

**Západočeská univerzita v Plzni**

**Fakulta aplikovaných věd**

**Katedra kybernetiky**

**BAKALÁŘSKÁ PRÁCE**

**Registrace obrazu**

**PLZEŇ, 2013**

**Jaroslav Antošovský**

## PROHLÁŠENÍ

Předkládám tímto k posouzení a obhajobě bakalářskou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne 19. 8. 2013

.....

*vlastnoruční podpis*

Chtěl bych tímto poděkovat vedoucímu své bakalářské práce Ing. Tomáši Rybovi za odborné vedení, ochotnou pomoc při práci, trpělivost, podnětné konzultace a neúnavnou podporu při práci.

## **ANOTACE**

První část této bakalářské práce se zaměřuje na aktuální stav problematiky registrace obrazu. Konkrétně jsou zde představeny základní metody transformace obrazu, interpolace, kritériální funkce a optimalizace. V následující části je poté představen návrh a implementace programu a univerzální metody pro registraci medicínských dat a dat z dálkového průzkumu Země. Konec celé práce je věnován testování funkčnosti navržené metody a zhodnocení dosažených výsledků.

## **KLÍČOVÁ SLOVA**

Registrace obrazu, transformace obrazu, interpolace, kritériální funkce, optimalizace

## **ANNOTATION**

First part of this bachelor's thesis focuses on the current state of the issue of image registration. Specifically, there are introduced basic methods of image transformation, interpolation, cost functions and optimization. The following section presents design and implementation of the program and universal method for registration of medical data and data from remote sensing. End of the thesis is dedicated to testing the functionality of the proposed method and evaluation of results.

## **KEYWORDS**

Image registration, image transformation, interpolation, cost function, optimization

# OBSAH

<b>1. Úvod</b> .....	<b>6</b>
<b>2. Metody registrace</b> .....	<b>7</b>
2.1. Dimensionalita .....	7
2.2. Báze registrace .....	8
2.3. Typ transformace .....	8
2.4. Doména transformace .....	9
2.5. Míra interakce.....	10
2.6. Optimalizační procedura.....	11
2.7. Zahrnuté modality .....	11
2.8. Subjekt.....	12
2.9. Objekt.....	12
<b>3. Kriteriaální funkce (míra podobnosti)</b> .....	<b>13</b>
3.1. Podobnostní kritéria založená na intenzitě v obrazech .....	13
3.2. Podobnostní kritéria založená na informaci v obrazech.....	16
<b>4. Interpolace</b> .....	<b>21</b>
<b>5. Optimalizace</b> .....	<b>25</b>
5.1. Enumerativní metody.....	25
5.2. Deterministické metody .....	26
5.3. Stochastické metody .....	28
5.4. Smíšené metody.....	29
<b>6. Cíl práce</b> .....	<b>31</b>
<b>7. Výsledky registrace</b> .....	<b>33</b>
7.1. Medicínská data .....	33
7.2. Dálkový průzkum Země.....	38
<b>8. Závěr</b> .....	<b>48</b>
<b>9. Literatura</b> .....	<b>50</b>

# 1. ÚVOD

Téma této bakalářské práce je jedním z mnoha odvětví počítačového zpracování obrazu. Aby nedošlo k nedorozumění, je důležité nejprve zmínit, že obrazem je v tomto případě myšlena digitální reprezentace reálné obrazové scény, jakou je např. fotografie pořízená digitálním fotoaparátem. Ačkoli jde o problém, který je diskutován od počátku počítačové éry, zažívá vědní disciplína počítačového zpracování obrazu skutečný „boom“ teprve v posledních letech. To je jistě dáno rychlým pokrokem v oblasti počítačové techniky, neboť operace, které by před dvaceti lety představovali pro tehdejší techniku obrovskou zátěž, dnešní počítače hravě zvládnou v řádu desetin sekundy. A právě díky těmto možnostem se hranice počítačového zpracování obrazu posouvají rychle kupředu a vznikají nová a nová odvětví. Jedním z těch ne příliš starých je právě ona registrace obrazu, kterou jsem si vybral jako téma na bakalářskou práci.

Registrace obrazu je zásadním krokem při zpracování a porovnávání dat v různých oblastech lidské činnosti. Její metody se stále více zdokonalují a dnes již dosahují výborných výsledků. S pomocí registrace obrazu jsme schopni v krátkém časovém úseku porovnat velké množství dat a vytvořit si tak celkový obrázek o řešeném problému. Nachází si své uplatnění jak při zkoumání nejvzdálenějších objektů ve vesmíru, tak u vedení robotické ruky při operacích s maximální přesností.

Registrace obrazu je proces, při kterém hledáme vhodnou transformaci jednoho obrazu (registrovaný obraz) tak, aby se co nejvíce přiblížil obrazu druhému (vztažný obraz). Oba tyto obrazy obvykle zachycují stejnou scénu, ovšem jsou pořízeny v odlišném čase, pohledu nebo jiným aparátem. Úkolem registrace je právě tyto rozdíly odstranit.

V této práci se zaměřím především na dva okruhy, a sice použití při zpracování medicínských dat a zpracování dat z dálkového průzkumu Země. Jelikož se jedná o naprosto odlišné oblasti lidské činnosti s naprosto odlišným typem zpracovávaných dat, neexistuje zatím univerzální metoda pro jejich registraci. Úkolem této bakalářské práce je tedy navrhnout a implementovat nějakou univerzální registrační metodu, která by dokázala počítat jak s medicínskými daty, tak s daty z dálkového průzkumu Země.

## 2. METODY REGISTRACE

Při výběru vhodné metody registrace obrazu je potřeba zaměřit se na samotný typ registrovaného obrazu a určit si hlavní priority celého procesu. Stejně tak jako u většiny problémů i zde se objevují pomyslné váhy mezi rychlostí a kvalitou. Některé metody jsou pomalejší, jejich výsledky ovšem výrazně kvalitativně přesahují metody rychlejší. V úlohách, kde je potřeba rychlého a alespoň přibližného výsledku jsou ale nepoužitelné. Pro kvalitní řešení daného problému je nutné si uvědomit, o jakou úlohu se jedná, jaká data jsou k dispozici a co je vlastně úkolem celé registrace (co od výsledku očekáváme). Metody registrace lze proto rozdělit podle několika hledisek. Různé zdroje uvádějí různá čísla, většina se ale shoduje na obecném rozdělení podle devíti základních kritérií [2].

### 2.1. Dimensionalita

Kritérium, které se zabývá počtem dimenzí registrovaných dat. Nejčastěji se jedná o 2D-2D registraci, tedy případ, kdy jsou oba obrazy dvoudimenzionální. Příkladem je klasické porovnávání rentgenových snímků. Další častý případ je 3D-3D registrace, např. porovnávání celých tomografických dat. Konečně, možný případ je i 2D-3D registrace, např. při porovnávání tomografických dat s rentgenovým snímkem.

V tomto kritériu je zahrnutý i případ, ve kterém je jednou z dimenzí čas. Zde jsou porovnávány stejné snímky v různých časových okamžicích. V medicíně jsou časové intervaly obecně kratší (hojení pacienta po operaci, sledování růstu nádoru, růst kostí) a často v rozmezí několika měsíců, maximálně let. U dálkového průzkumu Země je možné využití např. v zachycení vývoje jednotlivých měst v rozmezí několika let či desetiletí. Aktuálními problémy jsou např. monitorování pohybu a tání ledovců, stoupající hladina oceánů a s tím spojené zaplavování pobřežních oblastí a ostrovů, „rozdělení“ pouští a mnoho dalších.

## 2.2. Báze registrace

Další důležité kritérium, jehož podstatou je určení hlavních příznaků, které napomáhají při výpočtu parametrů transformace, je báze registrace. Podle toho se metody dělí na vnější (extrinsic) a vnitřní (intrinsic). V medicíně se využívá hlavně první zmíněné, kdy se na pacienta umístí snadno detekovatelné značky, které po získání snímků napomáhají k určení parametrů transformace. Druhá metoda využívá pouze informace ze samotného obrazu, např. hledají se tzv. signifikantní body typu roh apod. Toho se hojně využívá právě při dálkovém průzkumu Země, jelikož Zemský povrch je plný signifikantních bodů. Ať už se jedná o uměle vytvořené člověkem (silnice, domy, ostré rysy tvarů obdělávaných pozemků), tak i přírodní (skalní útvary, řeky). Naopak v medicíně je využití této metody jen výjimečné, neboť obecně je většina medicínských obrazů chudá na již zmíněné signifikantní body. Z tohoto důvodu se v poslední době dostává do popředí další metoda, která je založena na registraci jasových oblastí.

## 2.3. Typ transformace

Transformace je jedním z nejdůležitějších kroků registrace samotné, proto je potřeba věnovat dostatečnou pozornost při jejím výběru, resp. při výběru jejího typu. Mezi nejpoužívanější transformace patří transformace tuhého tělesa, afinní transformace a elastická transformace (obrázek č. 1) [6], [9].

### ***Transformace tuhého tělesa***

Jsou zachovány přímky a jejich rovnoběžnost, poměr délek stran i velikosti úhlů. Transformace tuhého tělesa se nejčastěji používá při registraci „pevných“ objektů, které se nedeformují (např. snímky budov). Pro svoji rychlost (menší počet parametrů) se však může použít i pro registraci objektů, které mohou podléhat mírnější deformaci (např. lidské tělo). Transformace tuhého tělesa zahrnuje:

a) *Posunutí (translace):*

Maticové vyjádření:

$$T_m = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ p_x & p_y & 1 \end{bmatrix}$$



*b) Otočení (rotace):*

Maticové vyjádření: 
$$T_m = \begin{bmatrix} \cos \varphi & \sin \varphi & 0 \\ -\sin \varphi & \cos \varphi & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

*c) Změna velikosti:*

Maticové vyjádření: 
$$T_m = \begin{bmatrix} p_x & 0 & 0 \\ 0 & p_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

### ***Afinní transformace***

Jsou zachovány přímky a jejich rovnoběžnost. Oproti transformaci tuhého tělesa navíc zahrnuje:

*a) Zkosení:*

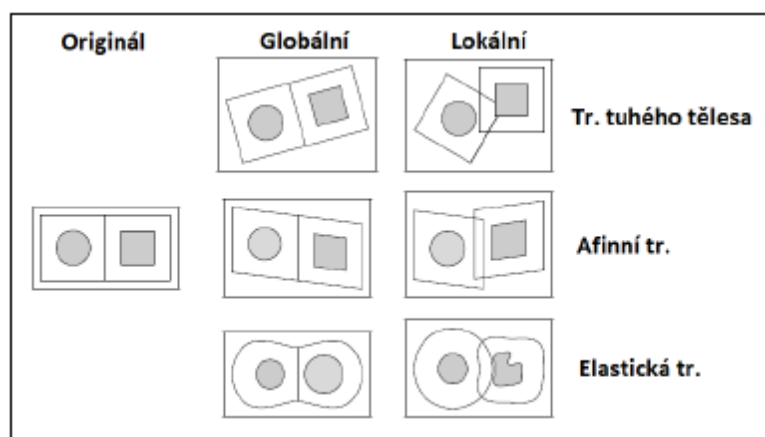
Maticové vyjádření: 
$$T_m = \begin{bmatrix} 1 & ph_y & 0 \\ ph_x & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

### ***Elastická transformace***

Mapuje přímky na křivky. Není dána obecným maticovým přepisem.

## **2.4. Doména transformace**

Jak již bylo řečeno, transformace je jednou z nejdůležitějších částí celého procesu registrace obrazu. V předchozí kapitole jsou uvedeny různé typy transformace a nyní je potřeba ujasnit, jak a v jaké míře je vhodné danou transformaci aplikovat. První a jednodušší možností je globální transformace, při které se daný typ transformace aplikuje na obraz jako celek. Druhá, složitější možnost je lokální transformace, při které se transformuje pouze vybraná část obrazu. Za určitých podmínek lze definovat různé typy transformací na různé části obrazu. Na obrázku č. 1 jsou příklady globálních a lokálních 2D transformací.



Obrázek 1. Globální a lokální 2D transformace.

## 2.5. Míra interakce


Měrou interakce se v tomto smyslu rozumí velikost zásahu uživatele do procesu registrace. Podle této velikosti se poté registrační metody dělí na automatické, semiautomatické a interaktivní. U automatických metod uživatel pouze dodá vstupní data, popř. informaci o těchto datech (aparát, na kterém byla data zachycena, čas zachycení). U interaktivních metod naopak uživatel řídí celou registraci v podstatě sám, program pouze doladí výsledné řešení, popř. kontroluje platnost uživatelem zadávaných dat (překlepy, nereálné velikosti parametrů). Semiautomatické metody se měrou interakce pohybují mezi dvěma předchozími. Uživatel většinou inicializuje algoritmus počátečním odhadem, poté proběhne proces registrace a na konci uživatel vyhodnotí algoritmem navržená řešení.

## 2.6. Optimalizační procedura

Celý proces registrace obrazu je založen na opakovaném porovnávání registrovaného obrazu se vztažným obrazem a odhadování parametrů dané transformace. Tyto parametry se odhadují na základě hledání extrémů kriteriální funkce. Zda se hledají maxima, či minima, záleží na daných požadavcích konkrétní kriteriální funkce. V ideálním případě existuje pouze jeden jediný extrém, který odpovídá správným parametrům transformace. V reálných příkladech však většinou existují také extrémy lokální, které nemusí vést (a většinou ani nevedou) k dobrým výsledkům. Optimalizační procedurou tedy myslíme optimální volbu této kriteriální funkce (míry podobnosti). Jak již bylo zmíněno, různé volby kriteriální funkce vedou k různým výsledkům.

## 2.7. Zahrnuté modality

Pojem modality může být interpretován jako způsob pořízení obrazu (typ zobrazovací metody). V medicíně je jednou z nejběžnějších zobrazovacích metod klasický rentgen. Další metody jsou např. CT, MR, PET, SPECT. Při dálkovém průzkumu Země jsou to pak satelitní snímky, popř. letecké fotografie, snímky za použití nočního vidění apod. Metody registrace obrazu se podle modality dělí na monomodální a multimodální. V prvním případě jsou oba obrazy (jak vztažný, tak registrovaný) pořízeny na zařízení stejného typu (mají stejnou modalitu). Druhý případ naopak zahrnuje situace, kdy je každý z obrazů pořízen na jiném zařízení (mají různou modalitu). Na obrázku č. 2 je ukázka multimodální registrace.



Obrázek 2. Ukázka multimodální registrace, zleva řez z CT, snímek z PET, výsledek fúze.

## **2.8. Subjekt**

Rozdělení metod registrace podle tohoto hlediska se týká hlavně medicínských dat. Intrasubjektivní registrací je případ, kdy všechna data pochází od jednoho pacienta. V opačném případě se jedná o registraci intersubjektivní. Speciální třídou je registrace atlasu. Atlas je soubor dat, který byl získán z velkého množství subjektů. Představuje tedy jakýsi zprůměrovaný ideální stav, i když ve skutečnosti v medicíně slovo průměr nebo ideální stav prakticky neexistuje.

## **2.9. Objekt**

Objektem je v tomto případě míněn bod zájmu registrace. V medicíně ho můžeme chápat jako konkrétní část těla určenou k registraci. Ke každému objektu musíme opět přistupovat konkrétní metodou pro registraci a optimalizovat tak co nejvíce průběh celého procesu. Např. při registraci hlavy uvažujeme neměnný tvar lebky (za normálních okolností se nedeformuje) a z použitelných typů transformací nám tedy zůstala transformace tuhého tělesa. Naopak při registraci jater je vhodné použít elastickou transformaci, která se vypořádá s nelineárními změnami. U dálkového průzkumu Země se pak jedná o podobné případy.

### **3. KRITERIÁLNÍ FUNKCE (MÍRA PODOBNOSTI)**

Míra podobnosti je jednou z nejdůležitějších částí procesu registrace obrazu, neboť slouží k výpočtu rozdílu mezi vztažným a registrovaným obrazem. Porovnávat můžeme jak celé obrazy (globální kriteriální funkce) tak i jejich části samostatně (lokální kriteriální funkce). Při správném zadání můžeme pro nalezení optimálního řešení použít na různé části jednoho obrazu různé kriteriální funkce. My se však budeme držet mnohem zajímavějšího rozdělení, a sice rozdělení na podobnostní kritéria založená na intenzitě v obrazech a podobnostní kritéria založená na informacích v obrazech.

#### **3.1. Podobnostní kritéria založená na intenzitě v obrazech**

Než přistoupím k samotným kritériím, uvedu pár základních pojmů, které jsou pro všechna kritéria (založená na intenzitě v obrazech) stejné. Mějme obrazové plochy A a B o různých intenzitách, které obsahují konečný počet pixelů. Plochu A můžeme charakterizovat vektorem  $a$ , který je tvořen hodnotami  $N$  pixelů uspořádaných např. do řádků. Plochu B potom definujeme vektorem  $b$ , jehož hodnoty uspořádáme do sloupce. Vznikl nám tedy vektorový prostor, který nese informace o intenzitách jednotlivých pixelů. Jelikož nyní můžeme hodnotu každého pixelu vyjádřit vektorem, mluvíme o intenzitním vektorovém prostoru. Při použití těchto kritérií jde tedy v podstatě o nalezení co nejvíce se podobajících vektorových polí.

U těchto metod se navíc vychází z předpokladu, že porovnávané dvojice bodů v jednotlivých obrazech mají podobnou intenzitu. Jsou tedy nejvhodnější při porovnávání monomodálních obrazů nebo jejich částí [1].

### **Euklidovská vzdálenost**

Nejjednodušší kritérium, které je závislé na absolutních délkách porovnávaných vektorů. Je založeno na euklidovské vzdálenosti:

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

### **Suma kvadrátů rozdílů**

Jedná se o kritérium velmi podobné euklidovské vzdálenosti, v tomto případě je však chápáno ve smyslu nejmenších čtverců. Často označováno zkratkou SSD (z anglického *sum of squares of differences*). Toto kritérium je velmi náchylné na změny kontrastu a na šumu v porovnávaných obrazech. Proto je jeho hlavní použití pouze při porovnávání velmi podobných obrazů. V těchto případech se ovšem ukazuje jako nejlepší kritériální funkce [1], [4].

Pokud se obrazy rovnají (jsou v ideálním překrytu), je hodnota SSD rovná nule. Snažíme se tedy nalézt minimální součet kvadrátů rozdílů intenzit všech uvažovaných bodů, tedy minimum následující funkce:

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

### **Korelační koeficient**

Kritérium označované zkratkou CC (z anglického *correlation coefficient*) je založeno na odečítání hodnot vektorů. Je proto vhodné v případech, kdy jsou jasy registrovaných obrazů lineárně závislé. Díky ne příliš složitému výpočtu a zároveň kvalitním výsledkům je korelační koeficient oblíbeným a velmi často používaným kritériem.

Z matematiky známe, že v případě korelačního koeficientu je hledaným extrémem maximum. Jedná se o zkoumání určité závislosti, přičemž minimální možná závislost se rovná nule (nejsou závislé) a maximální nabývá hodnoty jedna (maximálně závislé). V tomto případě se vychází ze stejných předpokladů a hledá se maximální možná hodnota funkce [1]:

$$CC(a, b) = \frac{\sum_{i=1}^N (a_i - \bar{a})(b_i - \bar{b})}{\sqrt{\sum_{i=1}^N (a_i - \bar{a})^2 \sum_{i=1}^N (b_i - \bar{b})^2}} \quad (3)$$

$$\text{kde } \bar{a} = \frac{1}{N} \sum_{i=1}^N a_i, \quad \bar{b} = \frac{1}{N} \sum_{i=1}^N b_i$$

jsou střední hodnoty jasu obrazu A a B.

### ***Uniformita poměru obrazu (Koeficient stejnorodosti obrazu)***

Kritérium označované zkratkou RIU (z anglického ratio image uniformity), bylo původně navrženo pro registraci PET obrazů. Uplatňuje se při monomodálním porovnávání obrazů a jeho výhodou je odolnost vůči lineárním změnám kontrastu. V dnešní době bylo navíc toto kritérium upraveno a používá se např. při registraci CT obrazů [1].

Celá metoda je založena na určení tzv. poměrového obrazu  $\mathbf{r}$ , který je dán poměrem intenzitních hodnot transformovaného a původního obrazu:

$$\mathbf{r} = \left[ \frac{a_1}{b_1} \frac{a_2}{b_2} \frac{a_3}{b_3} \quad \dots \quad \frac{a_N}{b_N} \right]^T \quad (4)$$

Z poměrového obrazu je posléze vypočítána standardní odchylka, kterou se snažíme minimalizovat:

$$C_{RIU}(a, b) = \frac{\sqrt{\sum_{i=1}^N (r_i - \bar{r})^2}}{\bar{r}}, \quad (5)$$

$$\text{kde } \bar{r} = \frac{1}{N} \sum_{i=1}^N r_i.$$

### 3.2. Podobnostní kritéria založená na informaci v obrazech

Kritéria založená na informacích v obrazech nacházejí své využití v případech, kdy není vhodné přímé využití údajů o intenzitách v porovnávaných obrazech. Předpokládáme totiž, že konkrétnímu bodu o jisté intenzitě ve vztažném obraze odpovídá bod v registrovaném obraze o intenzitě odlišné. Základní myšlenkou těchto kritérií je sdružený histogram, který zachycuje počet pixelů o jednotlivých intenzitách v porovnávaných obrazech. Další využívanou metodou je kritérium vzájemné informace, které je založené na entropii (míře informace) v porovnávaných obrazech. Díky těmto přístupům je možné provádět i multimodální registraci [1].

#### *2D sdružený histogram*

Nejprve uvedu pár základních pojmů. Mějme porovnávané obrazy A a B, které jsou reprezentovány stupni šedi. Histogram je matice  $h^{AB}$ , jejíž velikost je dána koeficienty  $q \times r$ , přičemž  $q$  je počet stupňů šedi v obraze A a  $r$  je počet stupňů šedi v obraze B. Jednotlivé pozice histogramu vyplňují odpovídající si hodnoty intenzit v obraze A a B. Sdružený histogram tedy sestavím prohledáním všech pozic v obrazech a zjištěním jednotlivých intenzit. Tento pak obsahuje informace o intenzitách v porovnávaných obrazech na odpovídajících si pozicích. V případě, kdy jsou porovnávané obrazy zcela shodné, leží prvky na hlavní diagonále matice sdruženého histogramu. Pokud je registrovaný obraz odvozen od vztažného obrazu nějakou jasovou transformační funkcí, jsou prvky matice soustředěny do křivky, která odpovídá průběhu funkce představující právě tuto jasovou transformaci.



Pokud se jedná o registraci multimodální, může nastat problém s klíčovými prvky obrazu, neboť jejich intenzitní hodnota (ve stupních šedi) se u různých modalit může lišit (např. tkáň při vyšetření CT, PET). Avšak mezi multimodálními obrazy, které mají stejnou geometrii, existují mezi hodnotami intenzit jisté vztahy. Jedná se o shlukování intenzitních hodnot v matici sdruženého histogramu. Pokud jsou obrazy podobné, dojde k těsnějšímu shluknutí. V opačném případě se od sebe hodnoty vzdalují.

Sdružený histogram je možné použít jak na porovnávání celých obrazů, tak na porovnávání jednotlivých částí [1].

### ***Sdružená entropie***

Entropií je zde myšlena míra informace, která je obsažena v jednotlivých obrazech. Tato metoda je založena na předpokladu pravděpodobnostního rozložení prvků a na teorii informace.

Předpokládejme sdruženou proměnnou (A, B), která má vektorovou hodnotu (l,m). Tento vektor je dán hodnotami intenzit v obrazech A a B na odpovídajících si pozicích jednotlivých pixelů. Nová proměnná má tedy tvar:

$$p_{AB}\{l, m\} \approx \frac{1}{N} h_{l,m}^{AB}. \quad (6)$$

Potřebný informační obsah je dán pravděpodobnostním rozložením intenzitních hodnot jednotlivých pixelů.

Entropii můžeme rozdělit na samostatnou a sdruženou. Samostatná entropie je označena  $H_A$  a  $H_B$ , zatímco sdružená entropie je označena  $H_{AB}$ . Hodnoty  $H_A$  a  $H_B$  udávají množství informace obsažené v jednotlivých obrazech A a B. Hodnota  $H_{AB}$  udává množství informace při spojení těchto dvou obrazů, tedy vlastně poskytuje informaci o jejich podobnosti. Minimalizace sdružené entropie způsobuje shlukování intenzitních hodnot. Z toho vyplývá, že jsou-li porovnávány obrazy shodné, hodnota sdružené entropie  $H_{AB}$  je rovna nule. Naopak, jsou-li porovnávány obrazy zcela odlišné, hodnota sdružené entropie  $H_{AB}$  je rovna součtu entropií jednotlivých obrazů [1].

Vzorce pro výpočet jednotlivých entropií:

$$H_A = - \sum_{l=1}^q p(a_l) \log p(a_l), \quad (7)$$

$$H_B = - \sum_{m=1}^r p(b_m) \log p(b_m). \quad (8)$$

Vzorec pro výpočet sdružené entropie:

$$H_{AB} = - \sum_{l=1}^q \sum_{m=1}^r p(a_l, b_m) \log p(a_l, b_m). \quad (9)$$

### ***Vzájemná informace***

Pravděpodobně nejpoužívanější kriteriální funkcí pro multimodální registraci je vzájemná informace, známá pod zkratkou MI (z anglického mutual information). Vychází z výše uvedených předpokladů sdružené entropie a teorie informace. Jedná se v podstatě o rozdíl součtu entropií jednotlivých obrazů a sdružené entropie:

$$I_{AB} = H_A + H_B - H_{AB}. \quad (10)$$

Ze vzorce vyplývá, že se snažíme o maximalizaci hodnoty  $I_{AB}$ , tedy o maximální podobnost souborů dat. Jak již bylo řečeno, jsou-li porovnávané obrazy zcela rozdílné, je hodnota sdružené entropie  $H_{AB}$  rovna součtu jednotlivých entropií samostatných porovnávaných obrazů ( $H_A$  a  $H_B$ ), tedy po odečtení se hodnota vzájemné informace  $I_{AB}$  rovná nule. Naopak, jsou-li porovnávané obrazy shodné, hodnota sdružené entropie  $H_{AB}$  je rovna nule a hodnota vzájemné informace  $I_{AB}$  je tedy maximální, přesněji se rovná součtu entropií  $H_A$  a  $H_B$ .

Princip celé metody je založen na předpokladu, že na intenzity šedi v porovnávaných obrazech nahlížíme jako na náhodné veličiny. Hlavní roli zde hraje pravděpodobnost výskytu hodnot intenzitních složek v porovnávaných obrazech a jejich entropie. Odhady pravděpodobností lze určit jako normované histogramy samostatných obrazů A a B a jako normovaný sdružený histogram AB [1], [4], [12].

Počáteční rozložení pravděpodobnosti normalizované l-tým řádkem a m-tým sloupcem sdruženého histogramu je možné zapsat jako:

$$p_{B|A}\{m|l\} \approx \frac{1}{N_l} h_{l,m}^{AB}, \text{ kde } N_l = \sum_{m=1}^r h_{l,m}^{AB} = h_l^A, \quad (11)$$

$$p_{A|B}\{l|m\} \approx \frac{1}{N_m} h_{l,m}^{AB}, \text{ kde } N_m = \sum_{l=1}^q h_{l,m}^{AB} = h_m^B. \quad (12)$$

Dále pro počáteční entropie samostatných obrazů A a B můžeme stanovit následující zápis:

$$H_{A|m} = - \sum_{l=1}^q p_A(l|m) \log p_A(l|m), \quad (13)$$

$$H_{B|l} = - \sum_{m=1}^r p_B(m|l) \log p_B(m|l). \quad (14)$$

A nakonec pro počáteční sdruženou entropii obrazů A a B:

$$H_{B|A} = - \sum_{l=1}^q p_A(l) H_{B|l} = - \sum_{l=1}^q \sum_{m=1}^r p_{AB}(m,l) \log p_{B|A}(m|l). \quad (15)$$

Případně naopak:

$$H_{A|B} = - \sum_{m=1}^r p_B(m) H_{A|m} = - \sum_{m=1}^r \sum_{l=1}^q p_{AB}(l, m) \log p_{A|B}(l|m). \quad (16)$$

Takto provedené zápisy sdružených entropií poskytují informaci zbývající v obraze B, známe-li obraz A (případně informaci zbývající v obraze A, známe-li obraz B).

Jiný zápis pro vzájemnou informaci může tedy vypadat takto:

$$I_{AB} = H_A - H_{A|B} = H_B - H_{B|A}. \quad (17)$$

Navíc je možné využít normalizovaný tvar označovaný zkratkou NMI (z anglického normalized mutual information), který je vhodný především pro registraci obrazů, které obsahují velké množství šumu. V takovém případě by totiž obyčejná MI neposkytovala dostatečně přesné výsledky. Normalizovaný tvar je dán vztahem [1]:

$$I_{AB} = \frac{H_A + H_B}{H_{AB}}. \quad (18)$$

## 4. INTERPOLACE


Interpolací je obecně míněno nalezení přibližné hodnoty funkce z nějakého intervalu v případě, že její hodnoty jsou známy jen v některých jiných bodech tohoto intervalu. Při práci s obrazy se tedy jedná o doplnění bodů obrazů do diskrétní obrazové mřížky [13].

### *Aproximace jasové funkce*

Předpokládejme, že jsme při registraci obrazu provedli transformaci (např. otočení o obecný úhel) a vypočítali tak nové souřadnice bodů  $x'$ ,  $y'$  v registrovaném obraze. Souřadnice  $x, y$  původních vzorků obrazové funkce  $f(x, y)$  byly celočíselné, neboť byly identické se vzorkovací mřížkou. Jelikož obraz reprezentujeme maticí, je tato mřížka pravoúhlá a za uzly mřížky považujeme vzorkovací body. Nově vypočtené souřadnice  $x'$ ,  $y'$  již ale celočíselné být nemusí, proto je nutné dopočítat hodnoty v konkrétních bodech původního předepsaného rastru. To provedeme aproximací (interpolací) průběhu plochy výstupního obrazu z dostupných vzorků tak, že je proložíme polynomem dvou proměnných  $x, y$ . Do vzniklé analytické rovnice dosadíme a vypočteme hodnoty transformované obrazové funkce v původně předepsaném výstupním rastru. Výsledkem aproximace (interpolace) je tedy jasová funkce  $f_n(l, k)$ , kde index  $n$  rozlišuje jednotlivé interpolační metody. Jasovou funkci  $f_n(l, k)$  lze vyjádřit takto [14]:

$$f_n(x, y) = \sum_{l=-\infty}^{+\infty} \sum_{k=-\infty}^{+\infty} g_s(l\Delta x, k\Delta y) h_n(x - l\Delta x, y - k\Delta y). \quad (19)$$

Funkce  $h_n$  je zvolené interpolační jádro. Pro zmírnění početní náročnosti volíme jako interpolační jádro pouze omezený počet sousedících bodů.




Obrázek 3. Ukázka vychýlení transformovaných bodů od původního předepsaného rastru.


### ***Interpolace nejbližším sousedem***

Metoda interpolace nejbližším sousedem (zkratka NN z anglického nearest neighbor) je jednou z nejjednodušších a zároveň nejrychlejších interpolačních metod. Místo dopočítávání nového bodu se pouze dosadí do mřížky přesná hodnota nejbližšího originálního bodu. Funkce  $f$  je tedy dána předpisem [14]:

$$f_1(x, y) = g_s(\text{okruh}(x), \text{okruh}(y)). \quad (20)$$



Obrázek 4. 1D interpolační jádro metody interpolace nejbližším sousedem.




Obrázek 5. Princip interpolace nejbližším sousedem.

### ***Bilineární interpolace***


Přestože je metoda bilineární interpolace složitější než metoda nejbližšího souseda, řadí se stále ještě mezi metody jednodušší a výpočetně méně náročné. K výpočtu nového bodu  $(x, y)$  obrazové mřížky využije znalosti čtyř nejbližších sousedů (tedy těch bodů, které pozici  $(x, y)$  obklopují), které lineárně zkombinuje. Vliv každého ze čtyř bodů je úměrný jeho blízkosti ke zpracovávanému bodu. Výsledný bod je tedy dán jejich váženým součtem, funkce  $f$  vypadá takto [14]:

$$f_2(x, y) = (1 - a)(1 - b)g_s(l, k) + a(1 - b)g_s(l + 1, k) + b(1 - a)g_s(l, k + 1) + abg_s(l + 1, k + 1), \quad (21)$$

kde  $l$  je oblast kolem  $x$ ,  $k$  je oblast kolem  $y$ ,  $a = x - l$ ,  $b = y - k$ .




Obrázek 6. 1D interpolační jádro metody bilineární interpolace.



Obrázek 7. Princip bilineární interpolace.

### ***Bikubická interpolace***

Jednou ze složitějších a výpočetně náročnějších interpolačních metod je bikubická interpolace. Díky ní můžeme dosáhnout lepších výsledků v kvalitě zobrazení obrazu. Hodnota nového hledaného bodu je počítána na základě znalosti hodnot 16 okolních bodů. K aproximaci těchto hodnot se používá polynom třetího řádu [14].



Obrázek 8. 1D interpolační jádro metody bikubické interpolace.



## 5. OPTIMALIZACE

Optimalizace je v dnešní době jednou z nejdůležitějších částí algoritmů pro registraci obrazů. Jak již bylo uvedeno dříve, hlavním úkolem registrace je nalezení extrému kriteriální funkce. U jednoduchých úloh je nalezení poměrně snadné a rychlé. U složitějších úloh však existuje více lokálních extrémů (které odpovídají řešení kriteriální funkce) a pro správnou registraci je nutné nalezení globálního extrému na celé množině všech možných výsledků. Navíc je zde kladen důraz na dobu hledání tohoto extrému. Cílem optimalizace je tedy nalezení globálního extrému v co nejkratším čase.

Většina optimalizačních metod se drží daného obecného postupu. Nejprve se určí zkušební body z prohledávané oblasti a pro tyto body se otestuje kriteriální funkce. Za pomoci konkrétní optimalizační metody se poté určí nové zkušební body a znovu se testuje kriteriální funkce. Toto se opakuje až do nalezení globálního extrému [11].

Optimalizační metody lze rozdělit do čtyř základních skupin.

### 5.1. Enumerativní metody

Enumerativní metody (česky také výčtové) jsou nejjednodušší optimalizační metody, které počítají se zadanými daty bez jakýchkoli předpokladů. Dosazují bod po bodu do kriteriální funkce a tím hledají nejlepší řešení.

#### ***Prohledávání hrubou silou***

Prohledávání hrubou silou (jinak také úplné prohledávání) je dokonalým příkladem enumerativní metody. Prohledává celý prostor možných řešení a snaží se v něm nalézt to nejlepší. Díky tomu je stoprocentně zaručeno nalezení ideálního řešení. Taková formulace řešení je však výpočet nesmírně časově náročná a prakticky nepoužitelná pro prohledávání větších prostorů, neboť s rostoucí velikostí dat, či parametrů, exponenciálně roste výpočetní náročnost algoritmu [4], [12].

## 5.2. Deterministické metody

K nalezení extrému dané kriteriální funkce se sice stále počítá pouze s reálnými, zadanými daty, výpočet se však zdaleka neprovádí v celém jejich prostoru. Z prostoru zadaných dat se počítá pouze s klíčovými hodnotami, čímž je dosaženo rychlejšího nalezení extrému. Problém těchto metod spočívá v ukončení algoritmu po nalezení extrému. To v praxi znamená, že nemusí být nalezeno optimální řešení, neboť algoritmus může uvíznout v lokálním extrému.

### ***Metoda největšího spádu (The Method of Steepest Descent)***

Jak již název napovídá, optimalizační metoda největšího spádu staví na výpočtu gradientu kriteriální funkce. Metodu tedy lze použít pouze v případě, kdy je kriteriální funkce diferencovatelná. Podstata metody největšího spádu spočívá ve vyhledání minima funkce ve směru jejího největšího spádu, který se vypočítá pomocí záporné hodnoty gradientu. Takto vypočtený bod je poté zvolen výchozím bodem pro další krok iterace, ve kterém se opět volí směr největšího spádu. Algoritmus končí po předem zvoleném počtu iterací a opět se zde zachoval problém s nalezením globálního extrému, neboť algoritmus může uvíznout v extrému lokálním. Z tohoto důvodu jsou tyto metody používané pouze na řešení určitých problémů, kde se například může klást důraz na požadavek konvexního tvaru kriteriální funkce [4], [10].

### ***Horolezecký algoritmus (Hill-climbing)***

Jedním z nejznámějších deterministických optimalizačních metod (nejen v problematice registrace obrazu) je horolezecký algoritmus. Na počátku se zvolí startovací bod, ke kterému je vypočtena hodnota kriteriální funkce. Tento bod je poté expandován, což znamená, že se vypočtou hodnoty všech okolních bodů. Poté jsou tyto nové body ohodnoceny podle toho, jak splňují dané kritérium. Následuje expanze nejlépe ohodnoceného bodu. Celý algoritmus končí ve chvíli, kdy všechny okolní body mají horší ohodnocení než právě expandovaný bod (popř. je-li dosaženo maximálního počtu iterací).

Bohužel, i horolezecký algoritmus je náchylný na lokální extrém, ve kterém algoritmus skončí a označí ho za optimální výsledek. Částečně lze tento problém odstranit opakovaným spouštěním algoritmu z různých míst prohledávaného prostoru (vícenásobná náhodná inicializace) a následným vybráním nejlepšího řešení z dosažených výsledků. Výhoda horolezeckého algoritmu je jeho jednoduchost, rychlost a paměťová náročnost. Algoritmus si během svého běhu nepotřebuje udržovat informaci o navštívených uzlech, stačí mu pouze ohodnocení aktuálního bodu s jeho nejbližším okolím [4], [7].

### ***Zakázané prohledávání (Tabu search)***

Optimalizační metoda zakázaného prohledávání je vlastně jakýmsi vylepšeným horolezeckým algoritmem. Jak již bylo řečeno, horolezecký algoritmus má obrovskou nevýhodu v uvíznutí v lokálních extrémech. Zakázané prohledávání přidává do horolezeckého algoritmu zásadní změnu, která dokáže tento problém (při správném nastavení parametrů) odstranit. Zavádí totiž do procesu paměť, do které ukládá K-počet předchozích stavů. Tyto stavy se nazývají zakázané a algoritmus do nich nesmí po určitou dobu znovu vstoupit (tato doba je přímo dána parametrem K, neboť pro právě přidáný zakázaný stav musí proběhnout K-iterací, aby mohl být tento stav znovu použit). V každém kroku iterace je tedy vybrán nejlepší stav, který ještě nebyl navštíven nebo byl navštíven již dávno a ze seznamu zakázaných stavů byl vypuštěn. Tímto je algoritmu umožněno vymanit se z lokálního extrému.

Jak již bylo uvedeno, důležitým parametrem je velikost zakázaného seznamu, tedy parametru K. Pokud se totiž zvolí K příliš malé, může dojít k zacyklení v okolí lokálního extrému a problém horolezeckého algoritmu přetrvá. Naopak, příliš velké K může způsobit „přeskočení“ oblasti s globálním extrémem a nemusí se mu již podařit ho později znovu najít [7], [8], [10].

### **5.3. Stochastické metody**

Na rozdíl od předchozích metod nepracují stochastické metody pouze s reálnými zadanými daty, nýbrž zavádí do procesu optimalizace také pravděpodobnost a náhodné jevy. Díky tomu jsou tyto metody schopné odstranit nedostatky deterministických metod jako je zpracování nespojité funkce nebo uvíznutí v lokálním extrému.

#### ***Slepý algoritmus (Blind Search)***

Nejjednodušší stochastickou optimalizační metodou je bezesporu slepý algoritmus. Jeho název je odvozen z faktu, že se neřídí žádnou strategií při hledání optimálního řešení, nýbrž pouze opakovaně generuje náhodné řešení z prohledávaného prostoru všech možných řešení a toto řešení si poté zapamatuje pouze v případě, že je lepší než řešení právě uložené v paměti. Ačkoli se může zdát, že slepý algoritmus je pouze méně dokonalým horolezeckým algoritmem (a v některých literaturách se dokonce můžeme setkat s jeho zařazením do deterministických metod právě jako předchůdce dokonalejšího horolezeckého algoritmu), toto tvrzení je nesprávné, neboť díky náhodnému jevu (při náhodném výběru porovnávaných řešení) odstraňuje, stejně jako ostatní stochastické metody, nedostatky metod deterministických. Navíc při stejném počtu iterací může v určitých úlohách dosáhnout lepšího řešení než horolezecký algoritmus, zejména pak v těch úlohách, které obsahují větší množství lokálních extrémů [4].

#### ***Simulované žíhání (Simulated Annealing)***

Algoritmus optimalizační metody simulovaného žíhání je inspirován přírodními jevy, na základě chování termodynamických systémů. Fyzikální princip je následující. Po zahřátí tělesa na určitou teplotu dochází v důsledku postupného řízeného ochlazování k dotváření (formování) krystalické mřížky materiálu, a sice do stavu s co nejmenší energií (rovnovážný stav). Tímto se odstraňují vnitřní defekty tělesa a zamezí se vytváření metastabilních struktur. Obecně platí, že čím je snižování teploty pomalejší, o to kvalitnější je výsledek procesu žíhání.

V případě simulovaného žíhání v procesu optimalizace při registraci obrazů má algoritmus iterační charakter. V každé iteraci je náhodně vygenerován bod z okolí aktuální pozice a následně se algoritmus rozhodne, zda se posune do nově vygenerovaného bodu nebo setrvá na aktuální pozici, díky čemuž směřuje nejpřímější cestou do lokálního extrému. Toto chování značně připomíná deterministický horolezecký algoritmus. Zásadní rozdíl však je v tom, že při rozhodování (zůstat v aktuální pozici nebo se posunout) hraje jistou roli pravděpodobnost. V jisté míře totiž může algoritmus akceptovat i horší řešení, čímž se vymaní z uvíznutí v lokálním extrému. Celý proces funguje na základě tzv. Boltzmannovy distribuce.

Boltzmannova distribuce:

$$P(E) \sim e^{\frac{-E}{kT}}, \quad (22)$$

kde  $P(E)$  udává pravděpodobnost, že systém přejde do energetického stavu  $E$  při teplotě  $T$ ,  $k$  je Boltzmannova konstanta [4], [7], [10], [11], [12].

#### **5.4. Smíšené metody**

Smíšené metody jsou v současné době nejvýkonnější optimalizační metody vůbec. Dosahují skvělých výsledků a jsou poměrně rychlé při řešení složitých problémů. Jak již název napovídá, jedná se o metody vzniklé kombinací deterministických a stochastických algoritmů. Prakticky jediné metody, které spolehlivě naleznou globální extrém.

#### ***Rojení částic (Particle Swarm Optimization)***

Optimalizační metoda rojení částic je metoda založená na principu chování živočišných společenstev (hejno ptáků, roj včel, atd). Přestože je každý člen samostatnou jednotkou, pohybuje se v oblasti ostatních, aby dosáhl lepších výsledků při hledání potravy. Každý člen si pamatuje místo s nejlepším ohodnocením (např. včela si pamatuje místo s největším výskytem květin) a zároveň dostává informace od ostatních členů.

V programovém řešení se nejprve náhodně vygeneruje počáteční populace. Všichni jedinci mají svou pozici (souřadnici) ve vyhledávaném prostoru, náhodně vygenerovaný vektor rychlosti, který udává směr jejich příštího letu, a pamatují si svou dosud nejlepší pozici vypočítanou pomocí účelové funkce. Každý jedinec si ukládá pozici se svým nejlepším ohodnocením a jedinec s nejlepším ohodnocením z celého hejna uloží navíc svoji pozici do společné paměti. Následně si každý jedinec podle získaných výsledků upraví svoji rychlost a směr pro další hledání. Po přesunutí na nové místo se opakuje celý cyklus, kdy opět každý z jedinců ohodnotí svoji aktuální pozici a zároveň je opět zjištěna nejlepší pozice z celého hejna. Algoritmus končí po naplnění ukončovací podmínky, kterou může být nalezení optimálního řešení nebo maximální počet iterací [4], [7], [10], [11].

## 6. CÍL PRÁCE

Cílem mé práce je navrhnout a implementovat vhodnou metodu pro registraci medicínských dat a dat z dálkového průzkumu Země.

Největším problémem při řešení takového problému je razantní odlišnost zpracovávaných dat. Při registraci medicínských dat (např. CT, MR snímky,...) se většinou setkáváme s jasně ohraničenými obrazy (např. snímek mozku, který je pevně ohraničen lebkou). Při takové registraci je poté velkou výhodou fakt, že se můžeme soustředit na registraci samotného objektu a nemusíme se zabývat jeho okolím (u medicínských dat je povětšinou okolní oblast černá). Tato informace se může zdát jako nepodstatná, z dosavadních výsledků dosažených při registraci však jasně vyplývá, že i takovýto detail může mít fatální vliv na výsledek celého procesu registrace. Dále je potřeba uvědomit si modalitu porovnávaných obrazů. U monomodální registrace je nejlepší možný výběr podobnostních kritérií z okruhu podobnostních kritérií založených na intenzitě v obrazu. Oproti tomu při multimodální registraci nedosahují tato kritéria nejlepších výsledků a vhodnější volbou by byla podobnostní kritéria založená na informaci v obrazu. Při registraci dat z dálkového průzkumu Země je situace identická. Jelikož však cílem mé práce je implementovat jednu univerzální metodu pro registraci dat z obou zmíněných oblastí, vybral jsem si podobnostní kritéria založená na intenzitě v obrazech a pokusil jsem se je vhodně vylepšit tak, aby dosahovali kvalitních výsledků jak při zpracování medicínských dat, tak při zpracování dat z dálkového průzkumu Země.

Při vytváření algoritmu bylo důležité zvolit si optimální přístup k problému. Z hlediska výběru podobnostních kritérií jsem si zvolil čtyři základní kritéria založená na intenzitě v obrazech – euklidovská vzdálenost, suma kvadrátů rozdílů, korelační koeficient a uniformita poměru obrazu. Dalším krokem byla volba interpolační metody. Zde jsem se rozhodl pro metodu nejbližšího souseda, která je pro tento případ dostačující a dosahuje nejlepších výsledků z hlediska časové náročnosti. Při výběru optimalizační metody jsem se přiklonil ke stochastické metodě simulovaného žíhání. Pro jednoduchost a zároveň dobrou názornost jsem ještě omezil typ transformace na pouhou rotaci.

Samotný algoritmus je napsán v programovacím jazyce Python. Přestože se Python v posledních letech dostává mezi hojně používané programovací jazyky, zatím bohužel nemá nijak velkou podporu pro obrazovou registraci. Z tohoto důvodu bylo nutné implementovat vlastní funkce, jako např. funkce pro výpočet měr podobnosti, atd. Kompletní algoritmus je k této práci přiložen na CD.




## 7. VÝSLEDKY REGISTRACE

### 7.1. Medicínská data


V první části této kapitoly se zaměřím na registraci medicínských dat.

#### *Monomodální registrace*

Při prvním spuštění programu jsem se pokusil o monomodální registraci snímků mozku získaných z CT vyšetření. Tyto dva obrazy jsou od sebe rotovány o 180°:



Obrázek 9. CT snímek mozku a CT snímek mozku rotovaný o 180°.



Obrázek 10. Ověření funkčnosti kriteriálních funkcí na CT snímcích mozku.

Na předchozích grafech (obr. č. 10) je orientačně ověřována funkčnost kriteriálních funkcí RIU (uniformita poměru obrazu), ED (euklidovská vzdálenost), CC (korelační koeficient) a SSD (suma kvadrátů rozdílů). Tyto grafy jsou v podstatě výsledkem prohledávání hrubou silou, kdy jsou spočteny jednotlivé hodnoty všech kriteriálních funkcí pro všechny přípustné hodnoty. Při výpočtu kriteriálních funkcí RIU, ED a SSD se hledá optimální řešení minimalizací funkce a z grafu je jasně vidět, že tato hodnota se blíží  $180^\circ$ . Oproti tomu kriteriální funkce CC přenáší optimální řešení do svého maxima (výsledky mohou nabývat hodnot od 0 do 1) a i v tomto případě se blíží hodnotě  $180^\circ$ . Přesné výsledky (hodnoty extrémů jednotlivých kriteriálních funkcí) nejsou zaznamenávány, neboť jak již bylo zmíněno, celý proces vykreslení grafů při prohledávání hrubou silou je prováděno pouze pro orientační zjištění funkčnosti kriteriálních funkcí pro konkrétní obrazová data.

Pro registraci obrazů z obr. č. 9 se tedy na první pohled jeví všechny čtyři vybrané kriteriální funkce jako správné a funkční a proto mohou přistoupit k další části, kterou je spuštění optimalizační metody simulovaného žihání. Tato metoda by měla pro každou z kriteriálních funkcí zjistit přesnou hodnotu hledaného extrému. Jelikož se však optimalizační metoda simulovaného žihání řadí mezi metody stochastické, je nutné brát v úvahu jistou míru náhody. Tuto metodu jsem tedy spustil desetkrát a výsledky zprůměroval. Hodnoty výsledků při jednotlivých výpočtech jsou zaznamenány v tabulce č. 1.

	RIU	ED	CC	SSD
1. výpočet	180.41853791	180.02335755	179.79917075	179.17227527
2. výpočet	180.42213016	180.00877389	179.99496485	179.9208591
3. výpočet	180.98897444	179.88823987	180.03228178	179.37470032
4. výpočet	180.3051816	179.82522784	179.91816864	181.33836519
5. výpočet	180.71395489	179.93770954	180.00000491	179.83612261
6. výpočet	180.48522358	180.03646863	179.91771501	179.79176109
7. výpočet	180.02730166	179.95719377	179.91790525	179.91224478
8. výpočet	180.45539016	180.01722318	179.91858573	179.75934871
9. výpočet	180.55619036	180.05104067	180.02708566	180.15011749
10. výpočet	180.43679345	179.87952161	179.97081979	179.96480626

Tabulka 1. Výsledky optimalizační metody Simulovaného žihání při registraci CT snímku a CT snímku rotovaného o 180°.

Průměrná hodnota spočtených výsledků při použití kriteriální funkce:

- RIU: 180.48096782°
- ED: 179.96247565°
- CC: 179.94967023°
- SSD: 179.92206008°


Průměrný čas jednoho výpočtu extrémní kriteriální funkce:

- RIU: 112 s
- ED: 38 s
- CC: 68 s
- SSD: 34 s


Po zhlédnutí výsledků je možno říci, že při monomodální registraci je navržený algoritmus úspěšný, neboť ve všech případech se liší od správného výsledku ( $180^\circ$ ) pouze v řádu desetin stupně. V tomto případě je tedy možné použít jakoukoli kriteriální funkci. Dalším ukazatelem kvality kriteriálních funkcí je časová náročnost výpočtu. Zde nejlépe dopadli funkce suma kvadrátů rozdílů a euklidovská vzdálenost.

### ***Multimodální registrace***

Při druhém spuštění programu jsem se pokusil o multimodální registraci snímků mozku získaných z CT vyšetření (vlevo T1 vážený obraz, vpravo  $\rho$  vážený obraz). Tyto dva obrazy jsou od sebe rotovány o  $180^\circ$ :



Obrázek 11. T1 vážený CT snímek mozku a  $\rho$  vážený CT snímek mozku rotovaný o  $180^\circ$ .



Obrázek 12. Ověření funkčnosti kritériálních funkcí na CT snímcích mozku.

Z grafů na obr. č. 12 je opět vidět, že funkčnost kritériálních funkcí při registraci CT snímků mozku je ve všech čtyřech případech správná. Hodnoty extrémů vypočtené optimalizační metodou simulovaného žíhání jsou opět zaznamenány v tabulce č. 2.

	RIU	ED	CC	SSD
1. výpočet	180.45373332	176.69571785	178.91485484	176.31542132
2. výpočet	180.24503576	176.71413928	178.91595502	176.83222789
3. výpočet	180.99846047	176.91895021	178.91572701	176.85177403
4. výpočet	179.68427562	176.70927689	178.91593881	177.1130449
5. výpočet	180.39396951	176.30484339	178.91561056	176.61301642
6. výpočet	180.24948059	176.73402097	178.91625784	176.32979825
7. výpočet	180.3291424	176.69578925	178.91589462	176.93119715
8. výpočet	181.53207378	176.75610079	178.91690499	177.11601432
9. výpočet	181.50005551	176.66407364	178.91595246	176.2028967
10. výpočet	181.53983712	176.71588261	178.91575491	176.29981323

Tabulka 2. Výsledky optimalizační metody Simulovaného žíhání při registraci CT snímků mozku.

Průměrná hodnota spočtených výsledků při použití kriteriální funkce:

- RIU: 180.69260641°
- ED: 176.69087949°
- CC: 178.91588511°
- SSD: 176.66052042°

Průměrný čas jednoho výpočtu extrému kriteriální funkce:

- RIU: 153 s
- ED: 37 s
- CC: 68 s
- SSD: 33 s

Z dosažených výsledků lze odvodit, že navržený algoritmus je funkční i pro multimodální registraci. Tentokrát však nejlepších výsledků z hlediska kriteriálních funkcí dosahuje uniformita poměru obrazu a korelační koeficient. Z hlediska časové náročnosti výpočtu se opět jeví jako nejlepší suma kvadrátů rozdílů a euklidovská vzdálenost. V tomto případě je tedy pro praktické využití důležité si před výběrem konkrétní kriteriální funkce uvědomit důležitost obou hledisek na řešeném problému (zda tento problém vyžaduje přesnější řešení na úkor časové náročnosti nebo zda postačí přibližný výsledek za až pětinou dobu výpočtu).

## **7.2. Dálkový průzkum Země**

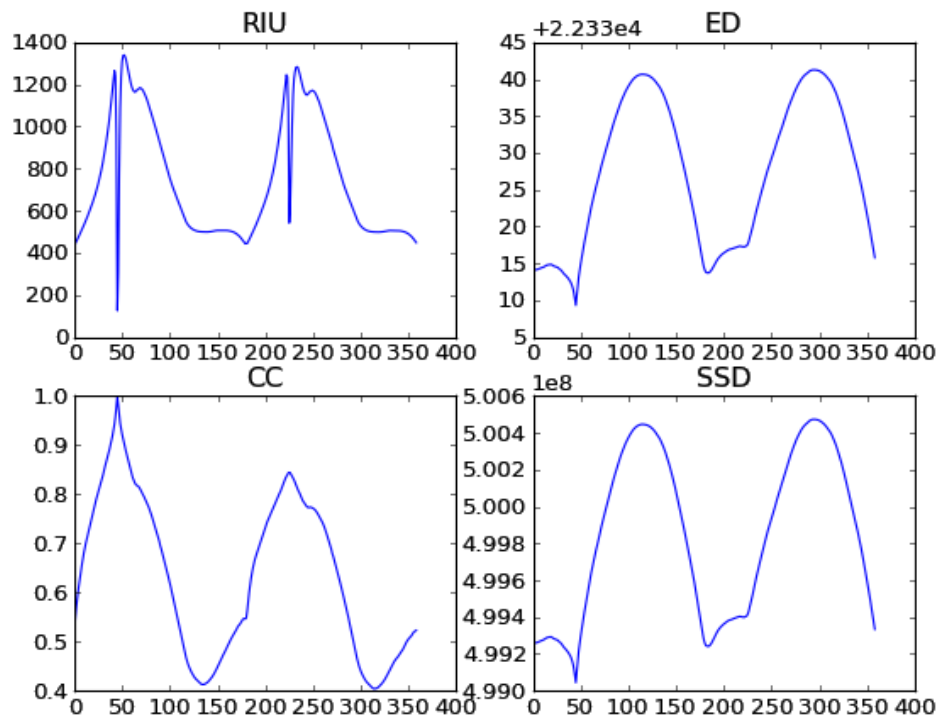
Jak z doposud získaných výsledků vyplývá, vybraná podobnostní kritéria založená na intenzitě v obrazu jsou pro registraci medicínských dat postačující a je zajímavé, že dosahují výborných výsledků jak při monomodální registraci, tak při registraci multimodální. V další části se pokusím zjistit, jak jsou tato kritéria vhodná pro registraci dat z dálkového průzkumu Země.

### Registrace celého obrazu

Nejprve jsem si připravil dva obrazy. První obraz zachycuje letecký pohled na areál ZČU na Borských polích. Druhý obraz je vytvořen rotací prvního obrazu o  $45^\circ$  a pozadí, které vzniklo při rotaci, je vyplněno černou barvou. Tímto krokem jsem se pokusil obrazy leteckých snímků alespoň trochu přiblížit k obrazům snímků mozku, neboť jsem vytvořil jakási pevná ohraničení, která se v reálném světě nevyskytují.



Obrázek 13. Letecký snímek ZČU a letecký snímek ZČU rotovaný o  $45^\circ$  s černým pozadím.



Obrázek 14. Ověření funkčnosti kriteriálních funkcí na leteckém snímku ZČU a leteckém snímku ZČU rotovaném o  $45^\circ$  s černým pozadím.

Z předchozích grafů (obrázek č. 14) mohu usoudit, že všechna podobnostní kritéria opět fungují správně, neboť u všech jsou hledané extrémy v okolí 45°. Na první pohled je patrné, že výsledky nejsou již tak jednoznačné a je zde určité riziko, že algoritmus „uvízne“ v nějakém lokálním extrému. V tabulce č. 3 jsou k dispozici přesné hodnoty výsledků optimalizační metody simulovaného žíhání.

	RIU	ED	CC	SSD
1. výpočet	44.73508289	44.94868845	45.02850262	44.8332586
2. výpočet	45.00577572	44.83725187	44.9853478	44.86298008
3. výpočet	44.90562692	45.00913563	45.00548573	45.46635682
4. výpočet	45.22776953	45.01131549	44.84646157	45.42043352
5. výpočet	45.03322185	45.00322659	44.94856704	44.99807815
6. výpočet	45.12785065	44.83454884	44.74860327	44.89358927
7. výpočet	45.65373262	45.0413473	45.01870751	44.92647325
8. výpočet	45.02843885	45.0326649	44.85485702	44.8436187
9. výpočet	45.36056798	44.68760898	44.79534004	44.9072715
10. výpočet	45.42245758	45.2519519	45.0398503	45.13072463

Tabulka 3. Výsledky optimalizační metody Simulovaného žíhání při registraci leteckého snímku ZČU a leteckého snímku ZČU rotovaného o 45° s černým pozadím.

Průměrná hodnota spočtených výsledků při použití kriteriální funkce:

- RIU: 45.15005246°
- ED: 44.965774°
- CC: 44.92717229°
- SSD: 45.02827845°

Průměrný čas jednoho výpočtu extrému kriteriální funkce:

- RIU: 213 s
- ED: 46 s
- CC: 101 s
- SSD: 43 s



Výsledek registrace je více než uspokojivý. Z hlediska vypočtených hodnot extrémů výsledky odpovídají správnému řešení s přesností na desetinu. Časová náročnost výpočtů se však zvýšila přibližně o třetinu. Důvodem takového zvýšení časové náročnosti výpočtů jsou větší rozměry registrovaných obrazů. Zatímco u předchozích registrovaných snímků mozku byly rozměry obrazu 181x217 pixelů (celkově 39 277 pixelů), rozměry leteckých snímků ZČU jsou 288x184 pixelů (celkově 52 992 pixelů). Z uvedených čísel je patrné, že tedy i rozměry právě porovnávaných obrazů vzrostly zhruba o třetinu a časová náročnost výpočtů tedy roste lineárně.


### ***Registrace výřezu obrazu***

Nyní otestuji celý program na „reálných datech“ a sice na leteckých snímcích z obrázku č. 15. Zde je patrné, že se jedná o registraci pouhého výřezu z nějakého velkého obrazu, neboť při otočení nevznikají žádné černé (nedefinované) oblasti. Nejprve se tedy rotuje celý obraz a až poté se udělá výřez požadované oblasti, která bude předmětem registrace.

Tato dvojice registrovaných obrazů již nemá s lékařskými daty nic společného, funkčnost zvolených podobnostních kritérií lze tedy jen těžko předvídat. Proto si opět vykreslím grafy s vývojem kritériálních funkcí při prohledávání hrubou silou (obrázek č. 16).



Obrázek 15. Letecký snímek ZČU a letecký snímek ZČU rotovaný o 45° s reálným pozadím.



Obrázek 16. Ověření funkčnosti kritériálních funkcí na leteckém snímku ZČU a leteckém snímku ZČU rotovaném o 45° s reálným pozadím.

Z grafů na obrázku č. 16 je vidět, že podobnostní kritéria v základní podobě nejsou vhodnou volbou pro registraci dat z dálkového průzkumu Země. Kritériální funkce uniformita poměru obrazu, euklidovská vzdálenost a suma kvadrátů rozdílů absolutně neodpovídají požadovanému průběhu a bez dalších úprav jsou prakticky nepoužitelné. Jedinou kritériální funkcí, která by mohla dosáhnout uspokojivého výsledku, je korelační koeficient. Přesné výsledky opět získám spuštěním optimalizační metody simulovaného žíhání.

	RIU	ED	CC	SSD
1. výpočet	0.14624827	0.20269313	43.91568254	0.03596529
2. výpočet	0.29713795	0.10170526	43.91569191	0.26498948
3. výpočet	0.25242632	0.05920346	43.91556248	0.08143145
4. výpočet	0.27768764	0.41609656	43.91576102	0.00971094
5. výpočet	0.30325121	0.01407478	43.91578527	0.39844452
6. výpočet	0.29879679	0.59934132	43.91571383	0.20609982
7. výpočet	0.20391579	0.03599594	43.9157937	0.05982043
8. výpočet	0.47204625	0.00994684	43.91579643	0.24057956
9. výpočet	0.28220919	0.3215345	43.91489724	0.32594329
10. výpočet	0.26638773	0.20154896	43.91579868	0.09593783

Tabulka 4. Výsledky optimalizační metody Simulovaného žíhání při registraci leteckého snímku ZČU a leteckého snímku ZČU rotovaného o 45° s reálným pozadím.

Průměrná hodnota spočtených výsledků při použití kriteriální funkce:

- RIU: 0.28001071°
- ED: 0.19621408°
- CC: 43.9156483°
- SSD: 0.17189226°

Průměrný čas jednoho výpočtu extrémů kriteriální funkce:

- RIU: 248 s
- ED: 47 s
- CC: 102 s
- SSD: 46 s

Výsledky potvrzují předchozí tvrzení o praktické nepoužitelnosti podobnostních kritérií v základní podobě na datech z dálkového průzkumu Země. Korelační koeficient je jedinou kriteriální funkcí s uspokojivými výsledky.


### ***Registrace s využitím binární masky***

V následující části se tedy pokusím vhodnou úpravou vylepšit dosavadní algoritmus tak, aby bylo možné použít čtyři vybraná podobnostní kritéria založená na intenzitě v obrazu (uniformita poměru obrazu, euklidovská vzdálenost, korelační koeficient a suma kvadrátů rozdílů) nejen pro registraci medicínských dat, ale i dat z dálkového průzkumu Země.

Pro nalezení správného řešení je nejprve důležité se zpětně podívat na získané výsledky a uvědomit si, proč tato kritéria v základní podobě nepracují správně s leteckými snímky a naopak, proč pracují výborně při porovnávání snímků mozku. Jako stěžejní bod pro správnou funkci těchto kritérií se jeví ohraničenost registrovaného objektu. U snímků mozku je celý obraz jasně ohraničen lebkou, která má neměnný tvar a v našem případě i stejnou velikost (v úvodu kapitoly jsem zmínil, že jsem se omezil pouze na rotaci registrovaných obrazů). U leteckých snímků ZČU se však s takovým pevným ohraničením nesetkáme a proto je důležité jej uměle vytvořit a tím docílit toho, že při porovnávání obrazů se bude počítat pouze s těmi oblastmi, které nás v daném kroku algoritmu zajímají.

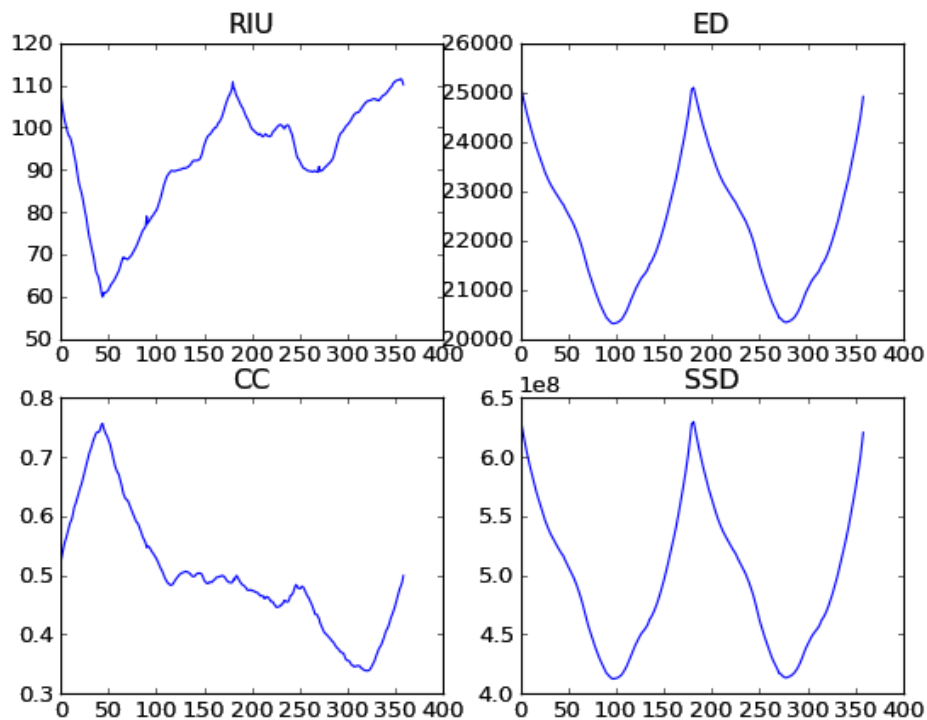
Úprava algoritmu tedy spočívá v tom, vytvořit v každém kroku jakousi masku, která reprezentuje výsek z původního, originálního obrazu, který nás v danou chvíli zajímá. Porovnávaná oblast byla až do této chvíle v každém kroku stejná a byla shodná s velikostí a tvarem původního obrazu. Po několika krocích (rotacích) se však objevuje problém s již zmíněnou černou oblastí, která se vytváří pro vyplnění prázdných částí v okolí obrazu. Tento problém pak neustále zesiluje. Při rotaci o  $90^\circ$  takto vzniklá černá oblast vyplňuje již téměř třetinu celého obrazu. Vytvořením vhodné masky lze tuto černou oblast ignorovat.

V každém kroku se tedy vytvoří nová maska nesoucí informaci o oblasti, která v nově vzniklém obrazu reprezentuje tu část z obrazu původního, která je pro registraci stěžejní. Pro názornost je na obrázku č. 17 bíle vyznačen tvar masky při rotaci o  $5^\circ$  a  $45^\circ$ . Algoritmus tedy v každém kroku porovnává pouze tu část, která je překryta konkrétní maskou a při výpočtu tudíž zcela ignoruje stále vznikající černé oblasti.



Obrázek 17. Tvar masky při rotaci 5° a tvar masky při rotaci 45°.

Spustím tedy celý program ještě jednou se stejnými porovnávanými obrazy (obrázek č. 15), ovšem nyní s funkcí maskování obrazu. Nejprve opět vykreslím graf pro orientační zjištění funkčnosti kriteriálních funkcí.



Obrázek 18. Ověření funkčnosti kriteriálních funkcí s maskováním na leteckém snímku ZČU a leteckém snímku ZČU rotovaném o 45° s reálným pozadím.

Z grafů na obrázku č. 18 bohužel vyplývá, že maskováním se nepodařilo vyřešit problém se špatnou funkčností kriteriálních funkcí euklidovská vzdálenost a suma kvadrátů rozdílů. Naproti tomu se výrazně vylepšil průběh kriteriálních funkcí uniformita poměru obrazu a korelační koeficient. Pro přesné výsledky jsem spustil ještě optimalizační metodu simulovaného žíhání.

	RIU	ED	CC	SSD
1. výpočet	44.56835891	97.14445949	44.73438579	97.04511322
2. výpočet	44.77125744	97.15822913	44.73440645	97.76370203
3. výpočet	44.93551136	97.02173317	44.73443076	96.71248244
4. výpočet	44.99191097	97.13546864	44.73441228	97.01145388
5. výpočet	44.99916388	97.48161989	44.7344006	97.01264181
6. výpočet	44.94427957	96.4139095	44.73444866	97.11865888
7. výpočet	45.15425528	97.76479015	44.73445132	97.51699114
8. výpočet	44.90800314	97.763924	44.73445077	97.02392277
9. výpočet	44.99400743	96.8845008	44.73445086	97.36710913
10. výpočet	44.98036758	96.75374156	44.73445003	97.02488297

Tabulka 5. Výsledky optimalizační metody simulovaného žíhání s maskováním při registraci leteckého snímku ZČU a leteckého snímku ZČU rotovaného o 45° s reálným pozadím.

Průměrná hodnota spočtených výsledků při použití kriteriální funkce:

- RIU: 44.92471156°
- ED: 97.15223763°
- CC: 44.73442875°
- SSD: 97.15969583°

Průměrný čas jednoho výpočtu extrémů kriteriální funkce:

- RIU: 202 s
- ED: 57 s
- CC: 107 s
- SSD: 66 s

Výsledek potvrdil funkčnost programu při použití kritériálních funkcí uniformita poměru obrazu a korelační koeficient. Výsledky jsou v obou případech uspokojivé. Z časového hlediska je podobnostní kritérium korelační koeficient o téměř polovinu rychlejší.

Nefunkčnost kritériálních funkcí euklidovské vzdálenosti a sumy kvadrátů rozdílů v tomto případě vyplývá přímo z jejich definic. U euklidovské vzdálenosti je výsledek porovnání dvou obrazů sumou odmocněného rozdílu intenzit jednotlivých pixelů. Čím je tedy porovnávaná oblast větší (byť jsou rozdíly jednotlivých porovnávaných pixelů malé), tím je i celková hodnota rozdílu větší. Při použití maskování při registraci dvou obrazů se porovnávaná oblast postupně zmenšuje a opět zvětšuje. V té části výpočtu, kdy je porovnávaná oblast největší (rotace  $0^\circ$ ,  $180^\circ$  a  $360^\circ$ ) má hodnota euklidovské vzdálenosti největší hodnotu a to bez ohledu na to, zda jsou rozdíly jednotlivých pixelů malé či velké. V druhém extrémním případě, kdy je porovnávaná oblast téměř třetinová ( $90^\circ$  a  $270^\circ$ ), dochází naopak k poklesu hodnoty euklidovské vzdálenosti a to opět bez ohledu na rozdíly jednotlivých pixelů. Analogicky je tomu u podobnostního kritéria suma kvadrátů rozdílů.

Při hledání řešení tohoto problému jsem se ještě pokusil o výpočet průměrné hodnoty chyby na jeden zobrazovací bod. Tu jsem počítal tak, že výslednou hodnotu v každém kroku registrace jsem ještě podělil počtem právě porovnávaných pixelů. Očekával jsem, že se tím problém alespoň částečně vyřeší a výsledek euklidovské vzdálenosti a sumy kvadrátů rozdílů se přiblíží příznivějším hodnotám. Toto očekávání se však nenaplnilo, neboť výsledné hodnoty zůstaly přibližně stejné a ani zdaleka se nepřiblížily správným výsledkům.

Pro tento nedostatek doporučuji používat program pouze s nastavením kritériálních funkcí uniformita poměru obrazu nebo korelační koeficient.

## 8. ZÁVĚR

Cílem mé práce bylo prostudovat literaturu zabývající se problémem registrace obrazu, a pomocí získaných znalostí navrhnout a implementovat univerzální metodu pro registraci medicínských dat a dat z dálkového průzkumu Země.

První část bakalářské práce je zaměřena na aktuální stav problematiky registrace obrazu. Jsou zde představeny postupy a metody pro řešení tohoto problému. Konkrétně představuje základní metody transformace obrazu, kriteriální funkce, interpolační metody a metody optimalizace. V další části je poté představen návrh a implementace programu. Konec celé práce je věnován testování navržené metody a zhodnocení dosažených výsledků. Ukázalo se, že se podařilo implementovat univerzální metodu pro registraci medicínských dat a dat z dálkového průzkumu Země. Algoritmus celého programu pro registraci je napsán v programovacím jazyce Python a je k dispozici na přiloženém CD.

V realizovaném programu byla pro jednoduchost a názornost omezena obecná transformace na pouhou rotaci. Jako určitý kompromis mezi početní náročností a dosahovanými výsledky byla z interpolačních metod použita interpolace nejbližším sousedem. Pro správný postup při hledání výsledků registrace jsem zvolil stochastickou optimalizační metodu simulovaného žíhání. V programu lze před spuštěním nastavit kriteriální funkci, která má být pro registraci použita. Záleží pouze na uživateli a povaze řešeného problému. Ukázalo se, že při použití kriteriální funkce uniformita poměru obrazu jsou výsledky přesnější, ovšem časová náročnost výpočtu je neuspokojivá. Naproti tomu, při použití kriteriální funkce korelační koeficient je čas potřebný k výpočtu téměř poloviční, dosažené výsledky ovšem nedosahují takových kvalit.

Jako hlavní nedostatek programu se jeví časová náročnost celého procesu registrace a díky chybějícímu grafickému uživatelskému rozhraní i jistá nepřehlednost při nastavování jednotlivých parametrů. Do budoucna bych chtěl program rozšířit o již zmíněné grafické uživatelské rozhraní, které by značně pomohlo k snadnější obsluze programu a zpřístupnilo by ho tak i naprostým laikům v oblasti programování. Dále bych chtěl k programu připojit další rozšiřující funkce, které by podpořili rychlejší získání výsledků. Jako jedno z možných řešení se jeví cílené „zničení“ registrovaných obrazů (např. „zahazením“ každého sudého pixelu), neboť, jak bylo při předchozím



testování zjištěno, časová náročnost výpočtů lineárně roste s počtem porovnávaných pixelů.

## 9. LITERATURA

- [1] Bistrý, J.: Registrace obrazu pomocí metody Optical Flow [diplomová práce], Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Brno, 2011
- [2] Ryba, T.: Analýza vývoje tumoru v čase z obrazových dat. Západočeská univerzita v Plzni, Fakulta aplikovaných věd, Plzeň, 2012
- [3] Goshtasby, A. Ardeshir: 2-D and 3-D Image Registration for Medical, Remote Sensing, and Industrial Applications, 2005
- [4] Ronková, P.: Optimalizace pro registraci obrazů založená na genetických algoritmech [diplomová práce], Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Brno, 2012
- [5] Článek ze serveru Wikipedia: Dálkový průzkum Země  
Dokument dostupný na URL  
[http://cs.wikipedia.org/wiki/Dálkový\\_průzkum\\_Země](http://cs.wikipedia.org/wiki/Dálkový_průzkum_Země), 2013
- [6] Černý, F.: Registrace obrazů a prostorová transformace,  
Dokument dostupný na <http://uprt.vscht.cz/mudrova/zob2/prezentace/IR.pdf>
- [7] Metelková, L.: Analytické programování aplikované na operátory evolučních algoritmů [diplomová práce], Univerzita Tomáše Bati ve Zlíně, Fakulta aplikované informatiky, Zlín, 2006
- [8] Lepš, M.: TABU search metoda, Dokument dostupný  
na [http://klobouk.fsv.cvut.cz/~leps/teaching/mmo/prednasky/prednaska05\\_Tabu.pdf](http://klobouk.fsv.cvut.cz/~leps/teaching/mmo/prednasky/prednaska05_Tabu.pdf),  
2007
- [9] Mudrová, M.: Geometrické transformace obrazů a související témata, Dokument  
dostupný na <http://uprt.vscht.cz/mudrova/zob/prednasky/09-TRANSFORMACE/transformace-tisk.pdf>, 2004
- [10] Dluhoš, P.: Metaheuristické optimalizační metody pro registraci obrazů z magnetické rezonance [bakalářská práce], Masarykova univerzita, Přírodovědecká fakulta, Brno, 2011

- [11] Pernicová, L.: Optimalizační metoda trust pro registraci medicínských obrazů [diplomová práce], Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Brno, 2012
- [12] Daněk, O.: Registrace obrazů buněk podle intenzit v obraze [diplomová práce], Masarykova univerzita, Fakulta informatiky, Brno, 2006
- [13] Václavík, J.: Interpolace obrazů [bakalářská práce], Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Brno, 2010
- [14] Sonka, M., Hlaváč, V., Boyle, R.: Image Processing, Analysis, and Machine Vision, 2006