




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

REGISTRACE CT OBJEMOVÝCH OBRAZŮ MOZKU POMOCÍ GLOBÁLNÍ AFINNÍ 3D TRANSFORMACE

REGISTRATION OF VOLUME CT BRAIN IMAGES BY MEANS OF GLOBAL AFFINE 3D
TRANSFORM

DIPLOMOVÁ PRÁCE
DIPLOMA THESIS


AUTOR PRÁCE
AUTHOR

Bc. KAROL MIKULÁŠ

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. PETR WALEK

BRNO 2012



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské inženýrství a bioinformatika

Student: Bc. Karol Mikuláš
Ročník: 2

ID: 98588
Akademický rok: 2011/2012

NÁZEV TÉMATU:

Registrace CT objemových obrazů mozku pomocí globální afinní 3D transformace

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši algoritmů a metod využívaných při lícování objemových medicínských dat. Zaměřte se především na lícování pomocí optimalizace globální intenzitní podobnostní funkce dvojice obrazů. 2) V programovém prostředí MATLAB realizujte algoritmus, který bude provádět globální afinní transformaci objemových dat podle pevně zadaných parametrů. 3) Navrhněte koncept algoritmu, který z obrazových dat odstraní pacientský stůl. 4) S ohledem na charakter poskytnutých obrazových dat (časová posloupnost CT obrazů, zachycující vývoj mozkového hematomu) vyberte a naprogramujte kritérium podobnosti obrazů. 5) Vyberte a popište optimalizační algoritmus, který bude vhodný pro řešení zadaného problému. Programy vytvořené v předešlých bodech propojte v jeden celek a pomocí vybraného optimalizačního algoritmu realizujte vlastní lícování obrazových dat. 6) Proveďte diskuzi a zhodnocení dosažených výsledků.

DOPORUČENÁ LITERATURA:

- [1] JAN, J. Medical Image Processing, Reconstruction and Restoration: Concepts and Methods, CRC Press, 2005. ISBN 0-8247-5849-8.
- [2] ZITOVÁ, B., FLUSSER, J. Image registration methods: a survey. Image and Vision Computing, Oct 2003, vol. 21, no. 11, p. 977-1000.

Termín zadání: 6.2.2012

Termín odevzdání: 18.5.2012

Vedoucí práce: Ing. Petr Walek
Konzultanti diplomové práce:

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

Děkuji vedoucímu diplomové práce Ing. Petrovi Walkovi za účinnou metodickou, pedagogickou a odbornou pomoc a za další cenné rady při zpracování mé diplomové práce a semestrálního projektu.

Také bych chtěl poděkovat celé rodině, přítelkyni a přátelům, kteří mě po všech stránkách při studiu podporovali.

V Brně dne 18. května 2012.....

podpis autora

Bibliografická citace mé práce:

MIKULÁŠ, K. *Registrace CT objemových obrazů mozku pomocí globální afinní 3D transformace*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 57 s. Vedoucí diplomové práce Ing. Petr Walek.

Abstrakt

V současné době dochází ve zdravotnictví k rychlému vývoji nových zobrazovacích metod a zdokonalování používaných metod. S tím dochází i k vývoji nových metod pro zpracování dat pořízených těmito metodami. Především v minulých několika letech se stala velmi využívanou metodou registrace dat, kdy dochází k transformacím obrazů stejné scény tak, aby si co nejvíce odpovídaly. Práce se zabývá právě touto metodou zpracování dat, které tak poskytují detailnější informace o jednotlivých strukturách, vývoji jednotlivých struktur v čase, umožňují zobrazovat současně fyziologické i anatomické informace nebo předzpracují data k dalšímu zpracování.

Klíčová slova

Slícování obrazu, 3D afinní transformace, interpolace, podobnostní kritérium, optimalizační metoda, Rentgenová výpočetní tomografie

Abstract

At present, the medical industry rapidly develops new imaging techniques and improves the imaging methods. Simultaneously also are developed new methods for processing data acquired by these methods. Especially in the past few years has become very used method of registration data, which leads to image transformations of the same scene so that the condition as possible. The work deals with the method of processing data that provides detailed information to individual structures, developments of individual structures over time, allows to simultaneously display anatomical and physiological information or preprocessing data for further processing.

Key Words

Image registration, 3D affine transformation, interpolation, similarity criteria, optimization method, X-ray computed tomography.

Obsah

Seznam obrázků.....	8
Úvod.....	10
1. Předzpracování	12
1.1. Vyhazení nasnímaných obrazů	12
1.2. Odstranění patientského stolu.....	12
2. Registrace obrazu.....	15
2.1. Geometrické transformace obrazu	15
2.2. Interpolace obrazu.....	18
2.3. Globální kriteriální funkce	19
2.3.1. <i>Podobnostní kritéria založená na intenzitě</i>	20
2.3.2. <i>Podobnostní kritéria založená na informačním obsahu</i>	22
2.4. Optimalizační funkce	23
3. Praktická část.....	28
3.1. Předzpracování obrazu	28
3.1.1. <i>Odstranění patientského stolu</i>	28
3.1.2. <i>Odstranění schodovitého artefaktu</i>	32
3.2. Uživatelské prostředí	33
3.2.1. <i>Menu</i>	34
3.2.2. <i>Volba parametrů</i>	37
3.2.3. <i>Informační panel</i>	38
3.2.4. <i>Grafické zobrazení vývoje registrace</i>	39
3.3. Registrace	39

3.3.1. Transformace	39
3.3.2. Interpolace.....	43
3.3.3. Výpočet podobnostního kritéria	43
3.3.4. Optimalizace.....	44
4. Diskuze výsledků.....	49
4.1. Program pro transformaci obrazu pevnými parametry	49
4.2. Odstranění patientského stolu.....	49
4.3. Registrace obrazu	52
5. Závěr	55
6. Seznam použité literatury	56
7. Seznam zkratk.....	58

Seznam obrázků

Obrázek 1 - Blokové schéma registrace	11
Obrázek 2 - Schodovitý artefakt	12
Obrázek 3 - Pacientský stůl	13
Obrázek 4 - Vychýlení transformovaných souřadnic	18
Obrázek 5 – Detekování stolu Houghovou transformací (invertované snímky)	29
Obrázek 6 - Detekování stolu podle obsahu objektu	31
Obrázek 7 - Vývojový diagram odstranění pacientského stolu	32
Obrázek 8 - Blokové schéma odstranění schodovitého artefaktu	32
Obrázek 9 - Zobrazení průběhu odstranění schodovitého artefaktu.	33
Obrázek 10 - Grafické prostředí programu Registrace objemových dat	34
Obrázek 11 – Menu	35
Obrázek 12 - Blokové schéma načtení registrovaných dat	36
Obrázek 13 - Nastavení vstupních parametrů optimalizační metody	37
Obrázek 14 - Informační panel	39
Obrázek 15 - Vývojový diagram registrace a interpolace	40
Obrázek 16 - Vývojový diagram vytvoření matice indexů pro registraci	41
Obrázek 17 - Vývojový diagram transformace dat.....	42
Obrázek 18 - Vývojový diagram výpočtu Cosinova kritéria.....	44
Obrázek 19 – Vývojový diagram schéma registrace	45
Obrázek 20 Vývojový diagram generování populace D	46
Obrázek 21 - Vývojový diagram Simplexové metody.....	47

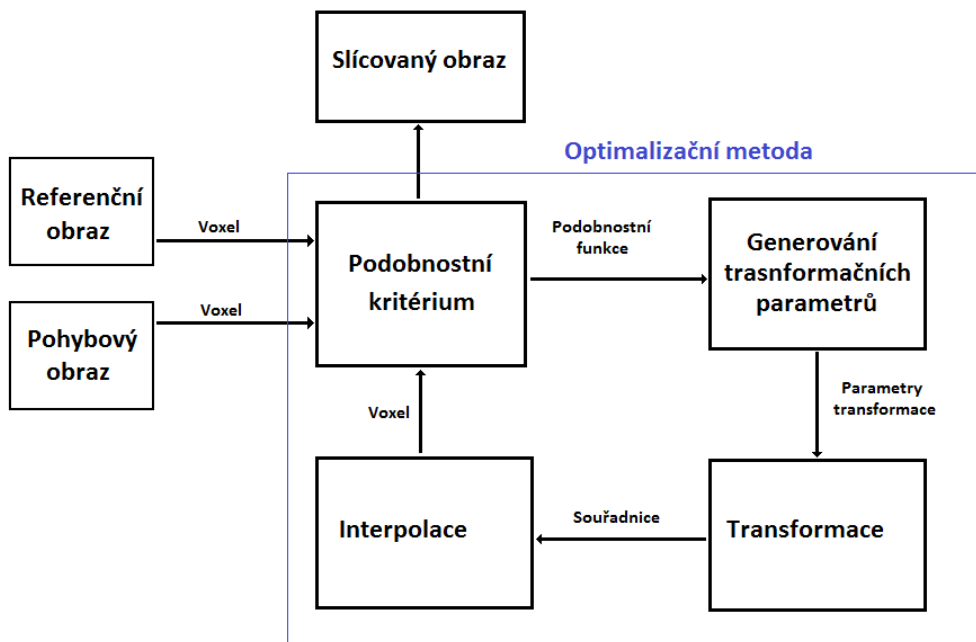
Obrázek 22 - Odstranění patientského stolu	50
Obrázek 23 - Zobrazení zbylých částí patientského stolu	51
Obrázek 24 - Koeficient kulatosti objektů v obraze	52
Obrázek 25 - Registrace kontrolního vzorku - rigidní transformace	53
Obrázek 26 - Registrace kontrolního vzorku - flexibilní transformace	53
Obrázek 27 - Registrace obrazu s vývojem hematomu.....	54

Úvod

Registrací obrazu se rozumí geometrická transformace obrazu, tak aby co nejvíce odpovídal vzorovému obrazu. Obrazy se kterými pracujeme, nazýváme referenční a pohybové. Referenční obrazy představují vzorovou scénu a pohybové obrazy jsou obrazy, které vůči referenčnímu obrazu geometricky transformujeme. Původ odlišností mezi referenčními a pohybovými obrazy má čtyři hlavní příčiny. Jsou jimi změny vzniklé snímáním scény v různých časových intervalech, snímáním scény z jiné polohy, snímáním scény odlišnou modalitou nebo porovnání scény vůči modelu [1,4].

Při registraci se nejprve vypočte podobnostní kritérium mezi obrazy a tím se získá matematická závislost mezi obrazy. Na základě této informace se v dalším kroku pomocí jedné z globálních optimalizačních metod naleznou nejvhodnější parametry, kterými se geometricky transformuje pohybový obraz, tak aby odpovídal referenčnímu obrazu. S těmito transformacemi často dochází k vychýlení pohybového snímku z původních obrazových souřadnic do nových, nedefinovaných, souřadnic. Tím dochází k potřebě použití jedné z metod interpolace, tedy dopočítání nedefinovaných souřadnic pohybového obrazu. Po dokončení transformace obrazu a následné interpolaci souřadnic se opět vypočte podobnostní kritérium mezi referenčním a pohybovým obrazem a na jeho základě optimalizační metoda určí nový vektor parametrů geometrické transformace. Tento cyklus se opakuje, dokud není splněna jedna z podmínek pro ukončení globální optimalizační metody, čímž se obrazy považují za registrované a cyklus se ukončuje (viz Obrázek 1, převzato a upraveno [7]).

Správná registrace obrazu je v medicínském oboru důležitá z důvodu získání shodných referenčních obrazů vůči pohybovým. Tím může pozorovatel prostudovat detailněji jednotlivé struktury, vývoj jednotlivých struktur v čase, současně zobrazovat fyziologické i anatomické informace nebo využít obraz k dalšímu zpracování jako je např. fúze obrazů a jiné. Proto je velmi důležité získat co nejpřesněji slícované obrazy.



Obrázek 1 - Blokové schéma registrace


Nejdůležitějším bodem registrace obrazů, na němž hlavně závisí kvalita slícování, je optimalizační metoda pro nalezení nejvhodnějších parametrů. Pro registraci medicínských obrazů bývá často využíváno simplexové metody [10,15,19] a genetických algoritmů [10,13,14,15], zvláště díky jednoduchosti, rychlosti metody a nízkým sklonům ke konvergenci do lokálních minim. Po vygenerování transformačních parametrů a samotné transformaci je nutné interpolovat získaná data. Základními 3D interpolacemi jsou metoda nejbližšího souseda, trilineární, trikubická a trikvadratická interpolace [1,4,6,9], všechny tyto metody mohou být použity při registraci medicínských obrazů, rozdílem mezi metodami je kvalita výsledného interpolovaného obrazu a s kvalitou ale i roste výpočetní a časová náročnost metody. Posledním důležitým krokem u registrace obrazů je výpočet podobnostního kritéria. Při volbě podobnostního kritéria, je nutné zohlednit důležité informace o registrovaných datech. V této diplomové práci jde o časový vývoj monomodálních dat stejné scény. Z tohoto je zvoleno Kosinové podobnostní kritérium.

1. Předzpracování

Předzpracování obrazu se využívá především, aby registrace nebyla ovlivněna artefakty, které se mohou v obrazech vyskytovat. Dalším z důvodů je odstranění neúčinných informací z obrazu. Při předzpracování dat v této práci byly provedeny úpravy pro odstranění posunu obrazů vzniklých při sekvenčním snímání a odstranění patientského stolu z obrazů.

1.1. Vyhlazení nasnímaných obrazů

Data použitá pro registraci byla pořízena pomocí rentgenové počítačové tomografie (CT), módem sekvenčního snímání. Na rozdíl od helikálního snímání nejde o plynulé posouvání stolu v průběhu snímání, ale o posun stolu po nasnímání určitého počtu snímků, v tomto případě po nasnímání 16 snímků. Sady dat jsou zatíženy schodovitým artefaktem, vyskytujícím se právě po 16 snímcích. Tato chyba se může projevit při samotné registraci, v případě, že jsou každá data zatížena schodovitým artefaktem v jiných místech. Posledním důvodem pro tuto formu předzpracování je zhoršený estetický vjem, který je patrný z Obrázek 2a.




Obrázek 2 - Schodovitý artefakt snímek (a) zobrazuje schodovitý artefakt vyskytující se ve vstupních datech. Snímek (b) zobrazuje data po vyhlazení

1.2. Odstranění patientského stolu

Odstranění patientského stolu z registrovaných obrazů (viz Obrázek 3), je důležitým krokem pro nalezení správné transformační funkce. Pokud bude hlava pacienta ve všech sadách obrazu zobrazena samostatně, můžeme na ni ve všech snímáních pohlížet, jako na identický

objekt, který je transformován globální geometrickou transformací. Proto na slícování obrazů bude možné použít globální afinní transformaci. Pokud by patientský stůl v obraze zůstal, bude se v každé sadě obrazů vyskytovat na stejné pozici (v případě stejných podmínek snímání), mírné natočení hlavy způsobí, že na obraz nebude možné aplikovat globální transformaci obrazu, ale bylo by potřeba transformaci obrazu provádět nelineární metodou (případně po částech spojitou lineární metodou). Tato práce se bude podrobněji zabývat dvěma metodami odstranění patientského stolu.



Obrázek 3 - Patientský stůl: snímek (a) zobrazuje strukturu patientského stůl ve 3D prostoru. Snímek (b) zobrazuje patientský stůl v samostatném 2D řezu

Detekce stolu pomocí Houghovy transformace

Houghova transformace je metoda vyhledávající parametricky popsatelné objekty v obraze pomocí jejich matematických předpisů. Nejčastěji vyhledávanými útvary jsou přímky, elipsy, kružnice apod., tedy struktury, jejichž předpis je známý a snadno formulovatelný. Výhodou Houghovy transformace je, že dokáže pracovat i s daty, které mohou být i větší mírou zašuměny a případně mohou být neúplné. [2]

Podle charakteru patientského stolu, můžeme na patientský stůl pohlížet jako na kružnici nebo elipsu. Pro takový útvar platí rovnice (1.1):

$$\begin{aligned}x &= x_0 - r_1 * \cos\varphi \\y &= y_0 - r_2 * \sin\varphi\end{aligned}\tag{1.1}$$

Pokud $r_1 = r_2$ jde o matematický předpis kružnice. Pokud $r_1 \neq r_2$ jde o matematický předpis elipsy.

Vstupem pro Houghovu transformaci je hrubá hranová reprezentace, která je vytvořena ze vstupního obrazu tak, že jsou na obraz aplikovány na lokální hranové operátory. Takto předzpracovaný obraz je následně binarizován podle vhodně zvoleného prahu. Následně je využita samotná podstata Houghovy transformace, vyhledávání objektů v obrazu podle zvoleného matematického předpisu popisující hledaný objekt. Výsledkem je množina řešení v Houghově prostoru, které odpovídají hledanému parametru.

Detekce stolu podle obsahu objektů v obraze

Tato metoda je založená na vyhledání objektu v obrazu s největším obsahem, který odpovídá hlavě. Základem metody je převod obrazu na binární data pomocí prahu získaného Otsu metodou a výpočet obsahu všech elementů v obrazu. Ze získaných informací o obsahu všech elementů v obrazu se vyhledá element s největší plochou. Tím se získá oblast s užitečnou informací, plocha hlavy, a zbylé objekty jsou jednotlivé části patientského stolu, které je nutné odstranit. Z binárního obrazu s detekovanými objekty, je element s největším obsahem, vyjmut z obrazu a odečten od původního binarizovaného obrazu, čímž se získají všechny zbylé objekty, které popisují patientský stůl. Tento proces se opakuje v každém řezu.

2. Registrace obrazu

Tato kapitola popisuje teorii procesu registrace a jednotlivé metody, které jsou při ní využívány.

2.1. Geometrické transformace obrazu

Jde o matematické operace, které transformují pohybový obraz, dle získaných geometrických transformačních funkcí. Tyto operace dělíme na globální transformace a transformace po částech. Dále existuje i projekční transformace, což je transformace, při které dochází k převedení vícerozměrného prostoru do méně rozměrného. Dalšími děleními transformačních funkcí jsou lineární transformace (transformace, pro které platí princip superpozice), nelineární transformace (pro které neplatí princip superpozice), tuhé transformace (transformace zachovávající délku a úhly jednotlivých stran) a pružné transformace (transformace, které mění délky a úhly jednotlivých stran). V této práci bude podrobně rozepsána globální afinní transformace obrazu, kterou bude praktická část diplomové práce řešena.

Globální transformace obrazu

Globální transformací rozumíme transformaci, při které se aplikuje stejná transformační funkce na všechny body obrazu. Dochází tedy ke geometrické transformaci \mathbf{T} původních souřadnic obrazu \mathbf{r} , čímž se získá nový transformovaný obraz \mathbf{r}' [4]:

$$\mathbf{r}(x, y) \rightarrow \mathbf{r}'(x', y')$$

$$\mathbf{r}' = \mathbf{T}(\mathbf{r}) \quad (2.1)$$

Ze vztahu (2.2) plyne, že jasové hodnoty původního obrazu \mathbf{r} , jsou transformovány transformační funkcí $\mathbf{f}(\mathbf{T})$ do nových transformovaných pozic obrazu \mathbf{r}' [4]:

$$\mathbf{f}(\mathbf{r}') = \mathbf{f}(\mathbf{T}(\mathbf{r})) \quad (2.2)$$

Afinní transformace

Při sloučení všech níže vypsanych lineárních transformací (posun, rotace, změna měřítka a zkosení), dostaneme afinní transformační matici. Jedná se o nejvyužívanější lineární transformaci obrazu. V praktické části této práce, bude využito právě 3D afinních transformací ke slícování objemových dat CT hlavy. [4]

V rovnici (2.3) je popsán vztah výsledného transformovaného obrazu \mathbf{r}' pomocí afinní transformační matice (\mathbf{A}), složené z níže popsaných transformačních matic pro rotaci (\mathbf{B}), zkosení (\mathbf{G}) a zvětšení (\mathbf{S}), která je aplikovaná na vstupní obraz \mathbf{r} .

$$\mathbf{r}' = \mathbf{GSBr} = \mathbf{Ar}. \quad (2.3)$$

Homogenizovaná afinní matice \mathbf{A} pro 3D transformaci dat je zapsána ve vztahu (2.4), kde transformační matice je tvořena hodnotami \mathbf{a} získané vynásobením matic \mathbf{G} , \mathbf{S} a \mathbf{B} a doplněné hodnotami \mathbf{t} udávající posun po osách \mathbf{x} , \mathbf{y} a \mathbf{z} .

$$\mathbf{A}(x, y, z) = \begin{bmatrix} a_{xx} & a_{xy} & a_{xz} & t_x \\ a_{yx} & a_{yy} & a_{yz} & t_y \\ a_{zx} & a_{zy} & a_{zz} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.4)$$

Posun

$$\mathbf{r}' = \mathbf{r} + \Delta\mathbf{r} \quad (2.5)$$

Posun o $\Delta\mathbf{r}$ obrazu \mathbf{r} je popsán vztahem (2.5), kde v 3D prostoru vyjádříme $\Delta\mathbf{r} = [\Delta\mathbf{x}, \Delta\mathbf{y}, \Delta\mathbf{z}]^T$. V praxi můžeme transformační matici pro posun \mathbf{T} vyjádřit (vztahem 2.6), kde hodnoty $t_{x,y,z}$ představují posun po jednotlivých osách. [3, 4]

$$\mathbf{T}(x, y, z) = \begin{bmatrix} 1 & 0 & 0 & t_x \\ 0 & 1 & 0 & t_y \\ 0 & 0 & 1 & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.6)$$

Rotace

Rotace transformuje obraz jeho otočením kolem jednotlivých os. Tato funkce má v trojrozměrné transformaci tři parametry α , β a γ (udávající hodnotu rotace v radiánech), rotace kolem příslušných os \mathbf{x} , \mathbf{y} a \mathbf{z} . [3]

Transformaci obrazu rotací lze obecně popsat vztahem (2.7), kde výsledný obraz \mathbf{r}' je transformován vynásobením rotační matice \mathbf{B} s původním obrazem:

$$\mathbf{r}' = \mathbf{Br} \quad (2.7)$$

Matice B je definována pro 3D prostor jako součin matic rotací pro jednotlivé osy zvlášť (viz vztah 2.8):

$$B = B_x(\alpha) * B_y(\beta) * B_z(\gamma) =$$

$$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(\alpha) & -\sin(\alpha) & 0 \\ 0 & \sin(\alpha) & \cos(\alpha) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} \cos(\beta) & 0 & \sin(\beta) & 0 \\ 0 & 1 & 0 & 0 \\ -\sin(\beta) & 0 & \cos(\beta) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} \cos(\gamma) & -\sin(\gamma) & 0 & 0 \\ \sin(\gamma) & \cos(\gamma) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

(2.8)

Změna měřítka

Při změně měřítka dochází k změně velikosti i pozice transformovaného objektu ve všech transformovaných osách. Pokud jsou hodnoty v intervalu (0,1), dochází ke zmenšení a posunutí objektu k počátku, pokud jsou vyšší než 1, dochází ke zvětšení obrazu a posunu objektu směrem od počátku. V případě, že jsou hodnoty menší než 0, dochází k zisku zrcadlového obrazu. [3]

$$r' = Sr \tag{2.9}$$

3D transformace změny měřítka je popsána maticí (2.10), kde jednotlivé hodnoty $s_{x,y,z}$ popisují míru zvětšení. Pro ponechání původního obrazu se na rozdíl od ostatních transformačních matic musí zadat hodnota 1 všem hodnotám s :

$$S(x, y, z) = \begin{bmatrix} s_x & 0 & 0 & 0 \\ 0 & s_y & 0 & 0 \\ 0 & 0 & s_z & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{2.10}$$

Zkosení

Při této geometrické transformaci dochází k transformacím úhlů ve zvolených osách, tedy ke zkosení transformovaného obrazu, který lze obecně popsat vztahem:


$$r' = Gr \tag{2.11}$$

3D transformační matici zkosení G lze zapsat jako součin matic pro zkosení úhlů pro samostatné osy x, y, z :

$$G(x, y, z) = \begin{bmatrix} 1 & g_{xy} & g_{xz} & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} 1 & 0 & 0 & 0 \\ g_{yx} & 1 & g_{yz} & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ g_{zx} & g_{zy} & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (2.12)$$

2.2. Interpolace obrazu

Výsledkem transformace často bývají souřadnice, které se nevyskytují v definovaném souřadnicovém poli, ale mezi jednotlivými body souřadnicového pole (viz Obrázek 4 [5]). Tím dochází k nutnosti přepočítat jasové informace těchto bodů do odpovídajících uzlových bodů souřadnicového pole. K tomu slouží proces interpolace, kdy se jasové hodnoty transformovaných bodů přepočítají do definovaných souřadnic obrazu pomocí jedné z metod interpolace. Jednotlivé interpolační metody se mezi sebou liší především v kvalitě výsledného interpolovaného obrazu. S rostoucí kvalitou interpolovaného obrazu však roste i výpočetní náročnost metody. V této kapitole budou blíže rozepsány metody nejbližšího souseda (NN), trilineární interpolace (TL), trikvadratické (TQ) a trikubické interpolace (TC).



Obrázek 4 - Vychýlení transformovaných souřadnic

Metoda nejbližšího souseda

Interpolace metodou nejbližšího souseda (NN) je nejjednodušší a výpočetně nejméně náročnou interpolační metodou, která je založena na přiřazení bodu, k nejbližší diskrétní souřadnici. Tato interpolace má pravoúhlý tvar jádra metody. Výsledek této metody není tak kvalitní jako u níže popsaných metod. Výhodou je zachování ostrosti hran, rychlost a jednoduchost, nevýhodou je silný vliv aliasingu. Metoda je považována za první interpolační metodu. [4, 5, 8, 9]

Trilineární interpolace

Kvalitnější a výpočetně náročnější interpolaci transformovaných dat dostaneme použitím metody TL interpolace. Metoda je založena na výpočtu pomocí algebraických polynomů (kvůli jednoduchosti polynomu často opomíjeno) odvozených z jádra metody NN, přesněji konvolucí jeho dvou jader. Tím dostaneme trojúhelníkovitý tvar charakter jádra metody, kterým je ovlivněna interpolace vzdáleností bodu od diskrétní souřadnice.[4,6,8,10]

Trikvadratická interpolace

Interpolace kvadratickou metodou je také založena na výpočtu pomocí algebraických polynomů. Jádro kvadratické interpolace je vytvořeno stejně jako jádro lineární metody, tedy konvolucí pravoúhlého jádra metody NN. Rozdíl konvoluce jádra kvadratického od jádra lineárního spočívá v tom, že konvoluce je provedena pro $N = 3$. Kvadratická interpolace spočívá v proložení diskrétní funkce parabolou. Metoda využívá pro větší přesnost více jak dvou bodů při výpočtu interpolované souřadnice, čímž se od předchozích metod liší.[8, 9, 10]

Trikubická interpolace

Tato metoda je ze všech čtyř metod nejkvalitnější a také výpočetně nejnáročnější. Stejně jako u TL a TQ interpolace, je metoda založena na využití algebraických polynomů a princip je také podobný, pouze interpolační řád polynomu je vyšší. Tím je umožněno využít většího počtu vstupních hodnot než TL a TQ interpolace, což vede k nejhladším přechodům mezi jednotlivými pixely. Pro kvalitnější interpolaci než u výše zmíněných, je potřeba využít alespoň konvolucí jader NN pro $N = 6$, u které je k interpolaci použito 12 sousedních bodů. Při $N = 8$ je použito k interpolaci již 16 sousedních bodů. [4,5,8,10]

2.3. Globální kriteriální funkce

Po transformování pohybového obrazu a interpolaci dat, je nutné vypočítat podobnostní kritérium, které určí podobnost mezi referenčním a pohybovým obrazem. Základní rozdělení kriteriálních funkcí je podle oblasti, která je porovnávána. Pokud se porovnává celý obraz, pak jde o globální kriteriální funkci. Je-li porovnávána jen část obrazu, mluvíme o lokální kriteriální funkci. Dále se můžou jednotlivé metody dělit do podskupin podle parametrů, jako jsou intenzita jasové informace, informační obsah, sledované body a povrch struktur v obrazu, kterými se porovnávají obrazy. V této práci budou podrobně vysvětleny globální kriteriální funkce založené na intenzitě a na informačním obsahu obrazů, které budou implementovány v praktické části diplomové práce.[4]

2.3.1. Podobnostní kritéria založená na intenzitě

Tato kritéria vypočítávají podobnostní funkci dvou obrazů na základě porovnávání jasové informace na odpovídajících pozicích. Pro diskrétní obrazy, se kterými se pracuje, platí, že jsou tvořeny konečným počtem pixelů N o konečných hodnotách jasových intenzit. Pro výpočet této informace je nutné převést vstupní obrazy do vektorů \mathbf{a} a \mathbf{b} , většina metod pro výpočet podobnostních funkcí vyžaduje stejnou délku těchto vektorů.

Metody založené na Euklidovské vzdálenosti

Jedná se o nejjednodušší výpočet podobnostní funkce, která je založena na Euklidovské vzdálenosti vektorů \mathbf{a} a \mathbf{b} (vzorec 2.13). Výsledkem metody Euklidovské vzdálenosti je suma rozdílů hodnot odpovídajících si pozic vektorů \mathbf{a} a \mathbf{b} . Z této metody vychází Suma rozdílů čtverců (SSD), ta se od předchozí metody odlišuje důrazem na větší nepodobnosti v porovnávaných obrazech (viz 2.14).

$$C_E(a, b) = |a - b| = \sqrt{\sum_{i=1}^N (a_i - b_i)^2} \quad (2.13)$$

$$C_{SSD}(a, b) = |a - b| = \sum_{i=1}^N (a_i - b_i)^2 = \sum_{i=1}^N (a_i)^2 - \sum_{i=1}^N (a_i b_i) + \sum_{i=1}^N (b_i)^2 \quad (2.14)$$

Další metodou je metoda Vzájemné korelace, která výsledné kritérium vypočítává z prostředního členu rovnice pro výpočet SSD (viz vzorec 2.14), to je vypočteno skalárním součinem vektorů \mathbf{a} a \mathbf{b} ($\mathbf{a} \cdot \mathbf{b}$). Metoda je velmi nespolehlivá z důvodu zanedbání dvou členů ve výpočtu (viz vztah 2.15). [4,5]

$$C_C(a, b) = \sum_{i=1}^N (a_i b_i) \propto \frac{1}{N} \sum_{i=1}^N (a_i b_i) \quad (2.15)$$

Metody založené na Euklidovské vzdálenosti jsou vhodné pouze pro monomodální data, kde nedochází ke změně kontrastu.

Úhlové (Kosinové) kritérium

Tato metoda je založená na výpočtu velikosti úhlu δ mezi vektory \mathbf{a} a \mathbf{b} (viz vztah 2.16). Díky tomu je metoda robustní vůči lineární změně kontrastu a bere se v potaz, že nejen identické

vektory mají stejnou orientaci, ale i vektory, u kterých je rozdílná intenzita zapříčiněna multiplikačním faktorem. Tím je docíleno, že lineární změna nemá na sensitivitu žádný vliv. Také bylo experimentálně ověřeno, že na výpočet nemá vliv ani monotónní transformace kontrastu[4]. Výsledek u této metody je v případě identických obrazů jednotkový a výsledné hodnoty se obvykle normalizují do v rozsahu $\langle -1, 1 \rangle$. [4]

$$C_A(a, b) = \frac{ab}{|a||b|} = \frac{\sum_i a_i b_i}{\sqrt{\sum_i a_i^2} \sqrt{\sum_i b_i^2}}, \quad ab = |a||b|\cos(\delta) \quad (2.16)$$

Korelační koeficient

Tato metoda popisuje míru lineární závislosti mezi dvěma porovnávanými obrazy. Korelační koeficient nabývá hodnot z intervalu $\langle -1, 1 \rangle$, kde výsledek = 1 vyjde při porovnání dvou identických obrazů, -1 pokud jde o navzájem inverzní obrazy. Varianta vychází z úhlové funkce, kde se stanoví střední hodnoty v jednotlivých oblastech a ty se od sebe odečtou. Hledaným parametrem je maximum funkce. [4]

$$C_{CC}(a, b) = \frac{\sum_i (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_i (a_i - \bar{a})^2} \sqrt{\sum_i (b_i - \bar{b})^2}}, \quad \bar{a} = \frac{1}{N} \sum_{i=1} a_i, \quad \bar{b} = \frac{1}{N} \sum_{i=1} b_i \quad (2.17)$$

Koeficient stejnorodosti obrazu

Metoda koeficientu stejnorodosti obrazu (RIU) vypočítává podobnostní kritérium na základě poměru intenzit v obraze transformovaného a referenčního obrazu. Hledanou hodnotou je minimum funkce. Tato metoda byla původně odvozena pro registraci PET obrazů, po upravení metody se v současnosti využívá i při registraci CT obrazů. Výhodou této metody je, stejně jako u úhlového kritéria, že lineární transformace kontrastu nemá vliv na výpočet kritéria [4, 5].

$$C_{RIU}(a, b) = \frac{\sqrt{\sum_i (r_i - \bar{r})^2}}{\bar{r}}, \quad \bar{r} = \frac{1}{N} \sum_i r_i$$

$$r = \left[\begin{array}{c} a_1 \ a_2 \ \dots \ a_N \\ b_1 \ b_2 \ \dots \ b_N \end{array} \right]^T \quad (2.18)$$

2.3.2. Podobnostní kritéria založená na informačním obsahu

Výpočet podobnostního kritéria pomocí metod založených na informačním obsahu registrovaných dat se využívá v případě, kdy nelze využít údajů o intenzitě. Tento případ často nastává u multimodálních dat, které zobrazují jiný parametr a mají odlišný charakter. Základním prvkem pro tato podobnostní kritéria je sdružený histogram. [4,5]

Sdružený histogram

Sdružený histogram poskytuje globální informaci o závislosti jasových intenzit mezi obrazy v odpovídajících si pozicích. Popišme tento histogram jako matici \mathbf{h}^{AB} bodů o velikosti $\mathbf{q} \times \mathbf{r}$, kde \mathbf{q} je počet odstínů šedi vyskytujících se v obrazu **A** a \mathbf{r} je počet odstínů šedi v obrazu **B**. Přičemž musí platit, že obrazy **A** a **B** jsou stejně velké. Pozice v histogramu udávají počet konkrétních kombinací stupňů šedi nacházející se v obou obrazech na stejných pozicích. Pokud porovnáme dva identické obrazy, výsledkem budou nenulové hodnoty ležící v hlavní diagonále jednorozměrného histogramu. Pokud bychom porovnávali identické obrazy s transformovanou jasovou informací, dostali bychom sdružený histogram s nenulovými hodnotami ležící v křivce, popisující právě tuto jasovou transformaci. Sdružený histogram pro totožné obrazy by obsahoval veškeré nenulové hodnoty v diagonále. Při změně jasové intenzity totožných obrazů, by křivka nenulových hodnot popisovala jasovou transformaci mezi oběma obrazy. Pokud by se porovnávaly obrazy na sobě nezávislé, nenulové hodnoty by byly rovnoměrně rozmístěné po celém sdruženém histogramu. [4]

Sdružená entropie

Entropie popisuje míru vnitřní neuspořádanosti systému, která je založená na předpokladu pravděpodobnostního rozložení prvků před přijetím symbolu zprávy. Čím více neurčitosti připadá zdroji, tím více informací se získá po obdržení symbolu. Sdružená entropie vyjadřuje množství informace obsažené ve sdružení obrazů **A** a **B**.

Pokud porovnáme dva identické obrazy, výsledkem sdružené entropie bude nula, jelikož nedochází k získání nové informace. Pokud porovnáváme obrazy na sobě nezávislé, získaná sdružená entropie bude rovna sumě entropií obou obrazů.

Entropii dělíme na individuální (H_A a H_B , viz vztah 2.19 [4]) a na sdruženou (H_{AB} viz vztah 2.20 [4]).[4]

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

$$H_B = - \sum_{m=1}^r p(b_m) \log p(b_m) \quad (2.19)$$

$$H_{AB} = - \sum_{l=1}^q \sum_{m=1}^r p(a_l b_m) \log p(a_l b_m) \quad (2.20)$$

Vzájemná informace

Výpočet podobnostního kritéria pomocí vzájemné informace (MI) je jednou z nejpoužívanějších metod pro výpočet podobnostního kritéria, vycházejícího ze sdružené entropie. MI popisuje míru vzájemné závislosti náhodných veličin, v tomto případě vzájemné závislosti intenzit šedi v porovnávaných obrazech. Výpočet kritéria se provádí odečtením součtu samostatných entropií od sdružené entropie (viz vztah 2.21 [4]). Při porovnání dvou identických obrazů je výsledkem vzájemné informace $I_{AB} = H_A = H_B$, nedochází k zisku nové informace. Při porovnání dvou na sobě nezávislých obrazů je výsledkem vzájemné informace $I = 0$, protože jejich individuální entropie (množství informace, které obrazy nesou) jsou shodné a prediktabilita obrazu B při znalosti obrazu A je nulová a tím je obdržena maximální nová informace o obrazu a po dosažení se tedy součet individuálních entropií vykrátí se sdruženou entropií. [5]

$$I_{AB} = H_A + H_B - H_{AB} \quad (2.21)$$

2.4. Optimalizační funkce

Obecně můžeme cíl optimalizačních algoritmů definovat jako hledání $\mathbf{x} \in \mathbb{X}$, podle souboru kritérií $F = \{f_1, f_2, \dots, f_n\}$, kterými nalezneme nejvhodnější řešení. U registrace obrazu jde o nalezení globálního extrému optimalizované funkce v podobě transformačních parametrů, kterými docílíme co nejlepší registrace obrazu. Výběr vhodné optimalizační funkce je nejobtížnějším a zároveň nejdůležitějším krokem k úspěšnému registrování obrazu.

Optimalizační funkce se dělí na stochastické a deterministické metody. Stochastické optimalizační funkce využívají prvku náhody pro nalezení globálního extrému (viz níže vedené metody). Tento prvek náhody slouží ke snížení možnosti uvíznutí v lokálních extrémech. Uvíznutí v lokálních extrémech vede k zisku chybného řešení. U deterministických optimalizačních metod, dochází k nalezení správného řešení umístěním startovního bodu do zvoleného počátku, odkud následně prohledává nejbližší okolí podle definovaných kroků. Deterministické funkce mají větší sklony k uvíznutí v lokálních extrémech.

Níže popsané optimalizační funkce jsou funkce využívající stochastických prvků pro nalezení globálního extrému.

Ukončení optimalizační funkce

Důležitým krokem pro nalezení globálního minima funkce je vhodné ukončení optimalizační metody. Problém, který může nastat při optimalizačních metodách, je uvíznutí v lokálních minimech funkce, které povede k předčasnému ukončení optimalizace a získání chybných parametrů. V závislosti na výběru podobnostního kritéria je optimalizační metoda ukončena pomocí jednoho ze dvou kritérií.

1. Ukončení počtu iterací

Při dokončení počtu iterací se ukončí optimalizační funkce a výsledkem je hodnota s nejlepším $f(x)$. Pokud je metoda ukončena tímto kritériem, není získána informace o kvalitě získaných parametrů.

2. Stagnace výsledku

Pokud je optimalizace ukončena tímto kritériem, v posledních iteracích již nedochází k novému vývoji výsledku a získané parametry jsou považovány za globální optimum. Na rozdíl od předchozího ukončovacího kritéria je známa kvalita výsledku.

Kontrolované náhodné prohledávání

Metoda vychází ze simplexové metody, známé jako Nelder – Meanova metoda. Základní jednotkou této metody je simplex S , který je definován jako množina nekomplanárních $d + 1$ bodů v prostoru D . Kde d definujeme jako rozměr D .

$$S = \{x_1, x_2, \dots, x_{d+1}\}$$

V simplexu se nachází, v případě registrace, parametry geometrické transformace náhodně vybraných jedinců z počáteční populace. Každý jedinec populace D obsahuje jedno řešení hledaného problému a funkční hodnotu podobnostního kritéria popisující jeho kvalitu. Principem celé metody je nalezení argumentu $f(x)$ s nejhorším funkčním předpisem $f(x)$, a pomocí reflexe přes těžiště simplexu, nalezení nového parametru s lepším $f(x)$, kterým je nahrazen. Po reflexi jedince s nejhorší hodnotou $f(x)$ přes těžiště simplexu je nová hodnota přepočtena a podle výsledné hodnoty dochází k jedné ze tří operací [17,18]:

- Reflexe
 - Jde o operaci provedenou v každém kroku
 - Simplex je přenášěn ve směru přes těžiště
- Kontrakce
 - Navazuje na informaci získanou z předchozí reflexe
 - Pokud je $f(x)$ horší než původní, simplex se posune blíže ke středu
- Expanze
 - Navazuje na informaci získanou z předchozí reflexe
 - Pokud je $f(x)$ lepší než původní, dochází k protažení simplexu v tomto směru

Metoda CRS má v současné době několik variant, mezi nejznámější metody patří základní varianta s nejhorší $f(x)$ (výše uvedená), varianta s nejlepší $f(x)$, varianta s náhodnou reflexí.

Varianta s náhodnou reflexí nachází hodnotu $f(x)$ s nejnižší funkční hodnotou a výpočet těžiště je proveden z náhodně vybraných simplexů. U varianty s náhodně dlouhou reflexí, je princip stejný jako základní varianta, pouze délka reflexe simplexu s nejhorší $f(x)$ přes těžiště je v každém kroku náhodná.

Evoluční algoritmy

Algoritmus vychází z evoluční teorie, sepsané Charlesem Darwinem, která popisuje závislost přežití jedince a jeho potomků na schopnosti přizpůsobit se prostředí a předat gen s touto informací dalším generacím.

Základním prvkem této metody je populace, kterou definujeme jako skupinu náhodně generovaných jedinců, kde každý jedinec obsahuje jedno řešení hledaného problému a funkční hodnotu podobnostní funkce. Na tuto populaci se postupně aplikují evoluční operátory. Těmito operátory jsou křížení, mutace a selekce, které slouží ke generování silnějších jedinců, kteří předávají svou informaci dalším generacím.[10]

- Selekce
 - Nejsilnější jedinci z populace mají šanci na přežití a předání svých genů potomstvu
- Křížení
 - Dva nebo více jedinců z populace si vymění informace
 - Vznik nových jedinců s kombinovanými vlastnostmi rodičů
- Mutace
 - Náhodná modifikace zakódované informace u jedince

Na každý z těchto evolučních operátorů je aplikován prvek náhody, který zamezuje uvíznutí metody v lokálním minimu a umožňuje tak nalezení globálního minima. U selekce je tento stochastický prvek aplikován v podobě náhodného výběru jedinců nebo na základě souboje, kterým je vybrán silnější jedinec. Takto vybraní jedinci jsou následně zkříženi, čímž dochází ke zkombinování informací jedinců a vytvoření nového jedince. Posledním prvkem evolučních operátorů je mutace, kdy u nově vzniklého jedince může dojít s určitou pravděpodobností k mutaci náhodného prvku v jeho genu.

Genetické algoritmy představují optimalizační metodu, která je snadno realizovatelná a nenáročná. Pro registraci medicínských dat jde o hojně využívanou metodu, která je využívána pro monomodální i multimodální data [13,14]. Některé metody využívají i kombinací více optimalizačních metod k nalezení globálního minima [15].

Simulované žíhání

Simulované žíhání vychází z poznatků o vytváření krystalů pomocí řízeného ochlazování žíhaného kovového materiálu. Krystalická struktura kovu je složena z nedokonalé krystalické mřížky obsahující malé defekty oslabující tvrdost materiálu. Vystavením materiálu vysoké teplotě, dochází ke zvýšení pohybu iontů a tím k rozpadu krystalické mřížky. Následným řízeným ochlazováním a zahříváním dochází k usazení iontů v nejnižším (energeticky výhodném) stavu a vzniká uspořádaná krystalická mřížka a kvalita žíhaného materiálu roste. Aby celý proces byl úspěšně proveden, ochlazování materiálu musí proběhnout dostatečně pomalu a teplota nesmí klesnout na příliš nízkou teplotu. [10, 16]

Kvalita metody simulovaného žíhání je závislá na volbě kroku řízeného ochlazování. Pomocí ochlazení se tato metoda snaží vyhnout uvíznutí v lokálním minimu, což je provedeno vysokými teplotními změnami, které se s klesající teplotou snižují. Teplotní změny musí být dostatečně velké, aby se algoritmus dostal z lokálního minima, ale nesmí být příliš velké, aby nedošlo k přeskočení globálního minima. Dalším stochastickým prvkem, který má

za účel vyvarovat se uvíznutí v lokálním minimu, je určitá pravděpodobnost toho, že bude vybrán prvek s horším řešením, než je optimální. To umožňuje metodě dostat se z lokálního minima v případě uvíznutí. [10,11]

Metoda rojení částic

Tato metoda vychází z poznatku chování ptačího hejna, kde každý jedinec v hejnu rozhoduje o směru a rychlosti svého letu individuálně, ale výsledkem je synchronizovaný pohyb hejna ptáků. Princip metody spočívá ve vložení určitého počtu částic do prostoru definovaného parametry kritériální funkce. Každá z částic nese dvě informace. První o vektoru rychlosti a druhou o pozici svého nejlepšího dosaženého řešení, informace se aktualizují v každé iteraci. Tyto částice mezi sebou komunikují a pohybují se na základě vztahu (2.22) [10].

$$v^{t+1} = wv^t + \phi_1 U_1 (b^t - x^t) + \phi_2 U_2 (l^t - x^t) \quad (2.22)$$

$$x^{t+1} = x^t + v^{t+1}$$

Kde x^t je pozice částice v iteraci t , v^t je rychlost v iteraci t , b^t je pozice nejlepšího dosud nalezeného řešení, l^t je pozice nejlepšího dosud nalezeného řešení v kroku t mezi všemi sousedy dané částice (dáno topologií populace) w , ϕ_1 a ϕ_2 udávají vliv setrvačnosti, nejlepší vlastní řešení rychlosti a nejlepší sousedovo řešení rychlosti, U_1 a U_2 matice s náhodně generovanými diagonálními hodnotami v intervalu $\langle 0,1 \rangle$.

S každou iterací dochází k aktualizování hodnot všech částic, takže se celý roj pohybuje prostorem přípustných řešení, přičemž je přitahován ke slibným místům. Je důležité volit koeficienty tak, aby nedocházelo k nekonečnému zrychlování a částice zůstali v prostoru přípustných řešení. [10,11]

3. Praktická část

V této kapitole budou rozebrány praktické úlohy, které byly zadány v diplomové práci. Prvním bodem je předzpracování obrazu, tedy odstranění patientského stolu a schodovitého artefaktu a v druhém bodu je rozebráno prostředí pro registraci objemových dat mozku. Celý program byl vytvořen v grafickém uživatelském prostředí (GUI) programu MatLab 2011b a odzkoušen na školním serveru IBM (12 jádrový procesor, 48GB RAM).

V praktické části této práce bylo zvoleno pro registraci 3D objemových dat simplexové metody pro nalezení globálního extrému, lineární interpolační metody a Kosinova kritéria pro výpočet podobnostní funkce. Před samotnou registrací bylo nutné předzpracovat vstupní data a odstranit z nich neúžitečné informace v podobě patientského stolu a odstranění schodovitého artefaktu způsobeného při snímání rentgenové počítačové tomografie sekvenční metodou.

3.1. Předzpracování obrazu

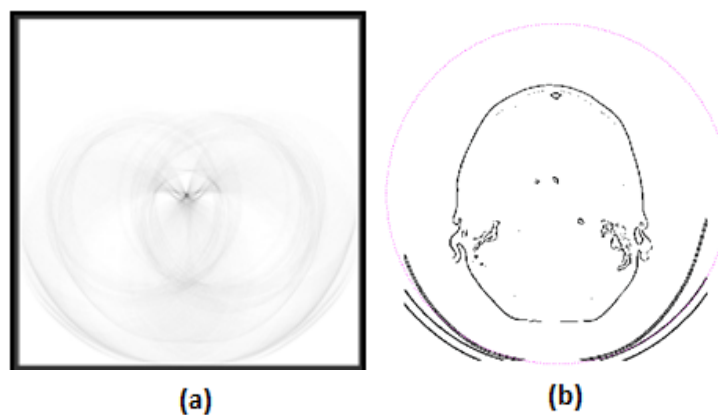
Data, které jsou použita pro registraci obrazu, jsou zatížena, výše zmíněnými, artefakty a neúžitečnými informacemi. Pro získání nejlepšího výsledku slícování dat, při kterém je používáno metody globální transformace, je nutné eliminovat veškeré neúžitečné informace z dat, které způsobují, že na data nelze aplikovat globální transformační funkci pro dosažení nejvhodnější registrace. V praktické části je pro odstranění patientského stolu využita metoda na základě detekce stolu podle obsahu objektů v obraze a zmíněn koncept pro odstranění stolu pomocí Houghovy transformace. Pro odstranění schodovitého artefaktu bylo využito programu vyhlazující schodovitý artefakt pomocí registrace dat fázovou korelací a gradientní metodou.

3.1.1. Odstranění patientského stolu

V této podkapitole budou popsány obě metody pro odstranění patientského stolu. Koncept metody využívající Houghovy transformace a metodu detekce patientského stolu podle obsahu objektů v obraze, která je použita v praktické části této práce. Jak bylo zmíněné v teoretické části (viz kapitole Odstranění patientského stolu), na každé sadě obrazových dat, je poloha hlavy pacienta jiná. Vzhledem k faktu, že patientský stůl je ve všech sadách měření stejný, je nutné odstranit patientský stůl, aby bylo možné použít globální transformační funkce.

Houghova transformace

Vstupem pro Houghovu transformaci je hrubá hranová reprezentace obrazu. Tu dostaneme z původního obrazu, na který prvně aplikujeme masky pro detekování horizontálních a vertikálních hran, čímž se zvýrazní hrany v obraze a potlačí neužitečná informace pro samotnou Houghovu transformaci. Dalším krokem pro vytvoření hrubé hranové reprezentace je obraz se zvýrazněnými hranami binarizovat podle stanoveného prahu, čímž je obdržena hrubá hranová reprezentace. Volba prahu je volena tak, aby byla odstraněna měkká tkáň a informace v obraze co nejvíce obsahoval strukturu o intenzitě samotného stolu. Po předzpracování dat může dojít na samotnou Houghovu transformaci. Dosazením proměnných (střed útvaru x_0, y_0 , poloměrů r_1, r_2 a úhlu φ) do vzorce (1.1) dostaneme konkrétně zvolenou kružnici nebo elipsu, kterou aplikujeme postupně na každý pixel v obraze. Pokud se v definované vzdálenosti od pixelu, ze kterého vedeme kružnici, nachází hodnota 1, přičte se do pomocné proměnné zisk. Proměnná s nejvyšším ziskem označuje střed útvaru (viz Obrázek 5a), který nejlépe popisuje matematický předpis (viz Obrázek 5b). Houghova transformace byla vytvořena s ohledem na to, že v každém snímání není dodrženo konstantní měřítko. Algoritmus postupně zkouší jednotlivé hodnoty poloměrů, ze kterých následně vybere ten, který se v obraze nejvíce shoduje s předpisem. Pro vyšší úspěšnost detekce, snížení časové a výpočetní náročnosti jsou vymezena oblast středu hledaného objektu, ve kterém by se měl nalézat střed kružnice (případně elipsy) a oblast, ve kterém dochází k vyhledávání objektu pomocí zvoleného předpisu.




Obrázek 5 – Detekování stolu Houghovou transformací (invertované snímky): obrázek (a) zobrazuje Houghův prostor pro kružnice s nalezeným nejlepším matematickým předpisem (tmavý bod ve středu). Obrázek (b) zobrazuje nalezenou nejlepší shodu s matematickým předpisem v detekovaném obrazu

Tato metoda časově náročná a výsledky nejsou tak přesné jako u druhé metody. Z toho důvodu bylo nutné provést u předzpracování většího odfiltrování vstupních dat, kdy výstupem hrubé hranové reprezentace byl pouze stůl a kostěná struktura lebky na přechodu kost - vzduch. Výsledkem detekce není přesně lokalizovaný vnitřní nebo vnější plášť stolu,

nýbrž jeho kombinace. Ale i po hlubší filtraci není nalezena požadovaná struktura (viz Obrázek 5 vpravo), proto se v algoritmu tato metoda nevyužívá.

Detekce stolu podle obsahu objektů v obraze

Nalezení stolu pomocí této metody, je mnohonásobně výpočetně méně náročná než předchozí. Metoda je založena na detekování všech objektů v obraze a vypočtení jejich obsahu. Při detekci stolu touto metodou jsou nejprve vstupní data binarizována pomocí prahu, který je zvolen Otsu metodou, který odděluje důležité informace (části stolu a hlavu) od neužitečných. Následně se rozdělí všechny objekty na samostatné elementy, algoritmem pro nalezení hranic. Na Obrázek 6 (vlevo) je možné pozorovat dohromady 6 detekovaných elementů v obraze (levý vnitřní plášť je u středu obrazu přerušen, je tedy brán jako dva elementy), pro které jsou pomocí implementované funkce vypočteny obsahy, ze kterých je vyhledána nejvyšší hodnota. Jelikož je obsah hlavy ve všech místech, kde se nachází patientský stůl podstatně větší než okolní elementy, nalezením maximální hodnoty tedy nalezneme hodnotu popisující obsah hlavy. Dalším krokem je vyplnění všech elementů v obraze. To je provedeno z důvodu, kdy po binarizaci vstupních dat dojde k odstranění části měkkých tkání a výskyt dutin v oblasti hlavy se projevuje jako vzduch. Vyplnění hlavy je nutné k vytvoření makety, která je následně využita v dalších částech programu. Tím se předejde ztrátám důležité informace v posledním kroku a maketa hlavy bude následně využita pro výpočet kriteriální funkce podobnosti obrazů. Po vyplnění všech elementů dochází k odstranění všech hodnot menších, než obsah maximálního elementu v obraze. Tak dostaneme pouze obraz se samostatnou hlavou pacienta, který odečteme od vytvořeného binárního obrazu v prvním kroku a získáme tak samostatný stůl (viz Obrázek 6 vpravo). Výsledkem je detekovaný patientský stůl a další možné neodfiltrované elementy (např. podložka podkládající pacientovu hlavu).



(a)

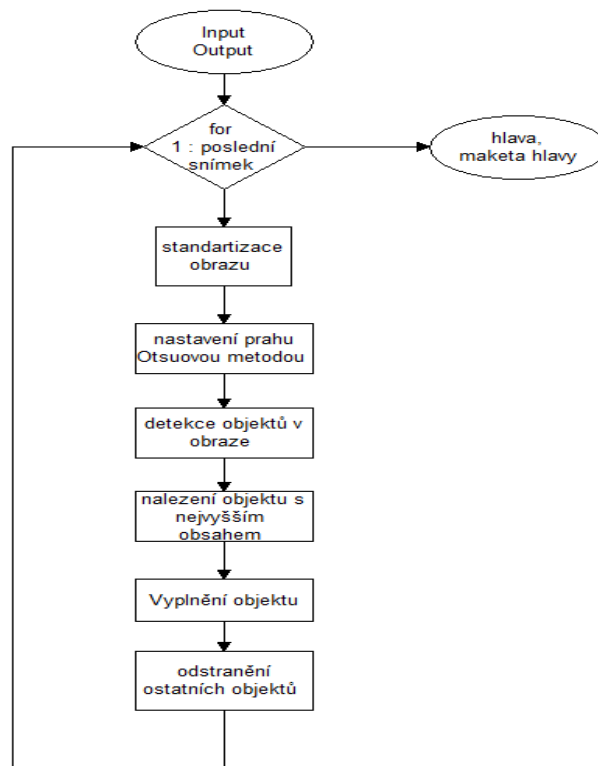
(b)

Obrázek 6 - Detekování stolu podle obsahu objektu: obrázek (a) zobrazuje binarizovanou maketu hlavy pacienta a kostru patientského stolu jednom řezu pomocí prahu získaného Otsu metodou. Snímek (b) zobrazuje samotnou konstrukci patientského stolu bez hlavy pacienta

Popis funkce:

```
function [obr,maketka] = pac_stul_velikost(obr)
```

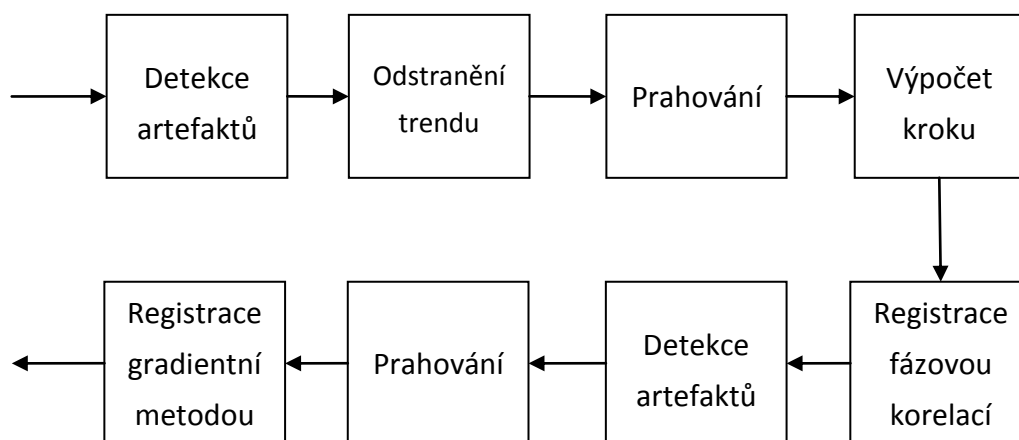
Vstup:
obr – 3D data s patientským stolem
Výstup:
obr – 3D data se samostatnou hlavou
maketka - 3D maketa hlavy



Obrázek 7 - Vývojový diagram odstranění pacientského stolu


3.1.2. Odstranění schodovitého artefaktu

Jak bylo zmíněno v kapitole Vyhlazení nasnímaných obrazů, data jsou zatížena schodovým artefaktem, který znemožňuje registraci. Tento fakt nebyl při zadávání práce znám a korekce tohoto artefaktu tedy přesahuje zadání diplomové práce. Po domluvě s vedoucím práce je pro korekci použit externí algoritmus popsany v [20]. Pro základní představu zde bude tento algoritmus stručně představen.



Obrázek 8 - Blokové schéma odstranění schodovitého artefaktu

Vstupem pro tuto metodu jsou 3D data se zmíněným schodovitým artefaktem (viz Obrázek 9a [20]). Prvním krokem je detekování pozic přechodů pomocí porovnání sousedních obrazů podobnostní metodou Euklidovské vzdálenosti (viz vzorec 2.13). Výsledkem je vektor hodnot s výraznými peaky zatížen trendem. Tento trend je odstraněn derivováním vektoru, čímž jsou hodnoty vyrovnány do jedné roviny. V dalším kroku je nastaven práh pro detekování peaků, který je vypočten jako průměr absolutních hodnot jednotlivých vektorů. Po detekování peaků dochází ke stanovení kroku pomocí mediánu, ve kterém se schodovitý artefakt projevuje. Nyní dochází k samotné registraci, tedy korekci schodovitěho artefaktu. První částí korekce je provedena pomocí registrace fázovou korelací, kdy dochází k vyhlazení obrazu a je odstraněna převážná část schodovitěho artefaktu (viz Obrázek 9b [20]). Následuje nové detekování pozic schodovitěho artefaktu, prahování detekovaných peaků a korekce pomocí registrace gradientní metodou. Výsledkem jsou vyhlazená 3D data (viz Obrázek 9c [20]).

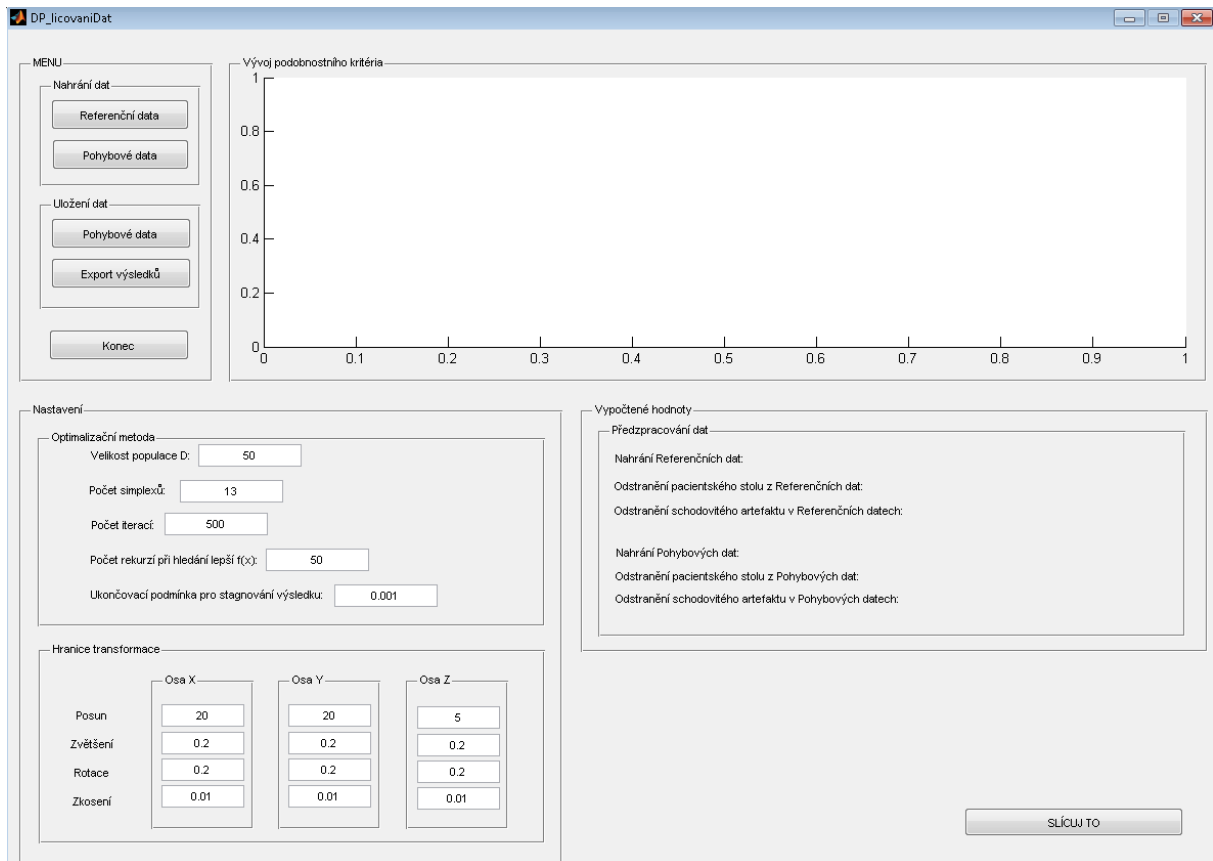


Obrázek 9 - Zobrazení průběhu odstranění schodovitěho artefaktu Na snímku (a) je průřez vstupních dat se schodovitým artefaktem. Obrázek (b) zobrazuje vyhlazení metodou fázové korelace. Snímek (c) popisuje výsledné vyhlazení pomocí gradientní metody.

3.2. Uživatelské prostředí

Grafické uživatelské prostředí GUI (viz Obrázek 10) je složeno z pěti základních částí, ve kterých si uživatel může zvolit veškeré operace s daty, navolit hranice generování prvotní populace optimalizační metody, zobrazit graf s vývojem podobnostní funkce, informačním panelem o stavu nahrání dat a jejich předzpracování. Posledním prvkem je spuštění

samotné registrace. Důvodem vysoké výpočetní náročnosti programu, bylo zvoleno toto základní rozhraní. Po opětovném přihlášení na server byl program MatLab natolik výpočetně zaměstnán, že vykreslování dat a důležitých hodnot nefungovalo a i samotný program se přestal reagovat.



Obrázek 10 - Grafické prostředí programu Registrace objemových dat

3.2.1. Menu

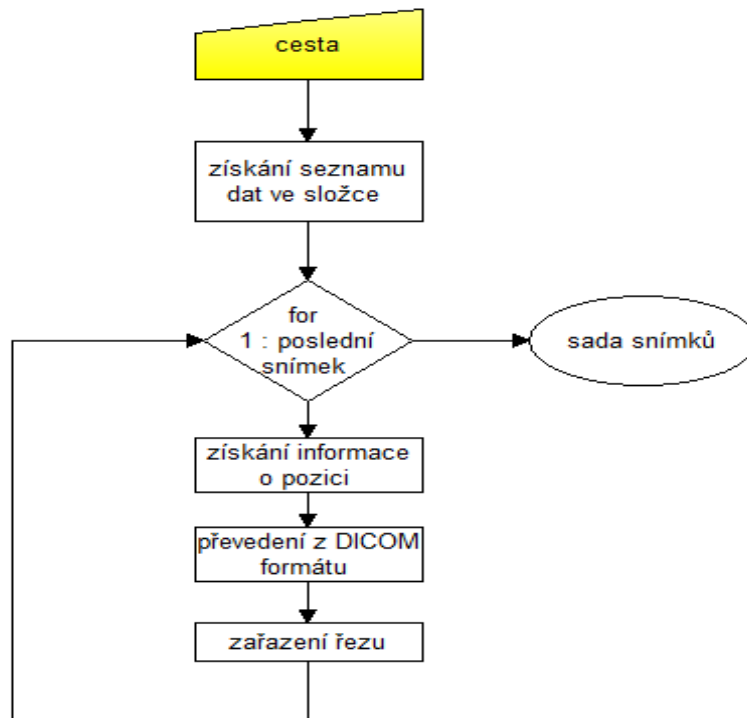
Nabídka Menu (Obrázek 11) se člení do tří skupin, které zde lze využít. Jsou jimi Nahrání dat, které umožní uživateli nahrát data formátu DICOM (Digital Imaging and Communications in Medicine, standard využívaný v oblasti zdravotnictví pro přenos, tisk, ukládání a zobrazování medicínských dat), Uložení dat, které umožňují uživateli uložit registrovaná data do formátu DICOM a exportovat výsledky a Ukončení.



Obrázek 11 – Menu

- **Nahrání dat**

V tomto panelu je možné načíst referenční a pohybová data formátu DICOM, která jsou následně registrována v programu. Prvně si uživatel pomocí grafického prostředí navolí cestu, ve které se data vyskytují. Jakmile je známa cesta, dochází k načtení seznamu souborů ve složce. Díky tomu je možné zjistit počet souborů ve složce (od celkové hodnoty je důležité odečíst poslední dvě hodnoty, které obsahují znaky „.“ a „..“ sloužící jako prvek pro přesun do nadřazených složek). Jakmile je znám počet souborů, je možné pomocí *for* cyklu jeden po druhém načíst do jedné matice. Dříve než je soubor načten, je nutné zjistit pomocí funkce *dicominfo* informace, které tyto soubory obsahují. Z důvodu nevhodného očíslování při získávání dat (1,10,100, namísto například formátu 001,010,100), dochází k chybnému seřazení řezů podle jejich string hodnoty názvu. Po vyvolání informace *instantNumber*, se zobrazí pořadové číslo, ve kterém byl řez nasnímán. Tento údaj slouží jako identifikátor, který je použit, jako hodnota řezu, kam je snímek v matici uložen. Následně jsou tato data předzpracována (viz odstranění patientského stolu a schodovitého artefaktu).



Obrázek 12 - Blokové schéma načtení registrovaných dat

Popis funkce:

function obr = nacteni(folder_name)

Vstup:
folder_name – cesta ke složce s DICOM daty
Výstup:
Obr – načtená data z DICOM formátu

- **Uložení dat**

Další možností v nabídce Menu je uložení registrovaných dat zpět do formátu DICOM pomocí tlačítka *Pohybová data. Export dat* slouží k uložení získaných dat jako je vývoj podobnostní funkce a vývoj transformačních parametrů do souboru *.mat, kde je možné si následně získané údaje přehledně zobrazit.

Popis funkce

function prevodDICOM(cil)

Vstup:
cíl – 3D data
Výstup:
převedená data do DICOM formátu (jednotlivé řezy)

- **Ukončení**

Poslední položkou je tlačítko *Konec*, které ukončí grafické prostředí a program MatLab.

3.2.2. Volba parametrů

V této části je možné zadat základní parametry pro optimalizační funkci, vhodná volba těchto parametrů má vliv na výsledek celé registrace.

Nastavení			
Optimalizační metoda			
Velikost populace D:	50		
Počet simplexů:	13		
Počet iterací:	500		
Počet rekurzí při hledání lepší f(x):	50		
Ukončovací podmínka pro stagnování výsledku:	0.001		
Hranice transformace			
	Osa X	Osa Y	Osa Z
Posun	20	20	5
Zvětšení	0.2	0.2	0.2
Rotace	0.2	0.2	0.2
Zkosení	0.01	0.01	0.01

Obrázek 13 - Nastavení vstupních parametrů optimalizační metody

- **Velikost populace D**

Velikost populace D, definuje počet náhodně vygenerovaných jedinců (jedinec populace D je soubor parametrů obsahující parametry transformace a podobnostní kritérium získané touto transformací), kteří se postupně vyvíjí, k hledanému řešení. Populace D, by se měla volit, tak aby splňovala podmínku $D \gg$ počet jedinců, kteří jsou vybráni do simplexu.

- **Počet simplexů**

Simplex je parametr udávající počet jedinců, kteří jsou využiti pro výpočet těžiště, přes které se překlápí jedinec s nejhorší hodnotou $f(x)$. Tento parametr by měl být volen jako počet parametrů geometrické transformace (dimenze prohledávaného prostoru) + 1, při afinní transformaci 3D dat, tedy 13 [12].

- **Počet iterací**

Tento parametr udává hodnotu pro počet cyklů optimalizační metody, při hledání nejvhodnějších parametrů transformace. Volba cyklů by měla být dostatečně velká, aby nedošlo k předčasnému ukončení optimalizace. Doporučuje se volit hodnotu v řádu stovek.

- **Počet rekurzí**

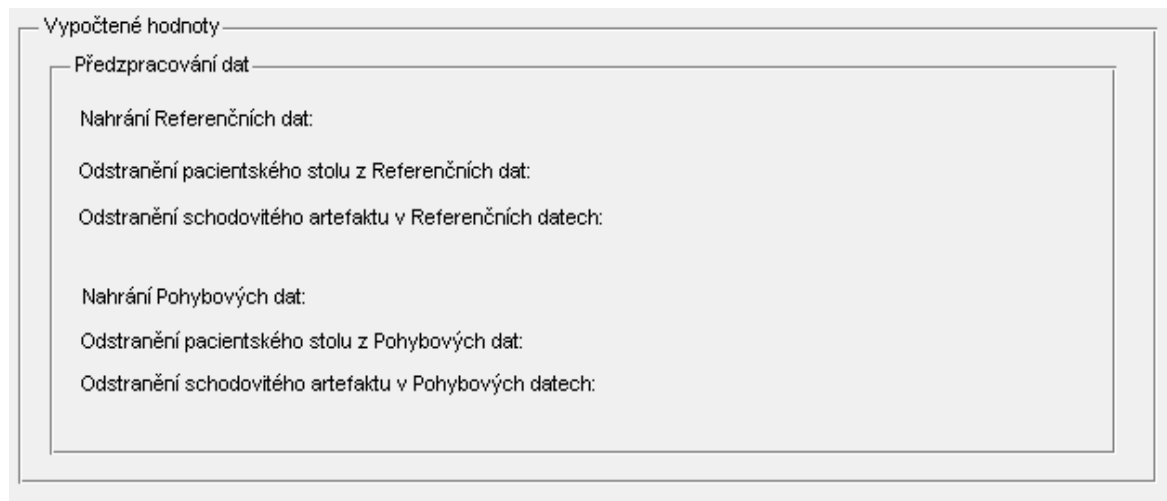
Počet rekurzí udává počet opakování, pokud není při překlopení přes těžiště simplexu nalezena lepší $f(x)$. S každou novou rekurzí dochází k výběru nového simplexu a přenesení hodnoty přes těžiště.

- **Nastavení parametrů populace D**

Nastavení těchto parametrů limituje hranice pro výběr rozsahu jednotlivých parametrů jedinců v populaci D. Mezi tyto parametry patří: posun, rotace, zvětšení a zkosení v osách x, y, z . Střední hodnoty jsou již přednastavené (hodnoty byly zvoleny na základě empirických měření), uživatel si tak volí jen rozpětí od této hodnoty.

3.2.3. Informační panel

Tento panel informuje o průběhu nahrání dat, odstranění schodovitého artefaktu a odstranění patientského stolu. Z důvodu vysoké náročnosti programu a komplikací získávání dat z podprogramů, zobrazení některých údajů bylo provedeno přes příkazový řádek. Jak bylo výše zmíněné, po opětovném připojení k serveru již program nereaguje na vyslané požadavky. Proto je vypisování funkcí zobrazováno přes příkazový řádek. Údaje, které se vypisují, jsou: počet iterací, počet rekurzí, hodnota $f(x)$ přenášeného jedince a soubor funkčních hodnot populace D.



Obrázek 14 - Informační panel

3.2.4. Grafické zobrazení vývoje registrace

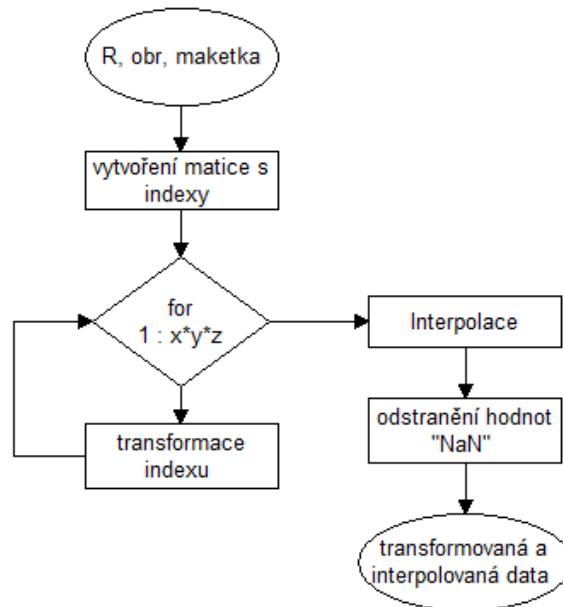
Grafické zobrazení vykreslí po ukončení registrace vývoj $f(x)$ v průběhu iterací. Graf z důvodu vysoké výpočetní náročnosti, nevykresluje data v průběhu, ale až po dokončení.

3.3. Registrace

3.3.1. Transformace

Transformace 3D objemových pomocí pevně zadaných parametrů, byla jedním z cílů semestrálního projektu. Pro snížení časové náročnosti, bylo hlavním cílem omezení počtu vnořených 3 vnořených *for* cyklů pro vytvoření polohových souřadnic každého voxelu – příliš časově náročné. Transformace dat o velikosti $512 \times 512 \times 224$ trvala přibližně 10 minut, proto bylo nutné eliminovat počet *for* cyklů na minimum. Po odstranění přebytečných 2 *for* cyklů se přepočítání matice několikanásobně snížilo a nyní dosahuje hodnoty něco málo přes 2 minuty.

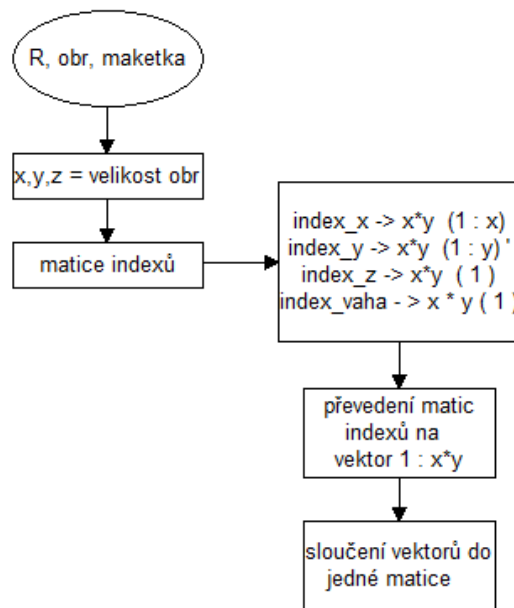
Popis metody transformace je zobrazen na Obrázek 15. Vstupem pro registraci obrazů je vstupní obraz, maketa vstupního obrazu a transformační matice \mathbf{R} . Prvním krokem je vytvoření matice s indexy, které jsou přepočteny vynásobením s transformační maticí \mathbf{R} podle vzorce (1.3) a tím získány nové souřadnice transformovaných dat. Následně dochází k interpolaci dat do definovaného souřadnicového pole a v posledním kroku jsou odstraněny hodnoty *NaN*, které označují souřadnice vyskytující se mimo původní data. Tyto hodnoty jsou vloženy funkcí *interp3*, která je rozepsána níže. Výstupem jsou registrovaná a interpolovaná data obrazu a makety obrazu. Bloky vytvoření matice a přepočet jsou detailněji popsány na Obrázek 16 a Obrázek 17.



Obrázek 15 - Vývojový diagram registrace a interpolace

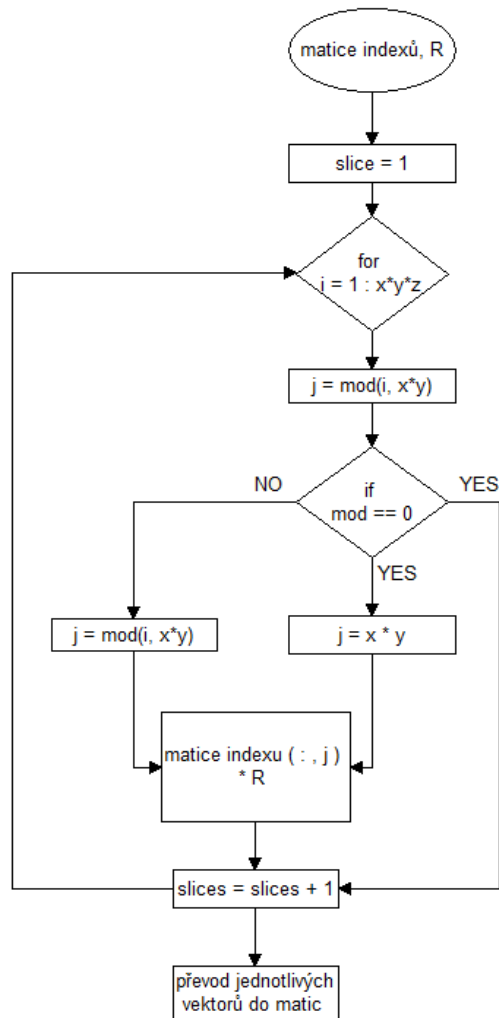
Prvním krokem vytvoření matice indexů (viz Obrázek 16) je zjištění velikosti vstupních obrazových dat. V dalším kroku dochází k vytvoření matic s indexy, které se budou geometricky transformovat. Nejdříve se vygeneruje matice s indexy pro osu x , o velikosti 512x512 pixelů s hodnotami od 1 : x v každém řádku, poté se vytvoří matice s indexy pro osu y (kterou lze jednoduše vytvořit jako invertovanou matici indexů k matici x), matice pro osu z (čili označení pozice řezu ve 3D obrazu), je tvořena hodnotami 1. Poslední matice, je tzv. váhová, která udává hodnotu transformace pro homogenizovanou transformační matici.

Tyto matice s indexy se v dalším kroku převedou na vektor a sloučí pod sebe do jedné matice (viz Obrázek 16). Takto jsou získány všechny kombinace indexů (x,y) , v prvních dvou vektorech. Třetí vektor (obsahující v původním stavu hodnoty = 1), a indexuje hodnoty pro osu z , které se po každém projetí počtu cyklu $x*y$ zvýší o 1. Poslední vektor udává váhu matice. Tento vektor je důležitý aby bylo možné vynásobit homogenizovanou matici o rozměru (4x4). Tím dochází k vytvoření kombinací všech hodnot indexů ve vstupní matici.



Obrázek 16 - Vývojový diagram vytvoření matice indexů pro registraci

Z Obrázek 17 je vidět, že po vytvoření matice s indexy, upravené pro transformaci obrazu bez využití více *for* cyklů, je vytvořena pomocná proměnná *slice*, která slouží pro definování indexů v ose *z*. V každém kroku *for* cyklu (délka *for* cyklu je dána součinem délek stran *x*, *y* a *z*) se vypočítá zbytek po dělení (mod) současného kroku vůči součinu rozměrů jednoho řezu. Pokud je výsledek nenulový, hodnota odkazuje na souřadnici v matici indexů definující souřadnici *x*, *y*, *z* a váhu matice, které jsou vynásobeny s transformační maticí *R*. Výpočet matice *R* se provádí pomocí funkce *promenna*, kde jsou hodnoty z vektoru parametrů transformace přepočteny do transformační matice (4x4) podle vzorce (1.3). V této funkci dochází k vynásobení matic, pro posun, rotaci, zvětšení a zkosení, s definovanými parametry. Po transformaci dat je opětovně porovnán zbytek po dělení současného kroku a součinu rozměru řezu. Pokud je hodnota nenulová, proměnná *slice* se nemění. Pokud je hodnota zbytku po dělení rovna nule, dochází k přičtení jedné k proměnné *slice*, tím dochází k posunu po ose *z* a transformaci dalšího řezu v objemových datech. Po získání přepočtených parametrů je nutné izolovat hodnoty pro jednotlivé osy. Tyto parametry se získávají, tak že z výsledné buňky s přepočtenými parametry, se pomocí funkce *cell2mat* převedou hodnoty do matice a z té jsou pomocí podmínky pro výběr každého 3. prvku od první pozice získány data *X*, pro výběr každého 3. prvku od druhé pozice získány data *Y* a pro výběr každého 3. prvku třetí pozice získány hodnoty data *Z*. Pro zachování přehlednosti vývojového diagramu je na Obrázek 17 použita podmínka *while* pouze jednou a výsledek z prvního cyklu je po přepočtení použit znovu, v programu se ta samá podmínka (se stejným výsledkem) vypočítává znovu po přepočtení indexu.



Obrázek 17 - Vývojový diagram transformace dat

Popis funkce:

function [cil, maketka] = rigid_trans2(R, obr, maketka)

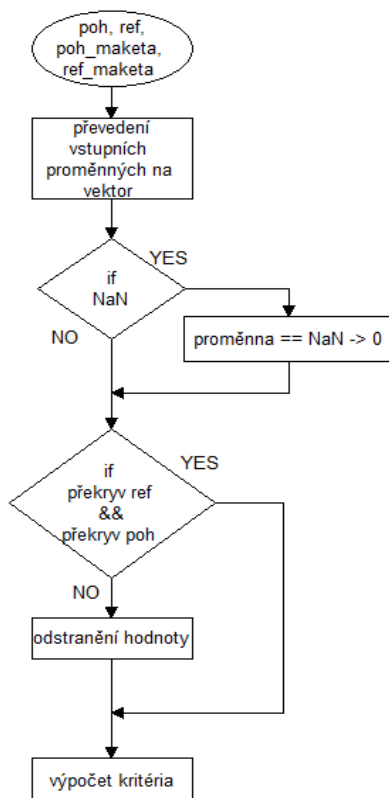
Vstup:
R – transformační matice (4x4)
obr – pohybová 3D data
maketka – 3D binarizovaná pohybová data s detekovanou hlavou
Výstup:
cil – transformovaná a interpolovaná 3D pohybová data
maketka – transformovaná a interpolovaná 3D binarizovaná data s detekovanou hlavou

3.3.2. Interpolace

Výpočet lineární interpolace je založen na základě získaných přepočtených indexů v předchozím kroku, které jsou již izolovány v samostatných maticích pro konkrétní osy. Tyto hodnoty jsou využity k interpolaci dat transformovaného obrazu a makety, která se využije při výpočtu podobnostního kritéria. K Interpolaci dat je použito funkce `interp3`, kde je možné vybrat jedné z metod: `nearest`, lineární (defaultní metoda), `cubic spline` a `trikubické` interpolace. Posledním krokem je výše zmíněná podmínka pro změnu všech `NaN` hodnot na 0. Hodnoty `NaN` jsou vygenerovány v případě, že při transformaci je zadána hodnota, která se nevyskytuje v transformovaném obrazu. Pro správný výpočet podobnostního kritéria je nutné proto tyto hodnoty odstranit a nahradit nulou.

3.3.3. Výpočet podobnostního kritéria

Výpočet podobnostního kritéria Kosinovou metodou, popisuje míru podobnosti mezi referenčním a pohybovým obrazem. Výpočet byl přizpůsoben pro zpracovávanou sadu dat. Pro získání přesnějších hodnot podobnostního kritéria je hodnota vypočtena z překryvu makety referenčního a pohybového souboru dat (získaných při odstranění patientského stolu). Tato podmínka je zavedena z důvodu získání relevantních dat. Velkou část obrazu tvoří vzduch (v podobě neužitečné informace), který by mohl značnou mírou ovlivňovat výsledek registrace. Voxely, na nichž se obě hlavy nepřekrývají, jsou odstraněny ze souboru referenčních i pohybových dat a převedeny z matice na vektor, který je následně použit při výpočtu samotného kritéria.



Obrázek 18 - Vývojový diagram výpočtu Cosinova kritéria

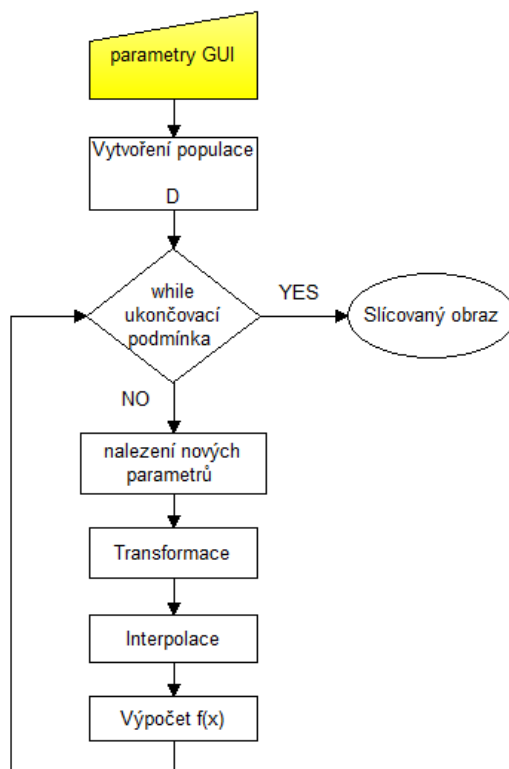
Popis funkce:

function kriterium = cos_kriterium(cil,cil1, maketa, maketa1)

Vstup:
cil – 3D referenční obrazová data
cil1 – 3D pohybová obrazová data
maketa – 3D binarizovaný obraz hlavy referenčního obrazu
maketa1 - 3D binarizovaný obraz hlavy pohybového obrazu
Výstup:
kriterium – hodnota podobnostní funkce

3.3.4. Optimalizace

V této části bude popsána registrace obrazu po praktické stránce. Po nahrání dat, předzpracování dat a nastavení vstupních hodnot pro optimalizační funkci, je možné spustit samotnou registraci obrazu. Princip metody vychází z vývojového diagramu (viz Obrázek 19).



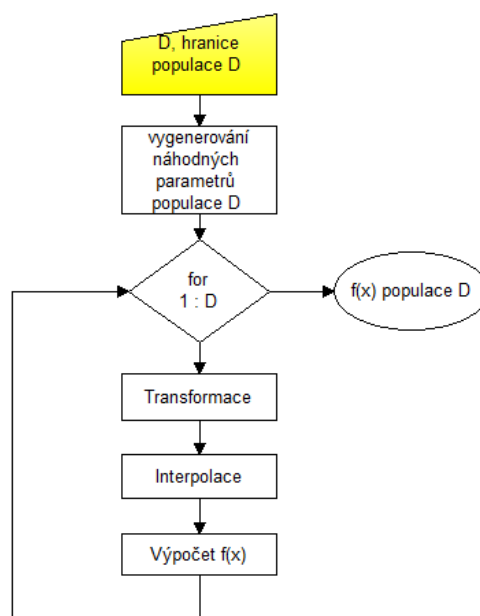
Obrázek 19 – Vývojový diagram schéma registrace

Vstupem pro tuto metodu jsou hodnoty zadané uživatelem v grafickém uživatelském prostředí. Prvně dochází k vytvoření populace D s náhodně zvolenými parametry (omezené hranicemi) transformace a k nim se vypočtou podobnostní funkce $f(x)$. Tito členové populace se budou v následujícím *while* cyklu vyvíjet dokud nenastane podmínka k ukončení cyklu (v programu je nastavena podmínka, která ukončuje program v případě ukončení počtu iterací). Druhou podmínkou, která se využívá u této metody je překročení limitu rozdílu podobnostní funkce nejlepšího a nejhoršího člena populace.

Vývojový diagram vygenerování populace o velikosti D jedinců je možné vidět na Obrázek 20. Vstupní parametry jsou definovány uživatelem v grafickém prostředí a k nim jsou přidružena vstupní obrazová data s jejich maketami. Výstupem funkce je populace D s vypočtenými funkčními hodnotami.

Prvním krokem je vygenerování D náhodných vektorů parametrů geometrických transformací v rozsahu vymezených zvolenými hranicemi, které uživatel taktéž zvolí v grafickém prostředí. Následuje cyklus *for*, který pro každého jedince provede transformaci pohybového obrazu s parametry konkrétního jedince, interpolaci a následně vypočte $f(x)$, která určuje kvalitu každého jedince v populaci. Nyní je tedy vygenerována výchozí populace o D jedincích, a určité průměrné kvalitě, která bude každou iterací optimalizace blíže funkční

hodnotě v globálním optimu. Bloková schémata transformace, a výpočtu kritériální funkce budou popsána v samostatných kapitolách.



Obrázek 20 Vývojový diagram generování populace D

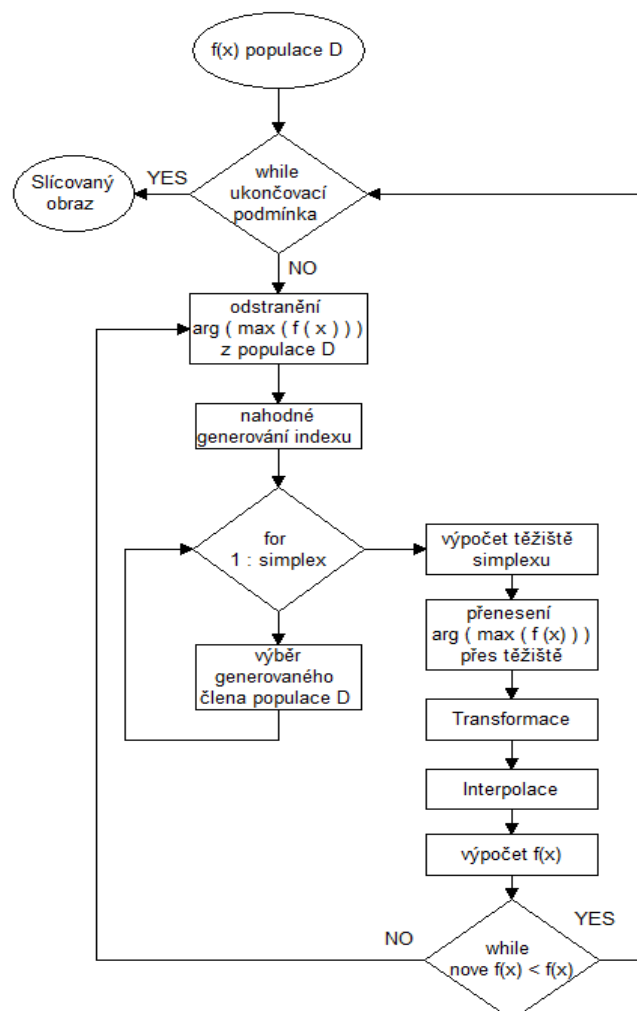
Na Obrázek 21 je podrobnější popis získání nového podobnostního kritéria $f(x)$. Vstupem pro tento blok jsou data zadaná uživatelem (počet simplexů, počet iterací, počet repetice a obě sady obrazových dat i s maketami).

Prvním krokem v programu je nalezení jedince s nejhorším podobnostním kritériem $f(x)$ v populaci D, dále označován jako $\arg(\max(f(x)))$, pomocí funkce *min*. Tento jedinec se z populace vyjme spolu s jeho funkční hodnotou $f(x)$. Následně se z populace bez $\arg(\max(f(x)))$ vybere zvolený počet jedinců pro výpočet těžiště simplexu. Výběr jedinců simplexu se provádí náhodně pomocí funkce *randi*. Funkce vygeneruje zvolený počet hodnot, definovaný proměnnou *pocetSimplexu*. Tyto hodnoty představují indexy pro výběr z jedinců populace v rozsahu $(1 : D - 1)$ a dochází k výpočtu jejich těžiště (průměrem pro každý parametr). Přes vypočtené těžiště se podle vzorce (2.1) překlopí vyjmutý $\arg(\max(f(x)))$ a získají se nové parametry transformace. Těmito parametry se pohybový obraz transformuje, následně interpoluje a nakonec vypočte nové $f(x)$.

$$y = \text{teziste} + \text{teziste} - \text{worst} \quad (3.1)$$

Kde y – je vektor s novými parametry transformace, **teziste** – průměr parametrů všech jedinců v simplexu, **worst** – argument ($\max(f(x))$)

Nově vypočtené kritérium $f(x)$ se porovná s $f(x)$ nejhoršího (odstraněného) jedince, pokud je nově získané $f(x)$ lepší než staré, je přijat nový jedinec do populace D spolu s jeho funkční hodnotou. Následně dochází k nalezení nového $\arg(\max(f(x)))$, dochází k vynulování podmínky pro počet repetice, je přičten cyklus k počtu iterací a cyklus se opakuje. Pokud se nenajde lepší $f(x)$ zachovává se nejhorší jedinec a cyklus se opakuje, pomocí rekurzivního cyklu (funkce modifikace). Rekurzivní funkce, je funkce, která v průběhu odkazuje na sebe samotnou, v tomto případě, pokud není nalezen lepší jedinec, hodnoty $\arg(\max(f(x)))$ jsou zpětně uloženy v populaci a dochází k výběru nového simplexu a cyklus se opakuje dokud není nalezen lepší $f(x)$. Pokud v počtu repetice není nalezen lepší $f(x)$, je nejhorší $f(x)$ nahrazen $f(x)$ těžištěm náhodně zvoleného simplexu a cyklus se opakuje, tato podmínka je z vývojového diagramu vynechána z důvodu srozumitelnosti diagramu.



Obrázek 21 - Vývojový diagram Simplexové metody

Popis funkce:

```
function [vyslednyPar,vyvoj,hodnoty] = optimalizaceCRS  
(D,limit,poh,ref,ref_maketa,poh_maketa,hranice,pocetSimplexu)
```

Vstup:
D – velikost populace D
Limit – počet iterací
poh – pohybová 3D data
ref – referenční 3D data
poh_maketa – pohybová 3D maketa
ref_maketa – referenční 3D maketa
hranice – hranice parametrů pro generování populace D
pocetSimplexu – počet použitých jedinců k výpočtu těžiště
Výstup:
vyslednyPar – nalezená nejlepší f(x)
vyvoj – vývoj f(x) od první po poslední iteraci
hodnoty – vývoj parametrů transformace od první po poslední iteraci
kriterium – podobnostní kritéria výsledné populace D

Popis podfunkce:

```
function [populace,kriterium,konec,hodnoty,iter2,y,pomKrit] = modifikace  
(kriterium,populace,poh,ref,poh_maketa,ref_maketa,hodnoty,D,iter2,pocetSimplexu)
```

Vstup:
populace - počet generovaných jedinců
kriterium - f(x) generované populace
konec - podmínka pro ukončení
hodnoty - vývoj parametrů
iter2 - počet repetice
pomKrit - f(x) hodnoty přenesené přes těžiště simplexu
Výstup:
kriterium - f(x) generované populace
populace - počet generovaných jedinců
poh - 3D registrovaná pohybová data
ref - 3D registrovaná referenční data
poh_maketa - 3D maketa pohybových dat
ref_maketa - 3D binární obraz
hodnoty - vývoj parametrů
D - velikost populace
iter2 - počet repetice
pocetSimplexu - počet hodnot populace D pro výpočet těžiště

4. Diskuze výsledků

4.1. Program pro transformaci obrazu pevnými parametry

V bodu 2 zadání diplomové práce bylo zadáno vytvořit algoritmus pro transformaci 3D dat pevnými parametry. Program je vytvořen podle schémat na Obrázek 15, Obrázek 16 a Obrázek 17. Pevná data jsou ve finálním registračním algoritmu nahrazena transformačními parametry generovanými optimalizační funkcí.

Transformace byla upravena pro snížení časové náročnosti podle Obrázek 16 a Obrázek 17 (viz kapitola Transformace), pro další snížení časové náročnosti by bylo vhodné přepsání cyklu *for* do cyklu *parfor*, kdy by se výpočet indexů snížil díky paralelnímu výpočtu, což by ovšem vyžadovalo další modifikace algoritmu pro afinní geometrickou transformaci.

Data získaná po transformování odpovídají teoretickým předpokladům. Po transformaci dat následuje interpolace, která pro kterou je zvolena lineární metoda. Důvodem volby jsou nižší časové a výpočetní nároky a výsledná data nejsou zatížena příliš velkou chybou, která by se projevovala při porovnání zkušebních pohybových a referenčních dat.


4.2. Odstranění patientského stolu

V bodu 3 zadání diplomové práce bylo vytvoření konceptu odstranění patientského stolu z dat. Pro tento bod byly vytvořeny dva koncepty. První pomocí detekce objektů v obraze Houghovou transformací, druhý pomocí obsahu objektů v obrazech.

Detekce, pomocí Houghovy transformace, našly oblast výskytu patientského stolu v datech správně až po výrazné segmentaci dat (odstraněním měkkých tkání pomocí vyššího prahu) a stanovení oblasti výskytu patientského stolu. Před tímto, docházelo k nalezení vhodnějších objektů hledaného matematického předpisu po obvodu lebky. Další kroky již proběhly se značnou chybou. Nalezení vnitřní nebo vnější části patientského stolu neproběhlo správně. Výsledkem byla kombinace vnitřní a vnější části stolu, která odpovídala více tvaru hledaného objektu. Metoda také v porovnání s níže popsanou metodou je značně časově náročná.

Detekce pomocí obsahu objektů v obraze byla v tomto směru úspěšnější. Tato metoda poskytuje získání další užitečné informace o datech, se kterými bylo v dalších částech programu pracováno. V této metodě nebylo základem nalezení patientského stolu, nýbrž nalezení

hlavy a odstranění zbylých neúčinných dat. Výsledný, vyplněný, detekovaný objekt, se převedl i do binárních hodnot a slouží jako podmínka pro výběr překrytých dat k výpočtu podobnostního kritéria.




(a)

(b)

Obrázek 22 - Odstranění patientského stolu snímek (a) zobrazuje vstupní data před odstraněním patientského stolu. Snímek (b) zobrazuje data po odstranění patientského stolu

Při odstranění patientského stolu metodou detekce objektů v obraze, která je využita v diplomové práci, je základní kostra stolu odstraněna celá. Ze zobrazených dat (viz Obrázek 23) jsou vidět části neodstraněných struktur podložky. Na Obrázek 23a,c je zřetelně vidět struktura podložky na patientsově hlavě. To je způsobeno váhou, kterou hlava působila na podložku, čímž došlo k otlacení. V Obrázek 23b,c je vidět ze dvou úhlů zbytek části podložky, kterou program pro odstranění patientského stolu zahrnul jako část hlavy a nebyla odstraněna spolu s dalšími strukturami stolu. Tyto vzniklé artefakty, by neměly mít velký vliv na později transformovaná data.




(a)

(b)

(c)

Obrázek 23 - Zobrazení zbylých částí patientského stolu snímek (a) zobrazuje detail otláčeniny způsobený podložkou Snímek(b) zobrazuje neodstraněnou část podložky, která je z jiného úhlu vidět na snímku(c) spolu se zmíněným otláčením

Při programování metody obsahu objektu v obraze bylo zohledněno faktu, že v žádné ze sérií dat není obsah patientského stolu větší než obsah hlavy. Algoritmus by mohl potenciálně selhat při snímání temenní části lebky, avšak v datech, která byla k dispozici, končí patientský stůl vždy dříve. Pro případ, že by stůl nekončil dříve, by stačilo pouze vytvořit a začlenit podmínku pro výpočet koeficientu kulatosti objektu v obraze (viz MatLab funkce „ipexroundness“). A odstranit vše co nesplňuje určitou hranici nebo v případě lepších výsledků, ponechat objekty, které splňují určitou podmínku. Objekty s kulatým, eliptickým, oválným,... tvarem přesahují koeficient 0,9 (viz Obrázek 24b). Hodnoty koeficientů kulatosti jsou pro objekt v levé dolní části: 0,02833 a pro pravý objekt 0,2114. Kulatý objekt ve středu obrázku má koeficient 0,9322.



Obrázek 24 - Koeficient kulatosti objektů v obraze. Snímek (a) představuje jeden z posledních řezů temenní části lebky, který je oproti ostatním strukturám menší. Snímek (b) zobrazuje hodnoty kulatosti pro jednotlivé struktury snímku (a).

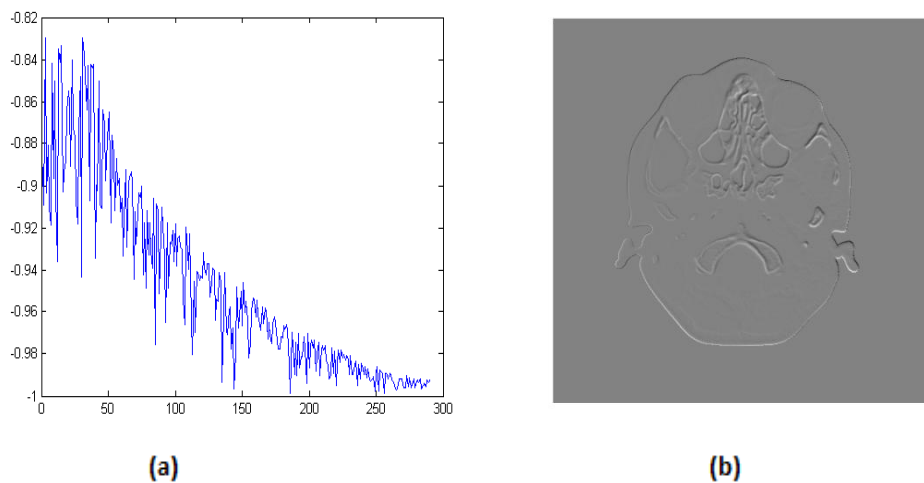
4.3. Registrace obrazu

Pro registraci 3D objemových dat jsou na vstup přivedena předzpracovaná data, která jsou z důvodu snížení časové náročnosti, ořezána na oblast detekovaného hematomu, sady 40 řezů. Transformace a interpolace této sady řezů zabere průměrně 120 sekund.

Při registraci obrazu bylo použito optimalizační funkce kontrolovaného náhodného prohledávání. Tato metoda byla upravena o podmínku, kdy dochází k vygenerování nového bodu, pokud není nalezeno v definovaném počtu rekurzí lepší funkční hodnoty. Bod je vygenerován průměrem (těžištěm) náhodně zvolených jedinců populace D . Tento krok byl proveden z důvodu častých zacyklení některých hodnot, které mnohdy našly lepší funkční hodnotu až po proběhnutí 100 a více repetí, kdy byla nalezena vhodná kombinace jedinců simplexu. Tento krok, kdy mnohdy bylo vygenerováno bodu s horší funkční hodnotou, byl zvolen po vzoru optimalizační metody Simulovaného žíhání. Kdy existuje jistá pravděpodobnost, že je přijaté horší řešení, čímž se předchází uvíznutí v lokálním minimu. Vzhledem k tomu, že je takto upravena hodnota s nejhorší funkční hodnotou v populaci D , nedochází k výrazné ztrátě informace v případě, kdy není nalezeno lepšího řešení.

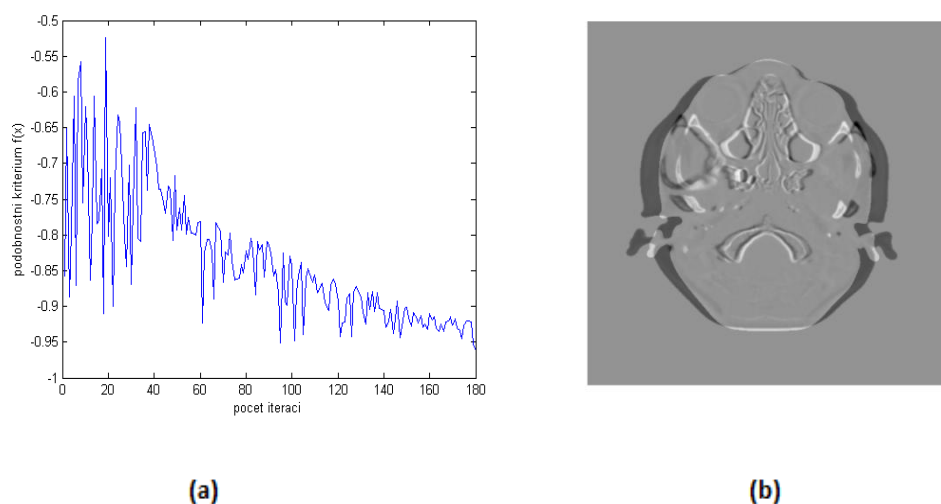
Pro výpočet podobnostní funkce bylo zvoleno Kosínovo kritérium. Při výpočtu bylo aplikováno výše zmíněného překryvu maket hlav pacienta v referenčních a pohybových datech, kdy jsou započtena pouze data, která se v překryvu vyskytují. Tento krok byl zvolen z důvodu velkého množství dat zobrazující vzduch, čímž docházelo k získání vysokých podobnostních funkcí i v případech kdy si obrazy nebyly podobné. Tato úprava se ukázala jako nevhodná. Hlavní příčinou chybných výsledků bylo z důvodu, že nebyla brána zřetel na

velikost překryvu dat a hodnota podobnostní funkce tak měla mít stejnou váhu pro překryv celé hlavy, stejně tak jako překryv jejich částí. Pro vyvarování se této chyby by bylo vhodné započítat míru překryvu vůči celkovým hodnotám maket. Tato chyba se projevila v případě flexibilních transformací. U tuhých transformací došlo ke správnému slícování obrazu. Z kontrolních registrací, nešlo posoudit chybu, která spočívá v nevhodném naprogramování překryvu.




Obrázek 25 - Registrace kontrolního vzorku - rigidní transformace. Snímek(a) popisuje vývoj podobnostního kritéria při optimalizaci kontrolního vzorku. Na snímku (b) je zobrazeno porovnání referenčního a registrovaného obrazu

Na Obrázek 25a je vývoj funkčních hodnot kontrolního vzorku, který je transformován pomocí rigidní transformace. Po 250 iterací se optimalizační metoda začíná pomalu ustalovat kolem globálního extrému, nejvyšší dosažená hodnota funkční hodnoty je -0.9985. Obrázek 25b zobrazuje porovnání referenčního a registrovaného obrazu.




Obrázek 26 - Registrace kontrolního vzorku - flexibilní transformace Snímek(a) popisuje vývoj podobnostního kritéria při optimalizaci kontrolního vzorku. Na snímku (b) je zobrazeno porovnání referenčního a registrovaného obrazu

Z Obrázek 26 u flexibilních transformací kontrolního vzorku lze pozorovat už při 180 iteracích pozvolné ustalování hodnot. Nalezená nejvyšší funkční hodnota je -0,9621.



(a)



(b)

Obrázek 27 - Registrace obrazu s vývojem hematomu. Snímek(a) popisuje vývoj podobnostního kritéria při optimalizaci zadaných dat. Na snímku (b) je zobrazeno porovnání referenčního a registrovaného obrazu

Cílem práce bylo registrovat sadu dat s vývojem hematomu v mozku pacienta. Z grafu na Obrázek 27a je vidět vývoj podobnostních kritérií podle očekávání směřující k minimu. Nalezené podobnostní optimum však nepopisuje vhodné transformační parametry pro transformaci obrazu. To je způsobené, výše zmíněným, nevhodným upravením výpočtu podobnostního kritéria. Jak je patrné z Obrázek 27b, překryv je sice ze strany referenčního obrazu 100%, avšak ze strany pohybového snímku je překryta jen část hlavy. To vedlo k tomu, že optimalizační metoda se vyvíjela ve směru, ve kterém se nenalézalo globální optimum pro registraci obrazu, a výsledkem se stala chybně registrována sada dat.

5. Závěr

Diplomová práce popisuje princip registrace obrazu objemových medicínských dat, jenž byla hlavní náplní, při registraci dat s vývojem hematomu v mozku pacienta. V kapitole 1 je čtenář seznámen s teoretickou stránkou principu předzpracování dat, která byla nutná k získání dat bez neužitečných informací v podobě patientského stolu a schodovitého artefaktu. Druhou kapitolu tvoří princip registrace obrazu, kde jsou podrobně popsány metody geometrické afinní transformace, interpolace, výpočtu podobnostního kritéria a optimalizačních funkcí.

Další kapitola obsahuje praktickou část diplomové práce, kde jsou popsány metody pro předzpracování a registraci objemových dat, které byly v této práci využity. Pro odstranění patientského stolu byly vytvořeny dva koncepty. Prvním je detekce patientského stolu pomocí Houghovy transformace a druhým je detekce patientského stolu pomocí obsahu objektů v obraze. Z těchto konceptů se lépe v praxi osvědčila metoda na základě detekce podle obsahu objektů a byla zakomponována do praktické části. Odstranění patientského stolu probíhá bezchybně, menších nedostatků se dostává při odstranění podložky pod hlavou pacienta, kde se místy vyskytují části zmíněné podložky. V průběhu plnění diplomové práce bylo zjištěno, že data jsou postižena schodovitým artefaktem, pro odstranění tohoto artefaktu bylo použito programu [20], který je popsán v kapitole 3.1.2.

Dalším z cílů práce bylo vytvoření metody afinní transformace podle pevných parametrů. Princip metody je v práci podrobně popsán a samotný program je zakomponován v programu registrace. Pro registraci obrazu bylo využito zmíněné afinní globální transformace dat, trilineární interpolace a pro výpočet podobnostního kritéria použito Kosinového kritéria. Právě podobnostní kritérium bylo nevhodně upraveno pro výpočet kritéria v oblasti překryvu hlavy v referenčních a pohybových datech. Tento fakt nebyl zjištěn při testovacích funkcích a při samotném spuštění registrace, trvající v řádu dnů, nebylo již možné měření opakovat. Tím se získávala nepřesná informace o podobnosti obou obrazů a nedošlo k registraci obrazu. Optimalizační funkce byla provedena pomocí kontrolovaného náhodného vyhledávání. Metoda optimalizace pracuje podle teoretických předpokladů.

Poslední kapitola obsahuje naměřené hodnoty a diskuzi k získaným datům.

6. Seznam použité literatury

- [1] ZITOVÁ, B., FLUSSER, J. *Image registration methods: a survey. Image and Vision Computing*, Oct 2003, vol. 21, no. 11, p. 977-1000.
- [2] Duda, R. O., Hart P. E. *Use of the Hough Transformation to Detect Lines and Curves in Pictures*, Comm. ACM, Vol. 15, pp. 11–15 (January, 1972)
- [3] ŽÁRA, Jiří. *Moderní počítačová grafika. 2.*, přeprac. a rozš. vyd. Praha : Computer Press, 2004. 609 s., 16 s. barev. obr. příl ISBN 8025104540
- [4] JAN, J. *Medical Image Processing, Reconstruction and Restoration: Concepts and Methods*, CRC Press, 2005. ISBN 0-8247-5849-8.
- [5] BISTRÝ, J. *Registrace obrazu pomocí metody Optical Flow*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 80s. Vedoucí diplomové práce Ing. Miloš Malínský
- [6] BAI Ying, WANG Dali, *On the Comparison of Trilinear, Cubic Spline, and Fuzzy Interpolation Methods in the High-Accuracy Measurements*, IEEE Transactions on Fuzzy Systems 2010, Vol. 18, p. 1016 – 1022
- [7] SCHWARZ D., PROVAZNIK I., *Registrace multimodálních medicínských obrazů s využitím Matlabu a ITK* [online] Dostupný z WWW: http://dsp.vscht.cz/konference_matlab/matlab04/schwarz.pdf
- [8] VÁCLAVÍK, J. *Interpolace obrazů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 50 s. Vedoucí bakalářské práce doc. Ing. Radim Kolář, Ph.D.
- [9] LEHMANN, T. M., GÖNNER, C., SPITZER, K. *Survey: Interpolation Methods in Medical Image Processing*. IEEE Transactions on Medical Imaging. 1999, vol. 18, p. 1049 - 1075.
- [10] WEISE, T.: *Global Optimization Algorithms – Theory and Application*, 2009 published by it-weise.de (self-published), Germany. 2009. Dostupné z WWW: <http://www.it-weise.de/documents/publications.html>

- [11] DLUHOŠ P.: *Metaheuristické optimalizační metody pro registraci obrazů z magnetické rezonance*. Brno: Přírodovědecká fakulta, Masarykova univerzita, 2011. 46s. Vedoucí bakalářské práce Ing. Daniel Schwarz, PhD
- [12] TVRDÍK, J.: *Evoluční algoritmy*. Skripta, Přírodovědecká fakulta, Ostravská univerzita, 2004. Dostupné z: <http://sofe2-files.pepiino.cz/statnice/Obecna%20Informatika/13,14/XEVAL.pdf>
- [13] INGOLE, V.T. *Medical Image Registration Using Genetic Algorithm*. In: [online]. Badera, India: PRMIT, 2009, 2010-12-16 [cit. 2012-04-07]. DOI: 10.1109/ICETET.2009.143. Dostupné z: www.ieee.org
- [14] NEJAD, A.G. *Genetic algorithm as the main optimizer for medical image registration*. In: [online]. Isfahan, 2010-3-11, 2011-31-01 [cit. 2012-04-07]. DOI: 10.1109/ICBME.2010.5704966. Dostupné z: www.ieee.org
- [15] XIUJIE, Zhang, Shen YI a Shiyong LI. *A hybrid Genetic Algorithm for Medical Image Registration Downhill Simplex Method*. In: [online]. 2009. vyd. Beijing, 2009, 2010-01-15 [cit. 2012-04-07]. DOI: 10.1109/YCICT.2009.5382367. Dostupné z: www.ieee.org
- [16] Kirkpatrick S., Gelatt C.D. ,Vecchi M.P., "Optimisation by simulated annealing", Science, volume 220, 4598, pp 671-680, 1983.
- [17] NELDER, J.A. a R. MEAD. *A Simplex Method for Function Minimization*. In: [online]. Cambridge, 1965 [cit. 2012-04-07]. Dostupné z: <http://comjnl.oxfordjournals.org/>
- [18] HUANG, Yuguang a W.F. McCOLL *An Improved Simplex Method for Function Minimization*. [online]. Oxford, 1996, 1996-10-14 [cit. 2012-04-07]. DOI: 10.1109/ICSMC.1996.565360. Dostupné z: www.ieee.org
- [19] JIN, Jing. *Global Optimization of Medical Image Registration Based on Nonlinear Correlation Measurement*. In: [online]. Shanghai, 2006, 2006-04-10 [cit. 2012-05-10]. DOI: 10.1109/IEMBS.2005.1617205. Dostupné z: www.ieee.org
- [20] WALEK, P.; JAN, J. *Fast and Automatic Skull Segmentation of Multidetector CT Head Images*. In Student EEICT Proceedings of the 18th Conference - Volume 3. 2012. s. 79-83. ISBN: 978-80-214-4462- 1.

7. Seznam zkratek

CT	
Computed Tomography (Počítačová Tomografie)	13, 19
DICOM	
Digital Imaging and Communications in Medicine	33
MI	
Mutual Information - Vzájemná Informace	21
NN	
Nearest Neighbour (Nejbližší soused)	17
PET	
Positron Emission Tomography (pozitronová emisní tomografie)	19
SSD	
Sum of Squared Differences - Suma Rozdílů Čtverců	18
TL	
Trilineární	17
TQ	
Trikvadratická	17