

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2017

Bc. Eva Kubalová



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

**VYUŽITÍ EVOLUČNÍCH ALGORITMŮ PRO LÍCOVÁNÍ
OBRAZU**

IMAGE REGISTRATION USING EVOLUTIONARY ALGORITHMS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Eva Kubalová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Martin Mézl

BRNO 2017



Diplomová práce

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

Ústav biomedicínského inženýrství

Studentka: Bc. Eva Kubalová

ID: 147613

Ročník: 2

Akademický rok: 2016/17

NÁZEV TÉMATU:

Využití evolučních algoritmů pro lícování obrazu

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s evolučními algoritmy pro matematickou optimalizaci. Proveďte rešerši využití těchto metod pro registraci obrazu. 2) Seznamte se s principem perfúzního zobrazování pomocí ultrazvuku a s problematikou registrace obrazu u ultrazvukových dat. 3) Implementujte vybranou kritériální funkci a alespoň jednu optimalizační metodu v programovém prostředí Matlab. Metody ověřte na testovacích snímcích. 4) Práci rozšiřte o implementaci dalších evolučních algoritmů. 5) Navržené algoritmy otestujte na dynamických ultrazvukových sekvencích, které budou poskytnuty vedoucím práce. 6) Proveďte vyhodnocení úspěšnosti registrace pomocí jednotlivých metod ve srovnání s manuální korekcí pohybu a jinými volně dostupnými implementovanými metodami.

DOPORUČENÁ LITERATURA:

[1] DAMAS, S., O. CORDÓN a J. SANTAMARÍA. Medical Image Registration Using Evolutionary Computation: An Experimental Survey. IEEE Computational Intelligence Magazine. 2011, 6(4): 26-42.

[2] HAUPT, Randy L a Witold PEDRYCZ. Practical genetic algorithms: a comprehensive framework of computational intelligence. 2nd ed. Hoboken, N.J.: Wiley-Interscience, 2004, xvii, 253 s. ISBN 978-0-471-45-65-3.

Termín zadání: 6.2.2017

Termín odevzdání: 19.5.2017

Vedoucí práce: Ing. Martin Mézl

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

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

Táto práca sa zaoberá využitím evolučných algoritmov pre lícovanie obrazových dát ako novšie používanou metaheuristickou optimalizačnou metódou. Obsahuje teoretický popis lícovania obrazov, s neskorším zameraním na ultrazvukové obrazy. Teoretickú časť dopĺňa kapitola zaoberajúca sa vybranými evolučnými algoritmami. Realizované boli tri optimalizačné metódy a to genetický algoritmus, metóda roja častíc a svetluškový algoritmus. Z pohľadu optimalizácie kritériálnej funkcie boli vybrané kritériá suma štvorcov rozdielov, kosínové kritérium a korelačný koeficient. Hlavnou časťou práce je testovanie navrhnutých algoritmov s cieľom ich optimálneho nastavenia pre následnú registráciu reálnych ultrazvukových sekvencií získaných pomocou kontrastného zobrazovania. Záver práce sa venuje vyhodnoteniu dosiahnutých úspešností registrácie.

KĽÚČOVÉ SLOVÁ

registrácia obrazov, kritériálna funkcia, optimalizácia, genetický algoritmus, ultrazvukové obrazy, perfúzne zobrazovanie, metóda roja častíc, svetluškový algoritmus

ABSTRACT

The diploma thesis deals with the image registration using evolutionary algorithms from metaheuristic optimization techniques which are considered recent and widely used. The first part of the thesis contains theoretical description of components in image registration and later focuses on the ultrasound images. In that part, the thesis explains chosen evolutionary algorithms. Three optimization methods have been implemented, in particular genetic algorithm, particle swarm optimization and firefly algorithm. Chosen similarity metrics for optimization are sum of squared differences, cosine similarity and correlation coefficient. The main part of thesis includes testing of proposed methods with the evaluation of obtained results. These parameters are later used for optimization of real ultrasound sequences obtained by the contrast imaging.

KEYWORDS

image registration, objective function, optimization, genetic algorithm, ultrasound images, perfusion imaging, particle swarm optimization, firefly algorithm

KUBALOVÁ, Eva *Využití evolučních algoritmů pro lícování obrazu*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2017. 86 s. Vedúci práce bol Ing. Martin Mézl

VYHLÁSENIE

Vyhlasujem, že som svoju diplomovú prácu na tému „Využití evolučních algoritů pro lícování obrazu“ vypracovala samostatne pod vedením vedúceho diplomovej práce, využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autorka uvedenej diplomovej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušila autorské práva tretích osôb, najmä som nezasiahla nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomá následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávnych dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákoníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autorky

POĎAKOVANIE

Rada by som poďakovala vedúcemu diplomovej práce pánovi Ing. Martinovi Mészlovi, za jeho odborné vedenie, konzultácie, čas, podnetné a konštruktívne návrhy k vypracovaniu diplomovej práce.

Brno

.....

podpis autorky

OBSAH

Úvod	11
1 Lícovanie obrazových dát	12
1.1 Geometrické transformácie	13
1.1.1 Rigidné transformácie	14
1.1.2 Flexibilné transformácie	15
1.1.3 Nelineárne transformácie	16
1.2 Podobnostné kritériá	16
1.2.1 Kritériá založené na intenzitách pixlov	17
1.2.2 Kritériá založené na vzájomnej informácii	18
1.3 Optimalizácia	19
1.3.1 Prehľad optimalizačných metód	21
2 Metaheuristické algoritmy optimalizácie	23
2.1 Simulované žihanie	23
2.2 Evolučné algoritmy	24
2.2.1 Genetické algoritmy	24
2.2.2 Popis dát pre genetické algoritmy	25
2.2.3 Genetický algoritmus	25
2.2.4 Terminológia v genetických algoritmoch	27
2.3 Metóda roja častíc	30
2.4 Svetluškový algoritmus	30
2.4.1 Princíp svetluškového optimalizačného algoritmu	31
3 Registrácia ultrazvukových dát	33
3.1 Perfúzne zobrazenie	34
4 Realizácia na simulovaných dátach	37
4.1 Testované obrazy	37
4.1.1 Výber oblasti záujmu	37
4.1.2 Kritériálne funkcie	38
4.2 Proces optimalizácie	39
4.2.1 Optimalizácia genetickým algoritmom	40
4.2.2 Optimalizácia rojovým algoritmom	42
4.2.3 Optimalizácia svetluškovým algoritmom	43
4.2.4 Kritériá úspešnosti registrácie	44

5	Vyhodnotenie úspešnosti testovania	46
5.1	Vyhodnotenie optimalizácie genetickým algoritmom	46
5.1.1	Vplyv množstva jedincov a počtu iterácií	46
5.1.2	Pravdepodobnosť a váha mutácie	54
5.1.3	Časová náročnosť genetických algoritmov	57
5.1.4	Výber optimálneho nastavenia parametrov	58
5.2	Vyhodnotenie optimalizácie rojovým algoritmom	59
5.2.1	Časová náročnosť algoritmu rojenia častíc	60
5.2.2	Optimálne nastavenie parametrov	61
5.3	Vyhodnotenie optimalizácie svetluškovým algoritmom	62
5.3.1	Vplyv počtu svetlušiek a počtu iterácií	62
5.3.2	Vplyv zmeny parametrov alpha a beta	63
5.3.3	Časová náročnosť svetluškového algoritmu	64
5.3.4	Optimálne nastavenia parametrov svetlušiek	66
6	Testovanie na sekvenciách dát	67
6.1	Obsluha funkcie imregister	68
6.2	Výsledky registrácie sekvencie pankreasu	69
6.2.1	Úprava dát pre funkciu imregister	72
6.3	Výsledky registrácie sekvencie srdca prasata	73
7	Užívateľské rozhranie - GUI	78
8	Záver	80
	Literatúra	83

ZOZNAM OBRÁZKOV

1.1	Hlavné komponenty v procese lícovania obrazov [3]	13
2.1	Cyklus genetického algoritmu [8]	27
2.2	Príklad jednobodového kríženia	29
2.3	Príklad viacbodového kríženia	29
4.1	Zobrazenie obrazu pôvodného (vľavo) a po transformácii (vpravo)	38
4.2	Zobrazenie vhodnej oblasti záujmu (vľavo) a nevhodnej (vpravo)	39
4.3	Vývojový diagram realizovaného spojitého genetického algoritmu [16]	40
4.4	Vývojový diagram rojového algoritmu	42
4.5	Vývojový diagram svetluškového algoritmu	43
5.1	Závislosť kvality registrácie na počte iterácií a počte jedincov, SSD	47
5.2	Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, SSD	49
5.3	Závislosť kvality registrácie na počte iterácií a počte jedincov, COS	51
5.4	Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, COS	51
5.5	Závislosť kvality registrácie na počte iterácií a počte jedincov, CC	52
5.6	Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, CC	54
5.7	Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovacej konštante, SSD	55
5.8	Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovacej konštante, COS	56
5.9	Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovacej konštante, CC	56
5.10	Časová náročnosť výpočtu genetického algoritmu	57
5.11	Časová náročnosť výpočtu algoritmu rojenia častíc	61
5.12	Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, SSD	63
5.13	Závislosť Euklidovskej vzdialenosti na parametroch alfa a beta, SSD	64
5.14	Závislosť Euklidovskej vzdialenosti na parametroch alfa a beta 2, SSD	65
5.15	Časová náročnosť svetluškového algoritmu	65
6.1	Kvality registrovaných snímok pankreasu, COS	71
6.2	Upravený snímok pre registráciu s imregister	72
6.3	Ukážka snímok zo sekvencie srdca prasata	74
6.4	Kvality registrovaných snímok srdca prasata, COS	76
7.1	Grafické užívateľské rozhranie, hlavný panel	78
7.2	Grafické užívateľské rozhranie, hlavný panel	79

7.3	Grafické užívateľské rozhranie, vedľajší panel	79
-----	--	----

ZOZNAM TABULIEK

4.1	Parametre výpočetného nástroja	45
5.1	Tabuľka získaných výsledkov pre genetický algoritmus, SSD	48
5.2	Tabuľka získaných výsledkov pre genetický algoritmus, COS	50
5.3	Tabuľka získaných výsledkov pre genetický algoritmus, CC	53
5.4	Tabuľka priemerných kvalít a Euklidovských vzdialeností, rojenie častíc	60
6.1	Tabuľka súčtov kvalít registrácie pre sekvenciu pankreasu	69
6.2	Tabuľka priemerných kvalít registrácie pre sekvenciu pankreasu	70
6.3	Časová náročnosť registrácie sekvencie pankreasu	71
6.4	Pôvodné a upravené nastavenie konfigurácie multimodal	73
6.5	Tabuľka kvalít registrácie pre sekvenciu srdca prasata	74
6.6	Tabuľka priemerných kvalít registrácie pre sekvenciu srdca prasata	75
6.7	Časová náročnosť registrácie sekvencie srdca prasata	76

ÚVOD

V digitálnom spracovaní obrazov je častou požiadavkou čo najpresnejšie zarovnanie rozdielných obrazov. V medicínskom zobrazovaní ide o veľmi užitočný spôsob ako získať aj z obrazov obstaraných rôznymi modalitami potrebnú informáciu pre čo najpresnejšiu diagnostiku. Úspešná registrácia multimodálnych dát tak môže poskytnúť komplexnejšiu informáciu nielen o anatómii, ale aj o funkčnosti sledovaných štruktúr. Ide o náročnú úlohu, ktorej cieľom je nájsť optimálne parametre transformácie maximalizovaním stupňa podobnosti meraného podobnostným kritériom medzi obrazmi, s využitím optimalizačných metód. Problémom sa zdá byť prípad definovania problému ako hľadania globálneho riešenia, kde veľmi sľubnú možnosť poskytujú prístupy registrácie obrazov s evolučnými algoritmi. Zavedením vplyvu heuristiky eliminujú nežiadúce sklznutie do lokálneho minima funkcií, ktoré vo väčšine prípadov nie je totožné s hľadaným globálnym optimom.

Obzvlášť zložitá je registrácia dát z ultrazvukových zobrazovacích systémov, ktorá je stále predmetom štúdie s cieľom nájsť vhodné kritériálne funkcie ako aj optimalizačné metódy, ktoré budú použiteľné aj napriek typickému zašumeniu obrazov šumom vo forme speklí. Značne menej preskúmanou oblasťou je registrácia obrazov získaných kontrastným ultrazukovým zobrazením, ktoré je vhodné pre zobrazovanie prekrvenia častí orgánov, zvýrazneným pomocou kontrastnej látky. Snahou je dosiahnuť čo najväčšiu presnosť registrácie aj pri obvykle veľkom množstve ultrazvukových sekvencií s ohľadom na realizovateľnosť v prijateľnom čase.

Táto práca je rozdelená do 6 hlavných častí. Prvou časťou je uvedenie do problematiky lícovania obrazov s popisom hlavných komponent tohto procesu. V druhej kapitole je popísaný úvod k metaheuristickým algoritmom optimalizácie s bližším popisom vybraných evolučných algoritmov, ktorými sú genetické algoritmy, metódy roja častíc a svetluškové algoritmy. Tretia kapitola sa venuje registrácii ultrazvukových dát s priblížením niektorých doposiaľ študovaných prístupov odlišujúcich sa v použitej kritériálnej funkcii a optimalizačnej metóde. Štvrtá kapitola sa zaoberá popisom navrhnutých a realizovaných evolučných algoritmov ako optimalizačných metód s názorným vysvetlením formou vývojových diagramov. Piata a zároveň najrozsiahlejšia časť práce popisuje testovanie a následne vyhodnotenie metód z pohľadu dosiahnutej úspešnosti registrácie ultrazvukových dát, s cieľom nájsť čo najvšeobecnejšie optimálne nastavenia parametrov jednotlivých metód. Testovanie bolo založené na registrácii referenčného a transformovaného obrazu so známymi hodnotami transformácie pre transláciu a rotáciu. Ďalšou kapitolou je vyhodnotenie úspešnosti registrácie s vybranými optimalizačnými metódami na reálnych ultrazvukových sekvenciách získaných kontrastným zobrazením. Poslednou časťou je doplnenie užívateľského rozhrania (GUI) pre jednoduchšiu obsluhu navrhnutých algoritmov.

1 LÍCOVANIE OBRAZOVÝCH DÁT

Snaha o získanie novej alebo kvalitnejšej informácie kombinovaním už existujúcich obrazových dát je často využívaným postupom v procese spracovania obrazov, nielen v medicínskych aplikáciách.

Lícovaním obrazov sa rozumie proces, ktorého cieľom je čo najpresnejšie stotožnenie odpovedajúceho si obsahu dvoch obrazov. Ide o geometrickú transformáciu, v prípade dvoch obrazov o mapovanie bodov z jedného obrazu do príslušných bodov druhého obrazu. Obraz, ktorý je v procese lícovania transformovaný, sa nazýva *pohybový*, so snahou dosiahnuť čo najväčšiu podobnosť s *referenčným* obrazom, ktorý sa v priebehu nemení. [3]

Jedným z kritérií pre delenie využitia registrácií obrazov môže byť práve rozdielny spôsob, akým boli referenčný a pohybový obraz snímané. Spôsoby získania obrazov sú rôzne:

- rozličné časy - rovnaká scéna je snímaná v rôznych časových intervaloch, často však so zmenenými podmienkami. Úlohou je zistiť zmeny scény medzi po sebe nasledujúcimi snímkami.
- Rôzne modality - obrazy rovnakej scény sú získané napr. s využitím magnetickej rezonancie (MR), počítačovej tomografie (CT) alebo pomocou ultrazvuku (UZ), ktoré sú vhodné pre zachytenie anatomickej štruktúry objektu. Pre získanie komplexnejšej informácie a následne pre čo najpresnejšiu diagnostiku sa tieto obrazy kombinujú s obrazovými dátami získanými pozitronovou emisnou tomografiou (PET) alebo jednofotónovou emisnou tomografiou (SPECT), zachytávajúcej funkčnosť a metabolickú aktivitu orgánov.
- Rôzne uhly - rovnaká scéna je snímaná z rôznych hľadísk, pre získanie širšej 2D alebo 3D perspektívy.
- Lokalizovanie scény v modeli - k dispozícii sú obrazy scény a jej model, ktorým môže byť počítačová reprezentácia scény napr. v inom rozmere. Cieľom je vymedziť danú scénu v modeli alebo ich porovnanie. Konkrétne využitie tejto aplikácie je v medicíne pre diagnostiku, porovnaním snímky pacienta s digitálnymi atlasmi. [30]


Matematickým vyjadrením hľadania parametrov vhodnej geometrickej transformácie medzi obrazom referenčným a pohybovým popisuje rovnica [9]:

$$\alpha_0 = \arg \max_{\alpha} c(B(x_B), A'(T_{\alpha}(x_A))), \quad x_B, T_{\alpha}(x_A) \in \Omega_{\alpha}. \quad (1.1)$$

V rovnici 1.1 je cieľom nájsť optimálny vektor parametrov α s ohľadom na minimalizovanie, resp. maximalizovanie kritéria podobnosti $c(B(x_B), A'(T_{\alpha}(x_A)))$. Obraz A je upravený podľa transformačnej funkcie T_{α} , aby si bol referenčný obraz

B čo najpodobnejší s už transformovaným pohybovým obrazom $A'(T_\alpha(x_A))$. Porovnanie týchto obrazov s často navzájom odlišným rozsahom je možné iba v mieste ich prieniku $\Omega_\alpha = X_A \cap X_B$, ktorý sa v priebehu mení. [9]

Lícovanie obrazov je iteratívnym procesom, ktorý pozostáva z viacerých častí. Medzi tie hlavné patria geometrické transformácie, ďalej podobnostné kritériá, ktoré určujú kvalitu stotožnenia obrazov, interpolácie pre výpočet nových hodnôt intenzity a nakoniec optimalizácie, ktoré slúžia pre hľadanie vhodných transformácií. Celý proces približuje obrázok 1.1, ktorého jednotlivé časti budú bližšie popísané v nasledujúcich podkapitolách. [3]



Obr. 1.1: Hlavné komponenty v procese lícovania obrazov [3]

1.1 Geometrické transformácie

Podstatou geometrických transformácií je mapovanie bodov pohybového obrazu do priestorových súradníc obrazu referenčného. Transformáciu T so súradnicami referenčného obrazu $r = (x, y)$ na priestorové súradnice $r' = (x', y')$ obrazu transformovaného v dvojrozmernom priestore popisuje rovnica 1.2. Rovnaký princíp platí aj pre trojrozmerné dáta [9]

$$r' = T(r). \quad (1.2)$$

Ak je každý bod pohybového obrazu transformovaný práve na jeden bod v obraze referenčnom alebo naopak, transformácia je reverzibilná a informačný obsah transformovaného obrazu ostáva zachovaný. Inverzná transformácia tak umožňuje obnoviť pôvodný obraz, čo je uvedené vo vzťahu 1.3.[9]

$$r = T^{-1}(r') \quad (1.3)$$

Podľa rozsahu pôsobenia na obraz môžu byť transformácie rozdelené na *globálne* a *lokálne*. Kým v prípade globálnej transformácie sú parametre platné pre celý obraz, u lokálnych môžu byť rôzne pre časti obrazu. Použitie rôznych parametrov v rozdelených častiach obrazu môže byť problémom z hľadiska zabezpečenia hladkosti prechodu medzi jednotlivými oblasťami. Ďalej použité transformácie sú rozdelené do dvoch skupín. [9]

1.1.1 Rigidné transformácie

Rigidné, inak nazývané aj tuhé transformácie, zachovávajú vzdialenosti, čiary aj uhly medzi bodmi, nedochádza k žiadnej geometrickej deformácii tvaru obrazu, iba k zmene polohy. Medzi ne patrí posun a rotácia obrazu. [9]

Najjednoduchšou operáciou je posun, teda pripočítanie hodnôt Δx a Δy k pôvodným súradniciam, ktoré sú v rovnici 1.4 určené vektorom Δr . [9]

$$r' = r + \Delta r \quad (1.4)$$

Kým posun je definovaný dvomi parametrami, rotácia obrazu okolo jednotlivých súradnicových osí je daná iba jedným uhlom θ . V rovnici pre rotáciu obrazu 1.5 sú pôvodné priestorové súradnice vynásobené transformačnou maticou B [9]

$$r' = Br, \quad \text{kde} \quad B = \begin{bmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{bmatrix}. \quad (1.5)$$

Výhodnejšie je spojenie týchto dvoch operácií do jedného transformačného vzťahu 1.6, ktorý predstavuje všeobecnú rigidnú transformáciu.

$$r' = Br + \Delta r \quad (1.6)$$

Maticové vyjadrenie zlúčenia posunu a rotácie je možné po rozšírení vektoru súradníc $r = (x, y)$ o tzv. homogénnu súradnicu c na tvar $r = (cx, cy, c)$, ktorou sa však žiadna nová informácia nepridáva. C je reálna konštanta, pričom v príklade 1.7 je zvolená hodnota $c = 1$ [9]

$$r' = Rr = \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta & \Delta x \\ \sin \theta & \cos \theta & \Delta y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}. \quad (1.7)$$

Doposiaľ uvedené vzťahy sú platné pre dvojrozmerné obrazy, avšak všetky sa dajú jednoduchým rozšírením upraviť na vzťahy pre obrazy trojrozmerné. V maticovom vyjadrení je vhodnejšie nahradenie koeficientov v transformačnej matici $B = [b_{ik}]$.

1.1.2 Flexibilné transformácie

Transformácie, ktoré spôsobujú deformáciu obrazu, v zmysle zmeny vzdialeností medzi jednotlivými bodmi v niektorých jeho častiach, sa nazývajú flexibilné, resp. pružné. Tie môžu byť ako lineárne, tak nelineárne. Medzi najjednoduchšie flexibilné transformácie patrí škálovanie a skosenie. [24]

Škálovanie je transformácia, ktorá slúži na zmenšovanie a zväčšovanie obrazu alebo na ňom špecifických objektov. V uvedenej rovnici 1.8 je S transformačná matica obsahujúca koeficienty zmeny mierky s_x a s_y v jednotlivých smeroch u dvojrozmerných obrazov

$$r' = Sr, \quad \text{kde} \quad S = \begin{bmatrix} s_x & 0 & 0 \\ 0 & s_y & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (1.8)$$

V prípade 3D obrazu je pridaný koeficient s_z v smere osi z . Ak je hodnota koeficientov v absolútnej hodnote patriaca do intervalu $(0,1)$, ide o zmenšenie obrazu, v opačnom prípade, teda ak je táto hodnota väčšia ako jedna, dochádza k zväčšeniu obrazu. Znamienko koeficientov udáva smer zmeny mierky. Ak sa $s_x = s_y$, vzájomné pomery sa nezmenia. [9]

Ďalšou transformáciou spôsobujúcou deformáciu obrazu je skosenie, u ktorého dochádza k zdanlivému posunu obrazu po vrstvách. Transformačná matica sa označuje G , pričom pre skosenia v osách x a y sa používa označenie G_x a G_y [9]

$$G = G_x G_y, \quad \text{kde} \quad G_x = \begin{bmatrix} 1 & g_{xy} & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} 1 & 0 & 0 \\ g_{yx} & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (1.9)$$

Kombináciou všetkých doposiaľ uvedených tuhých aj pružných transformácií zahŕňajúcich skosenie, škálovanie, rotáciu a posun obrazu vznikne najvšeobecnejšia lineárna transformácia, nazývaná afinná. Keďže patrí medzi lineárne transformácie rovnobežnosť hrán je zachovaná. Je určená rovnicou [9]

$$r' = GSRr = Ar, \quad \text{kde} \quad A = \begin{bmatrix} a_{11} & a_{12} & t_1 \\ a_{21} & a_{22} & t_2 \\ 0 & 0 & 1 \end{bmatrix}. \quad (1.10)$$

Transformačná matica obsahuje 6 nezávislých parametrov pre dvojrozmerné obrazy a 12 parametrov pre obrazy trojrozmerné. Je získaná postupným vynásobením všetkých čiastkových transformačných matíc, avšak je dôležité dbať na ich správnu postupnosť, keďže násobenie matíc nie je komutatívne.

1.1.3 Nelineárne transformácie

Všetky doteraz uvedené pružné geometrické transformácie patria do skupiny lineárnych transformácií. Ostatné transformácie spôsobujúce deformácie obrazov a tým ich skreslenie, sú nelineárne. Tie je možné rozdeliť do dvoch hlavných skupín na projektívne a zakrivujúce transformácie.

U projektívnych transformácií ostáva rovinnosť plôch a priamosť čiar bez zmeny, to znamená, priamky ostávajú priamkami, avšak rovnobežnosť už zachovaná nie je, rovnobežky sa teda zobrazia ako rôznobežky. Je daná rovnicou

$$r' = \frac{Ar}{p^T r + \alpha} \quad , \quad s \quad p^T = [p_1 \quad p_2], \quad (1.11)$$

kde konštanty A , p a α sú transformačnými parametrami. Čitateľ zlomku vyjadruje už vysvetlenú rovnicu pre afínnu transformáciu. Zvláštnym typom je perspektívna transformácia, pomocou ktorej sú trojrozmerné scény premietané do dvojrozmerných rovinných obrazov. [9]

V prípade zakrivujúcich transformácií nie je zachovaná ani jedna z týchto vlastností, dochádza k deformácii plôch aj priamok. Najjednoduchším typom sú polynomicke transformácie, najčastejšie dané polynómami prvého, druhého alebo maximálne tretieho stupňa. So zvyšujúcim sa rádom môže rásť náchylnosť k falošným osciláciám, čo v obraze spôsobuje lokálne deformácie, ktoré však môžu byť eliminované použitím polynomických funkcií po častiach. [9] [24]

1.2 Podobnostné kritériá

Ďalším krokom v procese registrácie obrazov, ktorý nasleduje po použití geometrických transformácií, je zhodnotenie miery podobnosti dvoch obrazov. Ide o meranie kvality transformácie T , ktoré sa stanovuje vypočítaním podobnostnej metriky medzi referenčným a transformovaným obrazom. Keďže úspešnosť celkového výsledku registrácie obrazov je závislá na presnom odhade ich stotožnenia, získanie reálneho čísla, ktoré nejakým spôsobom ohodnocuje použitú transformáciu, je dôležitou súčasťou celého procesu. [3]

Každé možné riešenie, teda ohodnotenie F je vypočítané ako stupeň podobnosti medzi pohybovým obrazom A , ktorý je transformovaný podľa funkcie f , a referenčným obrazom B . Výpočet tohto stupňa podobnosti Ψ je daný nasledovne [3]

$$F(A, B, f) = \Psi(f(A), B). \quad (1.12)$$

Podľa rozsahu posudzovaných oblastí môžu byť kritériá podobnosti rozdelené na globálne a lokálne. V prípade lokálnych kritérií sú porovnávané určité významné

regióny obrazov, ktorých veľkosť je konečná, avšak nie je presne stanovená či obmedzená. Podmienkou je úplné prekrytie týchto oblastí. Ak sú však porovnávané dva alebo viac obrazov, je nutné použiť globálne podobnostné kritériá. V konečnom dôsledku je ich princíp založený na vyjadrení lokálnych podobností v jednotlivých oblastiach ako celku, s využitím integrálu, sumy alebo priemernej hodnoty. Podľa pôvodu a dimenzie posudzovaných obrazových dát môžu byť kritéria rozdelené na tie, ktoré sú založené na intenzitách pixlov alebo ich informačnom obsahu. [9]

1.2.1 Kritériá založené na intenzitách pixlov

Väčšina prístupov patriacich do tejto kategórie vychádza z hľadania odpovedajúcich si vzorov v referenčnom a transformovanom obraze alebo ich častiach, ktoré sú pre zjednodušenie vymedzené napr. obdĺžnikovým oknom. Problémom tohto zjednodušenia je možné nezasiahnutie rovnakých častí obrazov ako dôsledok použitej geometrickej transformácie. Metóda sa zdá byť nedostatočná aj pri zvolení oblastí, v ktorých sa nenachádzajú žiadne detaily, a tak môžu byť chybné priradené nezohodujúce sa oblasti. [3]

Častou požiadavkou je rovnaká veľkosť porovnávaných oblastí A a B , ktorú sú určené konečným počtom pixlov N usporiadaných do vektorov a a b . Usporiadanie sa realizuje rovnakým spôsobom u oboch obrazov, aby dimenzie vektorov boli rovnaké.

Jednoduchým odčítaním vektorov a a b je získané jedno z najjednoduchších kritérií, Euklidovská vzdialenosť: [9]

$$C_E(a, b) = |a - b| = \sqrt{\sum_{i=1}^N (a_i - b_i)^2}. \quad (1.13)$$

Ďalším často používaným kritériom je suma štvorcov rozdielov (SSD, z angl. *sum of squared differences*), získaná ako druhá mocnina Euklidovskej vzdialenosti [9]

$$C_{SSD}(a, b) = \sum_{i=1}^N (a_i - b_i)^2. \quad (1.14)$$

Normalizovaním počtom pixelov N v oboch prípadoch sú výsledné hodnoty lepšie porovnateľné. Pre obidva spôsoby výpočtu platí, že obrazy sú úplne stotožnené, ak je hodnota vzdialenosti nulová, cieľom je teda minimalizácia hodnôt týchto kritérií. Nevýhodou obidvoch výpočtov je značná citlivosť na výraznejšie rozdiely intenzít medzi obrazmi A a B , ktoré môžu byť spôsobené zmenou osvetlenia v priebehu snímania, použitím kontrastnej látky alebo zmenou polohy nástrojov vzhľadom k objektu záujmu. Dochádza k nežiadúcemu skĺznutiu hodnôt do lokálneho minima. [3] [9]

Citlivosti predchádzajúcich kritérií k rozdielom intenzít medzi referenčným a pohybovým obrazom do určitej miery predchádza použitie kosínového (COS, z angl.

cosine similarity), resp. uhlového kritéria, ktoré nie je vôbec citlivé na lineárne zmeny kontrastu a zdá sa byť použiteľné aj v prípade nelineárnych zmien. Z definície funkcie kosínus vyplýva, že výsledné hodnoty môžu byť v intervale $< -1, 1 >$, s ohľadom na nezáporné hodnoty intenzít je interval obmedzený do rozsahu $< 0, 1 >$. Čím je uhol medzi obrazovými vektormi a a b menší, tým sa kosínus tohto uhla zväčšuje do hraničnej hodnoty intervalu. Kosínové kritérium môže byť vyjadrené nasledovne [9]

$$C_A(a, b) = \frac{ab}{|a||b|} = \frac{\sum_i a_i b_i}{\sqrt{\sum_i a_i^2} \sqrt{\sum_i b_i^2}}. \quad (1.15)$$

Odčítaním priemernej hodnoty od každého prvku je získané tiež často používané kritérium, nazvané normalizovaný korelačný koeficient (CC, z angl. *correlation coefficient*) [9]

$$C_{CC}(a, b) = \frac{\sum_i (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_i (a_i - \bar{a})^2} \sqrt{\sum_i (b_i - \bar{b})^2}}, \quad \bar{a} = \frac{1}{N} \sum_i a_i, \quad \bar{b} = \frac{1}{N} \sum_i b_i. \quad (1.16)$$

1.2.2 Kritériá založené na vzájomnej informácii

Všetky doteraz uvedené kritériá sú vhodné pre registráciu obrazov z rovnakej modality, ktorých intenzity nie sú značne odlišné a sú lineárne závislé. U multimodálnych obrazov však môžu byť podmienky pri snímaní natoľko odlišné, že porovnávanie ich rozdielnych hodnôt intenzít by viedlo k nekorektným výsledkom. Preto je vhodnejšie použiť znalosť o ich informačnom obsahu, čím môžu byť napr. korešpondujúce geometrické prvky v oboch obrazoch alebo vzdialenosť medzi nimi. [24]

Jednou z možností vyjadrenia vzťahu medzi obrazmi, ktorých počet úrovní šedi sa líši, je združený histogram. Grafické znázornenie poskytuje rýchly odhad o vzťahu medzi intenzitami v oboch obrazoch. Ak konkrétna hodnota intenzity v referenčnom obraze odpovedá viacerým hodnotám v transformovanom obraze, je možné predpokladať použitie niektorej rigidnej geometrickej transformácie. [9]

Ďalšou častou používanou mierou hodnotenia informácie je Shannonova entropia. Na jej vysvetlenie je nutné uviesť výpočet marginálnych pravdepodobností distribúcie hodnôt intenzít v obrazoch, kde A a B sú chápané ako náhodné veličiny

$$p_A\{l\} \approx \frac{1}{N} h_l^A, \quad (1.17)$$

N určuje počet pixlov obrazu A , l odpovedá počtu pixlov s úrovní intenzity (šedej) v hodnote l . Analogicky sa vyjadří pravdepodobnosť pre obraz B . Entropia sa potom vypočíta ako

$$H_A = \sum_{l=1}^q p(a_l) \log \frac{1}{p(a_l)} = - \sum_{l=1}^q p(a_l) \log p(a_l), \quad (1.18)$$

kde q je počet úrovní šedi v obraze A . Výraz $\log(1/p(a_l))$ vyjadruje množstvo získanej informácie z udalosti, ktoré je nepriamo úmerné pravdepodobnosti jej výskytu. Udalosťou sa v tomto význame myslí výskyt určitej úrovne šedi. Veľmi zriedkavo vyskytujúcej sa udalosti bude teda priradený veľký význam. Ak existuje iba jedna možnosť udalosti, nebude získaná žiadna informácia, pretože už bolo zrejmé, že táto udalosť nastane. [9]

Celkový výsledok udáva priemerné množstvo informácií získané z viacerých udalostí, preto musí byť každá udalosť váhovaná pravdepodobnosťou jej výskytu. Maximálna hodnota entropie je dosiahnutá za podmienok, keď každý stupeň šedi obrazu je zastúpený rovnako, s rovnakou početnosťou. S týmto súvisí chápanie entropie ako miery neistoty. Neistota je absolútna práve vtedy, keď je hodnota entropie maximálna, a naopak, znižuje sa so zvyšujúcou sa šancou výskytu určitej udalosti. Frekvencia výskytu úrovní šedej pre dvojice pixlov zo združeného histogramu sa dá použiť ako ďalšie kritérium podobnosti tzv. združenú entropiu: [9]

$$H_{AB} = - \sum_{l=1}^q \sum_{m=1}^r p(a_l, b_m) \log p(a_l, b_m). \quad (1.19)$$

Kombináciu Shannonovej entropie a združenej entropie využíva ďalšia miera podobnosti obrazov nazývaná vzájomná informácia. Je daná ako rozdiel súčtu informácie referenčného a transformovaného obrazu a informácie po ich zjednotení [9]

$$I_{AB} = H_A + H_B - H_{AB}. \quad (1.20)$$

V procese registrácie je úlohou vzájomnú informáciu maximalizovať, teda zároveň obrazy A a B tak, aby obsahovali najväčšie možné množstvo informácie. Zo vzťahu 1.20 vyplýva, že minimalizovaním združenej entropie je vzájomná informácia maximalizovaná. [9]

V praxi je výhodnejšie použiť vzájomnú informáciu ako len samotnú združenú entropiu, keďže zahŕňa aj hodnoty entropie individuálne pre každý obraz. Počítanie sa realizuje u oboch spôsobov na prekrývajúcich sa častiach obrazov, avšak vzájomná informácia je voči prekrytiu odolnejšia. [9]

1.3 Optimalizácia

Ďalšou z hlavných súčastí v procese registrácie obrazov je optimalizácia. Jej úlohou je vo všeobecnosti nájsť čo najlepší možný riešenie daného problému a vyžaduje si iteratívny prístup. U registrácie obrazov bude pod pojmom optimalizácia chápané hľadanie globálneho optima (maxima alebo minima) pre podobnostné

kritérium, v zmysle nájdenia najlepšej transformácie, po aplikácii ktorej si budú referenčný a transformovaný obraz čo najpodobnejšie. Úplne prekrytie týchto obrazov znamená úspešné nájdenie hľadaného optima. [9]

Ak je úlohou hľadanie globálneho minima, ktorému odpovedá práve jeden alebo viac bodov z množiny D , musí byť splnená podmienka

$$f(\bar{x}) \leq f(x), \quad \text{pre } \forall x \in D, \quad (1.21)$$

kde $\bar{x}$ je globálne optimum, v tomto prípade minimum, $f(x)$ je kritériálna funkcia určená ako $f : D \rightarrow \mathbb{R}$, $D \subseteq \mathbb{R}^d$. Globálne minimum je hľadané v súvislej oblasti D obmedzenom v d -rozmernom priestore [23]

$$D = \langle a_1, b_1 \rangle \times \langle a_2, b_2 \rangle \times \dots \times \langle a_d, b_d \rangle = \prod_{i=1}^d \langle a_i, b_i \rangle$$

$$a_i < b_i, i = 1, 2, \dots, d. \quad (1.22)$$

Nájdenie globálneho maxima je možné odvodiť z minima výpočtom $g(x) = -f(x)$. Kvalita riešenia problému 1.21 je stupňom dosiahnutej podobnosti medzi obrazmi po transformácii. [23]

Optimalizáciu je potrebné prispôbiť spracovaniu konkrétnych obrazových dát, s vybratím vhodnej kritériálnej funkcie v závislosti na type týchto dát. Všeobecný postup hľadania optima spočíva v prehľadávaní priestoru možných parametrov transformácie a skladá sa z nasledujúcich krokov

- zvolenie počiatočných skúšobných bodov z prehľadáwanej oblasti Ω ,
- otestovanie kritériálnej funkcie v oblasti pre body zvolené v predchádzajúcom kroku,
- výpočet nových skúšobných bodov pomocou konkrétného optimalizačného algoritmu,
- cyklické opakovanie krokov 2 a 3 až do nájdenia globálneho extrému kritériálnej funkcie. [9] [22]

Dôležitou súčasťou optimalizácie pri hľadaní globálneho extrému je vhodné stanovenie podmienok ukončenia optimalizačného algoritmu. Jednou z možností ukončenia je stanovenie počtu iterácií, ktoré je možné chápať dvoma spôsobmi. Počet iterácií bude daný ako počet možných riešení, pre ktoré bude kritériálna funkcia hodnotená alebo ako počet cyklov opakovania vnútri algoritmu v postupe hľadania optima. Druhou možnosťou je stanovenie terminálneho kritéria, po ktorého dosiahnutí sa proces zastaví. Týmto môže byť aj maximálny čas výpočtu stanovený užívateľom. Proces môže byť zastavený v prípade, kedy už nedochádza k zlepšeniu kvality riešenia, dospel k určitému riešeniu, ktoré je považované za dostatočne vyhovujúce. [27]

Všetky optimalizačné metódy musia počítať s rizikom nežiadúceho sklĺznutia do lokálneho minima, ktoré vo väčšine prípadov nie je totožné s globálnym minimom a vedie k chybným výsledným parametrom. Globálne optimalizačné algoritmy sa snažia konvergencii do lokálneho optima predchádzať zvolením vhodného kompromisu medzi požadovanou presnosťou riešenia a časom stráveným k jeho nájdeniu, ako aj čo najpresnejšou definíciou terminálnych podmienok. [27]

1.3.1 Prehľad optimalizačných metód

Vo všeobecnosti sa optimalizačné metódy delia na deterministické a stochastické. Deterministické algoritmy sú najčastejšie používané, ak je zaručený jasný vzťah medzi možnými riešeniami a ich využitím pre daný problém. Na rozdiel od stochastických sa do týchto metód nezavádza žiadna pravdepodobnosť, ale využíva sa znalosť o predchádzajúcom stave, a nové skúšobné body sú väčšinou vypočítané spôsobom hľadania najbližšieho suseda. Ak je vzťah medzi možným riešením a jeho vhodnosťou zložitejší, prehľadávaný priestor je príliš veľký, používajú sa stochastické metódy, ktoré tento priestor prehľadávajú heuristicky. Keďže sa tieto metódy inak nazývajú pravdepodobnostné, je zrejmé zavedenie náhody do celého procesu. Heuristika ako postup navyše využíva intuíciu a skúsenosť, čo však nezaručuje nájdenie riešenia. Práve vďaka zavedeniu náhody a pravdepodobnosti sú z pohľadu uviaznutia v lokálnom extréme odolnejšie stochastické algoritmy. [23] [27]

Medzi najznámejšie deterministické algoritmy patrí metóda najväčšieho spádu, horolezecký algoritmus, Newtonova a simplexová metóda. Často používanými stochastickými algoritmami sú slepé prehľadávanie a jeho modifikácie a tiež známe simulované žíhanie. Dôležitou triedou patriacou medzi stochastické algoritmy sú čoraz častejšie používané evolučné algoritmy, ktorých popisu sa bude venovať nasledujúca kapitola 2.

Prehľadávanie hrubou silou

Metóda prehľadávania hrubou silou, ako najjednoduchšia metóda, hľadá zarovnanie dvoch obrazov tak, aby bola stotožnená väčšina pixlov. Prehľadáva sa celý priestor, čím je zaručené nájdenie riešenia. Tento spôsob nie je reálne použiteľný pre príliš veľký počet parametrov, ktorých výpočet by nebolo možné obdržať v prijateľnom čase. Náročnosť výpočtu exponenciálne rastie so zväčšujúcim sa počtom parametrov. Výhodou algoritmu je možnosť pracovať so spojitými aj nespojitými premennými. [6]

Metóda najväčšieho spádu

Patrí do skupiny gradientných metód, ktoré ako názov napovedá, k výpočtu používajú prvú deriváciu, gradient. Použitie tejto metódy si vyžaduje spojitost kriteriálnej

funkcie. Princípom pre hľadanie extrémů je iteratívny postup v smere najväčšieho gradientu a to s pevne stanoveným alebo premenlivým krokom. Nevýhodou metódy je časté sklznutie do lokálnych extrémů u zložitejších funkcií, avšak postačujúca je v prípade jednoduchých funkcií, ideálne konvexného tvaru. Je základom pre Newtonovu metódu, ktorá na rozdiel využíva k aproximácii bodu parabolu s odhadom jej minima. [6] [22]

Simplexová metóda

V porovnaní s metódami využívajúcimi k odhadu optima derivácie, je simplexová metóda výpočtovo menej náročná. Simplexom sa myslí geometrický útvar, ktorého počet vrcholov je o jeden viac ako jeho rozmer v parametrickom priestore. V dvojrozmernom priestore sú vrcholy tohto útvaru tri a ich spojením sa vytvorí trojuholník. Podstatou metódy je ohodnotenie bodov spôsobom najlepší, dobrý a najhorší pre riešenie úlohy, čo sa realizuje v každom kroku. Najhoršia hodnota je zo simplexu odstránená a nahradí sa lepším riešením. K zisteniu súradníc nového bodu a jeho funkčnej hodnoty sa prevedie reflexia simplexu. Ak neposkytuje lepšie riešenie, prevedie sa kontrakcia alebo skrátenie. Metóda poskytuje spoľahlivé nájdenie lokálneho optima a je vhodná pre nespojité kritériálne funkcie. [6]

Náhodné prehľadávanie

Náhodné prehľadávanie inak nazvané aj slepý algoritmus, patrí medzi stochastické algoritmy hľadania globálneho optima. Funguje na princípe generovania náhodného riešenia, ktoré sa uloží do pamäti práve vtedy, ak je lepšie ako naposledy uložené riešenie. Generovanie prebieha až do určeného počtu iterácií. Je však dokázateľné, že so zvyšujúcim sa počtom iterácií sa nájdené riešenie približuje globálnemu extrému. V praxi sa používajú rôzne modifikácie tohto algoritmu, napr. zakázané prehľadávanie alebo kontrolované náhodné prehľadávanie. [23]

Horolezecký algoritmus

Horolezecký algoritmus sa radí do skupiny deterministických algoritmov. Na začiatku je zvolený bod, v ktorého okolí sa vypočítajú a ohodnotia všetky body z pohľadu riešenia úlohy. Bod s najlepším ohodnotením sa stáva riešením v danom kroku, a ktorého okolie sa bude ďalej prehľadávať. Metóda sa dá ukončiť stanoveným počtom iterácií alebo faktom, že žiadny z okolitých bodov už neposkytuje lepšie riešenie ako práve zvolený bod. Nežiadúcemu uviaznutiu v lokálnom minime je možné čiastočne zabrániť zvolenou veľkosťou okolia bodu alebo opakovaným spustením s iným počiatočným bodom priestoru. [22] [25]

2 METAHEURISTICKÉ ALGORITMY OPTIMALIZÁCIE

Velkou skupinou stochastických algoritmov, ktorá sa snaží efektívne prehľadávať priestor s cieľom nájsť optimálne riešenie, je trieda metaheuristických algoritmov. [24]

Patria medzi najúspešnejšie techniky schopné poskytnúť riešenie aj pre veľké množstvo komplexných a výpočtovo náročných optimalizačných problémov. Ide o všeobecné algoritmy, ktoré sú po aplikovaní malého množstva úprav použiteľné pre riešenia konkrétnych problémov. Poskytujú dobré výsledky, ktorých správnosť však nie je možné dokázať. Zvyčajne nemajú k dispozícii hlbší náhľad do problému, k dosiahnutiu výsledkov využívajú náhodu, odhad alebo skúšanie možných variant. Ich robustnosť potvrdzuje aj skutočnosť, že nie sú závislé na počiatočnom riešení problému a na rozdiel od iných metód (napr. gradientných) sú použiteľné aj pre iné, ako len spojité funkcie. [27]

Metaheuristické metódy je možné skombinovať s klasickými, v poradí aplikovanie stochastických metód a potom použitie deterministických. Kombinácia preskúmania a využitia schopností z oboch typov metód predurčuje tento hybridný prístup na dosiahnutie výborných výsledkov. [27]

Medzi najznámejšie a často využívané metaheuristické optimalizačné algoritmy patrí simulované žihanie. [24]

2.1 Simulované žihanie

Metóda simulované žihanie je založená na analógii z metalurgie, kde predstavuje techniku zahŕňajúcu ohrievanie a kontrolované chladenie kovu s vytváraním kryštalickej štruktúry s nízkou energiou. Práve energia materiálu je chápaná ako kritériálna funkcia optimalizačného problému, kedy jeho rôzne stavy predstavujú možné riešenia. Vychádza z princípu horolezeckého algoritmu, do ktorého zavádza pravdepodobnosť prijatia nového bodu. Pravdepodobnosť závisí na kontrolnej premennej, ktorou je v tomto prípade teplota. [24]

Počiatočná zvolená teplota je vysoká, teda všetky riešenia v prehľadávanom priestore sú prijateľné. Vyššia teplota znamená vyššiu pravdepodobnosť prijatia horšieho riešenia, čím umožňuje únik z lokálneho minima. Nízka teplota značí priblíženie sa globálnemu optimu. Na začiatku nastavená vysoká hodnota teploty sa v každej iterácii znižuje podľa predpisu (počet iterácií strávených v určitej teplote), ktorý je dôležitým faktorom k zaručeniu úspechu algoritmu. Čím pomalšie klesá, tým dôkladnejšie je algoritmom priestor prehľadaný. [24]

V každej iterácii je počítaná pravdepodobnosť prijatia nového bodu z aktuálneho riešenia x a susedného riešenia y . Ak je kvalita susedného riešenia lepšia, stáva sa novým riešením, ak je naopak horšia ako u aktuálneho riešenia, je prijaté práve s pravdepodobnosťou [1] [13]

$$p(x, y) = e^{\frac{f(y) - f(x)}{T}}. \quad (2.1)$$

Konvergencii algoritmu k optimu napomáhajú ukončovacie podmienky ako stanovenie pomeru zamietnutých riešení alebo minimálna teplota.

2.2 Evolučné algoritmy

Evolučné algoritmy sú významnou skupinou metaheuristických algoritmov, ktorých princíp je inšpirovaný prírodou, presnejšie evolučnými procesmi a genetikou. Kľúčovým prvkom je vyvíjajúca sa populácia, ktorá je určená ako skupina jedincov, pri čom každý jedinec predstavuje riešenie daného problému. Optimálne riešenie sa postupne vyvíja z tejto populácie, v čom spočíva hlavný rozdiel od klasických optimalizačných metód, ktoré postupujú v smere najlepšieho riešenia. Z biologických procesov využívajú mechanizmy kríženia, mutácie, prirodzeného výberu a prežitie najschopnejších jedincov, ktoré sa opakovane aplikujú na populáciu, čím sa vytvárajú generácie silnejších jedincov. Aplikovanie náhody na každý z týchto mechanizmov, nazvaných evolučné operátory, znižuje pravdepodobnosť uviaznutia v lokálnom minime, preto je vhodné ich použiť pre riešenie zložitých komplexných problémov. [25]

Skupina evolučných algoritmov zahŕňa genetické algoritmy, evolučné stratégie, genetické a evolučné programovanie, z ktorých najväčšia pozornosť bude venovaná najpoužívanejšej časti genetických algoritmov. Významnou súčasťou je oblasť rojovej inteligencie, využívajúca inteligentné správanie sebaorganizovaných systémov, kde patrí optimalizácia pomocou rojenia častíc a svetluškový algoritmus. [3]

2.2.1 Genetické algoritmy

Genetické algoritmy (GA, z angl. *genetic algorithm*) sú podskupinou evolučných algoritmov a sú založené na Darwinovej evolučnej teórii. Tá hovorí o tom, že dvojica rodičov predáva genetickú informáciu svojim potomkom a silnejší a prispôsobivejší jedinci majú väčšiu šancu prežitia aj reprodukcie. Na posúdenie miery prispôsobenia jedinca sa používa hodnotiaca funkcia *fitness*, ktorej hodnoty rastú s kvalitou riešenia. Jedinci s vyššou hodnotou fitness disponujú väčšou pravdepodobnosťou prežitia a predania genetickej informácie do generácie potomkov. [1]

Genetická informácia je uložená v chromozómoch, a predstavuje riešenie optimalizačného problému, ktorého kvalitu určuje práve fitness funkcia. Algoritmus posudzuje naraz viac riešení, obsiahnutých v populácii, ktoré sa v opakovanom procese skvalitňujú. [27]

2.2.2 Popis dát pre genetické algoritmy

Pre uvedenie do problematiky je potrebné uviesť a vysvetliť pár pojmov z oblasti genetiky a ich analógiu ku genetickým algoritmom, kde sa používajú.

- **Gén** - v genetike ako základný nositeľ genetickej informácie, tu bude chápaný ako časť chromozómu. Gény sú parametre optimalizovaného systému usporiadané lineárne za sebou do reťazca. Môžu nadobúdať iba určité hodnoty a označujú sa ako alely. [10]
- **Chromozóm** - je časť DNA, ktorá je špirálovito stočená. V genetických algoritmoch ide o vektor fixne danej alebo premenlivej dĺžky, ktorý je tvorený jedným a tým istým dátovým typom, čím okrem bitov môžu byť reálne čísla a symboly. Pre ďalšie pochopenie bude chromozóm definovaný ako binárny vektor s dĺžkou k [23]

$$\bar{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_k) \in \{0, 1\}^k.$$

- **Populácia** - je skupina chromozómov, z pohľadu optimalizácie daná ako množina rôznych riešení optimalizačnej úlohy. Počet prvkov, resp. jedincov v populácii je N a je možné ho zapísať ako [23]

$$P = (\bar{\alpha}_1, \bar{\alpha}_2, \dots, \bar{\alpha}_N).$$

- **Generácia** - je každá nová populácia, v ktorej jedinci získali genetickú informáciu od predchádzajúcej generácie ich rodičov.
- **Účelová funkcia** - označovaná ako f , hodnotí kvalitu možných riešení a tým slúži pre posúdenie ich vhodnosti. Obsahuje hľadaný extrém a určuje vzťah parametrov d_i s veličinou Q nasledovne [10]

$$Q = f(d_1, d_2, \dots, d_n).$$

2.2.3 Genetický algoritmus

Všeobecný cyklus genetického algoritmu pozostáva z niekoľkých hlavných krokov.


1. Inicializácia algoritmu generovaním náhodnej počiatkovej populácie, vytvorenej náhodnou kombináciou jednotiek a núl v prípade binárneho algoritmu. Každý bit zodpovedá génu.

2. Ohodnotenie každého jedinca kritériálnou funkciou a jej konverzia na vhodnosť. Podľa zámeru kritériálnej funkcie môžu byť hodnoty usporiadané vzostupne alebo zostupne.
3. Selekcia rodičov podľa hodnoty kritériálnej funkcie. Vyššia hodnota fitness funkcie znamená väčšiu šancu prežitia.
4. Kríženie jedincov, pre generovanie populácie potomkov. Môže byť realizované rekombináciou častí rodičov. V tejto časti sú zavedené dve náhodne rozhodnutia a to realizovanie alebo nerealizovanie kríženia a miesto, kde sa bude bod kríženia nachádzať.
5. Na vytvorených potomkov je aplikovaný ďalší genetický operátor, ktorým je mutácia. Mutáciou, čiastočnou zmenou génov v chromozóme jedinca sa rozširuje ešte nepreskúmaný priestor vyhľadávania.
6. Ohodnotenie všetkých vzniknutých potomkov rovnakým spôsobom ako u počiatočnej populácie.
7. Výber najlepších jedincov. Celá generácia rodičov môže byť nahradená novovzniknutou populáciou potomkov. Niektorí jedinci zo staršej populácie môžu byť zachovaní, ak je ich kvalita väčšia. Tento prístup sa nazýva elitárska stratégia.
8. Opakovanie celého postupu v cykle od kroku č. 2, až do splnenia podmienky ukončenia. [8]

Postup je pre ilustráciu znázornený na obrázku 2.1 formou vývojového diagramu.

Ukončenie celého cyklu môže byť určené rôznymi podmienkami. Najjednoduchšie a veľmi často používané je stanovenie maximálneho počtu iterácií. Ďalším kritériom môže byť už jasná konvergencia k jednému riešeniu, kedy je suma odchýlok medzi jedincami menšia ako predom zvolený prah. Je zrejmé, že sa vyskytujú už len najkvalitnejšie chromozómy a pravdepodobnosť nájdenia lepšieho riešenia je malá. Algoritmus je možné ukončiť aj prekročením určenej frekvencie výskytu najlepšieho jedinca, ktorý sa v generáciách opakuje. [10]

Nevýhodou práce s binárnymi genetickými algoritmami je nutné zváženie možnej dosiahnuteľnej presnosti, ktorá je určená kódovaním. Podľa počtu bitov potrebných k zakódovaniu jedinca a rozsahu hodnôt je možné kódovať iba určitý počet celých čísel a stanoviť chybu vyplývajúcu z kvantovania hodnôt. Zvyšovaním počtu bitov rastie presnosť parametrov a znižuje sa kvantizačná chyba, avšak je potrebné nájsť vhodný kompromis medzi presnosťou, výpočtovým časom a potrebnou pamäťou. Navyše aj malá zmena v chromozóme v dôsledku kríženia alebo mutácie môže spôsobiť výrazné zmeny, ktorým je možné predísť pomocou Grayovho kódovania, kde sa dve susedné hodnoty z prehľadávaného intervalu líšia iba jedným bitom. [6] [10]



Obr. 2.1: Cyklus genetického algoritmu [8]

2.2.4 Terminológia v genetických algoritmoch

Vhodnosť

Vhodnosť, používané pomenovanie pre fitness funkciu, je odvodená hodnota z účelovej funkcie. Konkrétna hodnota predstavuje kvalitu jedinca ako riešenie daného problému z hľadiska kriteriálnej funkcie. Ak je cieľom nájsť globálne minimum účelovej funkcie f , potom fitness F musí spĺňať podmienku

$$f(\bar{a}_i) \leq f(\bar{a}_j) \Rightarrow F(\bar{a}_i) \geq F(\bar{a}_j) > 0, \quad i, j = 0, 1, \dots, N.$$

Ak je vyžadovaná minimalizácia účelovej funkcie, pre fitness sa problém transformuje na maximalizáciu. Najjednoduchšie je lineárne zobrazenie funkčných hodnôt účelovej funkcie na fitness podľa vzťahu

$$F(\bar{a}) = \frac{F_{\max} - F_{\min}}{f_{\min} - f_{\max}} f(\bar{a}) + \frac{f_{\min} F_{\min} - f_{\max} F_{\max}}{f_{\min} - f_{\max}}, \quad (2.2)$$

kde f_{min} a f_{max} sú minimálna a maximálna hodnota účelovej funkcie jedinca $\bar{a}$, F_{min} a F_{max} sú najmenšia a najväčšia hodnota fitness funkcie. Zvyčajne je určené $F_{max} = 1$ a $F_{min} = \varepsilon$, kde ε je kladné číslo s hodnotou napr. $\varepsilon = 0,01$. Vzťah 2.2 je možné upraviť dosadením zvolených hodnôt až do podoby normalizovanej hodnoty fitness funkcie obmedzenej do intervalu (0,1). [23]

Selekcia

Výber jedincov, z ktorých bude vytvorená generácia potomkov je veľmi dôležitý krok genetického algoritmu. Výber je náhodný, avšak aby sa populácie zlepšovala, musí sa zvyšovať kvalita samotných jedincov, aby algoritmus konvergoval k správnejmu riešeniu. Základ tejto myšlienky je z evolučnej teórie, podľa ktorej najlepší jedinci prežívajú a vytvárajú populáciu potomkov. Ako ukazovateľ kvality sa používa hodnota fitness, podľa ktorej selekcia prebieha. Jedinci s vyššou hodnotou majú väčšiu šancu stať sa rodičmi a môžu byť vybraní aj viac ako jedenkrát. Selekčnými metódami sa dá ovplyvniť výber preferovanej skupiny jedincov, čím sa vytvára selekčný tlak. Väčší selekčný tlak znamená vyššiu preferenciu niektorých jedincov, a tým sa rýchlosť konvergenzie zväčšuje. Existuje viacero spôsobov selekcie. [22] [27]

- **Súboj** - vstupom je populácia jedincov a ich kvalita. Náhodne je vybraná dvojica jedincov, z ktorých sa vyberie lepší a ten postupuje zo súboja ďalej. Vplyvom náhody, ktorou výber prebieha je zaručená rôznorodosť. Realizovaný počet súbojov je daný počtom jedincov.
- **Vážená ruleta** - vyberá jedincov spôsobom prirodzeného výberu, väčšiu pravdepodobnosť výberu majú jedinci vyššej kvality. Najskôr sa vypočíta pravdepodobnosť výberu ako podiel kvality jedinca a sumy všetkých kvalít. Nasleduje výpočet distribučnej funkcie a stanovenie jej intervalov pre každého jedinca. Podľa priradenia náhodne vygenerovaného čísla do príslušného intervalu sa vyberie jedinec do výstupnej populácie. Postup sa opakuje podľa počtu jedincov v populácii a opäť najkvalitnejší jedinci môžu byť vybraní viackrát. [6] [16]

Elitizmus


Elitizmus zaručuje automatické zaradenie najkvalitnejšieho jedinca alebo viacerých do novej populácie, čo by len použitím metód selekcie nemuselo nastať. Po určitom počte generácií môžu byť nahradení kvalitnejšími jedincami. Zaradenie elitizmu do algoritmu napomáha urýchleniu konvergenzie. [22]

Kríženie

Kríženie je proces, v ktorom dochádza k výmene časti genetickej informácie medzi vybranou dvojicou jedincov za vzniku dvoch nových jedincov. Náhodne vygenerované číslo z intervalu (0,1) určí či ku kríženiu dôjde alebo v novej generácii budú


pôvodní jedinci bez zmeny. Podľa počtu deliacich bodov v rodičovských chromozómoch je známe jednobodové alebo viacbodové kríženie. [25]

- **Jednobodové kríženie** - v chromozómoch je práve jeden deliaci bod, umiestnený náhodne, ktorý ich rozdelí na dve časti a tie sú následne medzi rodičmi vymenené.



Obr. 2.2: Príklad jednobodového kríženia

- **Viacbodové kríženie** - chromozómy sú rozdelené v k bodoch, pri čom vznikne $k + 1$ častí chromozómov, ktoré sa medzi rodičmi prekrížia a vzniknú dvaja noví jedinci.



Obr. 2.3: Príklad viacbodového kríženia

Mutácia

Mutáciou sa myslí zámena náhodne vybraného génu za iný, nastávajúca s určitou pravdepodobnosťou. Vďaka mutácii sa zachováva genetická variabilita, pretože vznikajú noví jedinci. Zmenou len jedného bitu v chromozóme je získané nové riešenie, vďaka ktorému je možné opustiť lokálne minimum kriteriálnej funkcie. Zvyčajne sa volí percento mutovaných génov podľa veľkosti populácie, medzi 0,1% až 10%. V binárnom kódovaní mutácia znamená prehodenie 0 za 1 a naopak. [10] [25]

Reprodukcia

Nie je zaradená ako samostatný genetický operátor, ale vznikne spojením selekcie a kríženia do jedného kroku. Reprodukcia je však v tejto práci chápaná iba pri práci so spojitými genetickými algoritmi. Jednou z možných a neskôr použitých úprav je usporiadanie jedincov podľa kvality s následným výberom časti najlepších jedincov, ktorí sú podrobení kríženiu. Až novovzniknutí jedinci ďalej podliehajú mutácii. [16]

2.3 Metóda roja častíc

Metóda roja častíc (PSO, z angl. *particle swarm optimization*) je populačne založená optimalizačná metóda patriaca do skupiny evolučných algoritmov. Inšpiráciou pre ňu bolo synchronizované správanie rôznych skupín biologických organizmov, napr. vtáčieho krdla. Na rozdiel od genetických algoritmov nevyužíva genetické operátory, avšak cieľ nájsť optimálne riešenie so stále sa zvyšujúcou kvalitou jedincov v generáciách je totožný. [5] [24]

Každá častica je určená rýchlosťou a smerom pohybu, ktoré sa v každej iterácii aktualizujú. Algoritmus má niekoľko krokov.

1. Na začiatku je vygenerovaná populácia častíc, ktoré sú náhodne umiestnené v priestore.
2. Určí sa kvalita častíc z ich pozícií ako hodnota kritériálnej funkcie.
3. Každý jedinec nesie informáciu o svojej najlepšej pozícii x_{LJ} a funkčnej hodnote v nej, ktorú porovnáva s aktuálnou pozíciou. Vyberie sa pozícia s lepšou hodnotou a uloží sa ako x_{LJ} .
4. Po určení pozícií všetkých častíc sa do spoločnej pamäti populácie uloží pozícia x_{LP} a funkčná hodnota jedinca s najvyššou kvalitou.
5. V ďalšom kroku sa prepočíta rýchlosť a pozícia každej častice, podľa jej individuálnych a zdieľaných skúseností celej populácie nasledovne [6] [10]

$$\begin{aligned}\bar{v}_J(t+1) &= \bar{v}_J + c_1 r_1 (\bar{x}_{LP} - \bar{x}_J(t)) + c_2 r_2 (\bar{x}_{LJ} - \bar{x}_J(t)), \\ \bar{x}_J(t+1) &= \bar{x}_J(t) + \bar{v}_J(t+1).\end{aligned}\tag{2.3}$$

Váha vplyvu týchto skúseností sa môže meniť vďaka vynásobeniu náhodným číslom r_1 a r_2 z intervalu (0,1). Doposiaľ nevysvetleným znakom vzťahov je rýchlosť častice $\bar{v}_J(t)$ v iterácii t , jej pozícia $\bar{x}_J(t)$ a učiace faktory c_1 a c_2 . Rýchlosť v aktuálnej iterácii ukazuje snahu o zachovanie smeru pohybu. Výsledný smer pohybu bude ovplyvnený všetkými faktormi a bude mať tri zložky. Individuálna zložka predstavuje pokračovanie vo vlastnom smere, konzervatívna znamená posun v smere najlepšej individuálnej pozície a prispôsobivou zložkou sa myslí nasledovanie najlepšieho jedinca z populácie. [5] [25]

2.4 Svetluškový algoritmus

Svetluškový algoritmus (FA, z angl. *firefly algorithm*) je prírodou inšpirovaný algoritmus založený na schopnosti svetlušiek emitovať svetlo, tzv. bioluminiscencii. Princípom algoritmu je vydávanie signálu svetluškou práve vo forme svetla, čím priťahuje pozornosť ostatných svetlušiek. Z biologického hľadiska je vydávanie svetla regulované, dochádza k nemu pri párení, keď samičky takýmto spôsobom lákajú

potencionálnych partnerov, ktorí okolo nich lietajú alebo ako reakcia na prípadné nebezpečenstvo. Pre zjednodušenie a použitie ich správania ako optimalizačného algoritmu je predpokladom dodržanie troch nasledujúcich pravidiel.

1. Všetky svetlušky sú bezpohlavné, každá svetluška bez ohľadu na pohlavie je priťahovaná ostatnými.
2. Atraktivita svetlušky je daná jej jasom, vyšší jas znamená vyššiu mieru atraktivity jedinca v porovnaní so zvyšnými. Jasnejšia svetluška bude priťahovať menej jasnú, s jej znižujúcou sa atraktivitou bude rásť vzájomná vzdialenosť tejto dvojice svetlušiek.
3. Ak sa v okolí svetlušky nenachádza žiadna s vyšším jasom, pohyb je náhodný. Jas svetlušky je určený hodnotou kritériálnej funkcie podobne ako kvalita v prípade genetického algoritmu. [28] [29]

2.4.1 Princíp svetluškového optimalizačného algoritmu

Keďže algoritmus patrí do skupiny metód využívajúcich rojovú inteligenciu, inicializácia bude rovnaká ako v prípade metódy rojenia častí v podkapitole 2.3.

Na začiatku sa vygeneruje počiatočná populácia svetlušiek, ktoré sú náhodne rozložené v prehľadávanom priestore. Poloha svetlušky predstavuje riešenie vypočítané ako hodnota kritériálnej funkcie na tejto pozícii s cieľom minimalizácie alebo maximalizácie optimalizačného problému. V jednotlivých iteráciách sa porovnáva vždy dvojica svetlušiek spôsobom každá s každou s aplikovaním princípu, jasnejšia svetluška pritiahne menej jasnú. Súčasťou pohybu je aj náhodná zložka, ktorá so zvyšujúcim sa počtom opakovaní stráca na význame. Po každom opakovaní sa jedinci usporiadajú podľa kvality vzostupne alebo zostupne s vybratím najlepšieho a teda najjasnejšieho jedinca. [18] [28]

Atraktivita svetlušky

Príťažlivosť svetlušky je úmerná jasu, ktorý odpovedá hodnote kritériálnej funkcie $f(x_i)$, kde x_i predstavuje riešenie pre svetlušku i . Podľa predpokladu atraktivita β svetlušky i a j klesá so vzdialenosťou nasledovne

$$\beta(r_{ij}) = \beta_0 e^{-\gamma r_{ij}^2}, \quad (2.4)$$

kde β_0 je príťažlivosť svetlušky i a j pri vzdialenosti $r_{ij} = 0$.

Vzdialenosť a pohyb

Vzdialenosť medzi ktorýmkoľvek dvoma svetluškami i a j je definovaná ako kartézska vzdialenosť

$$r_{ij} = \|\bar{x}_j(t) - \bar{x}_i(t)\| = \sqrt{\sum_{k=1}^d (x_{j,k} - x_{i,k})^2}, \quad (2.5)$$

kde $x_{i,k}$ je k -tý komponent priestorovej súradnice x_i pre i -tú svetlušku v d rozmernom priestore.

Pre pohyb i -tej svetlušky k atraktívnejšej, jasnejšej svetluške j platí vzťah

$$\bar{x}_i(t+1) = \bar{x}_i(t) + \frac{\beta_0}{e^{\gamma r_{ij}^2}} (\bar{x}_j(t) - \bar{x}_i(t)) + \alpha(t)\bar{\varepsilon}(t), \quad (2.6)$$

kde β_0 je konštantná hodnota jasú predom zvolená, parameter $\alpha(t)$ udáva váhu náhodného pohybu. Náhodný pohyb $\varepsilon(t)$ sa určuje ako $r - 0,5$, kde r je náhodné číslo z intervalu $(0,1)$. Parameter γ udáva zmenu atraktivity svetlušky a jeho hodnota je rozhodujúca pre rýchlosť konvergenzie celého algoritmu. [17] [18]

3 REGISTRÁCIA ULTRAZVUKOVÝCH DÁT

Spomedzi spomínaných zobrazovacích modalít, patrí zobrazovanie ultrazvukom medzi neinvazívne, prakticky ľudskému telu neškodné, presné a dostatočne efektívne metódy používané v medicíne. Neohrozovanie pacienta nebezpečným žiarením, dostupnosť a schopnosť zobrazovania v reálnom čase, robí z ultrazvuku veľmi často používaný diagnostický zobrazovací nástroj. Široké využitie má pri napr. pri zobrazovaní ľudského mozgu, srdca, pečene a iných brušných a hrudných orgánov. [7]

Kvalitu určujúce rozlíšenie a kontrast obrazu sú ovplyvnené radou nežiadúcich fyzikálnych faktorov ako aj nedokonalosťou zobrazovacej modality. Prítomnosť multiplikatívneho šumu vo forme speklí a tieňovacie efekty, vytvárajú artefakty, kvôli ktorým sa spracovanie ultrazvukových dát stáva náročnou úlohou. Snahou je tieto nežiadúce efekty eliminovať s použitím vhodných nástrojov využívaných v spracovaní obrazov. Spekle sú spôsobené interferenciou koherentných ultrazvukových vln, vznikajúce pri prekryvaní ech s rôznymi fázami a amplitúdami, s rozsahom závislým na konštruktívnej alebo deštruktívnej interferencii. Práve tieto sú považované za hlavný zdroj šumu, ktorý je cieľom odfiltrovať tak, aby boli čo najviac zachované dôležité prvky obrazov. Filtrovanie šumu je možné realizovať viacerými spôsobmi. Často používané sú filtre aplikované priamo na originálny obraz, kde patrí jednoduchý priemerovací filter, nelineárny mediánový filter a ich úpravy s adaptívnymi váhami a taktiež filtrácia využívajúca princíp difúzie častíc. [4]

Z hľadiska registrácie ultrazvukových dát sa v súčasnosti rozvíjajú ako monomodálne, tak multimodálne metódy, ktoré sa snažia zvýšiť využiteľnosť informácií z nízko kontrastných ultrazvukových dát zlúčením s vysoko kontrastnými obrazmi z modalít ako napr. MRI.

Optimálne metódy pre registráciu nie je možné jasne určiť, kvôli doposiaľ rozsiahlemu množstvu zverejnených výsledkov. Autori v [7] poskytujú prehľad podobnostných metrík a optimalizácií pre registráciu ultrazvukových dát, ktorý je rozdelený podľa použitých rigidných alebo elastických transformácií. Taktiež poskytujú prehľad testovaných registračných techník a ich výsledky podľa anatomických štruktúr. Potvrdený bol napr. predpoklad rozdielneho správania sa kritérií podobnosti pri aplikovaní na rôzne orgány.

Jeden z prvých pokusov o registráciu ultrazvukových dát predstavili autori v [20]. Jednotlivé scany obstarané pomocou B-módu pod rozdielnymi uhlami, boli prahované s cieľom získať binárne obrazy. Ako kritérium podobnosti bol zvolený korelačný koeficient a transformačný model obsahoval iba rotáciu a transláciu. Akumulovaná chyba na testovacích fantómoch dosiahla 15 pixlov. Na ďalšie testovanie autori použili fantóm latexovej chirurgickej rukavice vyplnenej materiálom s vlastnosťami napodobňujúcimi tkanivo. Toto testovanie nebolo bližšie kvantifikované.

Autori však zistili, že metóda je vhodná vtedy, ak sa objekt záujmu nachádza v ohniskovom rozsahu snímača. Taktiež korelačný koeficient je možné použiť, ak sú obrazy snímané blízko seba s malým uhlom.

Pravdepodobne najjednoduchšie kritérium podobnosti založené na intenzite pixlov, sumu rozdielov štvorcov, použili autori [11] k analýze pohyblivosti myokardu s využitím elastickej registrácie. Transformačný model je založený na interpolácii s využitím polynomiálnej krivky B-spline. Vstupom do algoritmu boli páry po sebe idúcich obrazov v sekvencii pre jeden srdečný cyklus. Vo vylepšenej verzii autori použili časo-priestorový parametrický model, s preformulovaním registrácie ako globálneho optimalizačného problému. Metóda bola testovaná na sete vygenerovaných simulovaných sekvencií, ale aj reálnych patientských dátach. Pri uvažovanej hrúbke myokardu 1,2 cm odpovedajúcej približne 32 pixlom, bola priemerná geometrická chyba pre reálne sekvencie 1,265 pixlov.

Dôležitosť výberu podobnostného kritéria popisujú autori v [26], kde porovnali dosiahnuté výsledky s korelačným koeficientom a vzájomnou informáciou. Spomedzi optimalizačných algoritmov bola vybraná Powellova metóda konjugovaných smerov, hybridné zakázané prehľadávanie a hybridná stochasticko-deterministická metóda simulovaného žihania s Powellovou metódou. Testovanými obrazmi boli zašumené fantómy obličky a rez z volumetrického snímku myokardu. Vysoké percento správnych registrácií získali použitím hybridného zakázaného prehľadávania s kritériom vzájomnej informácie vhodným pre 2D - 2D aj 2D - 3D registráciu, ktorá vyžadovala menší počet iterácií k dosiahnutiu presnej registrácie v porovnaní s ostatnými metódami. Zlepšenie autori vidia v interaktívnom zvolení počiatočných bodov prehľadávania užívateľom a pokračovaní s využitím informácie o gradiente. Za úspešnú bola registrácia považovaná pri Euklidovskej vzdialenosti výsledných parametrov posunu a rotácie od referenčných hodnôt transformácií o menej ako 0,25 pixlu, resp. 0,25°.

Maximalizáciu kritéria vzájomnej informácie experimentálne potvrdili ako dostatočne presnú viacerí autori a to aj pri registrácii multimodálnych dát. V posledných rokoch rastie diagnostická využiteľnosť ultrazvuku so zavedením špecifických kontrastných látok potrebných k zobrazeniu perfúzie orgánmi. Pre tieto obrazy nie je potrebná registrácia pre celý ich rozsah, stačí vybrať iba určitú oblasť záujmu, čím sa zvýši rýchlosť výpočtov a tým aj celého procesu.

3.1 Perfúzne zobrazenie

Perfúziou sa myslí zobrazenie prekrvenia určitej časti tkaniva alebo orgánu. Ultrazvukové perfúzne zobrazovanie sa často používa na diagnostiku nádorových ochorení

a ischemických cievnych chorôb. K zobrazeniu prekrvenia a jeho kvantifikovaniu môže byť ultrazvuk použitý tradične pomocou Dopplera alebo novšie sa rozvíjajúcim použitím kontrastných látok vo forme mikrobubliniek. Z angličtiny sa pre takéto vyšetrenie používa skratka *CEUS* (*Contrast-enhanced ultrasound*). Táto metóda predstavuje výhodu porovnaním s Dopplerovskými metódami, u ktorých je ťažko rozpoznateľný rozdiel frekvenčných posunov pre prietok krvi a pohyb tkaniva, a nemôže byť použitý na detekciu prietoku krvi pomalšieho ako 1 mm/s . Základom analýzy perfúzných dát je sledovanie zmien koncentrácie aplikovanej kontrastnej látky v čase, pre vybranú časť tkaniva. [12] [21]

Mikrobubliny sú injektované intravenózne a slúžia ako markery krvného riečišťa, ktoré cirkulujú podobným spôsobom ako červené krvinky. Ich veľkosť je limitovaná priemerom pľúcnych kapilár, cez ktoré je plyný obsah eliminovaný a pohybuje sa v rozmedzí $2 - 7\text{ }\mu\text{m}$ v priemere. Pre obmedzenie rozpúšťania, stabilizovania a spomalenia difúzie plynu sa mikrobubliny zapúzdrujú do plášťa s vysokou molekulárnou hmotnosťou, ktorý môže byť tuhý vo forme denaturovaného albumínu alebo flexibilný, zložený z fosfolipidov. Tieto obaly sú filtrované obličkami a metabolizované pečeňou. [19] [21]

Akustická energia generovaná ultrazvukovým systémom pozostáva zo striedajúcich sa vysokých a nízkych tlakov pri danom frekvenčnom rozsahu a je hlavným parametrom ovplyvňujúcim správanie sa mikrobublín. Podľa veľkosti akustickej energie existujú 3 spôsoby interakcií medzi bublinami a ultrazvukovou energiou: rozptyl ultrazvukových vĺn, rezonancia a deštrukcia mikrobublín. Tie sa na rozdiel od mäkkých tkanív zreteľnejšie striedavo stláčajú pôsobením pozitívneho tlaku a naopak rozširujú pri negatívnom tlaku. Pravdepodobnosť zničenia mikrobublín určuje veličina mechanický index (MI), ktorá taktiež meria potenciál mechanického poškodenia tkanív, ktoré sú vystavené pôsobeniu ultrazvukových impulzov. V diagnostike sa používa v rozsahu od 0,05 do hodnoty 1,9. [19]

Pri veľmi nízkej akustickej energii a mechanickom indexe pod 0,1 sa priemer mikrobublín značne nemení, správajú sa ako rozptyľovače a synchronizovane oscilujú s frekvenciou dopadajúcej ultrazvukovej vlny. Zväčšeniu akustickej energie bubliny odpovedajú zmenami polomeru v čase. Ich rozširovanie a stláčanie sa stáva nerovnomerným, pretože silnejšie odolávajú kompresii než expanzii, čo vedie k nelineárnej oscilácii. Začínajú produkovať harmonické a subharmonické kmity podľa rezonančnej frekvencie ako zložky signálu. Frekvencia subharmonických je polovičná, u vyšších harmonických zložiek je v hodnotách násobkov základnej frekvencie. Keďže susedné tkanivá rezonujú len veľmi málo alebo vôbec, výhodnejšia je detekcia harmonických frekvencií v porovnaní so základnou vysielanou frekvenciou, pretože s nimi mikrobubliny rezonujú a zohráva kľúčovú úlohu pri odlíšení od echa tkanív. S ďalším zvýšením akustickej energie a hodnotou MI nad 0,5 sa narušuje plášť mikrobublín

a produkuje prechodný nelineárny echo signál až do deštrukcie, ktorá sa nazýva stimulovaná akustická emisia alebo strata korelácie medzi signálom získaným pred a po deštrukcii. [12] [19]

Pre ultrazvukové vyšetrenie s kontrastnými látkami je možné použiť zobrazenie konvenčným B-módom alebo využitím dopplerovských metód, ktoré sú veľmi citlivé na prítomnosť mikrobublín. Tie zvyšujú Dopplerov signál a tým aj senzitivitu na spomínaný ťažko detekovateľný nízky prietok. Kontrastné látky taktiež zvyšujú intenzitu signálu, čím zlepšujú analýzu a zvýrazňujú echoštruktúry na špecifických zobrazovacích sekvenciách, ktoré sú harmonické alebo pulzne - inverzné. Strata korelácie sa detekuje ako Dopplerov posun a vo farebnom Dopplerovskom ultrazvuku sa zobrazí ako náhodné farebné signály. [2] [12]

Rozhodujúci vplyv na výsledné zobrazenie má typ použitej kontrastnej látky, vlastnosti jej obalu a zvolená akustická energia s mechanickým indexom. Pri zvolení vysokého mechanického indexu dochádza k deštrukcii bublín a uvoľňovaniu akustickej energie s vysokým obsahom harmonických zložiek. Pri nízkom mechanickom indexe špecifické pulzné sekvencie privádzajú mikrobubliny k rezonancii a sú používané k zobrazovaniu perfúzie v reálnom čase. K zvýšeniu pomeru signálu k šumu je snahou potlačiť signál z tkanív pomocou špecifických zobrazovacích módov. To môže byť dosiahnuté zrušením fázy alebo impulzu, prípadne amplitúdovou moduláciou. Najjednoduchším riešením je u šedotónového zobrazenia použitie jednoduchej inverzie fázy alebo pulzu. Tieto módy sú známe pod anglickými názvami *Phase inversion mode* a *Pulse inversion mode*. [2] [12]

4 REALIZÁCIA NA SIMULOVANÝCH DÁTACH

Súčasťou práce je praktická realizácia registrácie simulovaných a reálnych obrazových dát s implementáciou vybraných evolučných algoritmov a kritériálnych funkcií v programovacom prostredí MATLAB. Táto kapitola sa zaoberá testovaním ultrazvukových dát pankreasu, s cieľom zistiť vplyv možných nastaviteľných parametrov u jednotlivých metód na úspešnosť registrácie. Toto vyhodnotenie a vybratie najlepších nastavení registračných parametrov je kľúčové pre registráciu celých sekvencií reálnych dát.


Z apriornej znalosti o dodanej ultrazvukovej sekvencii pankreasu bol zvolený transformačný model založený na využití rigidných transformácií, teda na horizontálnom a vertikálnom posune a na rotácii o zvolený uhol. K vyhodnoteniu funkčnosti navrhnutých algoritmov v zmysle kritériálnej funkcie a optimalizačného algoritmu bol z celej sekvencie vybraný jeden referenčný snímok, ktorý bol posunutý v smere osi x a y a natočený o uhol podľa predom známych hodnôt. Cieľom bolo vždy dvojicu takto transformovaného obrazu čo najviac stotožniť s referenčným obrazom, získať pôvodné hodnoty transformácie a zistiť optimálne registračné parametre.

4.1 Testované obrazy

Vybraný referenčný snímok pankreasu bol s ohľadom na veľkosť 434×266 pixlov vložený do väčšej matice núl, kvôli obmedzeniu nežiadúcej straty informácie pri translácii a rotácii. K realizácii týchto dvoch geometrických transformácií boli použité funkcie Matlabu, `imtranslate` pre posun a funkcia `imrotate` na rotáciu obrazu, s vybranou metódou bilinéarnej interpolácie, ktorá bola zvolená pre korektnosť výpočtu kritéria podobnosti medzi referenčným a transformovaným obrazom. Referenčnou pre posun v oboch smeroch bola hodnota 10 pixlov a uhol natočenia 10° . Takto transformovaný obraz je zobrazený na obrázku 4.1.

4.1.1 Výber oblasti záujmu

Z dôvodu zníženia časovej náročnosti a zvýšenia presnosti dosiahnutých výsledkov registrácie bolo dôležitou súčasťou definovanie vhodnej oblasti záujmu obrazu, kde prebiehal výpočet kritéria podobnosti referenčného a transformovaného obrazu. V základnom testovaní bola presne daná, kvôli opakovanému spúšťaniu jednotlivých algoritmov. Požadovaná oblasť sa pri porovnávaní dvojíc referenčného a transformovaného obrazu volila len u obrazu referenčného, aby mala porovnávaná oblasť u oboch rovnakú veľkosť. Určená oblasť je zobrazená na obrázku 4.2 vľavo, považovaná za vhodne zvolenú, pretože obsahuje časť snímky s podstatnou informáciou




Obr. 4.1: Zobrazenie obrazu pôvodného (vľavo) a po transformácii (vpravo)

o štruktúrach, ktoré sa v priebehu celej sekvencie dynamicky menia a registrácia v tejto časti má zmysel. V pravej časti tohto obrázku je príklad nevhodnej oblasti, ktorá zachytáva nepodstatnú časť snímky pankreasu a viedla by k nepresným výsledkom aj napriek správnej funkčnosti algoritmov.

Oblasť záujmu (ROI, region of interest) bola vyberaná pomocou funkcie Matlabu `roipoly`. Funkcia poskytuje užívateľovi aj možnosť priameho výberu oblasti na testovanom obraze, bez predchádzajúcej znalosti o priebehu v sekvencii. Výstupom je binárny obraz, kde pixely s hodnotou 1 patria do vybranej oblasti, hodnota 0 predstavuje nepodstatnú časť snímky. Tento obraz bol ďalej použitý ako maska, ktorá sa v procese optimalizácie násobila s referenčným, resp. pohybovým obrazom, čím sa hodnoty mimo určenú oblasť záujmu nahradili hodnotou 0.

4.1.2 Kriteriálne funkcie

Jedným z ďalších krokov v navrhnutom algoritme registrácie je výber kriteriálnej funkcie. Podľa dostupnej literatúry sú pri registrácii obrazových dát z jednej zobrazovacej modality vhodnejšie kritériá podobnosti založené na intenzitách pixlov. Z týchto boli pre testovanie zvolené teoreticky popísané kritériá z podkapitoly 1.2.1 a to normalizovaná suma štvorcov rozdielov, kosínové kritérium a normalizovaný korelačný koeficient.



Obr. 4.2: Zobrazenie vhodnej oblasti záujmu (vľavo) a nevhodnej (vpravo)

Podobnosť obrazov vyjadrenou ako hodnota kritériálnej funkcie je snahou optimalizovať a to jej maximalizovaním alebo minimalizovaním. V prípade sumy štvorcov rozdielov je pri úplnom stotožnení častí dvojice obrazov hodnota vzdialenosti nulová, pre určenie kvality riešenia bolo cieľom toto kritérium minimalizovať. Naopak z definície kosínového kritéria a korelačného koeficientu vyplýva snaha o ich maximalizovanie, dosiahnutie optimálnej registrácie v maxime funkcií, v hodnote 1.


4.2 Proces optimalizácie

Vo všeobecnom procese registrácie, s cieľom čo najviac pripodobniť dvojicu obrazov, je dôležitou súčasťou vhodné zvolenie optimalizačného algoritmu. Táto práca je zameraná na využitie evolučných algoritmov, z ktorých je v problematike registrácie ultrazvukových dát veľmi často využívaný genetický algoritmus. Z hľadiska teoreticky dosiahnuteľnej úspešnosti je v práci popísaný podrobnejšie. Pre porovnanie boli zvolené ďalšie dva evolučné algoritmy a to metóda roja častíc a z nej vychádzajúci svetluškový algoritmus.

4.2.1 Optimalizácia genetickým algoritmom

Prvou z navrhnutých a realizovaných optimalizačných metód je spojitý genetický algoritmus. V prípade práce so spojitými premennými je logickejšia reprezentácia hodnôt s pohyblivou desatinnou čiarkou, ako použitie binárneho vyjadrenia. Porovnaním s teoreticky popísaným binárnym genetickým algoritmom poskytuje širšiu oblasť reprezentácie hodnôt, bez obmedzenia kvantovaním a navyše vyžaduje menšiu pamäť. [6]

Postup realizácie tejto časti programu je pre názornejšiu ukážku uvedený na obrázku 4.3, kde na rozdiel od binárneho algoritmu je operátor kríženia a mutácie spojený do jedného kroku, reprodukcie. [16]



Obr. 4.3: Vývojový diagram realizovaného spojitého genetického algoritmu [16]

Počiatočná populácia

Počiatočná populácia uložená v matici o rozmere $N_{pop} \times N_{var}$ je náhodne vygenerovaná. N_{pop} udáva počet jedincov a N_{var} počet hľadaných premenných. Matica je následne vyplnená nenormalizovanými hodnotami medzi minimálnou a maximálnou hodnotou v rozsahu jednotlivých premenných nasledovne

$$p = (p_{max} - p_{min})r + p_{min} \quad , \quad (4.1)$$

kde p_{max} je najväčšie číslo v rozsahu premennej, p_{min} naopak najmenšie číslo, r je náhodne vygenerované číslo v rozsahu (0,1). Rovnakým spôsobom sú vyplnené stĺpce matice pre všetky 3 hľadané premenné. [6]

Podľa viacerých autorov sa práve definovanie počiatkovej populácie zdá byť kritickým prvkom vo vyhľadávacom procese, čo ovplyvňuje celkové dosiahnuté výsledky.

Reprodukcia

Ďalším krokom je stanovenie kvality jedincov v počiatkovej populácii, teda vypočítanie hodnoty kritériálnej funkcie. Podľa kvality sa jedinci usporiadajú a vyberie sa polovica najlepších. Z tejto skupiny sa postupne vyberajú dvojice jedincov $P1$ a $P2$, ktoré podstupujú lineárnemu kríženiu. Kombinovaním informácií z dvoch rodičov sú generovaní 3 potomci podľa vzťahov

$$\begin{aligned} O_1 &= 0,5P_1 + 0,5P_2 \\ O_2 &= 1,5P_1 - 0,5P_2 \\ O_3 &= -0,5P_1 + 1,5P_2 \end{aligned} \quad (4.2)$$

Hodnoty mimo rozmedzie dovtedy prezentovaných extrémov v populácii sú vyradené. Podľa kvality 3 vzniknutých potomkov sú vybratí dvaja najlepší. Postup sa opakuje až do vytvorenia populácie s požadovaným počtom jedincov. [6] [16]

Číselné koeficienty násobenia nie sú striktné dané, je možné použiť rôzne čísla pre každú premennú. Dokonca je možné stanoviť vzdialenosť od hranice rodičovských premenných, kde môže potomok ešte ležať. [6]

Mutácia

Bezprostredne po vytvorení populácie potomkov nasleduje krok mutácia, vďaka ktorej sú preskúvané nové možnosti riešení. Pravdepodobnosť mutácie bola v základnom testovaní volená z intervalu (0,1 - 0,8) s krokom 0,1 a porovnávala sa s náhodne vygenerovaným číslom z intervalu (0,1). Ak je pravdepodobnosť mutácie väčšia, alela X zmutuje na alelu X_{mut} podľa vzťahu

$$X_{mut} = X + a \left(1 - \frac{i}{I_{max}} \right) (r - 0,5), \quad (4.3)$$

kde a je váhová konštanta, i je aktuálna iterácia, I_{max} je stanovený maximálny počet iterácií, r je náhodne vygenerované číslo patriace do intervalu (0,1). [16]


Z pohľadu dosiahnutia čo najvyššej úspešnosti registrácie bol hodnotený vplyv zvolenej pravdepodobnosti mutácie ako aj váhovacej konštanty a , ktorá bola testovaná pre hodnoty 3, 5 a 7.

Ukončovacia podmienka

Samotný algoritmus má dve možnosti ukončenia. Prvou je dosiahnutý predom nastavený maximálny počet iterácií a druhou je podmienka stagnácie. Porovnávaný je vždy rozdiel maximálnej kvality v aktuálnej iterácii od najlepšieho jedinca v predchádzajúcom kroku s referenčnou hodnotou 1.10 E-06 .

4.2.2 Optimalizácia rojovým algoritmom

Ďalším evolučným algoritmom vybraným k realizácii je metóda rojenia častíc, teoreticky popísaná v podkapitole 2.3. Rovnako ako v prípade spojitého genetického algoritmu je na začiatku náhodne generovaná populácia častíc uložená do matice o rozmere $N_{pop} \times N_{var}$, teda počet jedincov $\times$ počet hľadaných premenných. Pre každú časticu je okrem toho generovaný vektor rýchlosti, ktorý udáva smer jej pohybu. Pre lepšiu názornosť je na nasledujúcom obrázku zobrazený vývojový diagram realizovanej optimalizačnej metódy. [13]



Obr. 4.4: Vývojový diagram rojového algoritmu

V porovnaní s genetickým algoritmom nevyužíva žiadne genetické operátory ako mutáciu a kríženie. Informáciu ostatným časticiam podáva iba najlepšia častica, čo


urýchľuje celkový čas výpočtu. Výhodou rojového algoritmu je jednoduchá realizovateľnosť a potreba úpravy len niekoľkých parametrov.

V realizovaní tejto časti programu majú na celkovú úspešnosť registrácie rozhodujúci vplyv zvolený počet častíc a maximálny počet iterácií behu algoritmu, ktorým je stanovená ukončovacia podmienka. Druhou možnosťou terminácie je rovnako ako u genetického algoritmu podmienka stagnácie. Nastaviteľnými parametrami sú učiace faktory c_1 a c_2 vysvetlené vo vzorci 2.3, ktoré sú z empirického hľadiska nastavené na hodnotu 2.

4.2.3 Optimalizácia svetluškovým algoritmom

Poslednou optimalizačnou metódou bol zvolený svetluškový algoritmus. Keďže patrí do rovnakej skupiny ako metóda rojenia častíc, teda rojových algoritmov, princíp generovania počiatočnej populácie svetlušiek náhodne rozmiestnených v priestore je totožný. Vypočítaním hodnoty kritériálnej funkcie sa stanoví kvalita jedinca, ktorá určuje príťažlivosť pre ostatných jedincov.

Celý navrhnutý algoritmus je zobrazený na vývojom diagrame 4.5, spolu s konkrétnymi hodnotami parametrov, ktoré sa v priebehu nemenili.



Obr. 4.5: Vývojový diagram svetluškového algoritmu

Od genetického algoritmu a metódy rojenia častíc sa odlišuje veľkým počtom parametrov, ktoré vstupujú do algoritmu a ovplyvňujú jeho priebeh. V samotnom testovaní bol posudzovaný vplyv váhy náhodného pohybu α , volený z intervalu (1,7), ktorý sa však v hlavnom cykle algoritmu prepočítaval podľa vzťahu $\alpha = \alpha\delta$ v každej iterácii. Parameter δ empiricky stanovený na hodnotu 0,97 určoval mieru náhodného pohybu svetlušiek. Ako konštantný bol stanovený aj parameter upravujúci príťažlivosť a to na hodnotu $\gamma = 0,01$. Po premennej α , druhým významným a sledovaným je parameter β_0 , vyjadrujúci príťažlivosť svetlušiek pri vzájomnej vzdialenosti 0.

Jedinou možnosťou ukončenia celého optimalizačného behu je dosiahnutie maximálneho počtu iterácií, ktorý je treba zvoliť s ohľadom na konkrétnu úlohu.

4.2.4 Kritériá úspešnosti registrácie

Pred samotným testovaním navrhnutých algoritmov na celej sekvencii dát bolo nevyhnutné otestovanie ich funkčnosti a správnosti na dátach so známymi hodnotami transformačných parametrov. Na vyhodnotenie úspešnosti bol použitý výpočet Euklidovskej vzdialenosti a kvalita dosiahnutého riešenia.

Euklidovská vzdialenosť

Euklidovská vzdialenosť vo všeobecnosti vyjadruje vzdialenosť dvoch bodov v priestore. Pri testovaní bolo požadované spätné zistenie dosiahnutých 3 hodnôt na konci algoritmu a to pre posun v horizontálnom a vertikálnom smere a pre rotáciu. Preto je nutné uvažovať výpočet Euklidovskej vzdialenosti v trojrozmernom priestore.

Súradnice bodu (x_1, y_1, z_1) predstavujú známe, referenčné hodnoty pre posun v smere osi x, y s hodnotou 10 pixlov a hodnotou 10° pre natočenie. Súradnice druhého bodu (x_2, y_2, z_2) sú algoritmami nájdené hodnoty v rovnakom poradí. Vzdialenosť medzi týmito dvomi bodmi sa vypočíta nasledovne podľa vzťahu

$$D = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2}. \quad (4.4)$$

V ideálnom prípade je táto vzdialenosť nulová, teda algoritmami boli získané rovnaké hodnoty ako referenčné. Po aplikovaní geometrických transformácií s týmito hodnotami na transformovaný obraz, by boli s referenčným obrazom úplne stotožnené. [14]

Kvalita registrácie

Druhým kritériom na posúdenie úspešnosti metód je kvalita získaného riešenia. Tá, ako už bolo spomenuté, odpovedá priamo hodnote kritériálnych funkcií počítaných medzi referenčným a pohybovým obrazom. Výslednú kvalitu po optimalizácii je nutné hodnotiť s ohľadom na konkrétne vybrané kritérium podobnosti, ktorého cieľom je v priebehu minimalizovať alebo maximalizovať. V prípade minimalizácie,

ktorá sa týka kritéria sumy štvorcov rozdielov, je nutné upraviť hodnotu vynásobení číslom (-1) a to preto, aby v bode globálneho minima bola hodnota maximálna.

Pre pripomenutie, kvalita bola počítaná iba v stanovenej oblasti záujmu, kde by podľa očakávania mala dosiahnuť vždy lepšie hodnoty po optimalizácii. Kvalita medzi referenčným a transformovaným obrazom vo výreze je na začiatku pre jednotlivé kombinácie optimalizačných metód s kritériálnymi funkciami rovnaká. Výsledná kvalita sa vypočíta ako hodnota kritériálnej funkcie vo výreze referenčného obrazu a obrazu spätne transformovaného s nájdenými hodnotami transformačných parametrov. Počítaním kvality z celého rozsahu nemusí dôjsť k plošnému zlepšeniu. [15]

Časová náročnosť

Z hľadiska úspešnosti registrácie je dôležitým kritériom aj realizovateľnosť algoritmov s ohľadom na čas potrebný pre výpočet. Preto je nutné voliť vhodný kompromis medzi dosiahnutou presnosťou a kvalitou riešení s prihliadnutím na časové nároky. Všetky testovania z kapitoly 5 a 6 boli počítané na stolnom počítači s nasledujúcimi parametrami v tabuľke 4.1. Hodnotením a porovnávaním registračných techník z pohľadu časových nárokov je vhodné zaoberať sa pri použití rovnakej výpočtovej techniky.

Tab. 4.1: Parametre výpočtového nástroja

procesor	i7 - 5820K (6 jadier x 3,3 GHz)
RAM	16 GB DDR4
verzia Matlabu	R2016b

5 VYHODNOTENIE ÚSPEŠNOSTI TESTOVANIA

Vyhodnotenie základného testovania je pre prehľadnosť rozdelené na viacero častí, kde sa osobitná pozornosť venuje každému optimalizačnému algoritmu. Pre každý algoritmus je zvlášť popísaná dosiahnutá úspešnosť registrácie podľa vybranej kritériálnej funkcie. Najmä v grafickom znázornení sú pre kritériálne funkcie používané skratky vychádzajúce z anglických názvov, SSD, suma štvorcov rozdielov, COS pre kosínové kritérium a CC pre normalizovaný korelačný koeficient.

V každej časti kapitoly sú popísané vplyvy jednotlivých parametrov, charakteristických pre daný typ metódy s následným vybratím optimálnych hodnôt. Pre získanie adekvátnych výsledkov testovania boli všetky kombinácie optimalizačných algoritmov s kritériálnymi funkciami spúšťané 10x.

5.1 Vyhodnotenie optimalizácie genetickým algoritmom

Testovanie genetického algoritmu bolo pre prehľadnosť rozdelené na dve časti. V prvej bol sledovaný vplyv zvoleného počtu jedincov, stanovený maximálny počet iterácií ako jedna z podmienok ukončenia algoritmu a pravdepodobnosť mutácie. Druhá časť bola realizovaná s konštantnou hodnotou parametra počet jedincov a maximálneho počtu iterácií so zmenou pravdepodobnosti mutácie a váhovacej konštanty mutácie.

5.1.1 Vplyv množstva jedincov a počtu iterácií

Zmeny hodnôt parametrov, ktoré ovplyvňovali úspešnosť registrácie sa cyklicky menili v zvolených intervaloch. Pre predstavu je nižšie uvedený jednoduchý pseudokód, ktorý bol použitý všeobecne pre všetky tri kritériálne funkcie, ktorá je dôležitá až v samotnej funkcii `GENETICKY ALGORITMUS`


```
for pocet_jedincov = 10 až 50 krok 10
  for pst_mutacie = 0,1 až 0,8 krok 0,1
    for max_iteracii = 10 až 50 krok 10
      function GENETICKY ALGORITMUS(jedincov, pst_mutacie, max_iteracii)
    end for
  end for
end for.
```

Vstupom do tejto funkcie je okrem ukázaných parametrov aj referenčný a transformovaný obraz. Celkovo je genetický algoritmus volaný $(200 \times 10)x$, pričom číslo 200 je množstvo všetkých možných kombinácií uvedených 3 parametrov, z čoho vyplýva aj počet vypočítaných kvalít a Euklidovských vzdialeností. Pre každú kombináciu tak bolo k dispozícii 10 hodnôt kvality riešenia, resp. vzdialeností, z ktorých bola vypočítaná priemerná hodnota.

Suma štvorcov rozdielov

Vzhľadom na podrobnejšiu analýzu vplyvu pravdepodobnosti mutácie v druhej časti testovania, bola z celkových výsledkov skúmaná iba závislosť kvality riešenia, resp. Euklidovskej vzdialenosti na množstve jedincov a maximálnom počte iterácií, s pravdepodobnosťou 0,1. Práve pri tejto hodnote boli zaznamenané najlepšie výsledky. Získané výsledky pre 25 kombinácií sú znázornené v tabuľke 5.1.

Ukazovateľ priemernej kvality v každej kombinácii ukázal zlepšenie kvality po optimalizácii genetickým algoritmom v porovnaní s hodnotou kvality pred, ktorá bola -0,0022621. Tým je možné konštatovať, že algoritmus smeroval k lepšiemu riešeniu. Pre lepšiu predstavu sú dané závislosti znázornené grafickou formou na obrázku 5.1.



Obr. 5.1: Závislosť kvality registrácie na počte iterácií a počte jedincov, SSD

Z tabuľky a obrázku 5.1 vyplýva, že pri malom množstve 10 jedincov a počte iterácií 10 je kvalita riešenia najhoršia. S narastajúcim počtom iterácií sa postupne


Tab. 5.1: Tabuľka získaných výsledkov pre genetický algoritmus, SSD

počet jedincov	maximum iterácií	priemerná kvalita	priemerná Euklidovská vzdialenosť
10	10	-1,21 E-03	8,20
10	20	-1,24 E-03	8,23
10	30	-1,12 E-03	7,95
10	40	-5,47 E-04	3,56
10	50	-6,99 E-04	4,09
20	10	-1,00 E-03	4,78
20	20	-4,79 E-04	2,12
20	30	-3,53 E-04	2,43
20	40	-9,34 E-05	0,28
20	50	-6,92 E-05	0,15
30	10	-4,44 E-04	1,67
30	20	-1,01 E-04	0,37
30	30	-8,90 E-05	0,25
30	40	-6,27 E-05	0,03
30	50	-6,44 E-05	0,06
40	10	-3,44 E-04	1,67
40	20	-1,60 E-04	0,38
40	30	-6,26 E-05	0,03
40	40	-6,18 E-05	0,01
40	50	-6,17 E-05	0,00
50	10	-1,44 E-04	0,64
50	20	-6,67 E-05	0,05
50	30	-6,21 E-05	0,02
50	40	-6,12 E-05	0,00
50	50	-6,13 E-05	0,00

zvyšuje, avšak tento počet jedincov je nepostačujúci. Naopak pri maximálnych nastaveniach parametrov s hodnotou 50 sa kvalita najviac blíži ideálnej hodnote 0. Optimálna z hľadiska dosiahnutej hodnoty kvality a časovej náročnosti je kombinácia nastavení 40 jedincov a 30 iterácií alebo ich číselná zámena. Práve tieto hodnoty boli zvolené pre testovanie v druhej časti optimalizácie genetickým algoritmom.

Jasnejším ukazovateľom opisovanej závislosti je v grafickom znázornení Euklidovská vzdialenosť na obrázku 5.2. Vyplývajú z nej rovnaké skutočnosti ako v prípade kvality riešenia, avšak v prípade malého počtu jedincov a iterácií je zrejmá značná

nepresnosť, a teda veľká odchýlka medzi algoritmom nájdenými a referenčnými hodnotami geometrických transformácií.



Obr. 5.2: Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, SSD

Priemerná Euklidovská vzdialenosť pre 10 jedincov a iterácií je 8,2, čo znamená, že algoritmus nie je možné považovať za úspešný, pretože nájdené hodnoty pre posun a rotáciu sa v najhoršom prípade líšili až o 8 pixlov, resp. 8°. S rastúcim počtom je však očividná klesajúca tendencia. Pri počte jedincov 20 je najväčšia priemerná odchýlka na úrovni odchýlky najmenej pre 10 jedincov a so zvyšovaním iterácií výrazne klesá. Zvolením 30 alebo 40 jedincov má krivka závislosti takmer totožný priebeh. Pri maximálnych hodnotách vstupných parametrov bolo optimalizačným algoritmom nájdené úplne presné riešenie.

Pri hodnotení Euklidovskej vzdialenosti je nutné podotknúť, že už pod dosiahnutú odchýlku hodnoty 1 pixel ide o takmer subpixelovú dosiahnutú presnosť.

Kosínové kritérium

Rovnako ako pri hodnotení testovania genetického algoritmu s kritériálnou funkciou suma rozdielov štvorcov, boli zmeny hodnôt a ich vplyv posudzované pri zvolenej pravdepodobnosti mutácie 0,1. Kompletne výsledky 25 kombinácií množstva jedincov a počtu iterácií zobrazuje tabuľka 5.2.


Najlepšia dosiahnuteľná hodnota kvality je pri použití kosínového kritéria v hodnote funkcie 1, pričom pred optimalizáciou dosahovala hodnotu 0,887 v oblasti záujmu obrazu. Z grafu závislosti kvality riešenia na obrázku 5.3 je opäť zrejmé, že

Tab. 5.2: Tabuľka získaných výsledkov pre genetický algoritmus, COS

počet jedincov	maximum iterácií	priemerná kvalita	priemerná Euklidovská vzdialenosť
10	10	0,919	9,160
10	20	0,935	10,259
10	30	0,945	6,922
10	40	0,945	2,653
10	50	0,981	2,775
20	10	0,958	3,930
20	20	0,974	2,127
20	30	0,981	1,888
20	40	0,995	0,308
20	50	0,996	0,149
30	10	0,977	1,824
30	20	0,992	0,767
30	30	0,997	0,096
30	40	0,997	0,037
30	50	0,997	0,008
40	10	0,991	1,006
40	20	0,994	0,466
40	30	0,997	0,106
40	40	0,997	0,040
40	50	0,997	0,006
50	10	0,994	0,482
50	20	0,997	0,036
50	30	0,997	0,007
50	40	0,997	0,007
50	50	0,997	0,005


malý počet iterácií v kombinácii s malým počtom jedincov poskytuje najhoršie riešenie. Plynulejšia konvergencia k optimálnej hodnote riešenia so zvyšujúcim sa počtom iterácií je zreteľná až pri počte jedincov 30, 40 a 50.

Celkovo najlepšia dosiahnutá hodnota kritériálnej funkcie vo výrezoch obrazov bola 0,997. Takúto hodnotu sa podarilo získať už pri 30 jedincoch v populácii so zadaným maximálnym počtom iterácií 30. Porovnaním relatívneho rozptylu vypočítaných kvalít sumy štvorcov rozdielov a kosínusového kritéria sa hodnoty u tohto kritéria zvyšujú, a tým aj zlepšujú po stotinách.



Obr. 5.3: Závislosť kvality registrácie na počte iterácií a počte jedincov, COS

V prípade Euklidovskej vzdialenosti je rozptyl odchýliek ešte väčší, zobrazený na obrázku 5.4.



Obr. 5.4: Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, COS


V priemere najväčšia odchýlka od referenčných hodnôt 10,26 je spôsobená dvomi výrazne odlišnými hodnotami parametrov transformácií, kde bol dokonca zamenený

smer translácie v smere osi x a y do záporných hodnôt. Pri výbere tohto kritéria je počet jedincov 10 aj pri vyššom počte iterácií nepostačujúci. Výrazná zmena k lepšiemu je s výberom 20 jedincov v populácii, avšak aj v tomto prípade bol v jednom z 10 pokusov pri počte iterácií 20 zamenený smer posunu. Najmenšia odchýlka 0,005 je očakávateľne pri maximálnom počte jedincov aj iterácií 50, kde sa v 6 z 10 prípadov podarilo nájsť úplne presné hodnoty. Z pohľadu časovej náročnosti pri takejto kombinácii ide o najdlhšie trvajúci výpočet.

Normalizovaný korelačný koeficient

Aj pri použití genetického algoritmu s hodnotiacou funkciou normalizovaný korelačný koeficient sú výsledky hodnotené pri pravdepodobnosti mutácie 0,1 a sú zobrazené v tabuľke 5.3. V procese optimalizácie je úlohou toto kritérium maximalizovať, najlepšie riešenie, resp. najlepší jedinec má kvalitu v hodnote funkcie rovnú 1. Hodnota kritériálnej funkcie v definovanej oblasti záujmu referenčného a transformovaného obrazu je pred optimalizáciou 0,878.

Rovnako ako u predchádzajúcich dvoch kritérií sa potvrdil predpoklad nedostatočnosti malého počtu jedincov a iterácií s počtom 10. Priemerná kvalita úspešnosti registrácie má pri tak malom počte jedincov s rastúcim počtom iterácií nepredvídateľný trend, viditeľný na grafe 5.5.



Obr. 5.5: Závislosť kvality registrácie na počte iterácií a počte jedincov, CC

Najväčšia odchýlka v zmysle Euklidovskej vzdialenosti je v kombinácii pre 10 jedincov a maximálny počet iterácií 20, kde je rozdiel najmenšej a najväčšej odchýlky vrámci 10 pokusov až 26,2 pixlov. Z pohľadu úspešnosti registrácie je vhodné


Tab. 5.3: Tabuľka získaných výsledkov pre genetický algoritmus, CC

počet jedincov	maximum iterácií	priemerná kvalita	priemerná Euklidovská vzdialenosť
10	10	0,915	10,206
10	20	0,912	12,343
10	30	0,950	5,960
10	40	0,937	8,809
10	50	0,969	4,321
20	10	0,955	3,572
20	20	0,971	2,621
20	30	0,973	2,425
20	40	0,996	0,270
20	50	0,996	0,154
30	10	0,982	1,485
30	20	0,991	0,651
30	30	0,996	0,126
30	40	0,997	0,011
30	50	0,997	0,040
40	10	0,994	0,504
40	20	0,994	0,209
40	30	0,997	0,026
40	40	0,997	0,009
40	50	0,997	0,009
50	10	0,992	0,711
50	20	0,997	0,024
50	30	0,997	0,013
50	40	0,997	0,004
50	50	0,997	0,003

použitie až od 30 jedincov, kde už kvalita od počtu iterácií 30 dosahuje najvyššiu možnú hodnotu 0,997. Pridaním ďalších 10 jedincov ako počtu možných riešení v populácii je priemerná kvalita už od najnižšieho počtu iterácií ustálená na najvyššej dosiahnuteľnej hodnote.

Odchýlky od referenčných hodnôt s normalizovaným korelačným koeficientom s výnimkou počtu jedincov 10, klesajú lineárne k optimálnej hodnote 0 so zvyšujúcim sa počtom jedincov a počtom opakovaní cyklu. Závislosť vypočítanej priemernej Euklidovskej vzdialenosti na dvoch meniacich sa parametroch je na obrázku 5.6.

Subpixelová presnosť už bola dosiahnutá pri stredných hodnotách intervalov, 30 jedincov a počte iterácií 40. Najvyššia hodnota 0,003 bola získaná až pre horné hranice intervalov, ktoré do genetického algoritmu vstupovali.



Obr. 5.6: Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, CC


5.1.2 Pravdepodobnosť a váha mutácie

V druhej časti testovania bol sledovaný vplyv nastavenej hodnoty pravdepodobnosti mutácie a váhovacej konštanty, uvedenej vo vzťahu 4.3. Algoritmus bol testovaný s 30 jedincami v populácii a maximálnym počtom iterácií 40 pre všetky tri kritériálne funkcie. Vyplývajú z prvej časti testovania, s tými hodnotami už je možné považovať algoritmus za úspešný s dostatočnou presnosťou. Vyjadrenie presnosti so zmenou sledovaných parametrov je ukázané grafickým znázornením priemerných Euklidovských vzdialeností.

Suma štvorcov rozdielov

Z grafu na obrázku 5.7 je možné vyčítať najhoršiu aj najlepšiu možnú kombináciu nastavenia parametrov. Najväčšie odchýlky nájdených transformačných parametrov sú pri nastavení váhovacej konštanty na 3 v kombinácii s malou pravdepodobnosťou jedince zmutovať. Je nutné dodať, že aj najväčšia odchýlka sa od referenčných hodnôt odlišuje v ráde desiatín pixlov. Vyjmúc tento extrémny prípad odchýlky s hodnotou 0,4, pre všetky ostatné kombinácie parametrov priemerná Euklidovská vzdialenosť

osciluje okolo hodnoty 0,05. Optimálne nastavenie je pre najnižšie hodnoty pravdepodobnosti mutácie 0,1 a 0,2 s nastavením váhovej konštanty na hodnotu 5 alebo 7.



Obr. 5.7: Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovej konštanty, SSD


Kosínové kritérium

Takmer identický priebeh majú závislosti Euklidovskej vzdialenosti s optimalizáciou kosínovým kritériom zobrazené v grafe 5.8. Porovnávaná nízka hodnota pravdepodobnosti mutácie s náhodne generovaným číslom z intervalu (0,1) znamená, že algoritmu je postačujúce poskytnúť aspon takúto možnosť preskúmať nové okolie a tým uniknúť z prípadného lokálneho extrému.


Odhladiac od jedinej výrazne odlišnej priemernej hodnoty Euklidovskej vzdialenosti 0,3, krivky pre váhové konštanty 3 a 5 sú ustálené v okolí hodnoty 0,05. Mierne rastúci lineárny trend má krivka pre váhovú konštantu 7. Aj pre toto kritérium je najvhodnejšia kombinácia s nižšou hodnotou pravdepodobnosti mutácie 0,1 alebo 0,2 s hodnotou váhy 5, kde sú odchýlky od referenčných hodnôt najmenšie.

Normalizovaný korelačný koeficient

V prípade tejto kritériálnej funkcie zobrazenej na obrázku 5.9 už nie je na prvý pohľad viditeľný jednoznačný charakter závislosti Euklidovskej vzdialenosti na sledovaných parametroch.



Obr. 5.8: Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovej konštanty, COS



Obr. 5.9: Závislosť Euklidovskej vzdialenosti na pravdepodobnosti mutácie a váhovej konštanty, CC

K hodnoteniu je však potrebné zohľadniť zmenu mierky v porovnaní s predchádzajúcimi kritériami, kde najväčšia odchýlka dosahuje hodnotu 0,13. To je spôsobené tým, že v jednom z 10 pokusov dosahovala odchýlka od referenčnej hodnoty


pre posun až 1 pixel. Ako najmenej vhodné nastavenie je možné uvažovať váhovaciu konštantu 7 s akoukoľvek kombináciou pravdepodobnosti, kde má krivka nepredvídateľný charakter aj pri pohľade na rozptýl hodnôt vrámci 10 pokusov spúšťania.

Aj pre toto kritérium je z grafu možné vyčítať najoptimálnejšiu kombináciu pravdepodobnosti mutácie 0,1 s váhovacou konštantou 5, kde v 6 prípadoch z 10 algoritmus našiel hodnoty transformačných parametrov s presnosťou na tisíce pixlov. So zvyšovaním pravdepodobnosti mutácie však aj pre túto hodnotu konštanty odchýlka od referenčných hodnôt rastie.

5.1.3 Časová náročnosť genetických algoritmov

Jednoznačným cieľom algoritmov je dosiahnuť čo najvyššiu presnosť z pohľadu dosiahnutej optimálnej hodnoty kvality riešenia alebo minimálnej hodnoty odchýlky nájdených parametrov transformácie od referenčných hodnôt. Napriek tejto snahe je dôležité dbať na časovú náročnosť algoritmov, ktorá sa s použitými kritériálnymi funkciami podľa zmeny počtu jedincov a iterácií líši.

Všeobecne pre všetky funkcie platí, so zvyšujúcim sa počtom jedincov v populácii a stanoveným maximálnym počtom iterácií časová náročnosť samotného algoritmu lineárne rastie. V grafe sú zobrazené pre všetky tri kritériá podobnosti na obrázku 5.10.



Obr. 5.10: Časová náročnosť výpočtu genetického algoritmu

Časovo najmenej náročným na výpočet je aj z názvu vyplývajúce najjednoduchšie kritérium suma štvorcov rozdielov, v grafe pod skratkou SSD. So vstupnými parametrami 10 jedincov a maximálny počet iterácií 10, trvá výpočet genetického algoritmu 4,36 sekundy. S postupným navyšovaním či už jedného, alebo druhého parametra o 10 sa táto doba zdvojnásobí, eventuálne pre hodnoty 30 strojnásobí atď. Nastavenie s najvyšším množstvom jedincov a iterácií je síce z hľadiska dosiahnutej presnosti najlepší, avšak časovo náročný. Všeobecne najviac času v priebehu algoritmu zaberá opakované otáčania a posúvanie obrazu s volaním funkcií Matlabu.

Z hľadiska potrebného času na výpočet sú si podobnejšie kosínové kritérium a korelačný koeficient. Už pre najmenšie hodnoty parametrov je kritérium SSD o 0,5 sekundy rýchlejšie ako kosínové kritérium a o 0,63 s ako optimalizácia korelačného koeficientu. Aj v tomto prípade však platí, že závislosť výpočtového času so zvyšujúcimi sa hodnotami sledovaných parametrov lineárne rastie.

5.1.4 Výber optimálneho nastavenia parametrov

Cielom testovania s podrobným vyhodnotením vplyvu uvedených parametrov bolo získať ich optimálne nastavenie pre nasledujúce testovanie na celej ultrazvukovej sekvencii. Preto boli pre testovanie zvolené čo možno najrôznejšie zmysluplné kombinácie parametrov, pre každú kombináciu spúšťané 10x. Tieto a výsledky z podobných testovaní sú z dôvodu veľkého rozsahu umiestnené na CD nosiči priloženom k tejto práci. Pre celkové vyhodnotenie úspešnosti algoritmu bolo teda potrebné poznať referenčné hodnoty transformačných parametrov a porovnávať ich s algoritmom nájdenými hodnotami. Kritériom výberu bolo dosiahnutie čo možno najlepšej kvality riešenia v zmysle čo najmenšej hodnoty kritériálnej funkcie, najmenšej odchýlky parametrov transformácie od referenčných hodnôt, avšak s ohľadom na časovú náročnosť algoritmu.

Zohľadnením získaných výsledkov bolo pre testovanie na reálnych dátach vybrané najjednoduchšie avšak dostatočne presné kritérium suma štvorcov rozdielov. Subpixelovú presnosť algoritmus dosahoval pri 40 jedincoch v populácii s maximálnym počtom iterácií 30. Posudzovaná bola nielen priemerná hodnota Euklidovskej vzdialenosti, ktorá v niektorých prípadoch môže byť zavádzajúca z dôvodu výskytu len jedného nepriaznivého výsledku, ale aj rozptyl odchýliek pre jednotlivé pokusy opakovaní. V 6 z 10 prípadov boli algoritmom nájdené presné hodnoty pri zaokrúhlení na tri desatinné miesta. V takejto kombinácii bol čas výpočtu 49,78 sekundy, čo je optimálne pri dosiahnutej presnosti, v porovnaní s vyššími hodnotami parametrov sa už presnosť výrazne nezlepšovala, ale čas výpočtu rástol.

Z druhej časti testovania vhodnej pravdepodobnosti mutácie a váhovacej konštanty bola pri výbere kritéria sumy štvorcov rozdielov ako ideálna zvolená kombi-

nácia 0,1 pre pravdepodobnosť s váhovacou konštantou 5. Z grafu 5.7 je pri tejto kombinácii vidieť minimálnu hodnotu Euklidovskej vzdialenosti 0,01.

5.2 Vyhodnotenie optimalizácie rojovým algoritmom

Z teoretického popisu metódy rojenia častíc a vlastnej realizácie v časti 4.2.2 je zrejmé, že v jednoduchšej forme je možné ovplyvniť presnosť metódy iba parametrom počtu jedincov v populácii a nastavením maximálneho počtu iterácií, prípadne dodatočným nastavením generovania počiatkovej množiny riešení. Sledovanie vplyvu počtu jedincov bolo realizované pre 10, 20, 30, 40 a 50 jedincov. Podľa viacerých zdrojov je algoritmus použiteľný až od počtu iterácií 50, ktorá bola stanovená ako spodná hranica až do počtu 100 s krokom 10. Dokopy 30 možných kombinácií nastavenia bolo spúšťaných 10x. Celkový prehľad vypočítaných priemerných kvalít a Euklidovských vzdialeností, uvedených pod skratkou Eu pre všetky 3 kritériálne funkcie, je v tabuľke 5.4. Kompletné výsledky sú opäť uvedené na priloženom CD.

Posudzujúc hodnotu kritériálnej funkcie ako kvalitu registrácie, dosahovala už pri malom počte jedincov a iterácií veľmi vysoké, resp. nízke hodnoty pre kritérium sumy štvorcov rozdielov. Pre tieto hodnoty sa v porovnaní s kvalitami pred optimalizáciou zvýšila minimálne o rád pre všetky tri kritéria. Pre kritérium sumy štvorcov rozdielov nastalo zlepšenie až o dva rády v porovnaní s počiatkovou hodnotou kvality $-2,26E-03$ a najlepšie možné riešenie s hodnotou $-6,12E-05$ bolo dosiahnuté pri počte častíc 50 a maximálnom počte iterácií 60. Pre ostatné dve kritériá je najvyššia dosiahnuteľná hodnota kvality 0,997, ktorá bola zaznamenaná už pri najnižšom počte častíc 10 v kombinácii s najvyšším počtom iterácií 100 pre kosínové kritérium a 90 pre optimalizáciu korelačným koeficientom.

Zreteľnejším ukazovateľom úspešnosti algoritmov je priemerná Euklidovská vzdialenosť. Pri počte častíc 10 je odchýlka nájdených hodnôt od referenčných variabilná aj pri zvyšujúcom sa počte iterácií. Zníženie o jeden rád je však pozorovateľné už s 20 časticami a to pre všetky tri hodnotiace funkcie. Pre najnižšie hodnoty Euklidovských vzdialeností 0,001 boli získané transformačné parametre so subpixelovou presnosťou. Pre získanie týchto najmenších odchýliek je z tabuľky vyplývajúce, potrebné nastaviť počet častíc na 40 alebo 50, s hodnotou maximálneho počtu iterácií medzi 90 až 100.

Tab. 5.4: Tabuľka priemerných kvalít a Euklidovských vzdialeností, rojenie častíc


počet jedincov	počet iterácií	kvalita SSD	kvalita COS	kvalita CC	Eu SSD	Eu COS	Eu CC
10	50	-8,41 E-05	0,994	0,995	0,311	0,594	0,500
10	60	-1,10 E-04	0,995	0,992	0,543	0,310	0,508
10	70	-7,15 E-05	0,989	0,996	0,213	0,927	0,268
10	80	-1,27 E-04	0,995	0,996	0,553	0,339	0,203
10	90	-9,46 E-05	0,996	0,997	0,300	0,204	0,032
10	100	-1,13 E-04	0,997	0,994	0,348	0,137	0,384
20	50	-6,19 E-05	0,997	0,997	0,013	0,049	0,037
20	60	-6,32 E-05	0,997	0,997	0,031	0,020	0,011
20	70	-6,23 E-05	0,997	0,997	0,028	0,054	0,011
20	80	-6,40 E-05	0,997	0,997	0,033	0,011	0,016
20	90	-7,53 E-05	0,997	0,997	0,140	0,005	0,005
20	100	-6,20 E-05	0,997	0,997	0,018	0,005	0,006
30	50	-6,13 E-05	0,997	0,997	0,008	0,012	0,006
30	60	-6,29 E-05	0,997	0,997	0,044	0,009	0,006
30	70	-6,33 E-05	0,997	0,997	0,018	0,002	0,003
30	80	-6,95 E-05	0,997	0,997	0,111	0,006	0,005
30	90	-6,69 E-05	0,997	0,997	0,078	0,001	0,003
30	100	-6,41 E-05	0,997	0,997	0,025	0,004	0,004
40	50	-6,42 E-05	0,997	0,997	0,064	0,005	0,008
40	60	-6,13 E-05	0,997	0,997	0,004	0,003	0,005
40	70	-7,00 E-05	0,997	0,997	0,050	0,003	0,003
40	80	-6,45 E-05	0,997	0,997	0,045	0,004	0,003
40	90	-8,14 E-05	0,997	0,997	0,164	0,002	0,002
40	100	-6,87 E-05	0,997	0,997	0,079	0,001	0,002
50	50	-6,13 E-05	0,997	0,997	0,005	0,005	0,006
50	60	-6,12 E-05	0,997	0,997	0,003	0,003	0,004
50	70	-7,09 E-05	0,997	0,997	0,064	0,002	0,003
50	80	-6,49 E-05	0,997	0,997	0,048	0,003	0,003
50	90	-6,84 E-05	0,997	0,997	0,099	0,001	0,002
50	100	-7,84 E-05	0,997	0,997	0,161	0,001	0,002

5.2.1 Časová náročnosť algoritmu rojenia častíc

S cieľom optimálneho nastavenia pre testovanie na sekvencii dát je aj tento algoritmus potrebné vyhodnotiť vzhľadom k časovej náročnosti výpočtov. Najkratšiu dobu

výpočtu si algoritmus vyžaduje pri minimálnom počte častíc a iterácií zo zvolených medzí a to pri použití kritéria suma štvorcov rozdielov. S rastúcim počtom častíc o 10 sa čas v priemere zdvojnásobí. Pri rovnakej hodnote počtu jedincov avšak so zvyšovaním počtu iterácií je rozdiel pre najmenší a najväčší voliteľný počet iterácií 50 a 100 len 4,3 sekundy, čo predstavuje výrazne nižšie nároky než pri zvyšovaní iterácií u genetického algoritmu. Z dôvodu zastavenia algoritmu druhou možnosťou, teda splnením podmienky stagnácie, trvala doba výpočtu pre 50 častíc a 100 iterácií menej ako pre rovnaký počet častíc, ale počet opakovaní cyklu 80 alebo 90.

Navzájom porovnateľnejšie sú opäť časy výpočtu kosínového kritéria s korelačným koeficientom. Z grafu 5.11 už je jasná lineárna závislosť zvyšovania časovej náročnosti s rastúcim počtom častíc, ako aj so zvyšovaním počtu iterácií. Najdlhšie trval výpočet v kombinácii 50 častíc a maximálny počet iterácií 100, pre optimalizáciu s korelačným koeficientom a to 66,78 sekundy.



Obr. 5.11: Časová náročnosť výpočtu algoritmu rojenia častíc

5.2.2 Optimálne nastavenie parametrov

Optimalizácia metódou rojenia častíc dosiahla v porovnaní s genetickým algoritmom prekvapivú presnosť nájdených parametrov a to pre všetky tri kritériálne funkcie. Priemerná hodnota odchýlky ani v jednom prípade neprekročila 1 pixel a to ani pri minimálnych hodnotách nastavení. Z dosiahnutých výsledkov zaznamenaných v

tabuľke 5.4 bolo ako najoptimálnejšie s ohľadom na časovú náročnosť vybrané kritérium normalizovaný korelačný koeficient. To dosahuje subpixelovo presné výsledky už pri relatívne nízkom počte častíc 20. S ohľadom na menší rozptyl priemerných odchýliek vrámci 10 pokusov bol zvolený ako optimálny počet častíc 40 s maximálnym počtom iterácií 70. V takejto kombinácii trval čas výpočtu 37,45 sekundy. Z časového hľadiska ide o kompromis medzi dostatočným počtom jedincov a počtom iterácií.

5.3 Vyhodnotenie optimalizácie svetluškovým algoritmom


Rovnako ako u vyhodnotenia testovania genetického algoritmu, aj testovanie optimalizácie svetluškovým algoritmom bolo pre prehľadnosť rozdelené na dve časti. V prvom testovaní bol hodnotený vplyv zmeny počtu svetlušíek v kombinácii s meniacim sa maximálnym počtom iterácií, do ktorého algoritmus prebieha. V druhej časti bolo cieľom posúdiť úspešnosť registrácie pri zmene parametrov, ktoré priamo ovplyvňujú konvergenciu k správne mu riešeniu a teda pohyb jednotlivých jedincov. Hodnotil sa vplyv parametra udávajúceho váhu náhodného pohybu α a počiatočnú svietivosť svetlušky β_0 .

5.3.1 Vplyv počtu svetlušíek a počtu iterácií

Počet svetlušíek rovnako ako maximálny počet iterácií algoritmu je nutné voliť s ohľadom na konkrétny optimalizačný problém. V problematike registrácie dvoch ultrazvukových snímkov sa po prvotnom testovaní ako najmenší použiteľný ukázal počet jedincov 20. S cieľom dosiahnuť čo najvyššiu presnosť registrácie v dôležitých častiach obrazu, je z empirického hľadiska potrebné zvoliť minimálne hodnotu 30 ako maximum opakovaní behu algoritmu. Testovaných bolo celkovo 30 kombinácií. Počet svetlušíek bol vyberaný z intervalu 20 až 60 s krokom 10. Maximálny počet iterácií bol vyberaný z hodnôt 30, 50, 60, 70, 90 a 100.

Počítaná bola okrem Euklidovskej vzdialenosti aj kvalita dosiahnutej registrácie ako hodnota kritériálnej funkcie v záujmovej časti obrazu, avšak tieto hodnoty a rozdiely medzi nimi sú veľmi malé pre pochopiteľné zobrazenie. Kritériom úspešnosti je preto Euklidovská vzdialenosť.

Pre všetky tri kritériá podobnosti je možné pozorovať rovnaký trend závislosti priemernej odchýlky na zmene dvoch parametrov, preto je pre názornú ukážku zobrazené iba jedno a to suma rozdielov štvorcov na obrázku 5.12.




Obr. 5.12: Závislosť Euklidovskej vzdialenosti na počte iterácií a počte jedincov, SSD

Pre najnižší počet iterácií s rôznym množstvom jedincov je hodnota variabilná od 0,17 pre 60 svetlušiek a 0,4 pre 20 svetlušiek v populácii. Zvyšovaním iterácií sa však rozdiel pre jednotlivé počty jedincov stráca, čo je vidieť už pri 90 iteráciách. V maximálnom počte iterácií 100 sú priemerné vzdialenosti totožné a majú hodnotu 0,03. Pre všetky kritériá platí rovnaký záver, so zvyšovaním počtu jedincov a iterácií sa odchýlka algoritmom nájdených hodnôt od referenčných znižuje. Najnižšia bola zaznamenaná odchýlka 0,017 pre kosínové kritérium so 60 svetluškami a 100 iteráciami.

5.3.2 Vplyv zmeny parametrov alpha a beta

Zo všetkých parametrov vstupujúcich do algoritmu sa najzásadnejší vplyv na úspešnosť registrácie prejavil pri zmene počiatkovej atraktivity svetlušky β_0 a váhe náhodného pohybu α . Algoritmus počítal s nemenným počtom 40 svetlušiek a 60 iterácií. Na začiatku vygenerovaná populácia jedincov bola použitá pre všetky uvedené kombinácie, aby bolo možné sledovať len testované premenné. Celkovo sa testovalo 49 kombinácií pre príťažlivosť svetlušky s hodnotami (0,08, 0,5, 2, 5, 8, 10, 15) a pre váhu náhodného pohybu v intervale (1,2,3,4,5,6,7). Prehľadnejšie je opäť popísanie úspešnosti registrácie z pohľadu priemernej Euklidovskej vzdialenosti, vypočítanej z 10 pokusov.

Keďže závislosť má pre všetky hodnoty α v kombinácii s prvými piatimi hodnotami pre β_0 rovnaký charakter, pre ukážku a popis je znova vybraté iba kritérium suma štvorcov rozdielov na obrázku 5.13.



Obr. 5.13: Závislosť Euklidovskej vzdialenosti na parametroch alfa a beta, SSD


Ideálnej situácii s hodnotou odchýlky 0 sa najviac priblížil parameter $\beta_0 = 0,5$ a to v kombinácii so všetkými hodnotami váhy náhodného pohybu. Hodnotami takmer zhodné a prijateľné sú odchýlky s parametrom $\beta_0 : 0,08, 2$ a 5 . Odchýlka $1,7$ pre kombináciu $\beta_0 = 0,08$ a $\alpha = 1$ je zapríčinená rozptýlením Euklidovských vzdialeností pre jednotlivé pokusy. Najlepšie riešenie bolo s odchýlkou $0,03$, pričom najhoršie dosahovalo hodnotu $3,88$, ktorá už predstavuje pixelovú nepresnosť nájdených hodnôt.

Pre zvyšné možnosti nastavenia parametru β_0 sa odchýlka znásobila pre všetky hodnoty atraktivity. Z tohto vyplýva skutočnosť, že zvyšujúca sa hodnota parametra β_0 nad hodnotu 5 negatívne ovplyvňuje úspešnosť registrácie bez ohľadu na parameter α .


Pre lepšiu predstavu závislosti Euklidovskej vzdialenosti najmä na parametre β_0 je na obrázku 5.14 uvedený čiarový graf, kde vidieť signifikantné zvýšenie odchýlky od referenčných hodnôt od hodnoty atraktivity 5 .

5.3.3 Časová náročnosť svetluškového algoritmu

Časovú náročnosť optimalizácie svetluškovým algoritmom je potrebné zohľadniť ako pre výber najvhodnejšej kritériálnej funkcie, tak aj pre výber optimálneho nastavenia počtu jedincov v populácii a maximálneho počtu iterácií. Pre všetky tri kritériá je zobrazená na obrázku 5.15.



Obr. 5.14: Závislosť Euklidovskej vzdialenosti na parametroch alfa a beta 2, SSD



Obr. 5.15: Časová náročnosť svetluškového algoritmu

Z grafu je zrejmé, že najrýchlejšie je aj v tomto prípade výpočtovo najjednoduchšie kritérium suma štvorcov rozdielov. Rozdiely pre najnižšie početové kombinácie 30 iterácií a 20 jedincov sa však rádovo líšia v desatinách sekúnd. Z grafu vyplýva lineárna závislosť času na obidvoch parametroch, teda pri zvyšovaní počtu jedincov aj iterácií čas výpočtu lineárne rastie. Najpomalší bol výpočet s korelačným koeficien-

tom so 60 svetluškami v populácii a počtom opakovaní hlavného cyklu 100x, kde dosiahol hodnotou 71,92 sekundy. S rovnakou kombináciou nastavené bolo kritérium suma štvorcov rozdielov rýchlejšie takmer o 8 sekúnd a kosínové kritérium o 1,6 sekundy. Najviac času zaberá opätovné volanie funkcií `imtranslate` a `imrotate`, v snahe pripodobniť pohybový obraz referenčnému v čo najväčšej miere.

5.3.4 Optimálne nastavenia parametrov svetlušiek

Ako už bolo v predchádzajúcej časti spomenuté, závislosti priemerných odchýliek na počte svetlušiek a iterácií sú rádovo veľmi podobné pre všetky tri kritériá. Aj keď algoritmus pri niektorých nastaveniach dosahoval pri pohľade na jednotlivé pokusy väčšiu presnosť, smerodajný pre výber optima bol aj výber s ohľadom na rozptyl pre jedno nastavenie vrámci 10 pokusov.

Dôležitým rozhodujúcim faktorom pri výbere vhodnej kritériálnej funkcie bola časová náročnosť výpočtov. Vyhodnotením prvej časti testovania bolo ako optimálny počet zvolených 30 svetlušiek, s optimalizačným procesom ukončeným po dosiahnutí 100 iterácií. Priemerná Euklidovská vzdialenosť sa pri tejto kombinácii pohybovala v stotinách pixlov. S ohľadom na čas bol pri takomto nastavení najrýchlejší výpočet s kritériom suma štvorcov rozdielov, o 3,3 sekundy rýchlejší ako kosínové kritérium a o 4,6 s ako korelačný koeficient.

Rozdiel medzi optimalizáciou jednoduchou metódou rojenia častíc a svetluškovým algoritmom je v možnosti ovplyvnenia pohybu jedincov, a tým aj zvýšenia presnosti riešenia alebo konverencie k správne výsledku. Z grafu bola ako optimálna počiatočná atraktivita svetlušky zvolená hodnota 0,5, pri ktorej sú nájdené transformačné parametre najpresnejšie vzhľadom na známe referenčné hodnoty. Váha náhodného pohybu má pri takomto nastavení už len minimálny vplyv na presnosť. Vybraná bola hodnota $\alpha = 6$.

6 TESTOVANIE NA SEKVENCIÁCH DÁT

Cielom celej predchádzajúcej kapitoly 5 bolo vybrať najoptimálnejšie nastavenia parametrov jednotlivých optimalizačných metód, ktorých znalosť je nevyhnutná pre úspešnú registráciu celej sekvencie obrazových dát. Obraz, ktorý bol v predošlej časti práce, bez aplikovania geometrických transformácií považovaný za referenčný, bol prvým obrazom celej ultrazvukovej sekvencie.

Úlohou pri práci s väčším počtom snímok zachytávajúcich jednu scénu bolo ich vzájomné stotožnenie tak, aby odpovedajúce si štruktúry mali rovnaké súradnice. Testovanie prebiehalo na dvoch sekvenciách dát. Prvou bola už spomínaná sekvencia dát pankreasu človeka, konkrétne muža s nádorovým ochorením, ktoré je na snímkoch viditeľné. Táto sekvencia obsahovala 270 snímok zachytených v časovej postupnosti. Druhými testovacími dátami boli snímky ľavej srdčnej komory prasťa. Sekvencia obsahovala 301 snímok, ktorých počet bol k dosiahnutiu relevantných výsledkov upravený a bude diskutovaný v ďalšej časti kapitoly.

Obidve ultrazvukové sekvencie boli snímané v dynamickom režime po podaní kontrastnej látky SonoVue. Problémom s registráciou týchto dát pomocou bežne používaných metód je meniaci sa kontrast v obraze.

K registrácii sekvencií boli použité 3 popísané optimalizačné metódy so zvolenou kritériálnou funkciou, s ktorou v časti testovania na simulovanej transformácii dosiahli najlepšie výsledky. Podrobné optimálne nastavenia metód s ohľadom na dosiahnutú úspešnosť registrácie a časovú náročnosť boli diskutované na konci každej časti vyhodnotenia vybraných algoritmov.

Overenie správnosti registrácie je v takomto prípade obmedzené na výpočet kvality riešenia registrovaných dvojíc obrazov, ktorá by mala byť vyššia v porovnaní s obrazmi neregistrovanými. Počítaná bola opäť tromi kritériálnymi funkciami suma štvorcov rozdielov, kosínové kritérium a normalizovaný korelačný koeficient. Hodnotu kvality, resp. kritériálnej funkcie má opäť zmysel počítat iba vo vybranej časti obrazu, ktorá obsahuje záujmové štruktúry. Všetky tri vybrané kritériá podobnosti patria do skupiny prístupov založených na intenzitách pixlov. Dosiahnuté kvality registrácie realizovanými metódami boli navyše porovnané s hodnotami po registrácii funkciou Matlabu `imregister`, ktorá je založená na rovnakom princípe.

Druhou, avšak nie číselne podložiteľnou možnosťou je vyhodnotenie zo subjektívneho pohľadu užívateľa. Aj bez apriornej znalosti o dátach je pri sústredení sa na danú štruktúru v registrovaných snímkoch možné posúdiť úspešnosť, resp. neúspešnosť registrácie.

6.1 Obsluha funkcie `imregister`

Použitím funkcie `imregister` je v Matlabe možné previesť automatickú registráciu monomodálnych a multimodálnych dát, ktorá je založená na intenzite pixlov. Syntax volania funkcie je v práci použitá ako `moving_reg = imregister(moving, fixed, transformType, optimizer, metric)`, kde `moving` označuje obraz transformovaný, `fixed` je referenčný obraz a `moving_reg` je výsledný registrovaný obraz. `transformType` označuje typ geometrickej transformácie, ktorá je v procese registrácie aplikovaná na pohybový obraz. Keďže táto práca sa zaoberá posunom v horizontálnom a vertikálnom smere spolu s rotáciou, tomuto odpovedá nastavenie transformácie `rigid`. [31]

Premenná `optimizer` odpovedá optimalizačnej metóde a `metric` je podobnostné kritérium, ktoré je snahou optimalizovať. Tie sú v Matlabe priamo preddefinované, avšak sú rôzne pre prácu s obrazmi pochádzajúcimi z jednej alebo viacerých modalít. Ich vytvorenie je pomocou funkcie v tvare `[optimizer, metric] = imregconfig(modality)`, kde sa dá zvoliť typ `monomodal`, resp. `multimodal`. [31]

Pri práci s monomodálnymi dátami funkcia využíva ako podobnostné kritérium strednú kvadratickú chybu (z angl. Mean square error) a optimalizáciu metódou gradientného zostupu v smere extrémov kritériálnej funkcie. Práve túto časť je možné priamo ovplyvniť zmenou niektorých nastavení podľa charakteru konkrétnych dát. Celkovo je možné nastaviť 5 nasledovných parametrov

- **GradientMagnitudeTolerance** - kontrola tolerancie veľkosti zostupu, vždy ide o kladnú hodnotu.
- **MinimumStepLength** - premenná kontroly konvergenzie. Pri nižšej hodnote konverguje k presnejším hodnotám, za cenu dlhšieho výpočtu.
- **MaximumStepLength** - ide o maximálnu hodnotu kroku na počiatku, ktorá sa v priebehu konvergenzie znižuje. Pri nastavení na vysokú hodnotu môže dôjsť k predčasnemu zlyhaniu.
- **MaximumIterations** - ako už názov napovedá, ide o maximálny počet iterácií, v základnom nastavení s hodnotou 100. Registrácia však môže dospieť k riešeniu aj pred dosiahnutím tohto počtu.
- **RelaxationFactor** - premenná definujúca rýchlosť s akou je znižovaná veľkosť kroku v priebehu konvergenzie. Hodnota je zvolená z intervalu (0,1). [31]

V prípade registrácie multimodálnych dát je preddefinovým podobnostným kritériom vzájomná informácia. Optimalizácia je realizovaná metódou patriacou do skupiny evolučných algoritmov. V snahe nájsť čo najlepší výsledok registrácie porovnáva zmenu parametrov z poslednej iterácie (rodičovská) s riešeniami v novej populácii, pričom sa do ďalšej iterácie zachová lepší jedinec. Registráciu je možné ovplyvniť zmenou nastavenia 4 parametrov

- **GrowthFactor** - kladná hodnota vyššia ako 1, ktorou je kontrolovaná rýchlosť vyhľadávania polomeru rastu. S hodnotou blížiacou sa 1, konverguje k lepším výsledkom s vyššou pravdepodobnosťou.
- **Epsilon** - minimálna hodnota prehľadávaného polomeru riešení. Čím nižšia hodnota, tým vyššia časová náročnosť, avšak poskytuje presnejšie výsledky.
- **InitialRadius** - veľkosť polomeru prehľadávacieho priestoru na začiatku optimalizácie. S vysokou hodnotou rastie pravdepodobnosť zlyhania a konvergenzie k nesprávnemu riešeniu.
- **MaximumIterations** - má rovnaký význam ako v prípade registrácie monomodálnych dát. [31]

6.2 Výsledky registrácie sekvencie pankreasu

Pre zhrnutie, najoptimálnejšie metódy registrácie boli vybrané genetický algoritmus s optimalizáciou kritériálnej funkcie suma štvorcov rozdielov, SSD, metóda rojenia častíc s korelačným koeficientom, CC a pre svetluškový algoritmus bolo ako najvhodnejšie opäť zvolené kritérium SSD. Súčty kvalít pre dvojice po sebe idúcich registrovaných obrazov sú uvedené v tabuľke 6.1. Ako už bolo spomenuté kvalita bola počítaná iba v záujmovej časti obrazu, ktorá je pre snímky pankreasu zobrazená na obrázku 4.2 vľavo. Priemerné hodnoty sú znázornené v tabuľke 6.2.

Tab. 6.1: Tabuľka súčtov kvalít registrácie pre sekvenciu pankreasu

	súčet SSD	súčet COS	súčet CC
neregistrované dáta	-0,274	254,563	253,331
genetický algoritmus	-0,144	261,031	260,347
metóda rojenia častíc	-0,148	261,715	261,088
svetluškový algoritmus	-0,142	261,050	260,372
imregister Monomodal	-0,218	257,466	256,481
imregister Multimodal	-0,200	256,147	255,099

V obidvoch tabuľkách sú uvedené aj hodnoty kvality vypočítanej pre neregistrované snímky, z čoho na prvý pohľad vyplýva, že všetky optimalizačné metódy ju v oblasti záujmu zvýšili, čo je očividnejšie pri prepočte na priemernú kvalitu, než pre jednoduchú sumu. Vzhľadom k tomu, že ide o sekvenciu reálnych dát, výsledky hodnôt kritériálnych funkcií už nie je možné očakávať s takou konvergenciou k ideálnym hodnotám ako pri simulovaných dátach. Na rozdiel od druhej sekvencie prasačieho srdca, pre snímky z pankreasu nebola prevedená manuálna korekcia, pretože pri takomto charaktere dát nebol nájdený vhodný význačný bod pre registráciu

Tab. 6.2: Tabuľka priemerných kvalít registrácie pre sekvenciu pankreasu

	priemer SSD	priemer COS	priemer CC
neregistrované dáta	-1,02 E-03	0,946	0,942
genetický algoritmus	-5,34 E-04	0,970	0,968
metóda rojenia častíc	-5,50 E-04	0,973	0,971
svetluškový algoritmus	-5,26 E-04	0,970	0,968
imregister Monomodal	-8,10 E-04	0,957	0,953
imregister Multimodal	-7,45 E-04	0,952	0,948


vyskytujúci sa na všetkých snímkoch.

Posudzovaním priemerných kvalít vypočítaných sumou štvorcov rozdielov nie je možné výsledky zhodnotiť, pretože hodnoty sa líšili až v ráde tisícín, ktoré po zaokrúhlení priniesli neporovnateľné hodnoty. Naopak z výpočtu kosínovým kritériom a korelačným koeficientom je jednoznačne vidieť, že najvyššia kvalita registrácie bola dosiahnutá v optimalizácii metódou rojenia častíc s kritériálnou funkciou korelačný koeficient. Optimalizáciou s genetickým a svetluškovým algoritmom sa podarilo získať rovnaké hodnoty kvalít. Registrácia funkciou Matlabu imregister poskytla zo všetkých metód najhoršie hodnoty kvality.

Názornejším zobrazením zahrňujúcim vyjadrenie priemerných hodnôt, rozptylov, ale aj extrémnych hodnôt je zobrazený na obrázku 6.1 formou škatuľového grafu (z angl. boxplot). Zobrazené je iba pre výpočet kvality kosínovým kritériom, keďže pre ostatné kritériálne funkcie by bola vizualizácia podobná.

Graf potvrdzuje fakt, že najvyššia priemerná hodnota kvality registrácie bola získaná metódou roja častíc a zároveň má aj najmenší rozptyl. Zároveň bola dosiahnutá aj najvyššia hodnota kvality, odhliadnuc od hodnoty 1, ktorá je ako najvyššia dosiahnutá u všetkých metód. Hodnota 1 bola získaná hneď pri registrácii prvých dvoch snímkov sekvencie, ktoré sú takmer totožné. Najodľahlejšie hodnoty pre tri vlastné realizované metódy sú v okolí hodnoty 0,935. Tieto odľahlé hodnoty sú v registrovaní ultrazvukových sekvencií spôsobené napríklad dýchacími pohybmi alebo inými rušivými elementmi, prípadne výskytom charakteristického šumu. Registráciou pomocou funkcií Matlabu sú získané hodnoty podstatne horšie. Stredná polovica hodnôt, teda medzi 1. a 3. kvartilom (horná a dolná hranica stredovej časti "škatule") má pre najmenej úspešnú multimodálnu metódu rozpätie od 0,943 do 0,962, čo je 1,5x viac ako pre metódu rojenia častíc. Odľahlá hodnota 0,911 vykreslená ako samostatný bod značí celkovo najnižšiu kvalitu registrovaných obrazov.

Registrácia celej sekvencie ultrazvukových dát je časovo náročnou úlohou, ktorá závisí od počtu snímkov sekvencie, ale aj vybranej optimalizačnej metódy. Pre všetkých 5 realizovaných metód sú zobrazené časové náročnosti v tabuľke 6.3. Časovo



Obr. 6.1: Kvality registrovaných snímkov pankreasu, COS

najnáročnejší je genetický algoritmus, ktorý po prepočte trval 3 hodiny aj 7 minút. Naopak ako veľmi rýchla sa ukázala registrácia funkciou Matlabu s nastavením pre monomodálne dáta, z hľadiska kvality ako druhá najmenej úspešná, ktorej výpočet trval necelých 5 minút.


Tab. 6.3: Časová náročnosť registrácie sekvencie pankreasu

	časová náročnosť algoritmov [s]
genetický algoritmus	12643,76
metóda rojenia častíc	9596,23
svetluškový algoritmus	9215,73
imregister Monomodal	280,60
imregister Multimodal	1387,44

Významným kritériom posúdenia úspešnosti registrácie je aj subjektívny pohľad na zaregistrovanú obrazovú sekvenciu, ktorý si však čiastočne vyžaduje znalosť sekvencie pred registráciou. Z tohto pohľadu sa názor autora práce zhoduje s numericky vyjadrenou úspešnosťou a ako najpresnejšia je zvolená metóda rojenia častíc. Aj napriek dosiahnutým výsledkom s použitím funkcie Matlabu sa zo subjektívneho hľadiska sekvencie zdajú byť zaregistrované nedostatočne, preto pre túto optimalizáciu bolo prevedené dodatočne predspracovanie.

6.2.1 Úprava dát pre funkciu imregister

S cieľom zvýšiť kvalitu registrácie aj funkciou Matlabu boli snímky sekvencie upravené, pretože registrácia v celom rozsahu snímok sa ukázala so subjektívnym vyhodnotením ako nedostatočná. Vybraná oblasť zobrazená na obrázku 6.2 bola zvolená tak, aby zachytila čo najväčšiu časť podstatnej časti ultrazvukovej snímky, bez nežiadúcich okrajových častí. Keďže na sekvenciách sú okrem priebehov kontrastných látok orgánmi zachytené aj napr. dýchacie pohyby, mohli byť dáta považované za multimodálne, napriek tomu, že pochádzajú z jednej modality.



Obr. 6.2: Upravený snímok pre registráciu s imregister

Konfigurácia Monomodal

Výrazné zlepšenie vizuálnej kvality registrácie pri tejto konfigurácii nastalo už len samotnou úpravou časti obrazu, preto všetky meniteľné parametre optimalizátora ostali nastavené na východzie hodnoty. Výpočet priemernej kvality v tejto časti pomocou kosínového kritéria však neukázal žiadne zvýšenie, hodnota 0,964 je len minimálnym zlepšením. Dostatočné numerické zvýšenie kvality sa na jej hodnote neprejavilo z dôvodu straty časti informácie počas optimalizácie vplyvom neustáleho natáčania a posúvania. Čas výpočtu sa zvýšil na 352 sekúnd.

Konfigurácia Multimodal

Konfigurácia multimodal bez dodatočnej zmeny nastavení vysvetlených parametrov zlyhala hneď na začiatku optimalizačného procesu kvôli rýchlej konvergencii k nesprávnemu riešeniu. Tá bola obmedzená zmenou pôvodného nastavenia. Opäť je

však posúdenie zvýšenia, resp. zníženia úspešnosti registrácie založené na subjektívnom pohľade, z dôvodu podobnej straty časti informácie spôsobených geometrickými transformáciami v procese optimalizácie alebo počiatočným orezaním oblasti záujmu.

Z tabuľky 6.4 porovnaním s pôvodnými hodnotami premenných vyplýva, či k zlepšeniu viedlo zvýšenie alebo zníženie hodnôt. Upravené hodnoty boli získané jednoduchým testovaním ich vplyvu na úspešnosť registrácie. Zvolenie vhodného nastavenia je závislé na konkrétnom charaktere dát. Priemerná kvalita vypočítaná kosínovým kritériom dosiahla hodnotu 0,968, čo sa blíži hodnotám, ktoré boli dosiahnuté pomocou genetického alebo svetluškového algoritmu.

Tab. 6.4: Pôvodné a upravené nastavenie konfigurácie multimodal


	pôvodné hodnoty	upravené hodnoty
GrowthFactor	1,05	1,01
Epsilon	1,50 E-6	7,50 E-8
InitialRadius	6,25 E-3	1,60 E-3
MaximumIterations	100	200

6.3 Výsledky registrácie sekvencie srdca prasata

Druhou poskytnutou sekvenciou boli snímky ľavej srdečnej komory prasata, ktorá obsahovala 301 snímok. Pri počiatočnej registrácii celej sekvencie bolo zistené, že v určitých častiach optimalizačné metódy nie sú schopné nájsť dostatočne kvalitné riešenie. Táto situácia nastáva kvôli snímaniu špecifickou metódou bolus & burst, ktorá v určitom časovom okamihu aplikuje vysokoenergetický pulz, a tým prevedie rozbitie kontrastnej látky. Zvýšenie energie sa prejaví zvýšením kontrastu v celom rozsahu obrazu, aj v oblastiach záujmu registrácie. To spôsobilo problém optimalizácie kritériálnych funkcií, ktorá pracuje práve na základe vyhodnotenia intenzity pixlov. Tento prípad zachytáva obrázok 6.3 v strede.

Druhým prípadom bola situácia, kedy už od istého časového okamihu snímky neobsahujú dostatočnú informáciu potrebnú pre úspešnú registráciu. Na základe tohto uváženia boli zo sekvencie separované konkrétne snímky 78, 79 a snímky od 202 až po koniec. Ukážky týchto dvoch situácií spolu s príkladom zobrazenia snímky na začiatku sekvencie s vyznačenou oblasťou záujmu je na obrázku 6.3. Z predošlej znalosti sekvencie bola ako najvhodnejšia oblasť záujmu zvolená práve horná hrana ľavej srdečnej komory, ktorá je na všetkých snímkoch sekvencie.

Aj v tomto prípade boli použité rovnaké optimalizačné metódy ako pri registrácii sekvencie pankreasu, avšak s miernou úpravou nastavenia počiatočných parametrov.



Obr. 6.3: Ukážka snímok zo sekvencie srdca prasata

Konkrétne bol pre metódu rojenia častíc zvýšený maximálny počet iterácií algoritmu z hodnoty 70 na 80 a pri registrácii so svetluškovým algoritmom bolo pridaných 10 možných riešení do počiatočnej populácie. Tieto zmeny boli kompromisom medzi zvýšením úspešnosti registrácie s len minimálnym vplyvom na zvýšenie časovej náročnosti algoritmov. Zaujímavým doplnením by bolo testovanie vplyvu generovania počiatočnej populácie, ktoré môže byť kritickou časťou optimalizačných algoritmov.

Súčty a priemerné hodnoty kvalít počítané v oblasti zájmu obrazu medzi susediacimi registrovanými snímkami sú v tabuľkách 6.5 a 6.6. Dosiahnuté kvality registrácie sú porovnané s hodnotami pred registráciou.

Tab. 6.5: Tabuľka kvalít registrácie pre sekvenciu srdca prasata

	súčet SSD	súčet COS	súčet CC
neregistrované dáta	-0,187	191,961	191,443
manuálna registrácia	-0,221	193,650	193,254
genetický algoritmus	-0,078	196,120	195,905
metóda rojenia častíc	-0,084	196,106	195,888
svetluškový algoritmus	-0,079	196,113	195,898
imregister Monomodal	-0,170	192,583	192,109
imregister Multimodal	-0,187	191,964	191,463

Porovnanie je doplnené výpočtom kvalít z dodanej sekvencie manuálne registrovaných snímok. Manuálnou registráciou sa myslí postupné zaznačovanie jedného vybraného bodu z vhodnej oblasti záujmu na všetkých snímkoch sekvencie, ide teda o registráciu založenú na význačných bodoch. Táto metóda je nenáročná, avšak náchylná na schopnosť užívateľa stále vyberať rovnaký bod sekvencie. Navyše bola v

Tab. 6.6: Tabuľka priemerných kvalít registrácie pre sekvenciu srdca prasata


	priemer SSD	priemer COS	priemer CC
neregistrované dáta	-9,42 E-04	0,965	0,962
manuálna registrácia	-1,11 E-03	0,973	0,971
genetický algoritmus	-3,94 E-04	0,986	0,984
metóda rojenia častíc	-4,21 E-04	0,985	0,984
svetluškový algoritmus	-3,96 E-04	0,985	0,984
imregister Monomodal	-8,53 E-04	0,968	0,965
imregister Multimodal	-9,42 E-04	0,965	0,962

procesu registrácie schopná vyhodnotiť len transláciu v horizontálnom a vertikálnom smere. Príklad význačného bodu je na obrázku 6.3 vľavo.

Porovnaním hodnôt kvality vypočítaných kosínovým kritériom je však už aj s manuálnou korekciou zvýšená priemerná hodnota z 0,965 na 0,973. Všetky tri vlastné realizované optimalizačné algoritmy dosahujú takmer identickú kvalitu registrácie s hodnotou 0,985, resp. 0,986 pre genetický algoritmus. Takéto rozdiely už môžu znamenať zvýšenie presnosti registrácie rádovo v pixloch v porovnaní s neregistrovanými dátami. Posudzovaním dosiahnutého riešenia registráciou pomocou funkcie **imregister** bolo zaznamenané len minimálne zlepšenie kvality pre nastavenie registrácie monomodálnych dát. Vybratím možnosti pre multimodálne dáta je hodnota rovnaká ako pre neregistrované snímky. Z toho vyplýva, že aj táto sekvencia si vyžaduje predspracovanie pri použití týchto funkcií a následné zistenie vplyvu vhodnosti zvolenej registrovanej časti s dodatočnou úpravou nastavení parametrov doplnenou o ďalšie testovanie.

Výsledky z výpočtov kosínového kritéria sú pre lepšiu predstavu opäť znázornené formou boxplotu na obrázku 6.4.

Všetky tri realizované metódy GA (genetický algoritmus), PSO (metóda roja častíc) a svetluškový algoritmus (FA) dosahujú rovnaké hodnoty, a to či už z pohľadu minimálnych a maximálnych hodnôt, extrémnych hodnôt, ktoré sa pohybujú v okolí hodnoty 0,971 alebo aj z pohľadu na zhodné priemerné kvality registrácie, ktoré sú v grafoch vyznačené krížikmi. Distribúcia hodnôt pre tieto metódy je symetrická, pričom stredná polovica všetkých hodnôt leží medzi 0,984 a 0,988. Značne asymetricky rozložené sú hodnoty kvality vypočítanej z registrovaných snímok funkciou Matlabu. Odlahlá hodnota z pohľadu minima je až na úrovni 0,933 pre monomodálne a 0,929 pre multimodálne nastavenie. Stredná polovica hodnôt má značne väčšie rozpätie 0,017 pre obidva prípady. Maximálna hodnota pre lepšiu variantu s monomodálnym nastavením je len na úrovni priemernej hodnoty zvyšných 3 algoritmov. Tak veľký rozptyl hodnôt je spôsobený neschopnosťou funkcie zachytiť



Obr. 6.4: Kvality registrovaných snímkov srdca prasata, COS

zmeny štruktúr v sekvencii, napr. vplyvom dýchacích pohybov prasata, ktoré vedú k zlyhaniu registrácie.

Z hľadiska časovej náročnosti jednotlivých metód z tabuľky 6.7 bol genetický algoritmus rovnako ako u registrácie sekvencie pankreasu najpomalší a to s časom takmer dve hodiny. Najrýchlejšou realizovanou je optimalizácia metódou rojenia častíc. Neporovnateľne rýchlejší je však výpočet funkciou `imregister` pohybujúci sa pri základnom nastavení rádovo v pár minútach.

Tab. 6.7: Časová náročnosť registrácie sekvencie srdca prasata


časová náročnosť algoritmov [s]	
genetický algoritmus	7011,19
metóda rojenia častíc	4671,35
svetluškový algoritmus	5709,77
imregister Monomodal	183,30
imregister Multimodal	160,35

Subjektívnym vizuálnym vyhodnotením sa ako najúspešnejšia zdá byť registrácia s optimalizačným genetickým algoritmom, kde je na sekvencii registrovaných snímkov pohyb hornej hrany srdečnej komory len minimálny a zároveň v dobe najväčšej koncentrácie látky je správne registrovaná aj bočná stena myokardu. Potom nasleduje optimalizácia svetluškovým algoritmom a metódou rojenia častíc. Ako najmenej

úspešná, resp. neúspešná je zo subjektívneho pohľadu registrácia funkciou Matlabu, avšak je nutné podotknúť, že v tejto časti bola testovaná bez prispôbenia, teda len v základnom nastavení.

7 UŽÍVATELSKÉ ROZHRAŇIE - GUI


Pre jednoduchšiu obsluhu navrhnutých algoritmov je práca doplnená o užívateľské prostredie, ktoré zahŕňa všetky tri realizované optimalizačné algoritmy s výberom z 3 kritériálnych funkcií. Skladá sa z niekoľkých užívateľsky intuitívnych krokov, s cieľom získať výslednú sekvenciu registrovaných dát. Na obrázku 7.1 je konkrétna ukážka s nastavením parametrov pre svetluškový algoritmus.



Obr. 7.1: Grafické užívateľské rozhranie, hlavný panel


1. Tlačidlom *Náčítať* sa vyberie jedna z dvoch sekvencií uložených v samostatných priečiinkoch. Vo vedľajšom okne sa zobrazí cesta, v ktorom sa nachádza.
2. Po zvolení priečinku sa automaticky načíta prvý snímok zo sekvencie. Tlačidlo *Vybrať oblasť* je určené pre vybratie konkrétnej oblasti záujmu. Ideálna užívateľom zvolená oblasť má pravidelný tvar, obvykle tvaru obdĺžnika. Výber oblasti je ukočený dvojklikom do počiatočne zvoleného bodu.
3. Vyznačenie oblasti záujmu.
4. V paneli *Optimalizačná metóda* je k dispozícii výber z troch uvedených optimalizačných algoritmov.
5. Vedľajší panel *Kritériálna funkcia* umožňuje výber z podobnostného kritéria suma štvorcov rozdielov, kosínového kritéria alebo korelačného koeficientu.

6. Zvolená kombinácia optimalizačnej metódy a kritériálnej funkcie sa potvrdí kliknutím na tlačítko *Potvrď výber*.
7. Podľa zvolenej kombinácie sa pod týmito dvoma panelmi objavujú nastaviteľné parametre. Pre všetky optimalizačné metódy je umožnený výber nastavenia *Počet iterácií* a *Počet jedincov*, resp. častíc. Pre genetický algoritmus je potrebné vybrať z rolovacieho menu aj hodnotu pravdepodobnosti mutácie. U svetluškového algoritmu je okrem počtu jedincov a iterácií možné meniť *Parameter alfa* a *Parameter beta*.
8. Požiadavka na registráciu sa potvrdí tlačítkom *Registruj*. Po správnom zadaní parametrov sa algoritmus inicializuje. Z dôvodu časovej náročnosti registrácie sa objaví okno s odhadom, v ktorej časti sa registrácia nachádza.



Obr. 7.2: Grafické užívateľské rozhranie, hlavný panel

9. Výstupom je sekvencia obrázkov, ktorá sa automaticky uloží a v ďalšom okne je možné si ju spustiť tlačidlom *Prehrať* alebo posúvať po jednotlivých snímkoch.



Obr. 7.3: Grafické užívateľské rozhranie, vedľajší panel

8 ZÁVER

Táto práca sa bližšie zaoberá problematikou lícovania obrazov s využitím evolučných algoritmov. Znalosť všeobecného postupu lícovania obrazových dát s vysvetlením geometrických transformácií, používaných kritérií podobnosti a dôležitého kroku optimalizácie, si vyžaduje praktická časť tejto práce. Teoreticky popísané sú vybrané metódy, konkrétne zamerané na registráciu ultrazvukových dát. Táto časť práce obsahuje aj rozbor princípu perfúzneho zobrazovania u ultrazvuku, ktorého pochopenie bolo nevyhnutné pre porozumenie dodaných dát a ich následnú registráciu.

Detailnejšie popísaná časť evolučných algoritmov ako jedna z možností optimalizačných techník bola vybraná kvôli schopnosti efektívneho prehľadania priestoru možných riešení a nájdenia optimálneho riešenia na globálnej úrovni. Podrobnejšie rozobratý bol genetický algoritmus, metóda roja častíc a svetluškový algoritmus.

Registrácia ultrazvukových sekvencií bola realizovaná optimalizáciou podobnostných kritérií založených na intenzitách pixlov. Konkrétne bola vybraná suma štvorcov rozdielov, kosínové kritérium a normalizovaný korelačný koeficient.

Hlavná časť práce sa venuje samotnej registrácii sekvencií všetkými troma metódami s výberom kritériálnej funkcie, ktorá sa v priebehu optimalizuje. Pred registráciou celej sekvencie bolo potrebné otestovať vstupné parametre jednotlivých funkcií s cieľom zistiť ich optimálne nastavenie. Optimálne nastavenia boli získané veľmi podrobným testovaním registrácie jedného referenčného obrazu, ktorým bol vybraný ultrazvukový snímok pankreasu zo sekvencie, ktorá bola ďalej spracovaná. Keďže práca sa zaoberá rigidnými geometrickými transformáciami, tento obraz bol posunutý a natočený o predom známe hodnoty. Cieľom registrácie bolo tieto obrazy stotožniť, aby odpovedajúca zvolená oblasť záujmu mala rovnaké priestorové súradnice a získať transformačné parametre, z ktorých porovnaním s referenčnými hodnotami bolo vypočítané jedno z možných kritérií úspešnosti, Euklidovská vzdialenosť.

Počet počiatočných riešení registrácie a maximálny počet iterácií sú dve rozhodujúce vstupné premenné, ktorých vplyv bol testovaný u všetkých troch metód. Pre genetický algoritmus je taktiež dôležité zahrnutie parametra pravdepodobnosti mutácie, celkovo bolo v prvej fáze testovaných 200 rôznych kombinácií, ktoré boli spustené 10x. Vyhodnotením takého množstva výsledkov bola ako najvhodnejšia určená kombinácia genetického algoritmu s optimalizáciou kritéria suma štvorcov rozdielov. Tá dosiahla pri optimálnom nastavení takmer ideálnu hodnotu kvality registrácie, odchýlkou od referenčných hodnôt sa ukázala ako dostatočne presná a časovo najmenej náročná. Avšak je nutné podotknúť, že takáto ideálna situácia platí iba pre umelo posunuté snímky. V prípade analýzy celej ultrazvukovej sekvencie, ktorá býva postihnutá charakteristickým šumom typu spekle a je získaná z dynamického režimu

s kontrastnou látkou, nemôže nikdy konvergovať až k ideálnej hodnote 0.

Presnosť na tisíciny pixlov v zmysle vypočítanej odchýlky dosiahla metóda roja častíc s použitím korelačného koeficientu u umelo posunutých snímkov. Testovaných bolo 30 kombinácií rôzneho počtu častíc a maximálneho počtu iterácií, celkovo bolo hodnotených 300 výsledkov hodnôt kvality v oblasti záujmu a vypočítaných Euklidovských vzdialeností.

Testovanie optimálneho nastavenia svetluškového algoritmu bolo rozdelené na dve časti, kde prvá je totožná ako u prvých dvoch algoritmov, v druhej časti bola navyše doplnená o sledovanie vplyvu na registráciu pri zmene parametra počiatkovej atraktivity svetlušky a váhy náhodného pohybu. Vyhodnotením všetkých kombinácií 30 z prvej časti a 49 z časti druhej bolo aka najúspešnejšia zvolená optimalizácia sumy štvorcov rozdielov, ktorá bola aj v tomto prípade časovo najmenej náročná.

Vyhodnotením takého množstva možných kombinácií sú tieto výsledky patrične podložené podrobným testovaním a ďalej použité ako najvhodnejšie nastavenia optimalizačných algoritmov. Úspešnosť registrácie celej sekvencie snímkov bola znova hodnotená ako hodnota kvality vypočítaná všetkými tromi kritériami.

V registrácii prvej sekvencie pankreasu bola najvyššia, resp. najnižšia hodnota kvality dosiahnutá najjednoduchšou metódou roja častíc. Rozdiely medzi ostatnými dvoma metódami sú však len minimálne. Rozhodnutiu pre výber celkovo najlepšej metódy z numerického aj subjektívneho hľadiska môže v tomto prípade pomôcť časová náročnosť jednotlivých algoritmov, ktorá bola najnižšia pre svetluškový algoritmus. Výsledky týchto metód sú porovnané s výstupmi automatickej registrácie pomocou funkcie Matlabu `imregister`. Tie ukázali, že použitie tejto funkcie si vyžaduje predspracovanie dát, keďže výsledky z registrovania celého rozsahu snímkov sa ukázali ako nedostatočné aj pri porovnaní s hodnotami pôvodných neregistrovaných dát.

Registráciou druhej sekvencie, ľavej srdečnej komory prasata, boli s ohľadom na vhodne zvolenú oblasť registrácie získané vyššie hodnoty kvalít. Tri vlastné optimalizačné metódy dosiahli zhodné hodnoty s presnosťou na tisíciny, preto je opäť rozhodujúci subjektívny pohľad a čas výpočtu. Ako najúspešnejší bol vizuálnym posúdením určený genetický algoritmus, ktorý však potrebuje najviac času. Použitie funkcie Matlabu si aj v prípade tejto sekvencie vyžaduje nevyhnutnú úpravu. Porovnaním výsledkov z manuálne registrovanej sekvencie je možné jednoznačne konštatovať vyššiu úspešnosť registrácie s použitím navrhnutých algoritmov.

Na záver je práca doplnená o užívateľské rozhranie pre jednoduchšiu obsluhu algoritmov. K registrácii je z dôvodu časovej náročnosti vybraný len obmedzený počet snímkov sekvencie.

Registrácia ultrazvukových sekvencií perfúzneho zobrazenia je v súčasnosti stále náročnou úlohou. Napriek preukázateľnej funkčnosti a úspešnosti registrácie s reali-

zovanými metódami na sekvencii pankreasu a prasačieho srdca, nie je možné zaručiť optimálne fungovanie registrácie komplexne na všetky dáta. Ako bolo ukázané testovaním, nie je možné jednoduché použitie implementovanej funkcie v Matlabe. Jednotlivé nastavenia a to už napríklad na začiatku optimalizačného procesu pri generovaní náhodných počiatočných riešení, ale aj v priebehu optimalizácie, je nutné voliť s ohľadom na charakter dát s prípadným dodatočným testovaním.

LITERATÚRA

- [1] AIT-AOUDIA, Samy a Ramdane MAHIOU. Medical Image Registration by Simulated Annealing and genetic algorithms. *Geometric Modeling and Imaging (GMAI '07)* [online]. IEEE, 2007, 145-148 [cit. 2016-12-17]. DOI: 10.1109/GMAI.2007.25. ISBN 0-7695-2901-1. Dostupné z: <http://ieeexplore.ieee.org/document/4271735/>
- [2] COSGROVE, David. *Ultrasound contrast agents: An overview* [online]. [cit. 2017-01-02]. DOI: 10.1016/j.ejrad.2006.06.022. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0720048X06003007>
- [3] DAMAS, S., O. CORDÓN a J. SANTAMARÍA. Medical Image Registration Using Evolutionary Computation: An Experimental Survey. *IEEE Computational Intelligence Magazine* [online]. 2011, 6(4), 26-42 [cit. 2016-12-17]. DOI: 10.1109/MCI.2011.942582. ISSN 1556-603x. Dostupné z: <http://ieeexplore.ieee.org/document/6052370/>
- [4] FERN, Antonio a Juan L. MATEO. Methodological Approach to Reducing Speckle Noise in Ultrasound Images. *2008 International Conference on BioMedical Engineering and Informatics* [online]. IEEE, 2008, 147-154 [cit. 2016-12-20]. Dostupné z: <http://ieeexplore.ieee.org/document/4549153/>
- [5] HASSAN, Rania, Babak COHANIM, Olivier DE WECK a Gerhard VENTER. *A Comparison of Particle Swarm Optimization and the Genetic Algorithm* [online]. [cit. 2017-05-18]. DOI: 10.2514/6.2005-1897. ISBN 10.2514/6.2005-1897. Dostupné z: <http://arc.aiaa.org/doi/10.2514/6.2005-1897>
- [6] HAUPT, Randy L. a S. E. HAUPT. *Practical genetic algorithms*. 2nd ed. Hoboken, N.J.: Wiley-Interscience, 2004. ISBN 04-714-5565-2.
- [7] CHE, Chengqian, Tejas SUDHARSHAN MATHAI a John GALEOTTI. Ultrasound Registration: A Review. *Methods* [online]. 2016, [cit. 2016-12-20]. DOI: 10.1016/j.ymeth.2016.12.006. ISSN 10462023. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1046202316304789>
- [8] IBRAHIEM, EL-EMARY a EL-KAREEM MONA M. ABD. On the application of genetic algorithms in finger prints registration. *World Applied Sciences Journal, 2008* [online]. 5(3), 276-281 [cit. 2016-12-17]. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.388.3415&rep=rep1&type=pdf>

- [9] JAN, Jiří. *Medical Image Processing, Reconstruction and Restoration - Concepts and Methods*. Boca Raton, FL, USA: CRC Press, Taylor and Francis Group, 2006, 760 s. Signal Processing and Comm., 1. ISBN 0-8247-5849-8.
- [10] KOZUMPLÍK, Jiří. *Evoluční algoritmy* [online]. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015 [cit. 2016-12-17]. (přednáška).
- [11] LEDESMA-CARBAYO, María J. a et al. Spatio-Temporal Nonrigid Registration for Ultrasound Cardiac Motion Estimation. *IEEE transactions on medical imaging* [online]. 2005, 24(9), 1113-1126 [cit. 2016-12-20].
- [12] LIU, Ji-Bin, Gervais WANSAICHEONG, Daniel A. MERTON, Flemming FORSBERG a Barry B. GOLDBERG. *Contrast-enhanced Ultrasound Imaging: State of the Art* [online]. [cit. 2017-01-02]. DOI: 10.1016/S0929-6441(09)60100-4. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0929644109601004>
- [13] MACHOWSKI, Lukasz a Tshilidzi MARWALA. *Evolutionary Optimisation Methods for Template Based Image Registration* [online]. 2007. [cit. 2017-05-18] Dostupné z: <https://pdfs.semanticscholar.org/a85a/b3b6c5de77c3>.
- [14] MALKAUTHEKAR, M.D. *Analysis of euclidean distance and manhattan distance measure in face recognition* [online]. [cit. 2017-05-17]. DOI: 10.1049/cp.2013.2636. ISBN 10.1049/cp.2013.2636. Dostupné z: <http://digital-library.theiet.org/content/conferences/10.1049/cp.2013.2636>
- [15] MELBOURNE, A, G RIDGWAY a D HAWKES. Image Similarity Metrics in Image Registratio. *Progress in biomedical optics and imaging* [online]. 2010, 11(33) [cit. 2017-05-18]. Dostupné z: <http://discovery.ucl.ac.uk/91782/1/91782.pdf>
- [16] MÉZL, Martin. *Evoluční algoritmy - cvičení 6*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. (přednáška k cvičení).
- [17] MÉZL, Martin. *Evoluční algoritmy - cvičení 10*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. (přednáška k cvičení).
- [18] MO, Yuan-bin, Yan-zhui MA a Qiao-yan ZHENG. *Optimal Choice of Parameters for Firefly Algorithm* [online]. [cit. 2017-05-17]. DOI:

- 10.1109/ICDMA.2013.210. ISBN 10.1109/ICDMA.2013.210. Dostupné z: <http://ieeexplore.ieee.org/document/6598132/>
- [19] OHLERTH, Stefanie a Robert T. O'BRIEN. Contrast ultrasound: General principles and veterinary clinical applications. *The Veterinary Journal* [online]. 2007, 501-512 [cit. 2017-01-02]. DOI: 10.1016/j.tvjl.2007.02.009. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1090023307000640>
- [20] PRINCE, J. a F.E. BARBER. A Method for the Reduction of Blurring Due to Registration Error in Compound Ultrasound Images. *1982 Ultrasonics Symposium* [online]. IEEE, 1982, 650-654 [cit. 2016-12-20]. DOI: 10.1109/ULTSYM.1982.197909. Dostupné z: <http://ieeexplore.ieee.org/document/1534849/>
- [21] QUAIA, Emilio. *Assessment of tissue perfusion by contrast-enhanced ultrasound* [online]. 2010, 604-615 [cit. 2017-01-04]. DOI: 10.1007/s00330-010-1965-6. ISBN 10.1007/s00330-010-1965-6. Dostupné z: <http://link.springer.com/10.1007/s00330-010-1965-6>
- [22] RONKOVÁ, P. *Optimalizace pro registraci obrazů založená na genetických algoritmech* [online]. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012 [cit. 2016-12-17]. Dostupné z: <https://core.ac.uk/download/pdf/30298468.pdf>
- [23] TVRDÍK, Josef. *Evoluční algoritmy* [online]. Ostrava: Ostravská univerzita: Fakulta přírodovědecká, 2004 [cit. 2016-12-17]. Dostupné z: http://prf.osu.cz/doktorske_studium/dokumenty/Evolutionary_Algorithms.pdf
- [24] VALSECCHI, Andrea, Sergio DAMAS a José SANTAMARIA. *Evolutionary Intensity-based Medical Image Registration: A Review* [online]. Bentham Science Publishers, 2013, 283-297 [cit. 2016-12-17].
- [25] VOLNÁ, Eva. *Evoluční algoritmy a neuronové sítě* [online]. OSTRAVA: Ostravská univerzita v Ostravě, 2012 [cit. 2016-12-17]. Dostupné z: <http://www1.osu.cz/~volna/>
- [26] WACHOWIAK, M.P., R. SMOLIKOVA a A.S. ELMAGHRABY. *Hybrid optimization for ultrasound and multimodal image registration* [online]. [cit. 2016-12-20]. DOI: 10.1109/IEMBS.2001.1017265. ISBN 10.1109/IEMBS.2001.1017265. Dostupné z: <http://ieeexplore.ieee.org/document/1017265/>

- [27] WEISE, Thomas. *Global Optimization Algorithms—Theory and Application* [online]. 2009, (2), 820 [cit. 2016-12-17]. Dostupné z: <http://www.it-weise.de/projects/book.pdf>
- [28] YANG, Xin-She. *Firefly Algorithms for Multimodal Optimization* [online]. [cit. 2017-05-17]. DOI: 10.1007/978-3-642-04944-6_14. ISBN 10.1007/978-3-642-04944-6_14. Dostupné z: http://link.springer.com/10.1007/978-3-642-04944-6_14
- [29] ZHANG, Yudong a Lenan WU. A Novel Method for Rigid Image Registration based on Firefly Algorithm. *International Journal of Research and Reviews in Soft and Intelligent Computing* [online]. 2012, 2(2), 141-146 [cit. 2017-05-17]. Dostupné z: https://www.researchgate.net/profile/Yudong_Zhang2/publication/267784653_A_Novel_Method_for_Rigid_Image_Registration_based_on_Firefly_Algorithm/links/5562948c08ae8c0cab3336a4.pdf
- [30] ZITOVA, Barbara a Jan FLUSSER. Image registration methods: a survey. *Image and vision computing* [online]. 2003, 977-1000 [cit. 2016-12-17]. Dostupné z: <http://library.utia.cas.cz/prace/20030125.pdf>
- [31] Image Processing Toolbox™ User's Guide. *MathWorks* [online]. Natick: The MathWorks, 2017 [cit. 2017-05-17]. Dostupné z: https://www.mathworks.com/help/pdf_doc/images/images_tb.pdf