

Genetické i evoluční algoritmy mají velký potenciál pro registraci obrazových dat sítě, a to jak pro statické, tak i dynamické snímky. Navržené metody mohou být dále optimalizovány a rozvíjeny pro zlepšení jejich přesnosti a efektivity.

Literatura

- [1] BÄCK, Thomas; GÜNTER, Rudolph a SCHWEFEL, Hans-Paul, 1997. Evolutionary Programming and Evolution Strategies: Similarities and Differences. Online. Dostupné také z: https://www.researchgate.net/publication/2611695_Evolutionary_Programming_and_Evolution_Strategies_Similarities_and_Differences.
- [2] BEYER, Hans-Georg a Hans-Paul SCHWEFEL. Evolution strategies – A comprehensive introduction. [online]. Natural Computing. 2002, roč. 1, č. 1, s. 3-52. ISSN 15677818. Dostupné z: <https://doi.org/10.1023/A:1015059928466>.
- [3] Digital Retinal Camera CR-1: Operation Manual. Online. Dostupné také z: <https://www.digitaleyecenter.com/wp-content/uploads/2015/10/Canon-CR-1-user-manual.pdf>.
- [4] COCIANU, Catalina-Lucia a Alexandru STAN. New Evolutionary-Based Techniques for Image Registration. Applied Sciences [online]. 2019, roč. 9, č. 1, s. 507-512. ISSN 2076-3417. Dostupné z: [doi:10.3390/app9010176](https://doi.org/10.3390/app9010176).
- [5] COCIANU, Catalina-Lucia, Alexandru Daniel STAN a Mihai AVRAMESCU. Firefly-Based Approaches of Image Recognition. Symmetry [online]. 2020, roč. 12, č. 6, s. 8-18. ISSN 2073-8994. Dostupné z: <https://doi.org/10.3390/sym12060881>.
- [6] DESHPANDE, Renuka Girish; RAGHA, Lata L a SHARMA, Satyendra Kumar, 2018. Video Quality Assessment through PSNR Estimation for Different Compression Standards. Online. Indonesian Journal of Electrical Engineering and Computer Science. 2018-09-01, roč. 11, č. 3, s. 918-924. ISSN 2502-4760. Dostupné z: <https://doi.org/10.11591/ijeecs.v11.i3.pp918-924>.
- [7] B, Dhanusha P; MUTHUKUMAR, A a LAKSHMI, A, 2022. Super-resolution of Retinal Fundus Images Using Generative Adversarial Networks. Online. 2022 Second International Conference on Next Generation Intelligent Systems (ICNGIS). 2022-7-29, s. 1-4. ISBN 978-1-6654-6792-6. Dostupné z: <https://doi.org/10.1109/ICNGIS54955.2022.10079882>.
- [8] DORIGO, Marco, Mauro BIRATTARI a Thomas STUTZLE. Ant colony optimization. IEEE Computational Intelligence Magazine [online]. 2006, roč. 1, č. 4, s. 28-39. ISSN 1556-603X. Dostupné z: [doi:10.1109/MCI.2006.329691](https://doi.org/10.1109/MCI.2006.329691).
- [9] FENG, Ruitao, Qingyun DU, Huanfeng SHEN a Xinghua LI. Region-by-Region Registration Combining Feature-Based and Optical Flow Methods for Remote

- Sensing Images. [online]. Remote Sensing. 2021, roč. 13, č. 8. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs13081475>.
- [10] Crossover in Genetic Algorithm, 2023. Online. <https://www.geeksforgeeks.org/>. Dostupné také z: <https://media.geeksforgeeks.org/wp-content/uploads/20190620121215/singleCrossover-2.png>.
- [11] GUPTA, Bhupendra; TIWARI, Mayank a LAKSHMI, A, 2022. Color retinal image enhancement using luminosity and quantile based contrast enhancement. Online. Multidimensional Systems and Signal Processing. 2022-7-29, roč. 30, č. 4, s. 1829-1837. ISBN 978-1-6654-6792-6. ISSN 0923-6082. Dostupné z: <https://doi.org/10.1007/s11045-019-00630-1>.
- [12] GUPTA, Sunanda; GROVER, Naresh a ZAHEERUDDIN, 2016. A New Optimization Approach Using Smoothed Images Based on ACO for Medical Image Registration. Online. International Journal of Information Engineering and Electronic Business. 2016-03-08, roč. 8, č. 2, s. 30-36. ISSN 20749023. Dostupné z: <https://doi.org/10.5815/ijieeb.2016.02.04>.
- [13] HAUPT, Randy L a S. E HAUPT. Practical genetic algorithms. 2nd ed. Hoboken, N.J.: John Wiley, c2004. ISBN 9780471455653.
- [14] HILALI-JAGHDAM, Inès; BEN ISHAK, Anis; ABDEL-KHALEK, S. a JAMAL, Amani, 2022. Quantum and classical genetic algorithms for multilevel segmentation of medical images: A comparative study. Online. Computer Communications. 2022-7-29, roč. 162, č. 4, s. 83-93. ISBN 978-1-6654-6792-6. ISSN 01403664. Dostupné z: <https://doi.org/10.1016/j.comcom.2020.08.010>.
- [15] HU, Haidong; PUN, Chi-Man; LIU, Ye; LAI, Xiangjing; YANG, Zeyu et al., 2020. An artificial bee algorithm with a leading group and its application into image registration. Online. Multimedia Tools and Applications. Roč. 79, č. 21-22, s. 14643-14669. ISSN 1380-7501. Dostupné z: <https://doi.org/10.1007/s11042-019-7211-6>.
- [16] JAN, Jiří. Medical image processing, reconstruction and analysis: concepts and methods. Second edition. London: CRC Press, 2020. ISBN 978-1-138-31028-5.
- [17] KACHITVICHYANUKUL, Voratas a POLI, Riccardo, 2012. Comparison of Three Evolutionary Algorithms: GA, PSO, and DE. Online. Industrial Engineering and Management Systems. 2012-09-30, roč. 11, č. 3, s. 215-223. ISSN 1598-7248. Dostupné z: <https://doi.org/10.7232/iems.2012.11.3.215>.

- [18] KATOCH, Sourabh, Sumit Singh CHAUHAN a Vijay KUMAR. A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications* [online]. Cham: Springer International Publishing, 2021, s. 8091-8126. ISSN 1380-7501. Dostupné z: [doi:10.1007/s11042-020-10139-6](https://doi.org/10.1007/s11042-020-10139-6).
- [19] KOLAR, Radim; VICAR, Tomas; ODSTRCILIK, Jan; VALTEROVA, Eva; SKORKOVSKA, Karolina et al., 2022. Multispectral retinal video-ophthalmoscope with fiber optic illumination. Online. *Journal of Biophotonics*. Roč. 15, č. 9. ISSN 1864-063X. Dostupné z: <https://doi.org/10.1002/jbio.202200094>.
- [20] KOZA, John a POLI, Riccardo, 2005. Genetic Programming. Online. Dostupné také z: https://www.researchgate.net/publication/229091441_Genetic_Programming.
- [21] KUBALOVÁ, Eva. Využití evolučních algoritmů pro lícování obrazu. [online]. Brno, 2017. Diplomová práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství. Vedoucí práce Martin Mézl. Dostupné z: <http://hdl.handle.net/11012/65479>.
- [22] KUMAR, Vijay a KUMAR, Dinesh, 2021. A Systematic Review on Firefly Algorithm: Past, Present, and Future. Online. *Archives of Computational Methods in Engineering*. Roč. 28, č. 4, s. 3269-3291. ISSN 1134-3060. Dostupné z: <https://doi.org/10.1007/s11831-020-09498-y>.
- [23] MALLAWAARACHCHI, Vijini, 2017. Introduction to Genetic Algorithms — Including Example Code. Online. In: [Www.towardsdatascience.com](http://www.towardsdatascience.com). Dostupné také z: <https://towardsdatascience.com/introduction-to-genetic-algorithms-including-example-code-e396e98d8bf3>.
- [24] MARINI, Federico a WALCZAK, Beata, 2015. Particle swarm optimization (PSO). A tutorial. Online. *Chemometrics and Intelligent Laboratory Systems*. Roč. 149, s. 153-165. ISSN 01697439. Dostupné z: <https://doi.org/10.1016/j.chemolab.2015.08.020>.
- [25] MARTÍNEZ-RÍO, Javier; CARMONA, Enrique J.; CANCELAS, Daniel; NOVO, Jorge a ORTEGA, Marcos, 2021. Robust multimodal registration of fluorescein angiography and optical coherence tomography angiography images using evolutionary algorithms. Online. *Computers in Biology and Medicine*. Roč. 134. ISSN 00104825. Dostupné z: <https://doi.org/10.1016/j.compbimed.2021.104529>.

- [26] MIRJALILI, Seyedali, Jin SONG DONG, Ali Safa SADIQ a Hossam FARIS. Genetic Algorithm: Theory, Literature Review, and Application in Image Reconstruction. *Nature-Inspired Optimizers*. [online]. Cham: Springer International Publishing, 2020, s. 69-85. ISSN 20054254. Dostupné z: doi:10.1007/978-3-030-12127-35.
- [27] Basics of affine transformation. [online]. Neutrium. 11.9.2012. Dostupné z: <https://neutrium.net/mathematics/basics-of-affine-transformation/>.
- [28] PENCHEVA, Tania; ATANASSOV, K. a SHANNON, A., 2009. Modeling of a Roulette Wheel Selection Operator in Genetic Algorithms Using Generalized Nets. Online. Dostupné také z: https://www.biomed.bas.bg/bioautomation/2009/vol_13.4/files/13.4_5.01.pdf.
- [29] PERERA, Yasith S.; RATNAWEERA, D.A.A.C.; DASANAYAKA, Chamila H. a ABEYKOON, Chamil, 2023. The role of artificial intelligence-driven soft sensors in advanced sustainable process industries: A critical review. Online. *Engineering Applications of Artificial Intelligence*. Roč. 121. ISSN 09521976. Dostupné z: <https://doi.org/10.1016/j.engappai.2023.105988>.
- [30] REEVES, Colin R. Genetic Algorithms. In: GENDREAU, Michel a Jean-Yves POTVIN. *Handbook of Metaheuristics*. International Series in Operations Research & Management Science 146. Springer Science+Business Media, LLC, 2010, s. 109-133. ISBN 978-1-4419-1665-5. DOI: 10.1007/978-1-4419-1665-5_5.
- [31] SARA, Umme, Morium AKTER a Mohammad Shorif UDDIN. Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study. *Journal of Computer and Communications*. 2019, roč. 07, č. 03, s. 8-18. ISSN 2327-5219. Dostupné z: <https://doi.org/10.4236/jcc.2019.73002>.
- [32] SEIXAS, Flavio Luiz, Luiz Satoru OCHI, Aura CONCI a Débora Muchaluat SAADE. Image registration using genetic algorithms. [online]. New York, New York, USA: ACM Press, 2008, s. 1145-1146. ISBN 9781605581309. Dostupné z: doi:10.1145/1389095.1389320.
- [33] TIAN, Ying, Hao Di MA a Mihai AVRAMESCU. Image Registration Based on Improved Ant Colony Algorithm. *Advanced Materials Research*. [online]. 2013, roč. 765-767, č. 6, s. 683-686. ISSN 1662-8985. Dostupné z: <https://doi.org/10.4028/www.scientific.net/AMR.765-767.683>.
- [34] Transformations in Math. Online. In: . Dostupné také z: <https://www.cuemath.com/geometry/transformations/>.

- [35] TROGLIO, G.; BENEDIKTSSON, J.A.; SERPICO, S.B.; MOSER, G.; KARLSSON, R.A. et al., 2008. Automatic registration of retina images based on genetic techniques. Online. 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. S. 5419-5424. ISBN 978-1-4244-1814-5. Dostupné z: <https://doi.org/10.1109/IEMBS.2008.4650440>.
- [36] VALSECCHI, Andrea, Sergio DAMAS a Jose SANTAMARIA. An image registration approach using genetic algorithms. 2012 IEEE Congress on Evolutionary Computation. [online]. IEEE, 2012, s. 1-8. ISBN 978-1-4673-1509-8. Dostupné z: [doi:10.1109/CEC.2012.6256162](https://doi.org/10.1109/CEC.2012.6256162).
- [37] VALSECCHI, Andrea; DUBOIS-LACOSTE, Jeremie; STUTZLE, Thomas; DAMAS, Sergio; SANTAMARIA, Jose et al., 2013. Evolutionary medical image registration using automatic parameter tuning. Online. 2013 IEEE Congress on Evolutionary Computation. S. 1326-1333. ISBN 978-1-4799-0454-9. Dostupné z: <https://doi.org/10.1109/CEC.2013.6557718>.
- [38] WACHOWIAK, M.P.; SMOLIKOVA, R.; ZHENG, Y.; ZURADA, J.M. a ELMAGHRABY, A.S., 2004. An Approach to Multimodal Biomedical Image Registration Utilizing Particle Swarm Optimization. Online. IEEE Transactions on Evolutionary Computation. Roč. 8, č. 3, s. 289-301. ISSN 1089-778X. Dostupné z: <https://doi.org/10.1109/TEVC.2004.826068>.
- [39] XIAO, Di. Retinal image registration and comparison for clinical decision support. Australasian Medical Journal. [online]. 2012, roč. 5, č. 9, s. 507-512. ISSN 18361935. Dostupné z: [doi:10.4066/AMJ.2012.1364](https://doi.org/10.4066/AMJ.2012.1364).
- [40] YANG, Xin-She, 2014. Nature-Inspired Optimization Algorithms. Online. Dostupné z: <https://doi.org/10.1016/C2013-0-01368-0>.