




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

PŘEDREGISTRACE PLICNÍCH OBJEMOVÝCH CT OBRAZOVÝCH DAT

PRE-REGISTRATION OF CT PULMONARY VOLUMETRIC IMAGE DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

BRANISLAV ŠIŠKA

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. JIŘÍ CHMELÍK

BRNO 2015



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Bakalářská práce

bakalářský studijní obor
Biomedicínská technika a bioinformatika

Student: Branislav Šiška
Ročník: 3

ID: 155605
Akademický rok: 2014/2015

NÁZEV TÉMATU:

Předregistrace plicních objemových CT obrazových dat

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou líčování plicních objemových CT obrazových dat. 2) Proveďte literární rešerši možných metod registrace obrazů a porovnejte jejich výhody a nevýhody. 3) Navrhnete metodu vhodnou pro předregistraci daných obrazových dat. 4) Realizujte navrženou metodu v programovém prostředí Matlab. 5) Realizovaný software ověřte na CT obrazových datech dostupných na pracovišti a proveďte případné modifikace metody pro maximalizaci účinnosti předregistrace. 6) Proveďte zhodnocení a diskutujte dosažené výsledky.

DOPORUČENÁ LITERATURA:

- [1] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. Boca Raton: Taylor, 2006, 730 s. ISBN 08-247-5849-8.
[2] ZITOVÁ, Barbara a FLUSSER, Jan. Image registration methods: a survey. Image and Vision Computing. 2003, roč. 21, č. 11, s. 977-1000.

Termín zadání: 9.2.2015

Termín odevzdání: 29.5.2015

Vedoucí práce: Ing. Jiří Chmelík

Konzultanti bakalářské práce:

**prof. Ing. Ivo Provazník,
Ph.D.**

UPOZORNĚNÍ:

Předseda oborové rady

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

Abstrakt

Bakalárska práca sa zaoberá predregistráciou pľúcnych objemových CT obrazových dát. Predregistrácia je riešená metódou fázovej korelácie pri rozklade 3D obrazu na 2D rezy usporiadané za sebou. Práca ďalej popisuje geometrické transformácie, interpolácie, výpočet podobnostných kritérií, optimalizáciu registrácie obrazu a proces samotnej registrácie obrazu. Predregistračný softvér je navrhnutý v programovom prostredí MATLAB®, kde prebieha predregistrácia 3D reálnych CT obrazových dát s dôrazom na rýchlosť procesu.

Kľúčové slová

Registrácia obrazu, fázová korelácia, geometrické transformácie obrazu, interpolácia, monomodálne pľúcne 3D CT obrazové dáta

Abstract

This bachelor thesis is dealing with pre-registration of CT pulmonary volumetric image data. Pre-registration is solved by phase correlation method, which decomposes 3D images into 2D slices arranged in a row. It further describes the geometric transformations, interpolation, calculations of similarity criteria, optimization of registration of images and the image registration process itself. The pre-registration software runs in MATLAB®, which works with 3D images of real CT image data with an emphasis on process speed.

Key words

Image registration, phase correlation, geometric transformation of image, interpolation, monomodal pulmonary 3D CT image data

Prehlásenie

Prehlasujem, že svoju bakalársku prácu na téma Předregistrace plicních objemových CT obrazových dát som vypracoval samostatne pod vedením vedúceho bakalárskej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú citované a uvedené v zozname použitých zdrojov na konci práce.

Ako autor uvedenej bakalárskej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto práce som neporušil autorské práva tretích osôb, nezasiahol som nedovoleným spôsobom do cudzích autorských práv osobnostných a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona č. 121/2000 Sb., vrátane možných trestnoprávnych dôsledkov vyplývajúcich z ustanovení časti druhej, hlavy VI. diel 4 Trestného zákonníka č. 40/2009Sb.

V Brne dňa

Podpis autora

Pod'akovanie

Ďakujem vedúcemu mojej bakalárskej práce Ing. Jiřímu Chmelíkovi za odbornú pomoc a čas, ktorý si pre mňa našiel pri spracovávaní mojej bakalárskej práce.

V Brne dňa

Podpis autora

ŠIŠKA, B. *Předregistrace plicních objemových CT obrazových dat*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 51 s.
Vedoucí bakalářské práce Ing. Jiří Chmelík.

Obsah

Zoznam obrázkov	vii
Úvod.....	8
1 Registrácia obrazu	9
1.1 Optimalizačné metódy registrácie obrazu	9
1.2 Fázová korelácia.....	18
1.3 Disparitná analýza.....	22
2 Návrh vlastnej metódy	24
3 Dosiahnuté výsledky.....	33
3.1 Obrazy bez simulovaného šumu	33
3.2 Obrazy so simulovaným šumom.....	38
3.3 Realné dáta	44
4 Záver.....	47
Použité zdroje	49
Zoznam použitých skratiek.....	51

Zoznam obrázkov

Obrázok 1-1 – Schéma registrácie obrazu	10
Obrázok 1-2 - Interpolácia najbližším susedom.	14
Obrázok 1-3 - Bilineárna interpolácia	14
Obrázok 1-4 - Bikubická interpolácia.....	15
Obrázok 1-5 – Prevod z kartézskych do polárnych súradníc.....	21
Obrázok 1-6 – Príklad disparitnej mapy	23
Obrázok 2-1 - Rozklad 3D dát na 2D rezy	25
Obrázok 2-2 – Obraz v kartézskych a log-polárnych súradniciach	26
Obrázok 2-3 – Blokové schéma algoritmu fázovej korelácie pre transláciu.	27
Obrázok 2-4 – Bloková schéma algoritmu fázovej korelácie pre rotáciu.....	29
Obrázok 2-5 – Bloková schéma algoritmu fázovej korelácie pre škálovanie.....	31
Obrázok 3-1 – Výsledky fázovej korelácie pre transláciu	33
Obrázok 3-3 – Výsledky fázovej korelácie pre rotáciu	34
Obrázok 3-4 – Grafy závislosti podobnostných kritérií na zvyšovaní hodnoty rotácie referenčného obrazu.....	35
Obrázok 3-5 – Výsledky fázovej korelácie pre škálovanie	36
Obrázok 3-6 – Grafy závislosti podobnostných kritérií na zmenách hodnôt škálovania referenčného obrazu.....	37
Obrázok 3-7 – Výsledky fázovej korelácie pre transláciu so šumom.....	38
Obrázok 3-8- Graf zobrazuje závislosť chybyne posunutých pixelov na rozptyle simulovaného gaussovho šumu so strednou hodnoutou 0.	39
Obrázok 3-9 - Výsledky fázovej korelácie pre rotáciu so šumom.....	40
Obrázok 3-10 – Graf zobrazuje závislosť priemerného počtu chybyne detekovaných stupňov na zvyšovaní rozptylu šumu.....	41
Obrázok 3-11 – Výsledky fázovej korelácie pre škálovanie	42
Obrázok 3-12 – Graf zobrazuje závislosť chyby detekovaného faktoru škálovania na zvyšujúcich sa hodnotách simulovaného gaussovho šumu	43
Obrázok 3-13 – Výsledky algoritmu rotácie na reálnych dátach pľúc	44
Obrázok 3-14 – Výsledky algoritmu registrácie pre reálne dáta pľúc v rovine x,y.....	45
Obrázok 3-15 – Výsledky algoritmu registrácie pre reálne dáta pľúc v rovine x,z.....	45
Obrázok 3-16 - Výsledky algoritmu registrácie pre reálne dáta pľúc v rovine y,z.....	46

Úvod

Registrácia obrazu je proces, kedy sa hľadá vhodná transformácia posunutého obrazu tak, aby sa čo najviac podobal referenčnému obrazu. Obidva porovnávané obrazy väčšinou snímajú rovnakú scénu. Snímky sú však urobené v rôznych časových okamihoch, alebo sú urobené pri inom snímacom úhľe. Ďalej môžu byť snímky urobené pri pohybe pacienta, ktorý je spôsobený dýchacími pohybmi, alebo pohybmi srdca. Registrácia obrazu sa ďalej používa pri opakovanom snímaní, napríklad pred a po operačnom vyšetrení, alebo pri zmene akvizičných parametrov snímania. Ďalšie použitie je na fúziu multimodálnych obrazov, napríklad MR a CT, kedy sa spája anatomická informácia obrazu s funkčnou. Vzniknutá fúzia obrazov obsahuje viac informácií, ako jednotlivé snímky samostatne. Väčšina registračných metód nebola pred desiatkami rokov vôbec použiteľná pre ich neznalosť a vysokú výpočetnú náročnosť. S postupným rozvojom počítačovej techniky sa však vyvynuli aj rôzne nové metódy registrácie obrazov, ktoré už nepredstavujú pre počítač takú vysokú výpočetnú náročnosť.

Existuje mnoho registračných metód, ktoré sú delené podľa viacerých kritérií. Registračné metódy, ktoré riešia rigidné transformácie sa používajú pri nepohyblivých scénach, ktoré neobsahujú pružný pohyb, napríklad pri snímkach kostí a hlavy. Registračné metódy, ktoré riešia afinné transformácie sa naopak používajú pri pohyblivých scénach, napríklad pri snímkach srdca. Zadanie práce je predregistrácia pľúcnych objemových CT obrazových dát a tak tomu treba prispôbiť aj výber vhodnej registračnej metódy. Zvolená metóda musí vedieť pracovať s monomodálnymi objemovými CT obrazovými dátami a musí čo najrýchlejšie registrovať obrazy s rigidnými transformáciami a škálovaním pri dostatočnom zachovaní obrazovej informácie. Predregistrácia obrazu tak slúži na potlačenie najväčších zmien medzi referenčným a posunutým obrazom, čo veľmi zrýchľuje ďalší výpočet pre dosiahnutie lepších výsledkov. Príklad metódy na zlepšenie výsledkov môže byť napríklad lokálna registrácia.

1 Registrácia obrazu

Registrácia obrazu je proces spracovania obrazu, kedy sa hľadá vhodná transformácia jedného obrazu A (posunutého), aby sa čo najviac podobal druhému obrazu B (referenčnému). Matematicky je to popísané ako hľadanie vhodných transformačných parametrov α transformácie T v obraze tak, aby bola zaistená maximálna, alebo minimálna hodnota kritériálnej funkcie c [1], podľa toho, kedy sú si porovnávané obrazy najviac podobné. Matematicky je to vzorcom možné popísať ako:

$$\alpha_0 = \arg \max_{\alpha} c(B(\mathbf{x}_B), A'(T_{\alpha}(\mathbf{x}_A))), \quad (1)$$

kde B je referenčný obraz, α sú parametre transformácie T_{α} , A' je už transformovaný obraz A , T_{α} je geometrická transformácia, ktorá transformuje posunutý obraz A , $c(\cdot)$ je kritérium podobnosti obrazov, \mathbf{x}_A je pozičný vektor obrazu A' a \mathbf{x}_B je pozičný vektor obrazu B .

1.1 Optimalizačné metódy registrácie obrazu

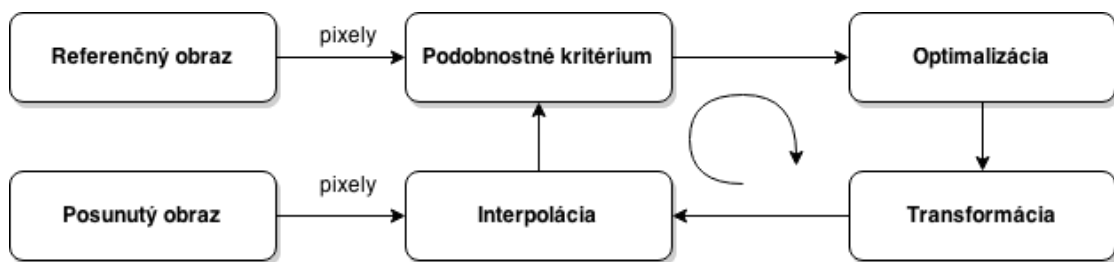
Registrácia obrazu sa delí podľa viacerých kritérií. V tejto práci sa využíva delenie registračných metód z knihy [1], podľa ktorej sa registrácia obrazu delí podľa:

Kritérium založené na intenzite v obrazoch – sú známe posunutý obraz A a referenčný obraz B . Obraz A môžeme definovať vektorom \mathbf{a} , ktorý obsahuje hodnoty N pixelov usporiadaných do riadku. Obraz B je definovaný obdobne vektorom \mathbf{b} . Každý pixel má tak priradenú svoju hodnotu. Aby sa obrazy čo najviac podobali, je potrebné aby sa čo najviac podobali aj ich odpovedajúce vektory. Kritérium porovnáva hodnoty intenzity priamo tak nie je veľmi náročné.

Kritérium založené na významných bodoch v obrazoch – na významných miestach obrazu ako sú hrany, v medicínskych obrazoch prechody medzi orgánmi, napr. medzi kosťou a mäkkým tkanivom sa vyznačia body. Správna detekcia hrán obrazu je najťažším krokom tejto metódy. Pre zjednodušenie detekcie významných bodov sa podávajú rôzne markery. Metóda sa najčastejšie využíva pri rigidných a afinných transformáciách. Ak je počet vyznačených bodov dostatočne veľký, tak sa môže použiť aj pri pružných transformáciách. Významné body sa delia na anatomické, ktoré sú viditeľné aj voľným okom a označuje ich sám užívateľ. Druhá kategória sú body geometrické. Do tejto kategórie patria rohy a krivky, ktoré sú detekované automaticky.

Kritérium založené na povrchu obrazu – táto metóda sa nezaobera len bodmi obrazu, ale jeho celými plochami a priestorovými útvarmi. Požíva sa pri rigídnej transformácii, ktorú zastupuje translácia a rotácia, ako aj pri elastickej transformácii.

Podľa ďalšieho delenia sa registrácia obrazu delí na globálnu a lokálnu. Pri globálnej sa jedna transformácia aplikuje na celý snímok. Na každú priestorovú súradnicu obrazu je aplikovaná rovnaká geometrická transformácia. Pri lokálnej registrácii sa transformuje len určitá časť celého snímku. Pre rôzne časti obrazu tak môže byť použitá iná geometrická transformácia. Schéma registrácie obrazu je zobrazená na Obrázok 1-1.



Obrázok 1-1 – Schéma registrácie obrazu, prevzaté a upravené z [2]

Geometrické transformácie

Geometrická transformácia obrazu A znamená mapovanie transformačnej funkcie T medzi priestorovými súradnicami obrazu A , ktorý je definovaný vektorom pozičných súradníc $\mathbf{r}=(x,y)$, kde x a y sú súradnice pozičného vektoru obrazu A , a vektorom pozičných súradníc $\mathbf{r}'=(x',y')$ transformovaného obrazu A' , kde x',y' sú súradnice pozičného vektoru obrazu A' [1]. Hodnoty jasu v obraze sa nemenia, ale sú len posunuté do nových súradníc, čo môžeme vyjadriť ako:

$$\mathbf{r}' = T(\mathbf{r}), \quad (2)$$

kde \mathbf{r}' je v tomto prípade sústava súradníc transformovaného obrazu, \mathbf{r} je sústava súradníc referenčného obrazu a T je použitá geometrická transformácia. Geometrické transformácie sa delia na dve hlavné skupiny a to na rigídne (tuhé) a flexibilné (pružné). Rigídne transformácie zachovávajú geometrický tvar pôvodného obrazu. Medzi rigídne transformácie patrí:

Translácia – vyjadruje posun pixelov obrazu, v ktorom \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{r} je sústava súradníc referenčného obrazu a $\Delta\mathbf{r}$ je rozdiel týchto súradníc. Platí:

$$\mathbf{r}' = \mathbf{r} + \Delta\mathbf{r}, \Delta\mathbf{r} = [\Delta x, \Delta y]^T. \quad (3)$$

Rotácia – transformovaný obraz je oproti referenčnému otočený o určitý uhol. Platí:

$$\mathbf{r}' = \mathbf{B}\mathbf{r}, \quad (4)$$

$$\mathbf{B} = \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix}, \quad (5)$$

kde \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{r} je sústava súradníc referenčného obrazu a \mathbf{B} je rotačná matica, ktorá vyjadruje otočenie transformovaného obrazu o uhol θ . Pre 3D rotáciu je rotačná matica vyjadrená ako:

$$\mathbf{B} = \begin{bmatrix} \cos\theta_z & -\sin\theta_z & 0 \\ \sin\theta_z & \cos\theta_z & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos\theta_y & 0 & \sin\theta_y \\ 0 & 1 & 0 \\ -\sin\theta_y & 0 & \cos\theta_y \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\theta_x & -\sin\theta_x \\ 0 & \sin\theta_x & \cos\theta_x \end{bmatrix}. \quad (6)$$

Pre zjednodušenie sa translácia a rotácia môžu zlúčiť do jednej rovnice, v ktorej platí:

$$\mathbf{r}' = \mathbf{B}\mathbf{r} + \Delta\mathbf{r}, \quad (7)$$

kde \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{B} je rotačná matica a $\Delta\mathbf{r}$ je rozdiel súradníc transformovaného a referenčného obrazu. Rovnicu sa ešte môže zjednodušiť zavedením matice \mathbf{R} , ktorá vyjadruje obecnú rigidnú geometrickú transformáciu, ako :

$$\mathbf{r}' = \mathbf{R}\mathbf{r}, \quad (8)$$

$$\mathbf{r}' = \begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} \cos\theta & -\sin\theta & \Delta x \\ \sin\theta & \cos\theta & \Delta y \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix}. \quad (9)$$

V 3D priestore pre spojenie translácie a rotácie, pri použití transformačných parametrov b platí [1]:

$$\mathbf{r}' = \begin{bmatrix} x' \\ y' \\ z' \\ 1 \end{bmatrix} = \begin{bmatrix} b_{11} & b_{12} & b_{13} & \Delta x \\ b_{21} & b_{22} & b_{23} & \Delta y \\ b_{31} & b_{32} & b_{33} & \Delta z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix}, \quad (10)$$

$$\mathbf{r} = \mathbf{R}\mathbf{r}', \quad (11)$$

kde \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{R} je matica, ktorá vyjadruje obecnú rigidnú geometrickú transformáciu a \mathbf{r} je sústava súradníc referenčného obrazu.

Flexibilné transformácie deformujú štruktúru obrazu a menia pri tom vzdialenosti medzi jednotlivými pixelmi [3]. Medzi flexibilné transformácie patria:

Škálovanie – vyjadruje zmenu mierky obrazu, pre ktorý platí, že \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{S} je škálovacia matica, v ktorej s_x a s_y vyjadrujú zmenu mierky v osi x a y, a \mathbf{r} je sústava súradníc referenčného obrazu. Matematicky to vyjadríme ako:

$$\mathbf{r}' = \mathbf{S}\mathbf{r}, \quad (12)$$

$$\mathbf{S} = \begin{bmatrix} s_x & 0 & 0 \\ 0 & s_y & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (13)$$

Pre 3D škálovaciu maticu platí:

$$\mathbf{S} = \begin{bmatrix} s_x & 0 & 0 & 0 \\ 0 & s_y & 0 & 0 \\ 0 & 0 & s_z & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (14)$$

Pre kombináciu rigidnej transformácie a škálovania platí:

$$\mathbf{r}' = \mathbf{S}\mathbf{R}\mathbf{r}, \quad (15)$$

$$\mathbf{S}\mathbf{R} = \begin{bmatrix} s_x & 0 & 0 \\ 0 & s_y & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos\theta & -\sin\theta & \Delta x \\ \sin\theta & \cos\theta & \Delta y \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} s_x \cos\theta & -s_x \sin\theta & s_x \Delta x \\ s_y \sin\theta & s_y \cos\theta & s_y \Delta y \\ 0 & 0 & 1 \end{bmatrix}, \quad (16)$$

kde \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{S} je škálovacia matica, \mathbf{R} je matica, ktorá vyjadruje obecnú rigidnú geometrickú transformáciu a \mathbf{r} je sústava súradníc referenčného obrazu.

Skosenie – vyjadruje postupný nárast posunu riadkov, alebo stĺpcov. Transformačnú maticu \mathbf{G} pre posun v osách x a y, kde \mathbf{G}_x je skosenie v osi x a \mathbf{G}_y je skosenie v osi y môžeme vyjadriť ako [3]:

$$\mathbf{G}_x = \begin{bmatrix} 1 & g_{xy} & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (17)$$

$$\mathbf{G}_y = \begin{bmatrix} 1 & 0 & 0 \\ 0 & g_{xy} & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (18)$$

Ďalšie delenie geometrických transformácií je na:

Lineárne transformácie – zachovávajú kolinearitu bodov a ich deliaci pomer. Priamky tak zostávajú priamkami a rovnobežky zostávajú rovnobežné. Zmenia sa však uhly. Patria sem afinne transformácie. Najvšeobecnejšia rovnica afinnej transformácie je definovaná ako:

$$\mathbf{r}' = \mathbf{GSRr} = \mathbf{Ar}, \quad (19)$$

kde \mathbf{r}' je sústava súradníc transformovaného obrazu, \mathbf{G} je matica skosenia, \mathbf{S} je škálovacia matica, \mathbf{R} je matica, ktorá vyjadruje všeobecnú rigidnú geometrickú transformáciu a \mathbf{r} je sústava súradníc referenčného obrazu. \mathbf{A} je transformačná matica všeobecnej afinnej geometrickej transformácie definovaná transformačnými parametrami a a t ako:

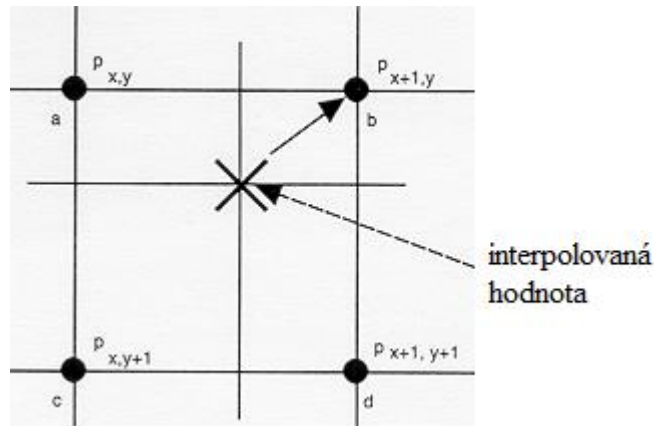
$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & t_1 \\ a_{21} & a_{22} & a_{23} & t_2 \\ a_{31} & a_{32} & a_{33} & t_3 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (20)$$

Nelineárne transformácie – spôsobujú porušenie rovnobežnosti, alebo zakrivenie priamok a plôch. Rovnobežky sa tak môžu stať rôznobežkami. Patria sem projektívne transformácie, ktoré zastupuje zakrivenie a využíva sa pri vyjadrení perspektívy a polynomicke transformácie, ktoré nový pozičný vektor obrazu počítajú použitím koeficientov polynómu. Viac informácií o polynomických transformáciach je v práci [4].

Interpolácia


Využíva sa na získanie hodnôt pixelov v obraze tam, kde obraz nie je navzorkovaný. Aby sa určili hodnoty týchto pixelov, obraz sa musí posunúť o neceločíselnú hodnotu do diskkrétnej obrazovej mriežky. Ak sa obraz neinterpoluje správne, môžu vzniknúť obrazové artefakty, či skreslenie.

Interpolácia najbližším susedom (NN) - tiež označovaná ako interpolácia nultého stupňa. Je najjednoduchšia a najrýchlejšia interpolačná metóda. Hodnota hľadaného pixelu zodpovedá hodnote pixelu, ktorý je k nemu najbližšie. Metóda zachováva ostrosť hrán, generuje však silný aliasing a preto sa hodí hlavne pri orientačnom zobrazovaní výsledku. Aliasing vzniká ak nie je dodržaný Nyquistov vzorkovací teorém [5]. Ukážka výpočtu nového pixelu je na Obrázok 1-2.



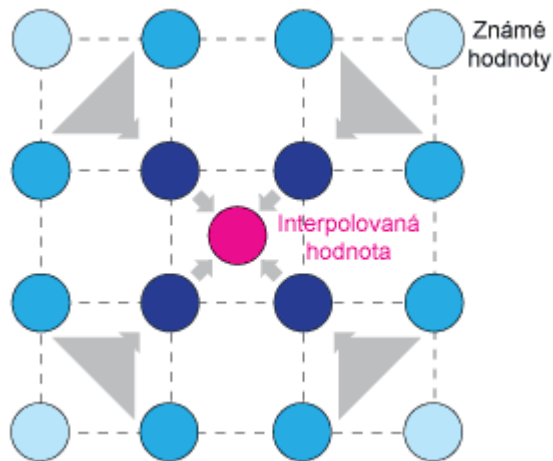
Obrázok 1-2 - Interpolácia najbližším susedom priradí novému pixelu hodnotu najbližšieho pixelu, prevzaté a upravené z [6].

Bilineárna interpolácia - metóda je náročnejšia na výpočet, ale dosahuje lepšie výsledky ako interpolácia najbližších susedov. Na výpočet hľadaného pixelu v posunutej mriežke sa používajú priemerné hodnoty 4 najbližších pixelov v okolí z pôvodnej mriežky. Metóda má silný protialiasingový účinok. Výsledok je jemnejší ako v prípade použitia interpolácie najbližším susedom. Ukážka výpočtu nového pixelu je na Obrázok 1-3.



Obrázok 1-3 - Bilineárna interpolácia počíta novú hodnotu pixelu ako priemer 4 najbližších pixelov, prevzaté a upravené z [6].

Bikubická interpolácia - je zo všetkých uvedených interpolácií najzložitejšia. Dosahuje však najkvalitnejšie výsledky. Výsledná hodnota vzniká aproximáciou zo 16 koeficientov 4 priľahlých uzlov v okolí z pôvodnej mriežky. Metóda je veľmi odolná proti aliasingu a dokáže vytvoriť veľmi jemné prechody medzi jednotlivými pixelmi. Ukážka výpočtu nového pixelu je na Obrázok 1-4.



Obrázok 1-4 - Bikubická interpolácia počíta novú hodnotu pixelu na základe váženého priemeru 16 najbližších hodnôt. Bližšie pixely (tmavo modrá) majú väčšiu váhu ako postupne vzdialenejšie pixely (modrá a slabo modrá), prevzaté a upravené z [6].

Ďalšie známe interpolačné metódy sú napríklad polynomiálna interpolácia, kedy sa hodnoty aproximujú interpolačnou funkciou tvorenou polynómom. Ďalej sa využíva skrátaná 2D funkcia sinc, ktorá je presná, ale výpočetne náročná. Okrem už spomenutých interpolaácií sa používa ešte metóda B-spline. Viac o týchto, ale aj ďalších interpolačných metódach využívaných pri spracovávaní medicínskych obrazov je v práci [7].

Podobnostné kritéria

Na hodnotenie registrácie je pre každú transformáciu používané podobnostné kritérium. Pre danú transformáciu vyhodnocuje mieru podobnosti medzi posunutým a referenčným obrazom, ktoré majú rovnaké rozmery. Podobnostné kritéria sa delia na :

Metóda najmenších štvorcov (SSD) - najzákladnejšia metóda pri porovnávaní dvoch obrazov. Ku optimálnej registrácii dochádza, ak sú porovnávané obrazy identické. Vtedy je hodnota SSD rovná nule. Ak hodnota SSD nie je rovná nule, ale je väčšia ako nula, optimálna registrácia je v minime funkcie. Metóda je vhodná pre obrazy, u ktorých je predpoklad, že sa čo najviac podobajú a obsahujú minimálny šum. Inak metóda nemusí byť účinná [2]. Platí :

$$C_{SSD}(\mathbf{a}, \mathbf{b}) = \frac{1}{N} \sum_{i=1}^N |a_i - b_i|^2, \quad (21)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, v tomto prípade \mathbf{a} je referenčný a \mathbf{b} je transformovaný obraz, i je príslušný bod obrazu, N je veľkosť obrazu.

Euklidová vzdialenosť - metódu dostaneme úpravou metódy súčtu rozdielu štvorcov SSD. Je založená na euklidovom rozdiel, ktorý je popísaný ako:

$$C_E(\mathbf{a}, \mathbf{b}) = |\mathbf{a} - \mathbf{b}| = \sqrt{\sum_{i=1}^N |a_i - b_i|^2}, \quad (22)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, i je príslušný bod obrazu, N je veľkosť obrazu.

Kosínové kritérium - v porovnávaných obrazoch porovnáva uhly vektorov. Výhoda je, že metóda je odolná proti lineárnym zmenám kontrastu [1]. Nadobúda hodnoty $(0,1)$, kde 1 predstavuje absolútnu zhodu. Platí :

$$C_A(\mathbf{a}, \mathbf{b}) = \frac{\mathbf{a}\mathbf{b}}{|\mathbf{a}||\mathbf{b}|} = \frac{\sum_i a_i b_i}{\sqrt{\sum_i a_i^2} \sqrt{\sum_i b_i^2}}, \quad (23)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, i je príslušný bod obrazu.

Korelačné kritérium – metóda sa využíva pri lineárnom vzťahu intenzít medzi porovnávanými obrazmi [2]. Najväčšia podobnosť medzi obrazmi je v maxime funkcie. Vychádza z korelácie, pre ktorú platí :

$$C_C(\mathbf{a}, \mathbf{b}) = \frac{1}{N} \sum_{i=1}^N (a_i b_i), \quad (24)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, i je príslušný bod obrazu a N je veľkosť obrazu.

Normalizovaný korelačný koeficient (NCC) - normalizáciou odstraňuje väčšinu nedostatkov korelačného koeficientu CC pri zachovaní výpočtovej náročnosti. Funkcia popisuje lineárnu závislosť dvoch súborov dát. Nadobúda hodnoty v rozmedzí $(-1,1)$. Ak je hodnota rovná 1, porovnávané obrazy sú identické. Vypočíta sa ako :

$$C_{NCC}(\mathbf{a}, \mathbf{b}) = \frac{\sum_i (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_i (a_i - \bar{a})^2} \sqrt{\sum_i (b_i - \bar{b})^2}}, \quad (25)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, i je príslušný bod obrazu, N je veľkosť obrazu, \bar{a} a \bar{b} sú stredné hodnoty, ktoré sa vypočítajú ako:

$$\bar{a} = \frac{1}{N} \sum_i a_i, \quad (26)$$

$$\bar{b} = \frac{1}{N} \sum_i b_i. \quad (27)$$

Kovariačný koeficient – popisuje prirodzenú mieru asociácie medzi dvoma premennými. Pre výpočet platí :

$$C_{CV}(\mathbf{a}, \mathbf{b}) = \sum_i (a_i - \bar{a})(b_i - \bar{b}), \quad (28)$$

kde \mathbf{a} a \mathbf{b} sú porovnávané obrazy, i je príslušný bod obrazu, \bar{a} a \bar{b} sú stredné hodnoty.

Vzájomná informácia (MI) – vyjadruje mieru závislostí porovnávaných obrazov. Metóda je použiteľná pre rôzne zobrazovacie modalities, napríklad pre MR a CT, je však náročná na výpočet. Výpočet MI pomocou entropií je počítaná ako :

$$MI(R, L') = H(R) + H(L') - H(R, L'), \quad (29)$$

kde $H(R)$ je entropia referenčného a $H(L')$ entropia transformovaného obrazu. Optimálna registrácia je v maxime hodnoty MI [2]. Vtedy sú porovnávané obrazy na sebe maximálne závislé, a teda rovnaké. Ak budú porovnávané obrazy maximálne nezávislé hodnota MI bude nula.

Optimalizácia

Optimalizácia je proces, ktorý opakovane porovnáva referenčný a registrovaný obraz a následne sa počítajú parametre použitej transformácie. Proces hľadá extrém podobnostnej funkcie. Nie vždy je však možné a potrebné nájsť hľadaného extrém. Cieľom optimalizačných metód je priblíženie sa ku správne riešenie na základe vhodne zvoleného podobnostného kritéria. V zložitejších úlohách sa môže vyskytovať viac lokálnych extrémov a teda aj viac riešení kriteriálnej funkcie. Pre správnu registráciu je potrebné nájsť globálny extrém na celej množine možných výsledkov. Metódy sa delia na tri hlavné skupiny:

Stochastické metódy – do optimalizácie zavádzajú náhodnosť a pracujú s pravdepodobnosťou. Môžu pracovať aj s nespojitými funkciami. Patrí sem napríklad metóda simulovaného žihania. Viac informácií o tejto metóde je v práci [8].

Deterministické metódy – minimum spojitej funkcie hľadajú analyticky klasickými matematickými postupmi. Patrí sem metóda deterministického gradientného zostupu. Viac o metóde je v práci [9].

Zmiešané metódy – sú najvýkonnejšie optimalizačné metódy, ktoré vznikli kombináciou stochastických a deterministických metód. Sú rýchle a dosahujú aj dobré výsledky.

Ďalšie delenie optimalizačných metód je na lokálne a globálne. Lokálne hľadajú extrém kriteriálnej funkcie v okolí blízkom počiatku. Hľadajú optimum len pre určitú obmedzenú oblasť obrazu. Využívajú sa pri pružných registráciách. Globálne metódy

nepracujú len s určitou časťou, ale pracujú s celým obrazom. Sú teda jednoduchšie ako lokálne optimalizačné metódy.

1.2 Fázová korelácia

Základný nástroj, ktorý využíva fázová korelácia je Fourierova transformácia (FT). Použitím FT sa originálna obrazová oblasť prevedie do spektrálnej roviny priestorových frekvencií. Vzniknuté spektrum je komplexná veličina. Veľkosť spektrálnej roviny sa nazýva amplitúdové spektrum a jej uhol fázové spektrum. Pre 2D obrazy sa využíva 2D diskretná Fourierova transformácia (DFT). V 2D spektre je jednosmerná zložka uprostred obrazu a smerom k okrajom sa frekvencia zvyšuje [10]. Pre obrazy f_1 a f_2 , ktoré sa líšia o posun (dx, dy) platí:

$$f_2(x, y) = f_1(x - dx, y - dy) . \quad (30)$$

Pre spektrum Fourierovej transformácie F_1 obrazu f_1 a spektrum Fourierovej transformácie F_2 obrazu f_2 platí:

$$F_2(u, v) = e^{-j2\pi(ux+vy)} \cdot F_1(u, v) , \quad (31)$$

kde e je základ prirodzeného logaritmu, j je komplexná jednotka, u a v sú FT koeficienty zodpovedajúce súradniciam obrazu x a y . Obrazy sa líšia fázou, ktorá je spojená s posunom obrazov. Pôsobením posunového teorému je fázový posun ekvivalentný fáze krížového výkonového spektra :

$$\frac{F_1(u,v)F'_2(u,v)}{|F_1(u,v)F'_2(u,v)|} = e^{j2\pi(ux_0+vy_0)} , \quad (32)$$

kde e je základ prirodzeného logaritmu, f_1 a f'_2 sú obrazy, F_1 je Fourierová transformácia obrazu f_1 a F'_2 je komplexná konjugácia F_2 [11]. Ak je obraz $f_2(x, y)$ replikou obrazu $f_1(x, y)$, posuntou o x_0, y_0 a rotovanou o uhol θ_0 platí:

$$f_2(x, y) = f_1(x \cdot \cos \theta_0 + y \cdot \sin \theta_0 - x_0, -x \cdot \sin \theta_0 + y \cdot \cos \theta_0 - y_0) . \quad (33)$$

Pre Fourierové transformácie $F_1(u, v)$ a $F_2(u, v)$ obrazov $f_1(x, y)$ a $f_2(x, y)$ ďalej platí:

$$F_2(u, v) = F_1(u \cdot \cos \theta_0 + v \cdot \sin \theta_0, -u \cdot \sin \theta_0 + v \cdot \cos \theta_0) . \quad (34)$$

Pre amplitúdové spektrá platí:

$$M_2(u, v) = M_1(u \cdot \cos \theta_0 + v \cdot \sin \theta_0, -u \cdot \sin \theta_0 + v \cdot \cos \theta_0) , \quad (35)$$

kde $M_1(u, v)$ je amplitudové spektrum obrazu $f_1(x, y)$ a $M_2(u, v)$ je amplitúdové spektrum obrazu $f_2(x, y)$. Po prevode súradníc do polárnych získame uhol ako:

$$M_1(\rho, \theta) = M_2(\rho, \theta - \theta_0), \quad (36)$$

kde θ je výsledný uhol, θ_0 je uhol, o ktorý bol referenčný obraz rotovaný a ρ je vzdialenosť od počiatku. Pre Fourierovú transformáciu $F_1(u, v)$ obrazu $f_1(x, y)$, ktorý je replika obrazu $f_2(x, y)$ a Fourierovú transformáciu $F_2(u, v)$ obrazu $f_2(x, y)$, ktorý má iné rozmery platí:

$$F_2(u, v) = \frac{1}{|ab|} F_1\left(\frac{u}{a}, \frac{v}{b}\right), \quad (37)$$

kde a je zmena mierky pre horizontálne súradnice a b je zmena mierky pre vertikálne súradnice. Pri prevode do log-polárnych súradníc je posun :

$$F_2(\ln u, \ln v) = F_1(\ln u - \ln a, \ln v - \ln b), \quad (38)$$

kde a je zmena mierky pre horizontálne súradnice a b je zmena mierky pre vertikálne súradnice, F_1 a F_2 sú Fourierové transformácie. Ak nahradíme $\xi = \ln u, \eta = \ln v, c = \ln a, d = \ln b$ rovnica má tvar:

$$F_2(\xi, \eta) = F_1(\xi - c, \eta - d). \quad (39)$$

Posunutie c, d a mierka a, b sú zistené ako:

$$a = e^c, \quad (40)$$

$$b = e^d, \quad (41)$$

kde e je základ prirodzeného logaritmu. V polárnych súradniciach, kde obraz $A(x, y)$ je preškálovaný do obrazu $B\left(\frac{x}{a}, \frac{y}{a}\right)$ platí :

$$\rho_1 = \sqrt{x^2 + y^2}, \quad (42)$$

$$\theta_1 = \tan^{-1}\left(\frac{y}{x}\right), \quad (43)$$

$$\rho_2 = \sqrt{\left(\frac{x}{a}\right)^2 + \left(\frac{y}{a}\right)^2} = \frac{1}{a} \sqrt{x^2 + y^2} = \frac{\rho_1}{a}, \quad (44)$$

$$\theta_2 = \tan^{-1}\left(\frac{\frac{y}{a}}{\frac{x}{a}}\right) = \tan^{-1}\left(\frac{y}{x}\right) = \theta_1, \quad (45)$$

kde ρ_1, ρ_2 sú veľkosti vzdialeností, θ_1, θ_2 sú veľkosti uhlov, a je mierka, x a y sú súradnice v obraze. Pre amplitúdové spektrá v polárnych súradniciach potom platí:

$$M_1(\rho_1, \theta) = M_2\left(\frac{\rho_1}{a}, \theta - \theta_0\right), \quad (46)$$

$$M_1(\ln \rho_1, \theta) = M_2(\ln \rho_1 - \ln a, \theta - \theta_0), \quad (47)$$

kde a je mierka, θ_0 je rotácia, ρ_1 je veľkosť vzdialenosti, θ je veľkosť uhlu. Ak opäť nahradíme $\xi = \ln \rho_1$, $c = \ln a$ rovnica má tvar :

$$M_1(\xi, \theta) = M_2(\xi - c, \theta - \theta_0). \quad (48)$$

V spektre obrazu, ktoré vznikne po Fourierovej transformácii sa v strede obrazu nachádzajú nízke frekvencie a po krajoch obrazu vysoké frekvencie. Periodicitou spektra obrazu dochádza ku skresleniu, keď na seba niektoré zložky na okrajoch spektra nemusia nadväzovať a vzniká tak okrajový efekt, ktorý je pre správny výsledok nutné potlačiť. Na potlačenie miest, kde dochádza k okrajovému efektu sa používajú váhové okná. Váhové okná sa aplikujú na obraz $A(x, y)$ po Fourierovej transformácii a môžu mať rôzny tvar. Najviac používané je 2D Hannovo okno definované ako [12]:


$$H(x, y) = \frac{1 + \cos\left(\frac{\pi x}{N_1}\right)}{2} \frac{1 + \cos\left(\frac{\pi y}{N_2}\right)}{2}, \quad (49)$$

kde N_1 a N_2 sú rozmery obrazu $A(x, y)$. Ďalšie váhové okno je 2D Gaussovo okno $W(x, y)$, ktoré je definované ako [12]:

$$W(x, y) = e^{-2\pi^2 \sigma^2 (x^2 + y^2)}, \quad (50)$$

kde σ je smerodajná odchýlka. Fázová korelácia pre rotáciu a škálovanie ďalej využíva prevod z kartézskych súradníc (x, y) do log-polárnych súradníc (ρ, θ) . Využíva sa pre svoju vlastnosť, že škálovanie a rotácia v kartézskych súradniciach zodpovedá translácii v log-polárnych súradniciach [11]. Ľubovoľný bod v polárnych súradniciach je určený svojou vzdialenosťou od počiatku a uhlom. Tento uhol zvierá úsečka, ktorá spája bod a počiatok s osou x . Logaritmom vzdialenosti ρ dostávame log-polárne súradnice. Log-polárna transformácia je definovaná ako konformné zobrazenie kartézskej roviny (x, y) do log-polárnej roviny (ρ, θ) . V polárnych súradniciach je ρ vzdialenosť od stredu obrazu (x_c, y_c) a θ zodpovedá uhlu. Bod kartézskych súradníc (x, y) tak môže byť zobrazený v polárnych súradniciach ako [11] :

$$(\rho, \theta) = \left(\sqrt{(x - x_c)^2 + (y - y_c)^2}, \tan^{-1} \frac{(y - y_c)}{(x - x_c)} \right). \quad (51)$$



Obrázok 1-5 – Prevod z kartézskych do polárnych súradníc, prevzaté a upravené z [11]

Prevod z kartézskych do polárnych súradníc je zobrazený na Obrázok 1-5. Čierne štvoruholníky ukazujú, že jednotlivé pixely sú pod konštantným uhlom od stredu obrazu. Rovnako aj prekrížené štvoruholníky sú v konštantnej vzdialenosti od stredu obrazu. Z toho je možné vyvodit', že rotácia obrazu spôsobí transláciu čiernych štvoruholníkov po osi theta. Podobne to platí aj pre škálovanie, ktoré spôsobí transláciu po osi rho. Polárne súradnice s logaritmickou osou sú definované jako :

$$(r, \theta) = (\log \rho, \theta) . \quad (52)$$

Ak je obraz preškálovaný hodnotou α tak sa jeho kartézske súradnice (x,y) zmenia na $(\alpha x, \alpha y)$. Zavedením logaritmu do polárnych súradníc platí :

$$(\log(\alpha x), \log(\alpha y)) = ((\log \alpha + \log x), (\log \alpha + \log y)) . \quad (53)$$

Účinky zmeny obrazu sú zobrazené trasnláciou na osi ρ a transláciou na osi θ . Ak je originálny obraz posunutý o $(\Delta x, \Delta y)$, tak v log-polárnych súradniciach je zobrazený ako:

$$\rho' = \log \sqrt{(\exp(\rho) \cos \theta - \Delta x)^2 + (\exp(\rho) \sin \theta - \Delta y)^2} , \quad (54)$$

$$\theta' = \arctan \frac{(\exp(\rho) \sin \theta - \Delta y)}{(\exp(\rho) \cos \theta - \Delta x)} . \quad (55)$$

Podľa týchto rovníc miera posunu produkuje zmenu v log-polárnom obraze. Preto log-polárny obraz nezachováva verne posúvne parametre obrazov [13], [14]. Na vyriešenie tohoto problému sa na obraz pred prevodom do log-polárnych súradníc aplikuje Fourierová transformácia a ďalej sa počíta s magnitúdovým spektrom obrazu. Využíva sa to, pretože magnitúdové spektrum referenčného a posunutého obrazu sú rovnaké, ale líšia sa fázovými spektrami.

1.3 Disparitná analýza

Je ďalšou z metód ako zistiť vzájomnú zmenu medzi obrazmi. Je to metóda, ktorá určuje posun medzi zodpovedajúcimi si bodmi v dvoch, alebo viacerých obrazoch rovnakej scény. Definované sú posunutý obraz A a referenčný obraz B . Ich pozičné vektory sú \mathbf{r}_A a \mathbf{r}_B . Vybraným pixelom obrazu sa priradí vektor pohybu. Body sa určujú buď ako významné body obrazu, alebo po uniformnej mriežke. Rozdielový vektor, tiež nazývaný ako disparita $\Delta\mathbf{r} = \mathbf{r}_B - \mathbf{r}_A$ určuje pohyb medzi zodpovedajúcimi si bodmi obrazov. Používajú sa rôzne hustoty výpočtov disparít, od niekoľkých až po všetky pixely obrazu. Na základe tejto hustoty sa potom vytvára disparitná mapa. Príklad takejto disparitnej mapy je na Obrázok 1-6. Ak nie je hustota disparitných výpočtov na vytvorenie mapy veľká, disparitná mapa sa môže vytvoriť aj interpoláciou z menšieho počtu bodov [1]. Nižšie je popísaný výpočet disparitnej mapy pomocou 2D nelineárnych prispôsobených filtrov. Úlohou prispôsobeného filtru je v tomto prípade lokalizácia malého výrezu referenčného obrazu v posunutom obraze. Disparita sa určuje len pre jeden bod uniformnej siete. Z posunutého obrazu sa vyberie malé okolie uzlového bodu mriežky, ktoré reprezentuje vzor. Tento vzor bude ďalej hľadaný v prehľadávacom priestore toho istého uzlového bodu v referenčnom obraze. Určuje sa lokálne podobnostné kritérium pre všetky polohy vzorovej matice v prehľadávanom priestore. Matematickým zápisom to je možné vyjadriť ako [3] :

$$\mathbf{p} = \arg \max_{\mathbf{p}} F(\mathbf{C}_{pp}(\mathbf{p}), \mathbf{B}_v) , \quad (56)$$

kde \mathbf{p} je hľadaný pozičný vektor, $\mathbf{C}_{pp}(\mathbf{p})$ je submatica prehľadavaného priestoru v referenčnom obraze A , ktorý má rovnaké rozmery ako posunutý obraz B . F je podobnostné kritérium, ktoré počíta najväčšiu podobnosť medzi posunutým a referenčným obrazom. Vektor \mathbf{p} vyjadruje disparitu. Výpočet jednej hodnoty podobnostnej mapy pomocou prispôsobených filtrov sa môže vyjadriť vo forme diskkrétnej dvojrozmernej konvolúcie vzorky \mathbf{B}_v posunutého obrazu s prehľadávacím priestorom \mathbf{A}_{pp} referenčného obrazu. Pri viacobjemných dátach sa konvolúcia môže urobiť cez frekvenčnú oblasť, čo výrazne zväčší efektívnosť výpočtu. Pre prispôsobený filter, ktorý vyjadruje lokálnu podobnostnú mapu \mathbf{Y} platí:

$$\mathbf{Y} = \mathbf{H} * \mathbf{A}_{pp} , \quad (57)$$

$$\text{kde} \quad \mathbf{H} = \mathbf{B}_v'' . \quad (58)$$

Ide o konvolúciu masky \mathbf{H} , ktorá vyjadruje impulznú charakteristiku filtra s prehľadávacím priestorom referenčného obrazu \mathbf{A}_{pp} . Ak od matice \mathbf{H} odpočítame priemernú hodnotu \bar{h} , získame rovnicu kovariančného filtra [3] :

$$Y = (H - \bar{h}) * A_{pp}, \quad (59)$$


kde

$$\bar{h} = \frac{1}{mn} \sum_{i=1}^m \sum_{k=1}^n h_{i,k}. \quad (60)$$

V tejto rovnici sú m, n rozmery impulznej charakteristiky. Základné lineárne prispôsobené filtre nepočítajú úplne presné výsledky. Vytvárajú však základ pre nelineárne prispôsobené filtre, ktoré počítajú výsledky oveľa presnejšie. Pomocou týchto filtrov sú počítané lokálne podobnostné mapy, ktoré predstavujú euklidovú vzdialenosť. Výsledok takýchto filtrov Y je možné vyjadriť ako :

$$Y = H * A_{pp} - \frac{P}{2}, \quad (61)$$

kde je od výsledku $H * A_{pp}$ odčítaná matica $P/2$, ktorá vyjadruje výsledok postupnosti operácii umocnenia prvkov matice A_{pp} a konvolúcie s maticou plnou jednotiek, ktorá má rovankú veľkosť ako matica H [3]. Nevýhodou disparitnej analýzy je, že automatické procesy nie sú presné. Chyba vzniká pri použití rôznych typoch obrazov, alebo použitím interpolácie. Výhodou je, že práca s 3D obrazmi nepotrebuje špeciálny prístup ako pri fázovej korelácii.



Obrázok 1-6 – Príklad disparitnej mapy, ktorá zobrazuje posun pixelov posunutého obrazu oproti referenčnému obrazu, prevzaté a upravené z [3]


2 Návrh vlastnej metódy

Ešte pred samotným procesom registrácie je nutné si pozrieť parametre registračného procesu. V prvom rade je to typ registrovaného obrazu. Ďalej je nutné zvážiť, či sa preferuje rýchlosť, alebo kvalita dosiahnutého výsledku. Niektoré metódy sú pomalšie, ale dosahujú kvalitnejšie a presnejšie výsledky. Keďže sa práca zaoberá predregistráciu CT objemových obrazov, tak je nutné čo najrýchlejšie zarovnanie mono modálnych objemových dát. Z registračných metód sú preto použiteľné tie, ktoré nekladú dôraz na dosiahnutú presnosť, ale hlavne na rýchlosť procesu. Jednotlivé registračné metódy boli vyskúšané na programoch ELASTIX [15] a IMARE [16]. V práci sú popísané dve metódy, ktoré slúžia na lícovanie obrazov a to disparitná analýza a fázová korelácia. Pri vypracovávaní algoritmu na predregistráciu bola zvolená metóda fázovej korelácie, hlavne pre jej rýchlosť, ktorá je pri predregistračnom procese kľúčová.

Pri registrácii reálnych dát sa postupuje následovne. Najprv sa zvolí referenčný a posunutý obraz, pre ktorý budú počítané transformácie. Pre posunutý obraz sa počíta faktor škálovania. Po škálovaní nasleduje výpočet rotácie. Výsledný obraz má síce správnu mierku a uhol, avšak často sa medzi referenčným a posunutým obrazom vyskytuje ešte translácia. Vzniká to práve pri spätnom preškálovaní a rotácii posunutého obrazu. Preto sa ako posledná počíta translácia medzi porovnávanými obrazmi. Existujú rôzne prístupy k nájdeniu registrovaného obrazu pomocou fázovej korelácie. Napríklad posunutý obraz sa najprv preškáluje a posunie tak, aby bol mierkou podobný referenčnému obrazu. Následne sa opäť počíta škálovanie a translácia posunutého obrazu, až kým sa škálovanie medzi porovnávanými obrazmi už nedá detekovať. Až po tomto procese sa prechádza k výpočtu rotácie, kedy sa opäť posunutý obraz spätne rotuje a posúva až do vtedy, kým rotácia medzi referenčným a posunutým obrazom nie je detekovateľná. Následne sa ešte dopočíta posledná translácia medzi obrazmi a na posunutý obraz sa aplikuje translácia podľa vypočítaných hodnôt. Výstupný obraz tohoto procesu je registrovaný obraz. Druhý prístup nájdenia referenčného obrazu najprv počíta výpočet škálovania medzi referenčným a posunutým obrazom. Výstupný obraz po spätnom preškálovaní vstupuje do výpočtu rotácie, a tento výstup po spätnej rotácii následne vstupuje do výpočtu translácie. Pre obraz, ktorý už prešiel spätnými transformáciami sa po tomto procese opäť počíta škálovanie, rotácia a translácia v zadanom poradí. Tento cyklus prebieha až do vtedy, kým sa už nedá detekovať zmena mierky, rotácia a posun medzi referenčným a posunutým obrazom, alebo je dosiahnutá dostačujúca hodnota podobnostného kritéria. V práci sa uplatňuje druhý prístup.


Keďže reálne dáta boli 3D, teda v troch dimenziách (x,y,z), fázová korelácia nemohla využiť posúvne vlastnosti spektra ako 2D dáta. Rotácia a škálovanie sa v 3D

originálnom obraze neprejavia transláciou v log-polárnom spektre. Problém je vyriešený rozkladom 3D obrazu na jednotlivé 2D rezy, ktoré sú usporiadané za sebou. Zobrazuje to Obrázok 2-1. Takto sa značne znížila výpočetná náročnosť algoritmu, keďže algoritmus využíva interpoláciu a koreláciu, ktoré sú omnoho menej výpočetne náročné pre 2D obrazy, ako pre 3D obrazy. Pri výpočte celočíselnej translácie medzi referenčným a posunutým obrazom sa nevyužíva interpolácia, takže celý proces prebieha v 3D. Rozklad na 2D dáta je teda použitý pri výpočte hodnôt škálovania a rotácie.



Obrázok 2-1 - Rozklad 3D dát na 2D rezy. Prevzaté a upravené z [17]

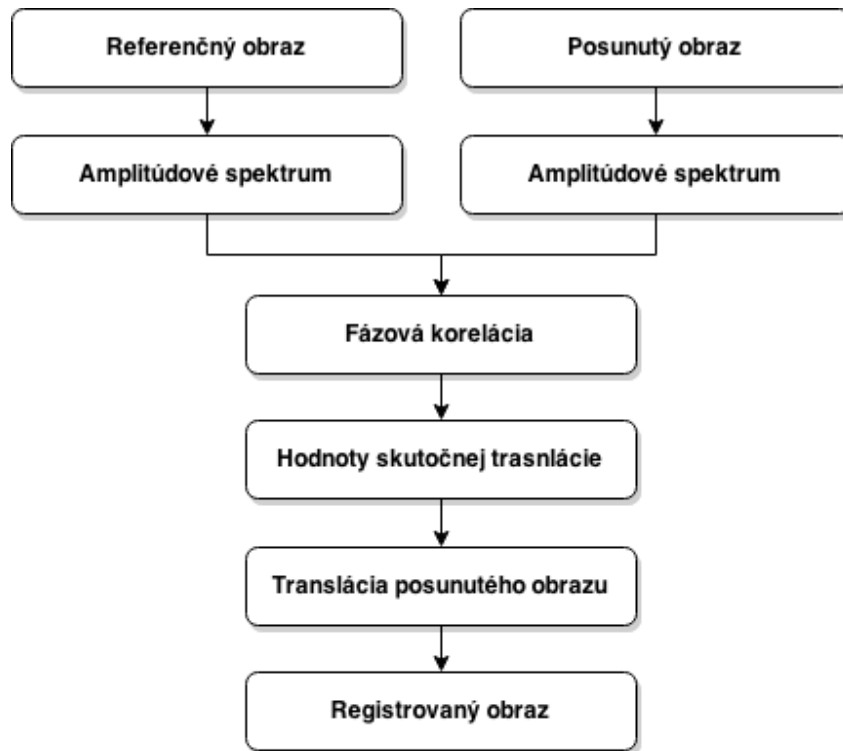
Prevod obrazu do log-polárnych súradníc je ďalšou časťou algoritmu. Najprv sa definuje logaritmický priestor podľa parametrov vstupného obrazu. Ďalej sa definuje uhol od 0° do 360° s určitým krokom. Čím je tento krok menší tým je obraz lepšie navzorkovaný, avšak výpočet trvá dlhšie. Aj najmenší krok je však obmedzený šírkou pixelu. Do takto definovaného logaritmického priestoru sú vypočítané odpovedajúce kartézské súradnice obrazu. Keďže niektoré pixely sa pri prevode prekryli, alebo vynechali, je nutné použitie niektorej z interpolačných metód na ich dopočítanie. V tomto prípade je použitá bilinéarna interpolácia hlavne pre dobrý pomer medzi rýchlosťou a presnosťou interpolácie. Obraz v kartézskych súradniciach, ktorý prešiel daným procesom prevodu z kartézskych súradníc do log-polárnych súradníc je zobrazený na Obrázok 2-2. Keďže navrhnutá metóda prevodu kartézskych súradníc do polárnych nebola ani po upravách dostatočne rýchla, čo je hlavná požiadavka predregistračnej metódy, práca využíva prevod z kartézskych do polárnych súradníc z [18]. K dispozícii je aj navrhnutá pomalšia, avšak v niektorých prípadoch presnejšia metóda prevodu.



Obrázok 2-2 – Obrázok A zobrazuje obraz v kartézskych súradniciach a obrázok B zobrazuje obrázok A v log-polárnych súradniciach

Navrhnutý algoritmus, ktorý pracuje s reálnymi obrazovými dátami objemových CT snímkov rieši nasledovné geometrické transformácie:

Translácia – na začiatku sa na referenčný a posunutý obraz aplikuje Fourierová transformácia. Získajú sa tak amplitúdové spektrá obrazov, ktoré medzi sebou korelujeme podľa vzorca pre fázovú koreláciu (32). Týmto procesom sa získa jedno spektrum s informáciami z oboch obrazov. Následne sa na toto spektrum aplikuje spätná Fourierová transformácia. Z reálnej časti výsledného spektra, sa určuje maximálna hodnota. Poloha maxima $[x,y,z]$ nám naznačuje veľkosť translácie v smere osi x, osi y a osi z. Tieto hodnoty ešte nemusia zodpovedať skutočnej translácii medzi obrazmi. Zistí sa to porovnaním hodnoty nájdennej translácie v daných osách x,y,z s odpovedajúcimi si rozmermi spektra obrazu v osách x,y,z, z ktorého sa určovalo maximum. Ak je hodnota nájdennej translácie z maxima v ose x menšia ako polovica spektra obrazu, z ktorého sa určilo maximum, tak hodnota tejto translácie je už skutočná translácia. Ak je však väčšia, alebo rovná, tak skutočná translácia je vypočítaná ako podiel rozmeru spektra obrazu, z ktorého sme určovali maximum a hodnoty nájdennej translácie. Tento výpočet prebehne pre smery x,y,z a slúži na určenie správneho smeru translácie. Po zistení hodnôt skutočnej translácie, sa aplikuje na posunutý obraz geometrická transformácia s vypočítanými skutočnými hodnotami translácie v ose x, ose y a ose z. Po tomto procese, ktorého blokové schéma je zobrazená na Obrázok 2-3 sú posunutý a referenčný obraz v prípade celočíselnej translácie úplne identické.



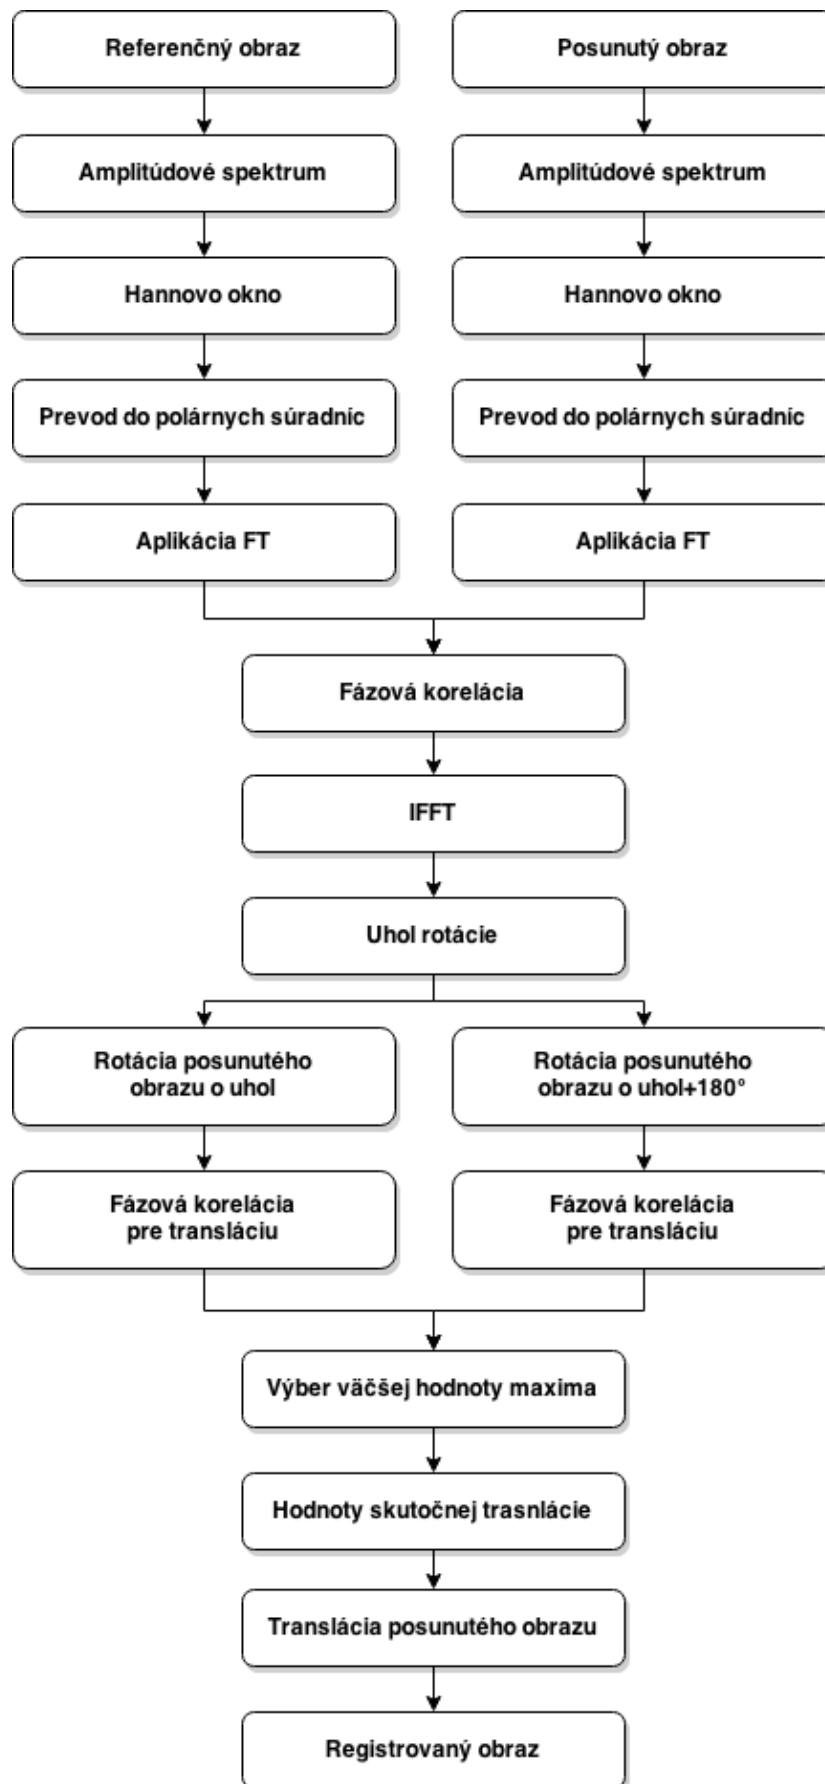
Obrázok 2-3 – Blokové schéma algoritmu fázovej korelácie pre transláciu.

Rotácia – na referenčný a posunutý obraz sa aplikuje Fourierová transformácia. Takto získané spektrá sa vynásobia Hannovým oknom, ktoré potláča miesta v spektre, kde dochádza k okrajovému efektu. Tieto spektrá referenčného a posunutého obrazu sú ďalej prevedené do polárnych súradníc. Na obidva spektrá v polárnych súradniciach sa aplikuje Fourierová transformácia. Následne sa spektrá korelujú podľa vzorca pre fázovú koreláciu (32). Z dvoch obrazov tak vzniká jedno spektrum, ktoré obsahuje informáciu o rotácii posunutého obrazu oproti referenčnému. Na výsledné spektrum sa aplikuje spätná Fourierová transformácia. Hodnota maxima sa určuje z reálnej časti tohoto spektra. Rotácia sa v polárnych súradniciach prejaví ako posun spektra posunutého obrazu oproti referenčnému. Uhol rotácie je získaný z ypsilonovej súradnice maxima a je vypočítaný ako:

$$uhol = a \cdot y, \quad (62)$$

kde a je počet stupňov na pixel v spektre obrazu, z ktorého určujeme maximum a y je ypsilonová hodnota maxima. Aby sa registroval posunutý obraz podľa referenčného obrazu, tak posunutý obraz sa musí rotovať o zápornú hodnotu vypočítaného uhla. Týmto spôsobom však získame len hodnotu uhla rotácie. Ďalej potrebujeme zistiť smer, v ktorom posunutý obraz treba rotovať. Posunutý obraz je preto rotovaný o zápornú hodnotu $uhol$ a tiež aj o zápornú hodnotu $uhol+180^\circ$. Pri procese je použitá interpolácia

NN. Vzniknuté dva obrazy sú rovnaké, avšak jeden je rotovaný oproti druhému o 180 stupňov. Pri porovnaní týchto obrazov s referenčným obrazom je detekovateľná ešte vzájomná translácia. Preto sa využije znalosť fázovej korelácie pre transláciu a obrazy sa posunú tak, aby sa zarovnali podľa referenčného obrazu. Po fázovej korelácii pre transláciu tak je známa jedna hodnota maxima pre obraz rotovaný o zápornú hodnotu u_{hol} a jedna hodnota maxima aj pre obraz rotovaný o zápornú hodnotu $u_{hol}+180^\circ$. Pre výpočet hľadanej translácie sa vyberá hodnota maxima toho obrazu, ktorá je väčšia. Na základe pozície zvoleného maxima sa posunie rotovaný obraz v ose x a v ose y. Výsledný registrovaný obraz tak už nie je rotovaný oproti referenčnému obrazu. Blokovaná schéma procesu je zobrazená na Obrázok 2-4.

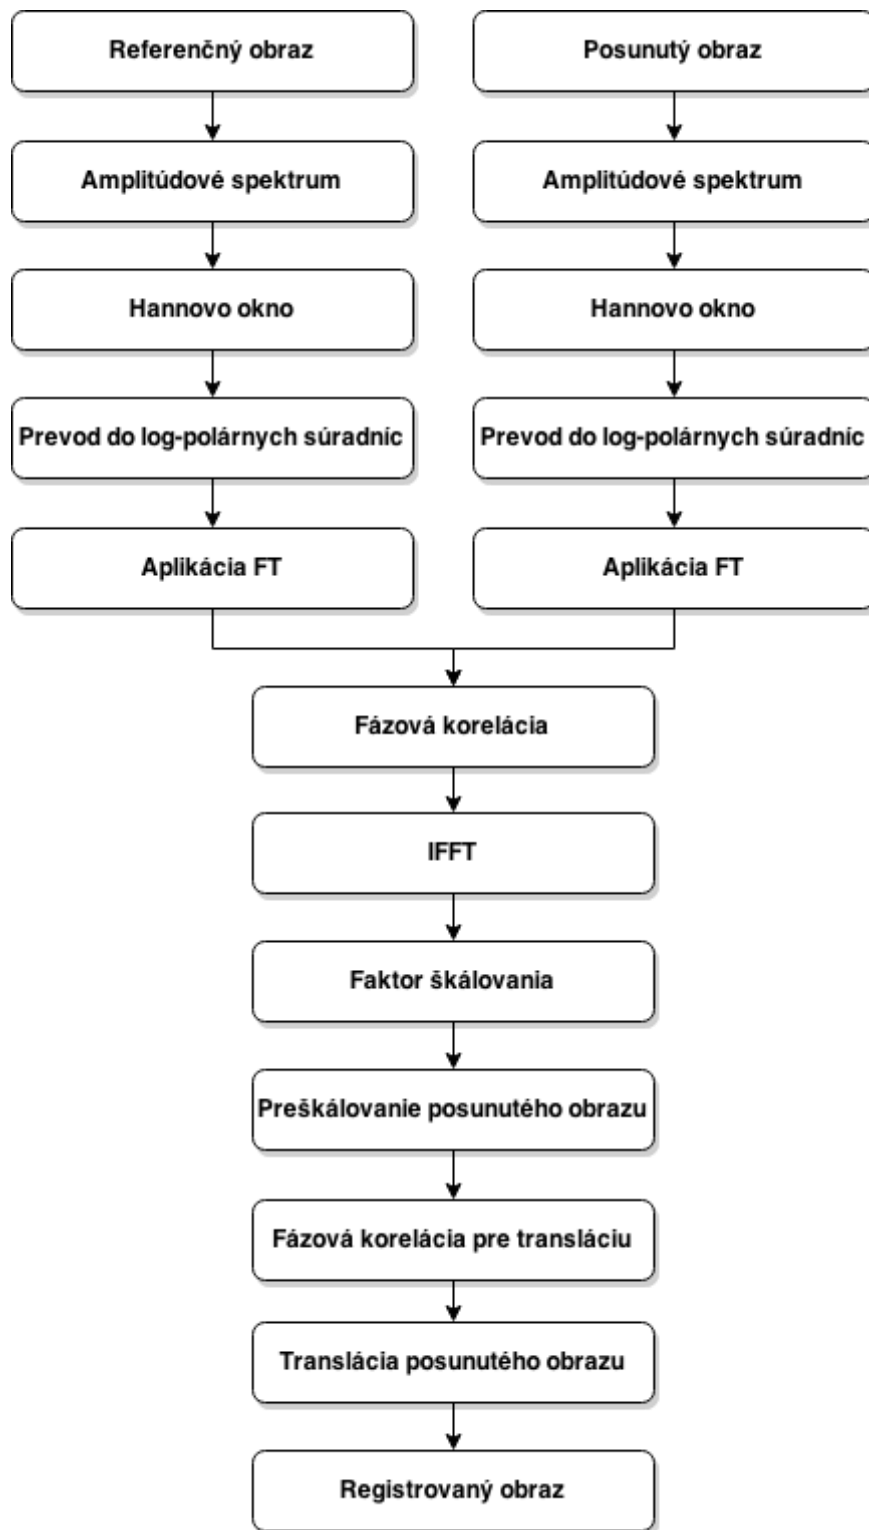


Obrázok 2-4 – Bloková schéma algoritmu fázovej korelácie pre rotáciu.

Škálovanie – na referenčný a posunutý obraz sa aplikuje Fourierová transformácia. Získajú sa tak spektrá týchto obrazov. Tieto spektrá sú vynásobené Hannovým oknom, ktoré potláča miesta v spektre, kde dochádza k okrajovému efektu. Následne sú spektrá prevedené do polárnych súradníc s logaritmickou osou. Na spektrá sa opäť aplikuje Fourierová transformácia a spektrá sa korelujú podľa vzorca pre fázovú koreláciu (32). Na toto spektrum sa potom aplikuje spätná Fourierová transformácia. Získané spektrum obsahuje informácie o veľkosti škálovania posunutého obrazu. Hodnota škálovania je vypočítaná z hodnoty maxima hodnôt v tomto spektre. Z polohy maxima sa hodnota škálovania s počíta ako :

$$s = e^x , \quad (63)$$

kde e je základ prirodzeného logaritmu a x je x -ová súradnica polohy maxima. Ďalej sa z hodnoty škálovania určuje faktor škálovania, ktorý určuje či ide o zmenšenie, alebo zväčšenie. Faktor škálovania je už hodnota, o ktorú treba preškálovať posunutý obraz podľa vypočítanej hodnoty v osách x,y . Pri preškálovaní je použitá bilinéarna interpolácia. Medzi referenčným obrazom a obrazom po preškálovaní je však ešte detekovateľná vzájomná translácia. Tá je odstránená už známou metódou fázovej korelácie pre transláciu. Výsledný obraz je registrovaný a podobá sa referenčnému obrazu. Blokova schéma procesu je zobrazená na Obrázok 2-5.



Obrázok 2-5 – Blokovaná schéma algoritmu fázovej korelácie pre škálovanie.

Spojenie translácie, rotácie a škálovania – ak posunutý obraz obsahuje tieto geometrické transformácie postup pri registrácii je nasledovný. Algoritmus v prvej fáze rozloží 3D obraz na 2D rezy snímkov CT, ktoré sú usporiadané za sebou. Tie sa

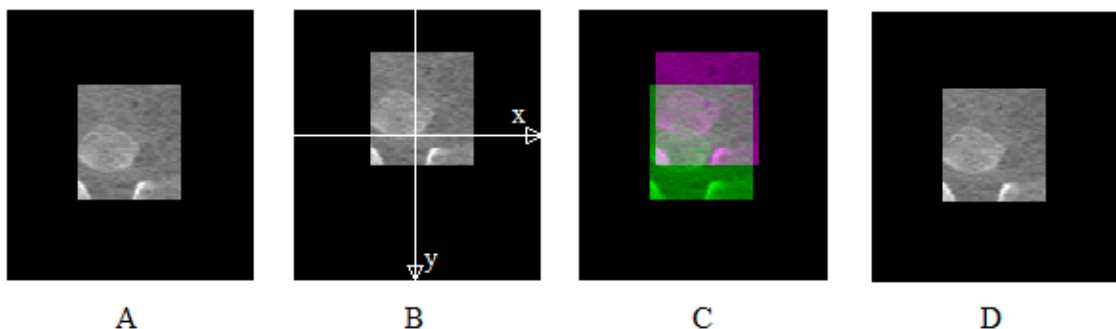
prechádzajú v cykloch a počíta sa škálovanie a rotácia. Do algoritmu vstupujú obrazy pri poradií dimenzií (x,y,z) v referenčnom a posunutom obraze. Následne sa vylúčia nezmyselné hodnoty škálovania a rotácie, ktoré vznikli pri porovnávaní obrazov, z ktorých jeden obsahuje len nuly. Tieto hodnoty by inak skresľovali výpočty. Výsledné hodnoty škálovania a rotácie sa určia ako medián zo všetkých rezov. Najprv sa teda vypočíta rotácia a škálovanie v 2D priestore (x,y) . Zanedbáva sa výpočet rotácie a škálovania v osi z . Preto sa po registrácii škálovania a rotácie posunutého obrazu v priestore (x,y) v ďalšom kroku preskupia dimenzie v referenčnom obraze a obraze posunutom, ktorý je už registrovaný v (x,y) na (z,y,x) a počítajú sa hodnoty škálovania a rotácie v 2D priestore (z,y) . Po registrácii posunutého obrazu v priestore (z,y) sa dimenzie referenčného obrazu a obrazu posunutého, ktorý je registrovaný v (x,y) a (z,y) opäť preskupia na (x,z,y) . Vypočítajú sa hodnoty škálovania a rotácie v priestore (x,z) a výsledný obraz je už registrovaný vo všetkých dimenziách, ako pre škálovanie, tak aj pre rotáciu. Obrazové dimenzie sú ďalej preskupené do pôvodného stavu (x,y,z) a na referenčný a posunutý obraz sa ešte aplikuje 3D fázová korelácia pre transláciu, ktorá zarovná poslednú detekovateľnú transláciu. Narozdiel od výpočtu samotného škálovania, alebo rotácie sa fázová korelácia pre transláciu nepoužíva pri rozklade v 2D rezoch, ale aplikuje sa až na obraz po spätnom škálovaní a spätnej rotácii. Výsledný obraz je registrovaný 3D obraz podľa referenčného 3D obrazu.

3 Dosiahnuté výsledky

Pre menšiu výpočetnú náročnosť je použitý výrez z reálnych dát o veľkosti 50x50x31. Tento výrez je vložený do matice núl, aby sa pri transformáciách neposunul mimo okna zobrazenia. Výsledný obraz s čiernym okrajom tak má veľkosť 120x120x31.

3.1 Obrazy bez simulovaného šumu

Translácia

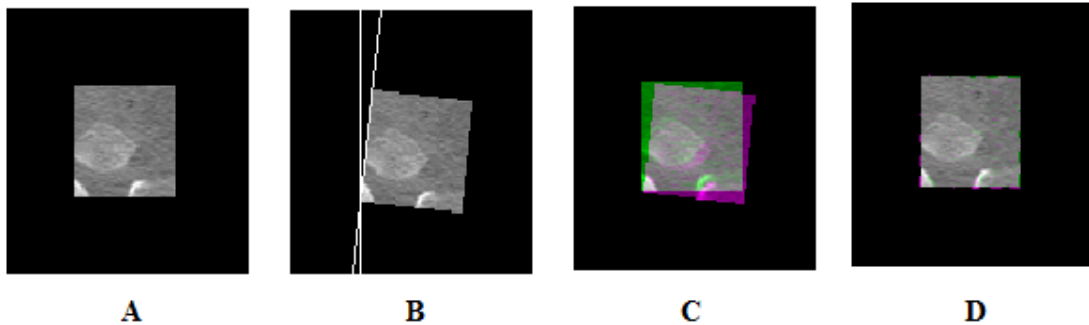


Obrázok 3-1 – Výsledky fázovej korelácie pre transláciu. Obrázok A je rez referenčným obrazom. Obrázok B je rez posunutým obrazom. Obrázok C zobrazuje fúziu rezov referenčného a posunutého obrazu pred registráciou a obrázok D zobrazuje fúziu rezov referenčného a registrovaného obrazu.

Na Obrázok 3-1 je zobrazená práca fázovej korelácie pre transláciu. Obrázok A zobrazuje rez referenčným obrazom. Obrázok B je rez posunutým obrazom, na ktorý bola aplikovaná translácia s hodnotami posunu 3 pixely v osi x a -15 pixelov v osi y. Osi x a y sú zaznačené v obrázku B bielou farbou. Obrázok C zobrazuje fúziu rezov referenčného a posunutého obrazu pred aplikovaním fázovej korelácie. Obrázok D zobrazuje fúziu rezov referenčného a registrovaného obrazu po fázovej koreláci. Z obrázku je viditeľné, že rezy sa úplne prekrývajú, čo dokazuje aj výpočet euklidovej vzdialenosti medzi referenčným a registrovaným obrazom. Pred vstupom do algoritmu bola euklidova vzdialenosť medzi referenčným a posunutým obrazom 0,347 a kosínové kritérium 0,9783. Po výstupe z algoritmu vyšla euklidova vzdialenosť 0 a hodnota kosínového kritéria medzi porovnávanými obrazmi 1. Podobnosť medzi referenčným a posunutým obrazom sa po výstupe z algoritmu zvýšila na maximum. Pri výpočte závislosti podobnostných kritérií medzi referenčným a registrovaným obrazom na zvyšujúcich sa hodnotách posunu referenčného obrazu mala euklidova vzdialenosť konštantnú hodnotu 0 a kosínové kritérium malo konštantnú hodnotu 1, čo znamená, že fázová korelácia pre


transláciu pracuje výborne ako pre malé celočíselné posuny, tak aj pre veľké celočíselné posuny medzi referenčným a posunutým obrazom.

Rotácia



Obrázok 3-2 – Výsledky fázovej korelácie pre rotáciu. Obrázok A je rez referenčným obrazom. Obrázok B je rez posunutým obrazom. Obrázok C je fúzia rezov referenčného a posunutého obrazu a obrázok D zobrazuje fúziu rezov referenčného a registrovaného obrazu.

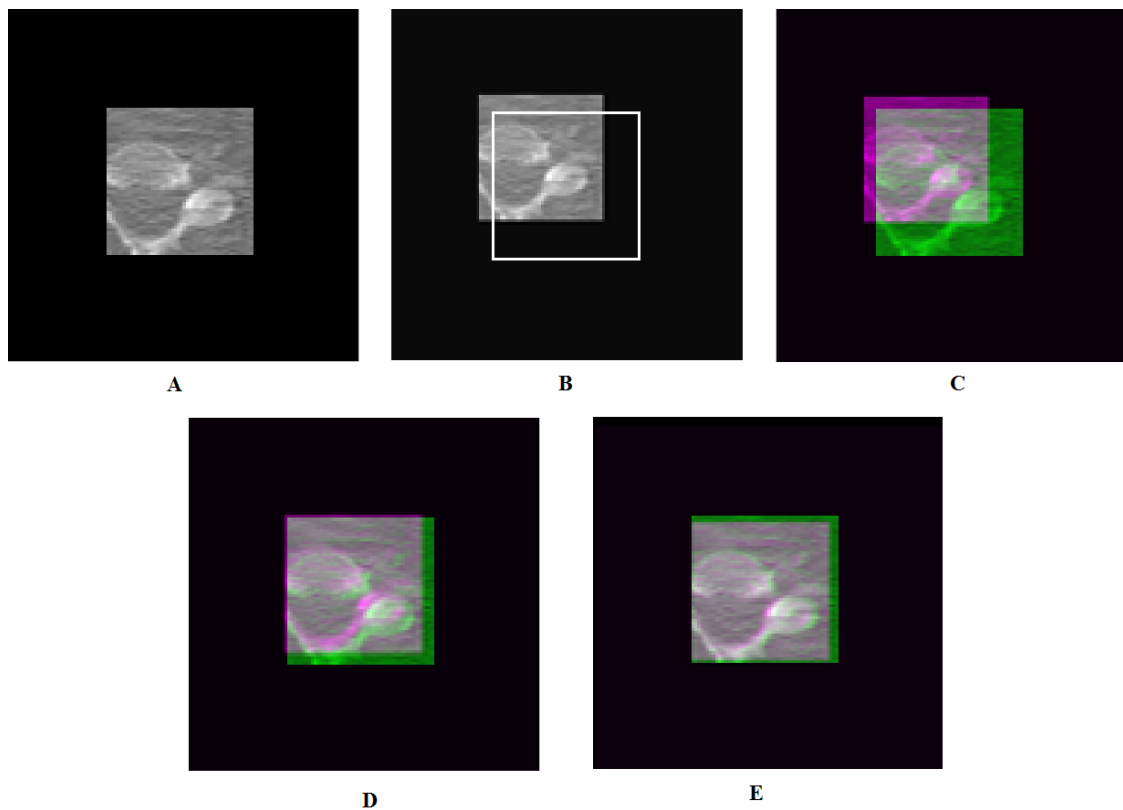
Na Obrázok 3-2 je zobrazená práca fázovej korelácie pre rotáciu. Na obrázku A je rez referenčným obrazom. Obrázok B je rez posunutým obrazom. Je to obraz referenčný, ktorý je rotovaný o 6° okolo ľavého spodného rohu výrezu reálnych dát. Obrázok C zobrazuje fúziu rezov referenčného a posunutého obrazu pred aplikovaním fázovej korelácie pre rotáciu. Obrázok D zobrazuje fúziu rezov referenčného a registrovaného obrazu po aplikovaní fázovej korelácie. Na hranách výrezu je možné pozorovať niekoľko nezarovnaných pixelov. Tieto nedokonalé zarovnané pixely vznikli chybou použitej interpolácie, keďže algoritmus detekoval správnu veľkosť uhla medzi referenčným a posunutým obrazom. Chyba interpolácie vzniká, pri dopočítavaní hodnoty intenzity celého pixelu aj pri zasiahnutí len malého kúsku tohoto pixelu. Obrazy sa teda prekrývajú, ale nie úplne. Pred vstupom do algoritmu bola euklidova vzdialenosť medzi referenčným a posunutým obrazom 0,3 a kosínové kritérium 0,969. Po výstupe z algoritmu sa euklidova vzdialenosť medzi referenčným a registrovaným obrazom znížila na 0,000631 a kosínové kritérium sa zvýšilo na 0,993. Podobnosť medzi porovnávanými obrazmi sa teda nezvýšila na maximum, ale algoritmus fázovej korelácie pre rotáciu túto podobnosť značne sa zvýšil.



Obrázok 3-3 – Grafy závislosti podobnostných kritérií medzi referenčným a registrovaným obrazom na zvyšovaní hodnoty rotácie referenčného obrazu.

Obrázok 3-3 A zobrazuje graf závislostí euklidovej vzdialenosti medzi referenčným a registrovaným obrazom na hodnotách rotácie referenčného obrazu. Rotáciou referenčného obrazu vznikol obraz posunutý. Z grafu je možné určiť, že euklidová vzdialenosť najprv stúpa (podobnosť medzi porovnávanými obrazmi sa znižuje) až k hodnotám rotácie 45° a potom klesá (podobnosť medzi porovnávanými obrazmi sa zvyšuje), až k hodnotám rotácie 90° . Závislosť sa periodicky opakuje. Najviac sú porovnávané obrazy podobné na začiatku pri malých uhloch a potom na konci pri blížení sa ku 360° . Tieto namerané výsledky odpovedajú aj Obrázku B, ktorý zobrazuje závislosť kosínového kritéria medzi referenčným a registrovaným obrazom na stúpajúcich hodnotách rotácie referenčného obrazu. Podobnosť klesá k hodnotám 45° a potom stúpa k 90° , čo sa periodicky opakuje. Najviac sú porovnávané obrazy podobné na začiatku pri malých uhloch a potom na konci pri blížení sa ku 360° . To zodpovedá tomu, že chyba interpolácie je najväčšia pri rotácií 45° a fázová korelácia pre rotáciu má najlepšie výsledky pri rotácii s malými hodnotami uhla. Na smere rotácie nezáleží. Schodovitosť kriviek je spôsobená tým, že výpočty prebiehali s krokom $0,5^\circ$.


Škálovanie



Obrázok 3-4 – Výsledky fázovej korelácie pre škálovanie. Obrázok A je rez referenčným obrazom. Obrázok B je rez posunutým obrazom, biely štvorec zobrazuje veľkosť výrezu referenčného obrazu. Obrázok C je fúzia rezov referenčného a posunutého obrazu pred vstupom do algoritmu. Obrázok D je fúzia rezov referenčného a spätne preškálovaného posunutého obrazu. Obrázok E je fúzia rezov referenčného a registrovaného posunutého obrazu.

Na Obrázok 3-4 je zobrazená práca algoritmu fázovej korelácie pre škálovanie. Obrázok A je rez referenčným obrazom. Obrázok B je rez obrazom posunutým. Posunutý obraz vznikol zmenšením referenčného obrazu. Tento obraz je preškálovaný s hodnotou 0,85. Biely štvorec v tomto obrázku zobrazuje pre lepšiu predstavivosť polohu výrezu referenčného obrazu. Obrázok C zobrazuje fúziu rezov referenčného a posunutého obrazu pred vstupom do algoritmu. Obrázok D zobrazuje fúziu rezov referenčného a posunutého obrazu, ktorý bol spätne preškálovaný. Z obrázku D je vidno, že tieto obrázky sú ešte vzájomne posunuté. Obrázok E zobrazuje fúziu rezov referenčného a registrovaného obrazu. Z obrázku E je vidno, že obrázok nebol správne spätne preškálovaný. Pri porovnávaní podobnosti je však badateľné, že podobnosť medzi referenčným a posunutým obrazom sa zvýšila. Toto zlepšenie môžeme dokázať opticky pri porovnaní obrázkov C a D a tiež to dokazujú aj hodnoty podobnostných kritérií. Pred vstupom do algoritmu bola euklidovú vzdialenosť medzi referenčným a posunutým obrazom 0,981

a kosínové kritérium 0,827. Po výstupe z algoritmu sa podobnosť medzi referenčným a registrovaným obrazom zvýšila s hodnotami euklidovej vzdialenosti 0,434 a kosínového kritéria 0,9725.




Obrázok 3-5 – Grafy závislosti podobnostných kritérií medzi referenčným a registrovaným obrazom na zmenách hodnôt škálovania referenčného obrazu.

Graf na Obrázok 3-5 A zobrazuje závislosť euklidovej vzdialenosti na zmenách hodnoty škálovania, ako v znižujúcom smere, tak aj v zvyšujúcom smere. Z grafu je možné určiť, že čím je hodnota škálovania vzdialenejšia od 1, podobnosť medzi referenčným a registrovaným obrazom klesá. To znamená, že algoritmus dosahuje lepšie výsledky pri nižších hodnotách detekovateľného škálovania medzi referenčným a posunutým obrazom ako pri vyšších hodnotách škálovania. To potvrdzuje aj Obrázok B, ktorý zobrazuje závislosť kosínového kritéria na zmenách hodnôt škálovania.


3.2 Obrazy so simulovaným šumom

Translácia



Obrázok 3-6 – Výsledky fázovej korelácie pre trasnláciu so simulovaným šumom. Obrázok A zobrazuje fúziu rezov referenčného a posunutého obrazu, na ktorý bola aplikovaná translácia s hodnotami $x=3$ pixely a $y=-15$ pixelov. Taktiež bol pridaný gaussov šum so strednou hodnotou 0 a rozptylom 0,4. Obrázok B zobrazuje fúziu rezov referenčného a registrovaného obrazu.


Obrázok 3-6 zobrazuje prácu fázovej korelácie pre trasnláciu pri zašumených obrazoch. Obrázok A je fúzia rezov referenčného a posunutého obrazu spolu s gaussovým šumom so strednou hodnotou 0 a rozptylom 0,4 pred vstupom do algoritmu a Obrázok B zobrazuje fúziu rezov referenčného a registrovaného obrazu po výstupe z algoritmu. Z výsledkov je viditeľné, že algoritmus dokázal registrovať aj obraz s gaussovým šumom so strednou hodnotou 0 a rozptylom 0,4. To dokazujú aj hodnoty podobnosti euklidovej vzdialenosti, ktorá bola pred vstupom do algoritmu 26,37 a kosínové kritérium 0,6606 a po výstupe z algoritmu sa podobnosť medzi referenčným a registrovaným obrazom zvýšila s hodnotami euklidovej vzdialenosti 16,9 a kosínového kritéria 0,9407. Podobnosť medzi zašumenými obrazmi je lepšie viditeľná z kosínového kritéria, ktoré je odolné voči lineárnym zmenám kontrastu. Podobnosť nie je maximálna, pretože každý obraz obsahuje iný šum.



Obrázok 3-7- Graf zobrazuje závislosť počtu chybne posunutých pixelov medzi referenčným a registrovaným obrazom na rozptyle simulovaného gaussovho šumu so strednou hodnotou 0.


Graf na Obrázok 3-7 uvádza závislosť priemerného počtu chybne posunutých pixelov na rozptyle gaussovho šumu so strednou hodnotou 0. Z grafu je možné určiť, že prvýkrát sa chybovosť priemerného posunu pixelov prejavila až za hodnotou rozptylu šumu 0,4. Ďalej sa so stúpajúcim rozptylom šumu v obraze zvyšuje aj počet chybne posunutých pixelov medzi referenčným a registrovaným obrazom. Od hodnoty rozptylu 1,4 sa už chybovosť prejavovala pri každom spustení algoritmu a priemerný počet posunutých pixelov závisel už na náhode, keďže išlo o zašumenie obrazu náhodne generovaným gaussovým šumom.

Rotácia



Obrázok 3-8 - Výsledky fázovej korelácie pre rotáciu so simulovaným šumom. Obrázok A zobrazuje fúziu rezov referenčného a obrazu rotovaného o 6 stupňov, ktorý je zašumený gaussovým šumom so strednou hodnotou 0 a rozptylom 0,02. Obrázok B zobrazuje fúziu rezov referenčného obrazu a posunutého obrazu, ktorý je spätne rotovaný. Obrázok C zobrazuje fúziu rezov referenčného a registrovaného obrazu s gaussovým šumom.


Obrázok 3-8 zobrazuje výsledky algoritmu fázovej korelácie pre rotáciu spolu s gaussovým šumom so strednou hodnotou 0 a rozptylom 0,02. Algoritmus v prvej fáze detekuje rotáciu medzi referenčným a posunutým obrazom. Následne rotuje posunutý obraz o zápornú hodnotu uhla, ktorý našiel medzi referenčným a posunutým obrazom. Výsledné obrazy sú však voči sebe ešte posunuté. Preto sa ešte použije fázová korelácia pre trasnláciu, ktorá tento posun zarovná. Pred vstupom do algoritmu bolo kosínové kritérium medzi referenčným a posunutým obrazom 0,872 a euklidová vzdialenosť 17,68. Po spätnej rotácii boli hodnoty pre kosínové kritérium 0,923 a euklidová vzdialenosť 13,23. Podobnosť medzi referenčným a registrovaným obrazom bola pre kosínové kritérium 0,958 a euklidová vzdialenosť 11,39. Z týchto hodnôt, ako aj z Obrázok 3-8 je možné určiť, že registrovaný obraz po výstupe algoritmu fázovej korelácie pre rotáciu je viac podobný s referenčným obrazom, ako posunutý obraz pred vstupom do algoritmu. Potvrdilo sa, že algoritmus fázovej korelácie funguje aj pri zašumení obrazu gaussovým šumom so strednou hodnotou 0 a rozptylom 0,02.



Obrázok 3-9 – Graf zobrazuje závislosť priemerného počtu chybné detekovaných stupňov na zvyšovaní rozptylu simulovaného šumu so strednou hodnotou 0. Hodnota rotácie 6°, 12° a 18°.


Graf na Obrázok 3-9 zobrazuje závislosť priemerného počtu chybné detekovaných stupňov rotácie na zvyšovaní rozptylu šumu so strednou hodnotou 0. Posunutý obraz vznikol rotovaním referenčného obrazu o 6° - modrá čiara, o 12° - zelená čiara a 18° - červená čiara. Z grafu je možné určiť, že prvé chybné detekované hodnoty rotácie pre uhol 6° sa vyskytli až za hodnotou 0,015 rozptylu šumu. Pre uhol rotácie 12° sa prvé chybné detekované hodnoty rotácie vyskytli za hodnotou 0,005 rozptylu šumu a pri uhle 18° za hodnotou 0,004 rozptylu šumu. Z týchto hodnôt, ako aj z grafu je možné vyvodit', že čím je väčšia hodnota rotácie pri vytvorení posunutého obrazu, tým je metóda fázovej korelácie pre rotáciu menej účinná pri pôsobení gaussového šumu so strednou hodnotou 0. Tvrdenie z Obrázok 3-3, že so vzrastajúcim uhlom rotácie sa zvyšuje chybovosť algoritmu sa potvrdilo aj pri simulovanom zašumení. Skoky v každom z priebehov sú spôsobené tým, že pri vyšších pôsobeniach rozptylu šumu už algoritmus chybné detekoval stupne rotácie pri každom spustení a presná hodnota takto chybné detekovaných stupňov bola závislá na náhode, keďže obraz bol zašumený náhodným gaussovým šumom so strednou hodnotou 0.

Škálovanie



Obrázok 3-10 – Výsledky fázovej korelácie pre škálovanie so simulovaným šumom. Obrázok A zobrazuje fúziu referenčného a posunutého obrazu, ktorý je zmenšený s hodnotou škálovania 0,085 a je zašumeným gaussovým šumom so strednou hodnotou 0 a rozptylom 0.004. Obrázok B zobrazuje fúziu referenčného a spätne preškálovaného posunutého obrazu. Obrázok C zobrazuje fúziu referenčného a registrovaného obrazu.

Na Obrázok 3-10 je zobrazená práca fázovej korelácie pre škálovanie spolu s gaussovým šumom so strednou hodnotou 0 a rozptylom 0.004. Obrázok A zobrazuje fúziu referenčného a posunutého obrazu pred vstupom do algoritmu. Algoritmus v prvej fáze detekuje rotáciu medzi referenčným a posunutým obrazom. Následne spätne preškáluje posunutý obraz o faktor škálovania, ktorý našiel medzi referenčným a posunutým obrazom. Obrázok B zobrazuje fúziu referenčného a spätne preškálovaného obrazu. Medzi porovnávanými obrazmi je ešte detekovateľná trasnlácia. Preto sa použije fázová korelácia pre trasnláciu, ktorá tento posun zarovná. Obrázok C zobrazuje fúziu referenčného a registrovaného obrazu. Z tohoto obrázku je viditeľné, že posunutý obraz nebol správne preškálovaný. Euklidova vzdialenosť medzi referenčným a posunutým obrazom bola pred vstupom do algoritmu 17,732 a kosínové kritérium 0,8338. Po spätnom preškálovaní sa podobnosť medzi obrazmi zvýšila s hodnotami euklidovej vzdialenosti 11,46 a kosínového kritéria 0,9318. Aj napriek tomu, že posunutý obraz nebol správne preškálovaný algoritmus zvýšil podobnosť medzi porovnávanými obrazmi. Po výstupe z algoritmu sa podobnosť opäť zvýšila s hodnotami podobnosti medzi referenčným a registrovaným obrazom pre euklidovú vzdialenosť 11,031 a pre kosínové kritérium 0,9611.




Obrázok 3-11 – Graf zobrazuje závislosť chyby detekovaného faktoru škálovania na zvyšujúcich sa hodnotách simulovaného gaussovho šumu so strednou hodnotou 0.

Graf na Obrázok 3-11 zobrazuje závislosť priemernej chyby faktoru škálovania, ktorý bol detekovaný medzi referenčným a posunutým obrazom pri zvyšovaní rozptylu gaussovho šumu so strednou hodnotou 0. Pri určovaní z grafu má z porovnávaných hodnôt škálovania najväčšiu priemernú chybovosť detekovateľného faktoru škálovania zmenšenie s hodnotou 0,8. Pri porovnaní chyby pri znižovaní obrazu, je z grafu viditeľné, že zmenšenie s hodnotou 0,8 má väčšiu priemernú chybovosť detekovateľného faktoru škálovania ako zmenšenie s hodnotou 0,9. Pri oboch hodnotách sa však chybovosť prejavila až pri rozptyle šumu 0.001. Pri porovnaní chyby pri zväčšovaní, je z grafu zrejmé, že zväčšenie s hodnotou 1,2 malo väčšiu priemernú chybovosť detekovateľného faktoru škálovania ako zväčšenie s hodnotou 1,1. Tieto hodnoty potvrdzujú tvrdenie z Obrázok 3-5, že so stúpajúcou hodnotou škálovania stúpa chybovosť algoritmu fázovej korelácie pre škálovanie. Toto tvrdenie bolo potvrdené aj pri simulovanom zvyšujúcom sa zašumení gaussovým šumom so strednou hodnotou 0. Mierne skoky sú spôsobené použitím gaussovho šumu, ktorý je generovaný náhodne, čo ovplyvňuje presnú priemernú chybu hodnôt faktoru škálovania.

3.3 Realné dáta


Najprv sa algoritmus testoval na reálnych 3D dátach pľúc, ktoré boli vysegmentované a umelo rotované o 15° , aby sa zistilo, či je algoritmus schopný detekovať geometrickú transformáciu pri reálnych dátach. Výsledky sú zobrazené na Obrázok 3-12. Po zistení, že algoritmus funguje správne sa už prešlo na testovanie registrácie reálnych vysegmentovaných dát bez umelej geometrickej transformácie. Hodnoty podobnostných kritérií pred vstupom do algoritmu medzi referenčným a posunutým obrazom z Obrázok 3-12 boli pre euklidovú vzdialenosť $1,09 \cdot 10^6$ a pre kosínové kritérium 0,48. Po výstupe z algoritmu sa podobnosť medzi referenčným a registrovaným obrazom zvýšila s hodnotami euklidovej vzdialenosti $3,18 \cdot 10^5$ a kosínového kritéria 0,86.




Obrázok 3-12 – Výsledky algoritmu na reálnych vysegmentovaných dátach pľúc s umelou rotáciou. Obrázok A zobrazuje fúziu rezov referenčného a posunutého obrazu. Obrázok B zobrazuje fúziu rezov referenčného a registrovaného obrazu. Pohľad v rovine x,y.

Výsledky registrácie z reálnych vysegmentovaných dát pľúc bez umelo pridanej geometrickej transformácie už nedosahovali také dobré výsledky, ako pri umelo vytvorenej rotácii, pretože obsahovali spojenie škálovania, rotácie a trasnlácie. Na Obrázok 3-13, Obrázok 3-14, Obrázok 3-15 sú zobrazené výsledky fúzií obrazov pred vstupom do algoritmu Obrázky A a po výstupe z algoritmu Obrázky B z rôznych pohľadov. Z týchto obrázkov je možné určiť, že polovica pľúc na ľavej strane bola registrovaná lepšie ako pravá polovica pľúc. Tento rozdiel je spôsobený tým, že hodnoty rotácie a škálovania sú počítané globálne, teda z celého obrazu. Lepšie výsledky by bolo

možné dosiahnuť aplikovaním algoritmu najprv na pravú polovicu pľúc a potom na ľavú polovicu samostatne. To by vyžadovalo segmentáciu jednotlivých pľúc.




Obrázok 3-13 – Výsledky algoritmu registrácie pre realné vysegmentované dáta pľúc. Obrázok A zobrazuje fúziu rezov referenčného a posunutého obrazu pred vstupom do algoritmu a Obrázok B zobrazuje fúziu rezov referenčného a registrovaného obrazu. Pohľad v rovine x,y.



Obrázok 3-14 – Výsledky algoritmu registrácie pre realné vysegmentované dáta pľúc. Obrázok A zobrazuje fúziu rezov referenčného a posunutého obrazu pred vstupom do algoritmu a Obrázok B zobrazuje fúziu rezov referenčného a registrovaného obrazu. Pohľad v rovine x,z.

Hodnoty podobnostných kritérií medzi referenčným a posunutým obrazom pred vstupom do algoritmu boli pre euklidovu vzdialenosť $9,26 \cdot 10^5$ a pre kosínové kritérium 0,59 a podobnosť medzi referenčným a registrovaným obrazom po výstupe z algoritmu bola pre euklidovu vzdialenosť $9,02 \cdot 10^5$ a kosínové kritérium 0,62. Podobnosť medzi porovnávanými obrazmi sa teda zvýšila.



A

B

Obrázok 3-15 - Výsledky algoritmu registrácie pre realné vysegmentované dáta pľúc. Obrázok A zobrazuje fúziu referenčného a posunutého obrazu pred vstupom do algoritmu a Obrázok B zobrazuje fúziu referenčného a registrovaného obrazu. Pohľad v rovine y,z.

4 Záver

Práca je členená na tri časti. V prvej časti sú popísané optimalizačné registračné metódy obrazov a z ďalších registračných metód sú spomenuté fázová korelácia a disparitná analýza. V ďalšej časti je popísaný návrh vlastnej metódy. K vypracovaniu je z registračných metód vybraná metóda fázovej korelácie, hlavne pre rýchlosť registračného procesu, ktorá je pri predregistrácii kľúčová. V tejto časti je popísaný proces registrácie pľúcnych objemových CT obrazových dát rozkladom na 2D rezy usporiadané za sebou, prevod z kartézskych súradníc do polárnych súradníc, a aj proces samotných fázových korelácií pre transláciu, rotáciu a škálovanie s odpovedajúcimi blokovými schémami. Ako posledný je popísaný proces celkového algoritmu, ktorý zahŕňa všetky spomenuté geometrické transformácie.

V tretej časti práce sú popísané dosiahnuté výsledky. Testovanie prebiehalo pre menšiu výpočetnú náročnosť na výreze z reálnych dát o veľkosti $50 \times 50 \times 31$, ktorý bol vložený do matice núl, aby sa pri geometrických transformáciách neposunul mimo okno zobrazenia. Výsledný obraz tak mal veľkosť $120 \times 120 \times 31$. Z geometrických transformácií boli vyskúšané a riešené translácia, rotácia a škálovanie, ako bez simulovaného šumu, tak aj so simulovaným gaussovým šumom. Pri všetkých vyskúšaných geometrických transformáciách mal zvyšujúci sa gaussov šum nepriaznivý vplyv na algoritmus, čo sa prejavilo zhoršením podobnosti medzi referenčným a registrovaným obrazom. Najviac náchylná na gaussov šum bola fázová korelácia pre škálovanie, ktorá chyby detekovala pri gaussovom šume so strednou hodnotou 0 a rozptyloch v ráde 10^{-3} , za ňou nasledovala fázová korelácia pre rotáciu ktorá chyby detekovala pri rozptyloch šumu v ráde 10^{-2} , a najodolnejšia bola fázová korelácia pre transláciu, ktorá chyby detekovala pri rozptyloch šumu v ráde 10^{-1} . Pri výsledkoch bez použitia simulovaného šumu algoritmus pracuje rovnako dobre pri malých celočíselných posunoch, ako aj pri veľkých celočíselných posunoch. Pri rotácií sa podobnosť medzi referenčným a registrovaným obrazom najprv znižovala do hodnoty rotácie 45° a potom podobnosť začala stúpať do hodnoty rotácie 90° . Nameraná závislosť sa s miernymi odchýlkami periodicky opakovala. Najviac sú porovnávané obrazy podobné na začiatku pri malých uhloch a potom na konci pri blížení sa ku uhlu rotácie 360° . Tieto výsledky odpovedajú tomu, že chyba interpolácie je najväčšia pri uhle 45° . Na smere rotácie nezáleží. Pre škálovanie sa podobnosť medzi referenčným a posunutým obrazom znižovala so zvyšujúcou sa odchýlkou od hodnoty 1. Algoritmus pre škálovanie mal najväčšiu chybovosť, pretože je najviac závislý na polohe nájdeného maxima. Presnosť polohy tohoto maxima je daná hlavne rozlíšením obrazu v log-polárnych súradniciach. Rozlíšenie by pre presnosť výpočtu malo byť čo najväčšie. Treba však zvážiť, že sa tým zvyšuje výpočetná náročnosť tvorená hlavne interpoláciou pri vzniku log-polárnych obrazov a následne koreláciou

jednotlivých spektier. Keďže sa práca zaoberá predregistráciou, dôraz sa kladie hlavne na rýchlosť výpočtu pri zachovaní dostatočnej obrazovej informácie.

Ďalšou z možností ako zlepšiť nájdenie polohy maxima je použiť väčšie vstupné obrázky, ktoré obsahujú viac obrazových informácií. To platí napríklad pri testovaní na reálnych dátach. Algoritmus dokázal na reálnych dátach detekovať ako škálovanie, tak aj rotáciu a trasnláciu. Keďže sa však parametre geometrických transformácií počítali z porovnávaných obrazov globálne, je možné na vysegmentovaných plúcach pozorovať, že sa jedna časť pľúc registrovala lepšie ako druhá. Algoritmus teda detekoval správne parametre geometrických transformácií pre jednu časť pľúc, avšak tieto hodnoty parametrov boli použité aj na druhú časť pľúc. To je spôsobené tým, že hodnota maxima sa vyberá z tej časti pľúc, ktorá obsahuje viac obrazovej informácie. Tento problém by mohol byť vyriešený použitím fázovej korelácie, ktorá by počítala parametre transformácií lokálne pre každú polovicu pľúc. Z dosiahnutých výsledkov je možné usúdiť, že navrhnutý algoritmus zväčšoval podobnosť medzi porovnávanými obrazmi značným spôsobom pri všetkých vyskúšaných geometrických transformáciách. Algoritmus dokázal registrovať obraz, ktorý obsahoval jednotlivé geometrické tranformácie samostatne, ako aj obraz, ktorý obsahuje škálovanie, rotáciu a transláciu dokopy.

Použité zdroje

- [1] JAN, Jiří. Medical image processing, reconstruction and restoration: concepts and methods. Boca Raton: Taylor, 2006, 730 s. ISBN 08-247-5849-8.
- [2] Elektrovue - Internetový časopis (<http://www.elektrovue.cz>), Vol.15, (2013), No.4, pp.254-259, ISSN 1213-1539, článek v časopise
- [3] WALEK, P.; LAMOŠ, M.; JAN, J. Analýza biomedicínských obrazů. Analýza biomedicínských obrazů. Brno: 2013. s. 1-138. ISBN: 978-80-214-4792- 9
- [4] FAKULTA ŽIVOTNÍHO PROSTŘEDÍ, Katedra informatiky a geoinformatiky. Mapový Server [online]. [cit. 2015-05-25]. Dostupné z: mapserver.fzp.ujep.cz/hmu/dokumenty/metodika.pdf
- [5] MACHÁČEK, Martin. Encyklopedie fyziky. 1. vyd. Praha: Mladá fronta, 1995, 408 s. ISBN 8020402373.
- [6] PIHAN, R.: Fotoroman. [online]. [cit. 2015-04-12]. Dostupné z: http://www.fotoroman.cz/glossary2/3_interpolace.htm
- [7] LEHMANN, T M, C GÖNNER, K SPITZER: Survey: interpolation methods in medical image processing. IEEE transactions on medical imaging, 1999, roč. 18, č. 11: s. 1049-75, ISSN 0278-0062.
- [8] KIRKPATRICK, S., C. D. GELATT, M. P. VECCHI: Optimization by simulated annealing. Science (New York, N.Y.), 1983, roč. 220, č. 4598: s. 671-80, ISSN 0036-8075.
- [9] KLEIN, Stefan, Josien P. W. PLUIM, Marius STARING, Max A. VIERGEVER: Adaptive Stochastic Gradient Descent Optimisation for Image Registration. International Journal of Computer Vision, 2008, roc. 81, c. 3: s. 227-239, ISSN 0920-5691.
- [10] REDDY, B.S. a B.N. CHATTERJI. An FFT-based technique for translation, rotation, and scale-invariant image registration. In: *IEEE Transactions on Image Processing* [online]. 1996, s. 1266-1271 [cit. 2014-12-22]. DOI:10.1109/83.506761.
- [11] SARVAIYA, Jignesh, Suprava PATNAIK a Kajal KOTHARI. Image Registration Using Log Polar Transform and Phase Correlation to Recover Higher Scale. In: *Journal of Pattern Recognition Research* [online]. 2012, s. 90-105 [cit. 2014-12-22]. DOI: 10.13176/11.355.
- [12] HE, Bei, Guijin WANG, Xinggang LIN, Chenbo SHI a Chunxiao LIU. High-Accuracy Sub-Pixel Registration for Noisy Images Based on Phase Correlation. In: *IEICE Transactions on Information and Systems* [online]. 2011, s. 2541-2544 [cit. 2015-04-16]. DOI: 10.1587/transinf.e94.d.2541. Dostupné z: http://www.aoki.ecei.tohoku.ac.jp/research/docs/e86-a_8_1925.pdf
- [13] ZHUO Liu, Shigeo Wada, "Translation, Rotation and Scale Invariant Texture Characterization Method," IEEE proceedings of ISSPIT, pp103-106, 18-21, 2004.

- [14] Q. CHEN, M. Defrise, F. Deconinck, "Symmetric phase-only matched filtering of Fourier–Mellin transform for image registration and recognition," *IEEE Trans. on Pattern Analysis and Machine Intelligence* 16, 1156–1168, 1994.
- [15] KLEIN, Stefan & a Marius STARING. Elastix. Josien P.W. PLUIM. Elastix [online]. [cit. 2015-05-22]. Dostupné z: <http://elastix.isi.uu.nl/download.php>
- [16] Department of Image Processing. IMARE Image Registration Toolbox [online]. ZITOVÁ, Barbara a Filip ŠROUBEK. [cit. 2015-05-22]. Dostupné z: <http://zoi.utia.cas.cz/imare-toolbox>
- [17] Diagnostic Imaging Associates: Virtual Chceck-Up Full Body Scanning. [online]. [cit. 2015-04-21]. Dostupné z: http://www.diaxray.com/services/vcu_full_body.html
- [18] The MathWorks, Inc.: Matlab Central [online]. [cit. 2015-05-26]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/27023-log-polar-image-sampling>
- [19] ZITOVÁ, Barbara a FLUSSER, Jan. Image registration methods: a survey. *Image and Vision Computing*. 2003, roč. 21, č. 11, s. 977-1000.
- [20] HAJNAL, Joseph V, D HAWKES, Derek L HILL: *Medical image registration*. Boca Raton: CRC Press, 2001, ISBN 08-493-0064-9, 382 s.
- [21] Lepš, M.: TABU search metoda, Dokument dostupný na http://klobouk.fsv.cvut.cz/~leps/teaching/mmo/prednasky/prednaska05_Tabu.pdf
- [22] AUDETTE, Michel A., Frank P. FERRIE a Terry M. PETERS. An algorithmic overview of surface registration techniques for medical imaging. *Medical Image Analysis* [online]. 2000, vol. 4, issue 3, s. 201-217 [cit. 2014-12-23]. DOI: 10.1016/S1361-8415(00)00014-1. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1361841500000141>
- [23] OLIVEIRA, Francisco P.M., João Manuel R.S. TAVARES a Terry M. PETERS. *Medical image registration: a review*. *Computer Methods in Biomechanics and Biomedical Engineering*. 2014-01-25, vol. 17, issue 2, s. 73-93. DOI: 10.1080/10255842.2012.670855. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/10255842.2012.670855>
- [24] ČERNÝ, F.: *Registrace obrazů a prostorová transformace*, Dokument dostupný na <http://uprt.vscht.cz/mudrova/zob2/prezentace/IR.pdf>
- [25] S. Klein, M. Staring, K. Murphy, M.A. Viergever, J.P.W. Pluim, "elastix: a toolbox for intensity based medical image registration," *IEEE Transactions on Medical Imaging*, vol. 29, no. 1, pp. 196 - 205, January 2010
- [26] D.P. Shamonin, E.E. Bron, B.P.F. Lelieveldt, M. Smits, S. Klein and M. Staring, "Fast Parallel Image Registration on CPU and GPU for Diagnostic Classification of Alzheimer's Disease", *Frontiers in Neuroinformatics*, vol. 7, no. 50, pp. 1-15, January 2014

Zoznam použitých skratiek

CT - computed tomography – röntgenová počítačová tomografia

MR - magnetic resonance – magnetická rezonancia

PET - positron emission tomography – pozitronová emisná tomografia

SPECT - single photon emission tomography – jednofotónová emisná tomografia

NN - nearest neighbour – najbližší sused

SSD - sum of squared differences - súčet rozdielu štvorcov

CC – correlation coefficient - korelačný koeficient

NCC – normalized correlation coefficient - normalizovaný korelačný koeficient

MI – mutual information – vzájomná informácia

3D – trojrozmerný

2D – dvojrozmerný