




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV NIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

METODA SLEDOVÁNÍ PŘÍZNAKŮ PRO REGISTRACI SEKVENCE MEDICÍNSKÝCH OBRAZŮ

FEATURE TRACKING METHOD FOR MEDICAL IMAGES REGISTRATION

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. TOMÁŠ JAKUBÍK

VEDOUCÍ PRÁCE
SUPERVISOR

ING. VRATISLAV HARABIŠ

BRNO 2012



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Student: Bc. Tomáš Jakubík

ID: 98483

Ročník: 2

Akademický rok: 2011/2012

NÁZEV TÉMATU:

Metoda sledování příznaků pro registraci sekvence medicínských obrazů

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši metod registrace medicínských obrazů. Zaměřte se zejména na možnosti registrace sekvence obrazů s využitím metod sledování příznaků. 2) Stanovte hlavní cíle práce, které vedou k návrhu a implementaci vhodné registrační metody pro zpracování sekvencí dat získané během perfuzního zobrazování. 3) Navrhněte vhodnou metodu pro registraci sekvencí dat, metodu implementujte v prostředí Matlab nebo C++ s možností využití dostupných knihoven (ITK, MATITK). 4) Navrženou metodu otestujte na dostatečném vzorku simulovaných i reálných dat. Navrhněte metodiku hodnocení a vyhodnoťte výsledky metody registrace. 5) Proveďte diskuzi navržené metody a implementace, zhodnoťte dosažené výsledky, výkon a rychlost navrženého řešení.

DOPORUČENÁ LITERATURA:

[1] CERVANTES, A., KANG, E. Progressive multi-image registration based on feature cracking. Image Processing, Computer Vision, vol. 1, 2006.

[2] BOHS, L. Speckle tracking for multi-dimensional flow estimation. Ultrasonics, vol. 38, 2000, pp. 369-375.

Termín zadání: 6.2.2012

Termín odevzdání: 18.5.2012

Vedoucí práce: Ing. Vratislav Harabiš

Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

UPOZORNĚNÍ:

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

ABSTRAKT

Cieľom tejto diplomovej práce je zoznámiť sa s problematikou registrácie sekvencie medicínskych obrazov. Hlavným cieľom bolo zamerať sa na metódu sledovania príznakov v obraze a rôzne možnosti jej implementácie. V teoretickej časti boli popísané rôzne metódy detekcie význačných bodov a metód párovania týchto bodov. V praktickej časti boli tieto metódy implementované v programovom prostredí Matlab a bolo vytvorené jednoduché grafické rozhranie.

Kľúčové slova:

registrácia obrazov, sledovanie príznakov v obraze, detekcia význačných bodov, párovanie význačných bodov

ABSTRACT

The aim of this thesis is to familiarize with the issue of registration of medical image sequences. The main objective was to focus on the method of feature tracking in the image and various options of its implementation. The theoretical part describes various methods for detection of feature points and feature point matching methods. In the practical part these methods were implemented in Matlab programming environment and a simple graphical user interface was created.

Keywords:

image registration, feature point tracking, feature point detection, feature point matching

JAKUBÍK, T. Metoda sledování příznaků pro registraci sekvence medicínských obrazů.
Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních
technologií, 2012. 66 s. Vedoucí diplomové práce Ing. Vratislav Harabiš.

PREHLÁSENIE

Prehlasujem, že svoju diplomovú prácu na tému Metoda sledování příznaků pro registraci sekvence medicínských obrazů som vypracoval samostatne, pod vedením vedúceho diplomovej práce a s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zoznamu literatúry na konci práce.

Ako autor uvedenej diplomovej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobných a som si plne vedomý následkov porušenia ustanovení § 11 a autorského zákona č. 121/2000 Sb., vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia § 152 trestného zákona č. 140/1961 Sb.

V Brne dňa

.....

(podpis autora)

Ďakujem vedúcemu diplomovej práce Ing. Vratislavovi Harabišovi za podporu a odbornú pedagogickú pomoc, ako aj za ďalšie cenné rady a zhovievavosť pri spracovaní mojej diplomovej práce.

V Brne dňa

.....

(podpis autora)

Obsah

1. Úvod.....	1
2. Klasifikácia registračných metód.....	2
3. Geometrické transformácie	5
3.1. Rigidné transformácie	6
3.1.1. Translácia	6
3.1.2. Rotácia.....	7
3.2. Nonrigidné transformácie	7
3.2.1. Dilatácia – zmena mierky osi	7
3.2.2. Afinná transformácia	8
3.2.3. Projektívna transformácia.....	8
4. Sledovanie význačných bodov (Feature point tracking).....	9
4.1. Detekcia význačných bodov	10
4.1.1. Metóda SUSAN.....	10
4.1.2. Harrisov detektor	12
4.1.3. KLT detektor, Shi-Tomasi detektor	15
4.1.4. Entropia bodov	16
4.1.5. SIFT deskriptor.....	17
4.1.6. SURF deskriptor.....	20
4.1.7. FAST detektor	25
4.2. Hľadanie rovnakých párov význačných bodov.....	27
4.2.1. Korelačný koeficient lokálnej oblasti - LACC.....	27
4.2.2. Metóda najmenších Euklidových vzdialeností.....	30
4.3. Eliminácia nekorešpondujúcich si párov	30
5. Realizovaný program	33
5.1. Panel Načítanie súborov.....	34
5.2. Panel Spustenie registrácie.....	34
5.2.1. Popis algoritmu funkcie harris.m	35
5.2.2. Popis algoritmu funkcie ST_detect.m	36
5.2.3. Popis algoritmu funkcie local_entropy.m.....	36
5.2.4. Popis algoritmu funkcie match_FP_distance.m	36
5.2.5. Popis algoritmu funkcie match_LACC.m	36

5.2.6. Popis algoritmu funkcie LACC_distance_matching.m.....	37
5.3. Panel Vykresľovanie a Zobrazenie	37
6. Testovanie naprogramovaných metód	39
6.1. Porovnanie detekcie význačných bodov pomocou jednotlivých metód	39
6.1.1. Testovanie rýchlosti detektorov	39
6.1.2. Test a vyhodnotenie počtu a stability detekovaných význačných bodov	41
6.2. Porovnanie metód párovania význačných bodov.....	46
6.2.1. Časová náročnosť párovania význačných bodov	46
6.2.2. Porovnanie a zhodnotenie párovania význačných bodov.....	48
7. Výsledky registrácie snímku	52
8. Záver	60
Zoznam použitej literatúry	61
Príloha I.....	64
Príloha II	65
Príloha III	66

1. Úvod

Pod pojmom registrácia sekvencie obrazov rozumieme proces, za pomoci ktorého dosiahneme zarovnanie jednotlivých po sebe nasledujúcich snímok jednej scény tak, aby sa body v jednom obraze prekrývali s odpovedajúcimi si bodmi v druhom obraze. Typickým príkladom registrácie sekvencie snímok v bežnom živote, je vytváranie panoramatických fotografií z menších čiastkových snímok oblasti.

V medicínskej aplikácii, ktorou sa budeme primárne zaoberať, sa s registráciou snímok možno stretnúť predovšetkým u tomografických metód zobrazovania ľudského tela, ako CT, MRI, SPECT a PET. Tu sa registračné metódy uplatňujú predovšetkým pri zarovnávaní tomografických rovín, čo je prvý predpoklad k úspešnému vytvoreniu trojdimenzionálneho obrazu ľudského tela. Avšak čoraz častejšie sa požaduje aj zobrazenie snímok z viacerých medicínskych metód do jedného obrazu, čím dostaneme vo výsledku obraz s omnoho väčšou výpovednou a diagnostickou hodnotou. Napríklad v prípade PET a CT vidíme nielen distribúciu radionuklidu v tele, ale aj anatomické štruktúry tela.

Cieľom registrácie dvoch, alebo viacerých obrazov je nájdenie vzájomných vzťahov medzi danými obrazmi, za pomoci ktorých môžeme vytvoriť vhodnú geometrickú transformáciu. Keďže problematika stanovenia geometrickej transformácie zo získaných vzťahov prevyšuje možnosti tejto práce, budú v nej popísané len základné geometrické transformácie a ich princípy. Podrobnejšie sa táto práca bude zaoberať metódami hľadania daných vzťahov potrebných k určeniu geometrickej transformácie. Keďže táto problematika je veľmi obsiahla, tak táto práca bude hlavne zameraná na metódy, ktoré pracujú na základe hľadania a sledovania príznakov či význačných bodov v obraze.

Tieto metódy budú podrobne popísané, bude popísaná funkcia jednotlivých metód a niektoré z nich implementované v programovom prostredí Matlab. Na základe tejto implementácie budú jednotlivé metódy porovnané z hľadiska rýchlosti, účinnosti stanovenia význačných bodov a ich následného spárovania. Na základe týchto hodnotení bude stanovená najlepšia metóda pre registráciu daných testovacích, ako aj reálnych snímok. Ako vzor pre registráciu reálnych obrazov poslúžia snímky MRI.

2. Klasifikácia registračných metód

Pri registrácii obrazov možno postupovať viacerými spôsobmi a metódami. Každá z týchto metód môže pracovať na inom princípe hneď od počiatočnej fáze registrácie, alebo môže mať spočiatku spoločné znaky s inou metódou a odlišovať sa až vo finálnych fázach. Preto klasifikujeme jednotlivé metódy registrácie obrazov podľa kritérií popísaných v [1].

1. *Dimenzionalita obrazu* – udáva počet rozmerov geometrického priestoru, s ktorým pracujeme pri registrácii obrazu. V medicíne sa najčastejšie stretávame s registráciou dvojdimenzionálnych (2D) alebo trojdimenzionálnych (3D) obrazov. V súčasnosti sa však stále častejšie objavuje aj požiadavka na registráciu 3D obrazov v čase, a teda v štvordimenzionálnom (4D) priestore.
2. *Základný charakter registrácie* – udáva, či pri registrácii obrazov používame nejaké vonkajšie umelé objekty, ktoré sú dobre viditeľné a ktoré nám poskytujú prídavné informácie o snímanej scéne (stereo taktický rám, navádzacie značky), alebo pracujeme len s informáciami, ktoré nám poskytuje samotná snímaná scéna (intrinsické metódy). Prvý prípad možno v medicínskej oblasti zaznamenať napríklad pri použití Leksellovho gama noža. Druhý prípad je však omnoho častejší, napríklad pri snímkach tomografických zobrazovacích metód. Intrinsické metódy sa ďalej delia na metódy využívajúce získania význačných orientačných bodov (väčšinou určených manuálne obsluhou registrácie), segmentačné metódy a metódy porovnávania parametrov pixlov (voxlov v 3D).
3. *Charakter a doména geometrickej transformácie* – udáva druh transformácie použitej na dosiahnutie registrácie ako aj to, či je transformácia použitá na celý obraz (globálne), alebo viac častí obrazu má definovanú svoju vlastnú transformáciu. Geometrickými transformáciami sa budeme zaoberať podrobnejšie v ďalšej časti práce.
4. *Stupeň interakcie* – udáva, ako veľmi môže užívateľ zasahovať do procesu registrácie.

Plne interaktívna registrácia znamená, že užívateľ prevádza registráciu sám v reálnom čase. Teda sám manuálne zarovnáva obrazy tak, aby sa korešpondujúce si body v obraze prekryli. Toto je v medicíne takmer nepoužiteľná metóda vzhľadom na časovú náročnosť. Poloautomatický režim znamená pre užívateľa jak voľnosť pri voľbe metód

v jednotlivých fázach registrácie, tak aj možnosť voľby parametrov týchto metód. Tým možno doceliť dobré výsledky registrácie, avšak za cenu vyššej časovej náročnosti, keďže nie vždy parametru prinesie lepší výsledok. Automatický proces registrácie znamená pre užívateľa nemožnosť akokoľvek zasahovať do procesu registrácie. Jediný vstup ktorý sa väčšinou požaduje od užívateľa je výber vstupných obrazov, avšak pri registrácii obrazov v reálnom čase (napríklad pri snímaní CT) nie je ani tento údaj potrebný.

5. *Optimalizačná procedúra* – udáva, či sa registračná transformácia vypočítava priamo z parametrov ktoré poznáme, alebo na základe hľadania optima funkcie, ktorá je definovaná na základe týchto získaných parametrov. V druhom prípade môže ísť napríklad na hľadania najlepšej registrácie za pomoci rôznych rozlíšení obrazov alebo rôzneho stupňa rozostrenia.
6. *Modality v registrácii* – udáva, koľko rôznych modalít obrazu vstupuje do registrácie. Monomodálnymi (intramodal) aplikáciami rozumieme to, že všetky obrazy ktoré vstupujú do registrácie sú získané len pomocou jednej metódy. Teda dá sa predpokladať vysoká miera podobnosti obrazov. Naproti tomu v multimodálnej (intermodal) registrácii je miera podobnosti medzi obrazmi menšia, keďže nemusia pochádzať z rovnakej metódy snímania (CT+MRI, CT+PET). Modalita však nemusí byť zviazaná len s metódou akvizície obrazu, ale modalitou sa môže rozumieť aj registrácia dvoch rozdielnych (avšak vzájomne podobných) objektov, ako je napríklad modalita a model. Príkladom môže byť registrácia MRI obrazu mozgu s matematicky definovaným kompartmentovým modelom štruktúry mozgu. Posledným prípadom, ktorý spadá pod toto delenie je registrácia pacienta a modality. Toto možno pochopiť na príklade umiestňovania pacienta na RTG stôl pomocou navádzacích laserov, ktoré boli predtým nastavené zo znalosti predošlých snímaní anatómie tela pacienta, napríklad pomocou CT.
7. *Subjekt* – udáva, či obrazy ktoré vstupujú do registrácie pochádzajú od jediného snímaného subjektu (pacienta), alebo od viacerých. Hovoríme teda o registrácii intrasubjektu (jeden) alebo intersubjektu (viacero). V prípade, že do registrácie vstupuje okrem obrazu získaného od pacienta aj obraz, ktorý je nejakým spôsobom skonštruovaný za použitia mnohých subjektov podobného charakteru (model), hovoríme o registrácii „atlasu“.

8. *Objekt* – udáva, ktorý objekt snímame v danom subjekte. V medicíne to teda znamená, či sa jedná o snímky hlavy, hrudníku, končatín, orgánov, poprípade iných častí ľudského tela.

Keďže registračná procedúra môže byť vždy vyjadrená pomocou troch hlavných častí ktorými sú definovanie problému, registračná paradigma (súbor registračných princípov) a optimalizačný proces, je každá jedna metóda presne klasifikovaná uvedeným delením. Samozrejme, že uvedené delenia sú z istej časti vzájomne prepojené a navzájom sa ovplyvňujú. Možno povedať, že definovanie problému určuje klasifikáciu podľa kritérií 6) 7) a 8) a má priamy vplyv na kritéria 1) a 3). Paradigma prevažne priamo ovplyvňuje kritéria klasifikácie podľa 2) 3) a 4) zatiaľ čo optimalizačná procedúra ovplyvňuje kritérium 4) a kontroluje kritérium 5). Tieto tri hlavné časti sú na sebe nezávislé. [2]


3. Geometrické transformácie

Každý obraz, ktorý vstupuje do registrácie možno popísať súradným systémom, ktorý definuje priestor tohto obrazu. Naša definícia registrácie je založená na geometrických transformáciách, ktoré sú vlastne mapovaním bodov z priestoru X jedného obrazu, na body priestoru Y druhého obrazu. Po aplikovaní transformácie T na bod v priestore X , ktorý je reprezentovaný stĺpcovým vektorom x , dostávame transformovaný bod x' . [3]

$$x' = T(x)$$

Pokiaľ bod y v priestore Y korešponduje s bodom x v priestore X , potom úspešnou transformáciou dosiahneme toho, že súradnice bodu x' budú rovnaké, alebo približne rovnaké ako bodu y . Akékoľvek nenulové posunutie $T(x) - y$ znamená registračnú chybu. Všetku možné skupiny transformácií môžeme rozdeliť do dvoch základných skupín, a to na tuhé (rigidné) transformácie a na pružné (nonrigid) transformácie. Toto delenia má zmysel aj pre medicínske aplikácie, keďže mnoho častí ľudského tela má rigidné správanie sa v priestore, teda ich tvar sa v krátkom časovom úseku nemení, ale je pevne daný. Typickým príkladom sú kosti, lebka a chrbtica. Naproti tomu väčšina ľudských orgánov sa správa značne nonrigidne, a teda mení svoj tvar v krátkom časovom úseku. Najlepším príkladom je srdce. [3]

V predošlej kapitole bolo spomenuté, že transformácie sa môžu deliť na lokálne a globálne. Globálne transformácie sú použité na celé obrazy, pričom lokálne len na určité oblasti obrazu. Lokálne transformácie obvykle nie sú použité priamo, pretože môžu porušiť lokálnu kontinuitu a nezvratiteľnosť transformácie môže narušiť jednoduché prevzorkovanie obrazu pri použití tejto transformácie na obraz. Pojem lokálna transformácia je rezervovaný pre transformácie, ktoré sú kombináciou aspoň dvoch transformácií aplikovaných na pod-obrazy, ktoré nemôžu byť definované ako globálna transformácia. Preto, jediná transformácia aplikovaná na nejaké záujmové oblasti v obraze je vlastne „globálna transformácia“, ktorá je teraz aplikovaná na nový obraz, ktorý je vlastne pod-obrazom pôvodného obrazu. Každú lokálnu transformáciu je teda možno považovať za globálnu v určitej oblasti obrazu. Väčšinou sú rigidné a afinné transformácie označované ako globálne a krivkové transformácie sú označované ako lokálne.



Obrázok 3.1 Ukážka lokálnej a globálnej transformácie

3.1. Rigidné transformácie

Rigidné transformácie, alebo rigidné mapovania, sú definované ako geometrické transformácie ktoré zachovávajú všetky vzdialenosti. Tieto transformácie taktiež zachovávajú rovnobežnosť a rovnosť línií (ako aj planaritu, teda rovinnosť povrchov) a všetky nenulové uhly medzi rovnými líniami. Rovnako zachovávajú aj rovnobežnosť jednotlivých línií. Registračné problémy ktoré sú limitované na rigidné transformácie sa nazývajú *rigidné registračné problémy*. Rigidné transformácie sú ľahko definovateľné, a delia sa v základe v podstate len na dva druhy. Prvým je translácia, teda posunutie a druhým *rotácia*, teda otočenie. Keďže budeme pracovať rovinnými obrazmi, budeme sa pohybovať len v 2D súradnom systéme. [3]

3.1.1. Translácia

Je to transformácia, pri ktorej nastáva posun obrazu po zadanom vektore. Je teda určená len vektorom posunutia. Zostávajú zachované všetky vzdialenosti aj uhly v obraze. Aplikáciou tejto transformácie T na bod P získame bod P' o súradniciach (podľa [3])

$$x' = x + x_T \quad y' = y + y_T$$

Maticové vyjadrenie transformácie posunutia má pre homogénne súradnice tvar (podľa [3])

$$P' = P \cdot T \quad [x', y', 1] = [x, y, 1] \cdot \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ X_T & Y_T & 1 \end{bmatrix}$$

3.1.2. Rotácia

Je to transformácia, pri ktorej dochádza k otočeniu obrazu o uhol α so stredom otáčania v počiatku súradného systému. Opäť zostávajú zachované všetky vzdialenosti a uhly. Kladný smer otáčania je proti smeru otáčania hodinových ručičiek, od osy X k ose Y. Záporný je v opačnom smere. Aplikáciou tejto transformácie na bod P získame bod P' a táto transformácia T je daná vzťahom (podľa [3])

$$x' = x \cdot \cos \alpha - y \cdot \sin \alpha \qquad y' = x \cdot \sin \alpha + y \cdot \cos \alpha$$

Maticové vyjadrenie transformácie posunutia má pre homogénne súradnice tvar (podľa [3])

$$P' = P \cdot R \qquad [x', y', 1] = [x, y, 1] \cdot \begin{bmatrix} \cos \alpha & \sin \alpha & 0 \\ -\sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

3.2. Nonrigidné transformácie

Sú to také transformácie, alebo mapovania, ktoré nezachovávajú buď vzdialenosti, alebo nezachovávajú uhly, poprípade nezachovávajú ani jeden z týchto parametrov. Taktiež nemusia vždy zachovať rovnobežnosť línií. Používajú sa pri nonrigidných registračných problémoch, napríklad pri registrácii obrazov srdca alebo pľúc.

3.2.1. Dilatácia – zmena mierky osi

Je to transformácia, pri ktorej dochádza k zmene mierky v jednej, alebo v oboch osiach. Pri aplikácii transformácie na bod P v rovine s homogénnymi súradnicami, nastáva buď to zväčšenie pri mierke $S_{x,y} > 1$, zmenšenie pri mierke $0 < S_{x,y} < 1$, alebo k zrkadleniu pri mierke $S_{x,y} < 0$. Pri týchto transformáciách nedochádza k zachovaniu veľkosti uhlov. Jediný prípad, keď sa zachovávajú veľkosti uhlov je pri $S_x = S_y$. Zmena mierky je daná vzťahom (podľa [3])

$$x' = x \cdot S_x \qquad y' = y \cdot S_y$$

Maticové vyjadrenie dilatácie má tvar (podľa [3])

$$P' = P \cdot S \qquad [x', y', 1] = [x, y, 1] \cdot \begin{bmatrix} S_x & 0 & 0 \\ 0 & S_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

3.2.2. Afinná transformácia

Je to transformácia, pri ktorej dochádza ku skoseniu obrazu. Nie sú zachované veľkosti uhlov, avšak zachováva sa rovnobežnosť línií. Pri transformácii len v smere jednej osi dochádza k zachovaniu rozmerov u línií, ktoré sú rovnobežné s danou osou. Pri transformácií v oboch osách nie sú zachované žiadne rozmery. Transformácia je daná vzťahom (podľa [3])

$$x' = x + S_{hx} \cdot y \qquad y' = y + S_{hy} \cdot x$$

Ak koeficient skosenia v jednej osi $S_h = 0$, nedochádza v tejto osi ku skoseniu. Maticový zápis afinnej transformácie má tvar (podľa [3])

$$P' = P \cdot S_h \qquad [x', y', 1] = [x, y, 1] \cdot \begin{bmatrix} 1 & S_{hx} & 0 \\ S_{hy} & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

3.2.3. Projektívna transformácia

Je to transformácia, ktorá sa používa pre vyjadrovanie perspektívy, teda na transformáciu 2D obrazu do „kvázi 3D“. Po transformácii nie sú v obraze zachované ani uhly, ani rozmery a ani rovnobežnosť línií. Jediný parameter ktorý je zachovaný je priamosť línií. Transformácia je daná vzťahom (podľa [3])

$$x' = x \frac{1}{1+z/d} \qquad y' = y \frac{1}{1+z/d}$$

kde d je vzdialenosť „projekčnej roviny“ od pozorovateľa a z je hĺbka projekcie jednotlivých bodov. Maticový zápis projekčnej transformácie má tvar (podľa

$$P' = P \cdot H_{ab} \qquad [x', y', 1] = [x, y, 1] \cdot \begin{bmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & 1 \end{bmatrix}$$

4. Sledovanie význačných bodov (Feature point tracking)

Algoritmus pre sledovanie význačných bodov môže byť rozdelený do troch štádií – detekcia významných bodov (niekedy označované ako „corner“ - rohy), hľadanie rovnakých párov význačných bodov a eliminácia párov, ktoré si navzájom neodpovedajú.

V súčasnej dobe existuje veľké množstvo algoritmov na detekciu význačných bodov, ktoré môžu byť v obširnejšom pohľade rozdelené do viacerých kategórií. Prvé z nich využívajú nelineárnej filtrácie, podobne ako hranový detektor SUSAN (Smallest Univalued Segment Assimilating Nucleus – najmenší jednohodnotový segment približujúci sa k základu) ktorý navrhol Stephen Smith [4], ktorý pracuje na základe vzťahu jedného centrálného pixlu ku svojmu okoliu. Tento hranový detektor dokáže efektívne pracovať aj pri obraze obsahujúcom šum, keďže nepotrebuje derivovať obraz (hľadať minimá a maximá).

Druhá skupina algoritmov je založená na zakriveniach, napríklad ako metóda Kitchen and Rosenfeld [5]. Táto metóda potrebuje v prvom rade extrahovať hrany a následne vyhľadáva význačné body na základe zakrivenia jednotlivých hrán. Nevýhodou týchto metód je potreba komplikovaných kalkulácií ako je posudzovanie zhodnosti kriviek a ich následné úpravy, čo znamená že rýchlosť spracovania týchto algoritmov je relatívne malá oproti iným metódam.

Tretia skupina algoritmov využíva sledovanie zmeny intenzity pixlu. Typickým príkladom takejto metódy je Harris – Stevensov detektor [6]. Ten produkuje hranovú odozvu významných bodov na základe analýzy ich vlastných hodnôt. Keďže táto metóda nepotrebuje explicitne využívať kľúčového sa okna na, jej spracovanie je veľmi rýchle. Avšak, táto metóda je citlivá na šum v obraze, pretože využíva okrem iného aj deriváciu obrazu prvého rádu.

Hľadanie zodpovedajúcich si párov bodov znamená nájsť také význačné body, ktoré sa nachádzajú v oboch registrovaných obrazoch. Opäť existuje mnoho algoritmov ktoré možno principiálne rozdeliť do dvoch kategórií. Prvou je hľadanie zhody na základe zhodných oblastí. Väčšina algoritmov je tohto typu. Tie vyberajú navzájom si zodpovedajúce páry na základe lokálnych korelačných koeficientoch. Tieto však využívajú len lokálne charakteristiky obrazu, preto vysoká korelačná hodnota nemusí vždy viesť k správne nájdeniu páru význačných bodov. Druhou metódou je hľadanie zhody na základe zhodných význačných bodov. Táto metóda si vyžaduje kalkuláciu

význačných bodov hrán a oblastí. Tieto význačné body sú akousi abstraktným popisom obsahu obrazu a sú nezávislé na rozdielnej intenzite svetla v obraze, ako aj nezávisle na geometrických transformáciách obrazu, no požadujú vysoké nároky na výpočtovú silu. Hľadanie zodpovedajúcich si párov môže byť charakterizované aj pomocou ich optimalizačnej schémy. Niektoré používajú globálne optimalizačné metódy ako je dynamické programovanie, relaxačné metódy a mnohé iné. Zvyšné využívajú nejakého lokálneho algoritmu ako je simulované žihanie, náhodné hľadanie a iné. Väčšina týchto metód vyžaduje nejaké extra obmedzenia, ktoré pokiaľ nie sú splnené tak sú tieto metódy nepoužiteľné. Niektoré metódy [7] využívajú lineárneho programovania ktoré je veľmi efektívne, no využíva príliš mnoho pamäte a potrebuje aspoň približné stanovenie počtu správne spárovaných význačných bodov.


Ďalším nemenej dôležitým problémom pri registrácii pomocou význačných bodov je to, aby sme eliminovali páry ktoré si navzájom nekorešponujú. Toto nesprávne stanovenie dvojíc by mohlo mať za následok nesprávne určenie geometrickej transformácie a teda aj nesprávnu registráciu obrazov. V súčasnosti sa ako najviac efektívna metóda v tejto oblasti ukazuje eliminácia za pomoci najmenšieho mediánu štvorcov [20] ktorou sa budeme zaoberať.

4.1. Detekcia význačných bodov

V hlavnej časti kapitoly sme si popísali rôzne možnosti detekcie význačných bodov pomocou rôznych metód. Vzhľadom na vlastnosti jednotlivých metód detekcie sa ako najvýhodnejšia javí prvá a tretia možnosť, teda detekcia za pomoci nelineárnej filtrácie a detekcia pomocou sledovania zmeny intenzity pixlu . Týmito dvomi metódami sa teda budeme zaoberať podrobnejšie.

4.1.1. Metóda SUSAN

Každý obrazový pixel je použitý ako centrálny bod malej masky, ktorá obsahuje pár bodov, ktoré sú najbližšie k centrálnemu (Obrázok 4.1) pre štyri rôzne pozície. Masky je limitovaná pomocou kruhu s krížikom v strede indikujúcim centrálny pixel, ktorý je označený ako nukleus. [4]



Obrázok 4.1 Štyri masky detektora umiestnené na rôznych miestach obrazu

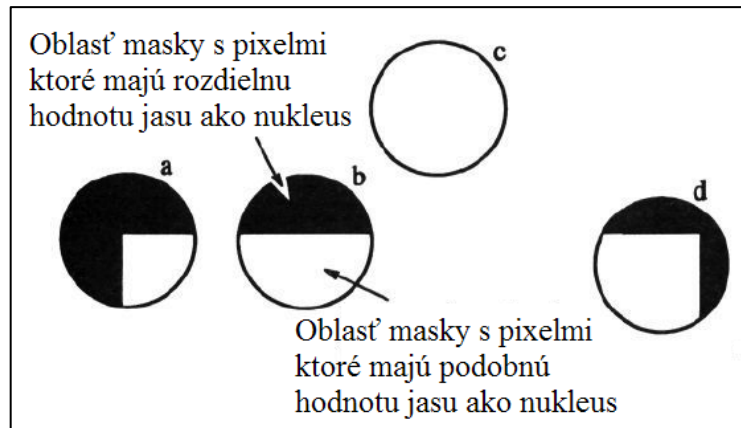
Prvým krokom je zistiť intenzitu jasnu nukleusu a porovnať ju s intenzitou jasnu ostatných pixlov, ktoré sú vo vnútri kruhovej masky. To je dané jednoduchou funkciou

$$c(\vec{r}, \vec{r}_0) = e^{-\left(\frac{(I(\vec{r}) - I(\vec{r}_0))^6}{t}\right)}$$

kde \vec{r}_0 je pozícia nukleusu v obraze, \vec{r} je pozícia niektorého z bodov masky, $I(\vec{r})$ je hodnota intenzity jasnu tohto obrazu, t je prahová hodnota rozdielu intenzity jasnu a c je výstup funkcie. [4]

Pixle s rovnakou, alebo podobnou intenzitou akú má nukleus sú potom považované za časť rovnakej oblasti v obraze (napríklad tmavá a svetlá oblasť - Obrázok 4.2). Na ďalšom obrázku je potom bielou farbou znázornená maska s pixlami ktoré majú podobnú intenzitu jasnu ako nukleus a čiernou farbou maska s pixlami ktoré majú inú hodnotu intenzity jasnu než má nukleus. Biela časť masky je teraz použitá na rozhodnutie, či nukleus leží na rohu (význačnom bode) alebo nie. [4]

Bielu časť masky budeme nazývať „USAN“ alebo „univalu segment assimilating nucleus – jednodnotové segmenty približujúce sa k nukleusu“. Jednodnotové segmenty budeme rozumieť časť masky, ktorá ma lokálne konštantnú alebo takmer konštantnú intenzitu jasnu. [4]



Obrázok 4.2 Štyri masky s označením USAN-ov

Z obrázku 4.2 je možno vidieť, že USAN ktorý korešponduje s rohom, prípad a), je relatívne malý. V skutočnosti, ak je USAN oblasťou ktorá zahrňuje približne polovicu masky alebo menej, potom je nukleus umiestnený pri konvexnom okraji jednorodnotovej oblasti. Prípady b) a c) teda nespĺňajú túto podmienku. Pokiaľ je horný limit USAN oblasti nastavený na časť menšiu ako je jedna polovica oblasti masky, potom zakrivenie konvexnej hrany musí byť nad nejakou minimálnou hranicou. [4]

Taktiež je jasné, že lokálnym minimom v USAN oblasti nájdeme presnú polohu rohu. Napríklad USAN v prípade d) nebude mať tak malú oblasť ako keby bol nukleus umiestnený presne na rohu ako je to v prípade a). Odtiaľ pochádza názov metódy „Smallest USAN“. [4]

Jednou z výhod tohto detektoru je to, že v algoritme nevyužíva žiadne derivácie jasu. Pri použití prvej alebo druhej derivácie jasu dochádza totiž k zvýrazneniu šumu v obraze. Iné metódy sa snažia toto odstrániť použitím vyhladzovania derivovaných obrazov, avšak toto má za následok zníženie kvality lokalizácie (presnosť lokalizácie) rohov v obraze. Keďže tento detektor nevyužíva žiadnych derivácií nenastáva degradácia obrazu pri vyhladzovaní a teda aj neklesá kvalita lokalizácie význačných bodov.

4.1.2. Harrisov detektor

Harrisov detektor pracuje, na rozdiel od iných metód tak, že detekuje v obraze hrany aj rohy zároveň. Pracuje buď na princípe vytvorenia hranovej reprezentácie obrazu, alebo môže pracovať aj priamo s obrazom prevedeným do šedotónovej reprezentácie. Hranová reprezentácia sa vytvára pomocou aplikácie nejakého z dostupných hranových detektorov (najčastejšie Cannyho operátor). Následne sa v tejto hranovej reprezentácii

detekujú význačné body ktoré sú zhodné s rohmi jednotlivých hrán. Význačnosť týchto bodov spočíva vo veľmi rýchlej zmene intenzity jasu v horizontálnom aj vertikálnom smere. Napríklad ak je v objekte prítomný štvorec, tak v jeho štyroch rohoch sú veľmi dobre použiteľné ako významné body. Toto je možné s výhodou využiť pri analýze pohybu objektov, a teda aj v algoritme sledovania význačných bodov. Podobne sa táto detekcia dá aplikovať aj na spomenutý šedotónový obraz, v ktorom hľadáme taktiež veľmi intenzívne prechody medzi jednotlivými objektmi. [6]

Tento detektor, podobne ako KLT detektor v nasledujúcej kapitole, pracuje na princípe matice lokálnej štruktúry C , ktorá má tvar (podľa [8])

$$C = \begin{bmatrix} \left(\frac{\partial I}{\partial x}\right)^2 & \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} \\ \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} & \left(\frac{\partial I}{\partial y}\right)^2 \end{bmatrix} = \begin{bmatrix} \frac{\partial I}{\partial x} \\ \frac{\partial I}{\partial y} \end{bmatrix} \begin{bmatrix} \frac{\partial I}{\partial x} & \frac{\partial I}{\partial y} \end{bmatrix}$$

pričom v praxi sú parciálne derivácie $\partial I/\partial x$ a $\partial I/\partial y$ často nahradené, respektíve konvolované s jednodimenzionálnou horizontálnou a vertikálnou Prewittovou maskou.

Ďalej nech sú λ_1 a λ_2 vlastné čísla matice C , pričom $\lambda_1 > \lambda_2$. Keďže C je symetrická a pozitívne semi-definitná, obe hodnoty λ_1 aj λ_2 sú kladné čísla, avšak môžu byť aj nulové. Z toho je možno vyvodit' záver že:

- v jednotnej a homogénnej oblasti je $\lambda_1 = \lambda_2 = 0$.
- v mieste prechodovej hrany je $\lambda_1 > \lambda_2 = 0$. Vlastný vektor korešpondujúci s λ_1 je asociovaný so smerom ktorý je kolmý ku okraju hrany.
- v mieste kde sa nachádza roh objektu, $\lambda_1 \geq \lambda_2 > 0$. Čím väčšie sú hodnoty λ_1 a λ_2 , tým väčší je kontrast prechodu hrán ktoré sú kolmé na korešpondujúce vlastné vektory.

Z toho vyplýva, že vo vlastných vektoroch matice sú uvedené jednotlivé smery hrán a vo vlastných číslach matice sú uvedené magnitúdy hrán (výraznosť hrán). Z toho možno usúdiť, že roh objektu by mal byť označený v tej lokalite, ktorá má vlastnú hodnotu λ_2 menšiu ako λ_1 a zároveň však dostatočne veľkú. [6]

Harrisov detektor pracuje na rovnakom princípe, avšak pred samotným spracovaním je štruktúra matice vyhladená za pomoci Gaussového filtra. Teda jeho matica lokálnej štruktúry má tvar (podľa [6])

$$C_{Harris} = \omega_G(\sigma) * \begin{bmatrix} \left(\frac{\partial I}{\partial x}\right)^2 & \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} \\ \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} & \left(\frac{\partial I}{\partial y}\right)^2 \end{bmatrix}$$

Kde $\omega_G(\sigma)$ je izotropný Gaussov filter so štandardným rozptylom σ a operácia $*$ predstavuje konvolúciu. Potom odozva jednotlivých rohov na túto operáciu je definovaná vzťahom (podľa [6])

$$r(x, y) = \det(C_{Harris}(x, y)) - \kappa(\text{trace}(C_{Harris}(x, y)))^2$$

kde κ je nastaviteľný operátor a $C_{Harris}(x, y)$ je matica lokálnej štruktúry na súradniciach (x, y) .

K tomu aby sa zabránilo prílišnému množstvu detekcií ktoré by sa kumulovali okolo jedného bodu, je zvyčajne vytvorený proces potlačenia nájdených význačných bodov, ktoré sú definované okolo nevýrazných okrajových prechodoch pri výraznejších. Toto možno popísať vlastne ako prahovanie, kedy dôjde k označeniu bodu ako výrazného. Z toho vyplýva, že Harrisov detektor teda vyžaduje, aby boli špecifikované tri ďalšie parametre: konštanta κ , rádius d na určenie susednej oblasti v ktorej majú byť potlačené nevýrazné body, a prahovacia hranica t . Vo vyjadrení vlastných čísel to znamená, že $\det(C_{Harris}) = \lambda_1 \lambda_2$ a $\text{trace}(C_{Harris}) = \lambda_1 + \lambda_2$. Nech sa $\lambda_1 = \lambda_2$ a $\lambda_2 = \alpha \lambda_1$ kde $0 \leq \alpha \leq 1$ tak potom odozva rohov r je možno zapísať ako (podľa [6])

$$r = \lambda^2(\alpha - \kappa(1 + \alpha)^2) \geq 0 \quad \Rightarrow \quad \kappa \leq \frac{\alpha}{(1 + \alpha)^2}$$

Pokiaľ sú v oblasti prítomné dva rovnako výrazné význačné body potom $\alpha = 1$. Z toho vyplýva že $\kappa \leq 1/4$. Ak je jedna z prítomných význačných bodov nevýrazná, teda α je veľmi malé, potom (podľa [6])

$$r \approx \lambda^2(\alpha - \kappa) \geq 0 \quad \Rightarrow \quad \kappa < \approx \alpha \ll 1$$

Z toho vyplýva, že κ slúži viac menej ako hranica medzi výraznými a nevýraznými význačnými bodmi. Čím je κ väčšie, tým bude detektor menej citlivý na detekciu význačných bodov, takže čím je κ menšie tým viac význačných bodov v obraze sme schopný detekovať. Najvhodnejšie je experimentálne nájsť takú hodnotu koeficientu κ , aby sme nedostávali moc význačných bodov v jednej oblasti, ale zároveň aby ich bolo dostatok na úspešnú registráciu. [6]

4.1.3. KLT detektor, Shi-Tomasi detektor

Detektor Kanade-Lucas-Tomasi (často označovaný aj ako Shi-Tomasi, ktorí princíp detektoru podrobne popísali [9]) bol z časového hľadiska navrhnutý neskôr ako Harrisov detektor na ktorom je z veľkej časti založený. Má dva parametre:

- prahovovú hodnotu λ_{\min} na druhej vlastnej hodnote matice λ_2
- okno okolia bodu s rádiusom \tilde{d}

Algoritmus detektoru je veľmi podobný ako ten u Harrisovho detektora. Najskôr je pre každý bod (x,y) obrazu skonštruovaná lokálna matica z okolia \mathcal{R} $(2\tilde{d} + 1) \times (2\tilde{d} + 1)$ daného bodu (podľa [8])


$$C_{KLT}(x, y) = \begin{bmatrix} \sum \sum_{\mathcal{R}} \left(\frac{\partial I}{\partial x}\right)^2 & \sum \sum_{\mathcal{R}} \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} \\ \sum \sum_{\mathcal{R}} \frac{\partial I}{\partial x} \frac{\partial I}{\partial y} & \sum \sum_{\mathcal{R}} \left(\frac{\partial I}{\partial y}\right)^2 \end{bmatrix}$$

Následne sa vypočítajú najmenšie vlastné hodnoty λ_2 matice $C_{KLT}(x,y)$. Pokiaľ je $\lambda_2 > \lambda_{\min}$ uloží sa pozícia bodu (x,y) do zoznamu L potenciálnych význačných bodov. Po vypočítaní všetkých hodnôt a ich uložení do zoznamu sa jednotlivé význačné body zoradia zostupne podľa jednotlivých hodnôt λ_2 . Následne sa začnú vyberať jednotlivé význačné body tak, že sa postupne prechádza celý zoznam od najväčších hodnôt a body, ktoré sa nachádzajú v okolí \mathcal{R} iného bodu ktorý bol predtým vybratý sú vyradené z tohto zoznamu. Výstupom KLT detektoru je zoznam význačných bodov, ktorých hodnota $\lambda_2 > \lambda_{\min}$ a zároveň nemajú vo svojom okolí \mathcal{R} žiadne iné body. Pre stanovenie veľkosti tohto okolia neexistujú žiadne špecifické pravidlá, väčšinou sa parameter \tilde{d} volí v rozsahu 2 až 10 poprípade aj viac v závislosti na veľkosti obrazu alebo preferenciách užívateľa. [9]

Súčasťou vytvárania matice C_{KLT} síce nie je Gaussov vyhladzovací filter, avšak sumačná operácia cez okolie \mathcal{R} poskytuje jednotné vyhladzovanie okolo každého bodu (x,y) . Parametre λ_{\min} a \tilde{d} KLT detektoru sú podobné parametrom κ a d použitým u Harrisovho detektora. Pri implementácii tohto detektoru sa vo väčšine prípadov na rozdiel od teoretickej aplikácie nezadáva h parametru \tilde{d} , ale radšej sa zadá maximálny počet detekovaných význačných bodov. [9]

4.1.4. Entropia bodov

Pôvodne sa pojem entropia vzťahoval k teórii termodynamiky, no čoraz častejšie sa zavádza aj do informačnej teórie, čoho sa dá s výhodou využiť v mnohých aplikáciách. Entropia všeobecne znamená mieru neusporiadanosti, či chaosu v danom prostredí. Čím je táto väčšia, tým rastie aj hodnota entropie. Napríklad plyn má väčšiu hodnotu entropie, keďže jeho molekuly sa pohybujú chaoticky v neusporiadaných smeroch, na rozdiel od pevnej látky, kde sú molekuly viazané pevnými väzbami. Podobne je to možno vidieť aj v teórii príslušnosti k dvom hraničným bodom skupiny prvkov (napríklad 0 a 1). Pokiaľ možno s vysokou pravdepodobnosťou určiť, že nejaký prvok prináleží k jednej alebo k druhej hranici tejto skupiny, tak jeho hodnota entropie klesá. Naopak pokiaľ nie je možné jednoznačne určiť jeho príslušnosť k nejakému hraničnému bodu má tento prvok vysokú hodnotu entropie (Obrázok 4.3). [10]



Obrázok 4.3 Hodnoty entropie k pravdepodobnosti príslušnosti prvku k hraničným bodom skupiny prvkov, prevzaté z [10]

Detekcia význačných bodov pomocou entropie v obraze spočíva vo výpočte miery neusporiadanosti jednotlivých obrazových bodov. U medicínskych šedotónových obrazov vychádza tento výpočet zo znalosti histogramu, teda zastúpenia jednotlivých stupňov intenzity pixlu v obraze. Z tejto znalosti sa vypočíta pravdepodobnosť výskytu jednotlivých intenzít v obraze.

Následne sa obraz postupne prechádza vopred definovaným oknom, v ktorom hľadáme hodnoty entropie stredného bodu okna. Preto sa používajú vyhľadávacie masky ktoré majú jednoznačne určený stred – štvorcové s nepárnou veľkosťou strany alebo kruhové

s nepárnou veľkosťou priemeru. Nepárnosťou ich rozmerov je zaručené to, že bod ku ktorému sa vypočítava entropia okolia bude vždy ležať v strede práve vybraného okolia. V týchto maskách sa potom vypočíta hodnota entropie daného bodu voči okolitým bodom (podľa [10])

$$Entropia = - \sum p \cdot \log_2 p$$

kde p je zastúpenie jednotlivých intenzít v obraze a teda vo vzťahu ku celkovému počtu intenzít zastupuje pravdepodobnosť výskytu danej intenzity. Táto vypočítaná hodnota entropie vybraného okolia sa priradí na pozíciu pôvodného bodu. Týmto spôsobom sa postupne vypočíta hodnota entropie okolia pre každý jeden bod v obraze. Vypočítané hodnoty entropie sa nakoniec porovnávajú s nastavenou hraničnou hodnotou, pričom body ktorých hodnota entropie je vyššia ako táto hranica sú označené ako význačné.

Touto metódou však môže byť v určitých prípadoch detekované veľké množstvo bodov s relatívne malými vzdialenosťami, čo pôsobí nežiaduco pri párovaní význačných bodov. Preto sa získané význačné body filtrujú metódou maxima funkcie. Nájde sa bod s maximálnou hodnotou entropie a vytvorí sa okolo neho kruhové okolie o definovanom polomere, v ktorom sa body označené ako význačné nulujú. Toto sa opakuje až pokým sa neodstránia všetky zhľuky význačných bodov v obraze.

4.1.5. SIFT deskriptor

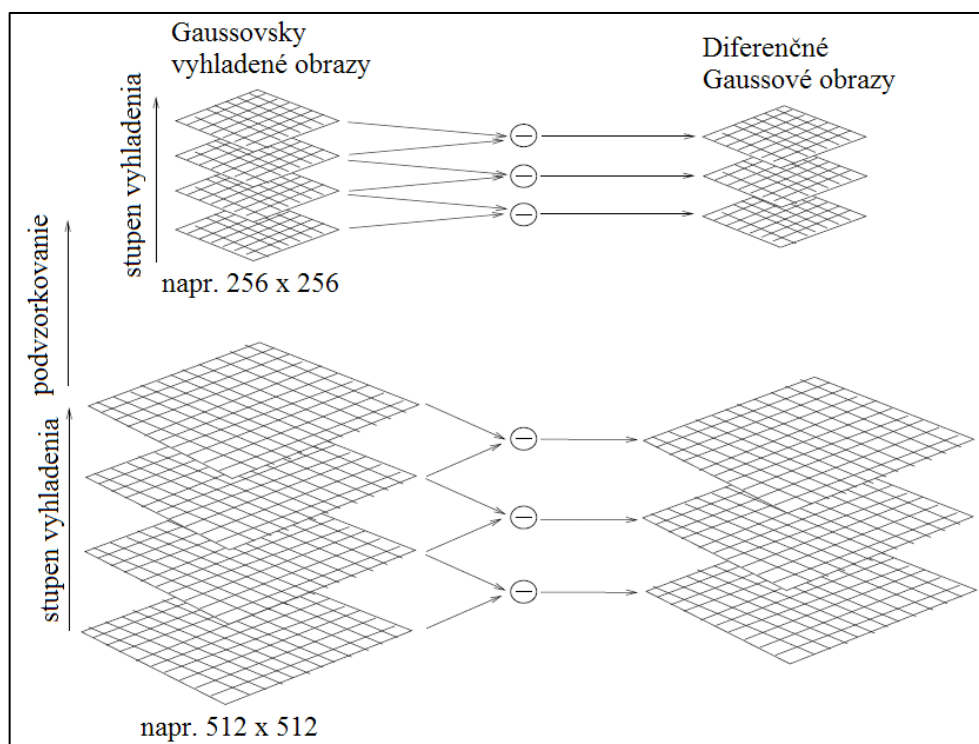
SIFT (Scale Invariant Feature Transform) detektor poskytuje relatívne nový prístup k detekcii význačných bodov. Jeho výhodou je, že význačné body ním detekované sú vektory ktoré reprezentujú lokálne obrazové merania, ktoré sa javia ako značne nemenné k posunu obrazu, zmene mierky a rotácie, ako ja čiastočne nemenné pri zmenách osvetlenia scény a lokálnych deformácií. [8]

Pri detekcii význačných bodov pomocou SIFT detektora je vstupný obraz $I(x,y)$ najskôr konvolovaný s Gaussovým filtrom ktorých štandardné deviácie $\{\sigma_1, \sigma_2, \dots\}$ sa líšia o pevne daný koeficient. To znamená, že $\sigma_{j+1} = k\sigma_j$ kde k je skalárna konštanta ktorá by mala byť nastavená na $\sqrt{2}$. Tieto konvolúcie vyprodukujú niekoľko vyhladených obrazov $\{G(x, y, \sigma_1), G(x, y, \sigma_2), \dots\}$. Vyhladené obrazy sú potom navzájom odčítané, čoho výsledkom je menší počet (3 alebo 4) diferenčných Gaussových obrazov. (podľa [11])


$$D(x, y, \sigma_j) = G(x, y, \sigma_{j+1}) - G(x, y, \sigma_j)$$

Pôvodné vyhladené obrazy (nie diferenčné) sú následne prevzorkované, a znova sú od seba odčítané, čoho výsledkom je druhá sada diferenčných Gaussových obrazov (Obrázok 4.4). Každý bod týchto obrazov je potom analyzovaný, a niektoré z nich sú označené ako kľúčové (význačné body). Kľúčový bod je taký, kde sa nachádza lokálne maximum alebo minimum z jeho 8 susedných bodov na rovnakom obraze a zároveň aj z 9 susedných bodov na obraze pod a nad aktuálnym obrazom (viď Obrázok 4.5). [8]

Kľúčové body identifikované v predchádzajúcom procese sú potom preskúmané kvôli ich nožnej eliminácii, pokiaľ dve lokálne principiálne krivky intenzitného profilu okolo tohto kľúčového bodu presahujú špecifikovaný hodnotový prah. Tento eliminačný proces zahŕňa stanovovanie pomeru medzi dvoma vlastnými hodnotami Hessian-ovej matice 2x2 z lokálnych intenzít obrazu v okolí daného kľúčového bodu. [11]

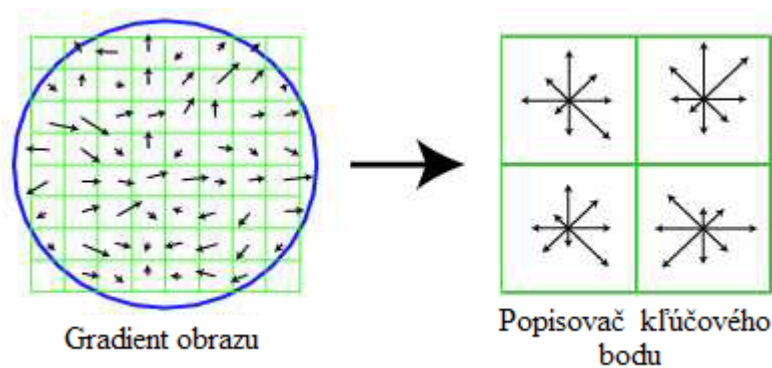


Obrázok 4.4 Pyramída vytvárania diferenčných Gaussových obrazov, prevzaté a upravené z [11]



Obrázok 4.5 Klúčový bod - maximum alebo minimum jeho 26 susedov ($9 + 8 + 9$), prevzaté a upravené z [11]

Po nájdení umiestnenia kľúčového bodu sú preskúvané okolité intenzitné a gradientové informácie okolo každého takéhoto bodu kvôli zakódovaniu SIFT popisovača (SIFT deskriptor) tohto bodu. Sú počítané gradienty obrazu, ktoré sú klasifikované do ôsmich smerov v histogramovom poli 4×4 , čím dostávame SIFT popisovač dlhý 128 elementov pre každý jeden obrazový bod. Na Obrázok 4.6 je uvedená zjednodušená varianta. [11]



Obrázok 4.6 Zjednodušený príklad 2×2 popisovača vypočítaného z 8×8 poľa vektorov gradientov obrázku, prevzaté a upravené z [11]

Na rozdiel od Harrisovho a KLT detektora, význačné body SIFT detektora sa často nezhodujú s na prvý pohľad význačnými bodmi v obraze (väčšinou rohy objektov). Avšak SIFT popis význačných bodov poskytuje užitočné informácie pri registrácii obrazov a rozpoznávaní objektov z informácií ukrytých vo vzájomných vzťahoch medzi jednotlivými bodmi obrazu. Význačné body detekované a popísané pomocou SIFT

popisovača sa v ďalších krokoch registrácie párujú pomocou miery zhody v týchto popisovačoch, a nie napríklad pomocou pozícií bodov. [11]

4.1.6. SURF deskriptor

SURF detektor pracuje na podobnom princípe ako SIFT, z ktorého vychádza, avšak pristupuje inak k fáze detekovania význačných bodov. SURF detektor, na rozdiel od SIFT, nevytvára zmenšené podvzorkované obrazy, ale miesto toho vytvorí rozdielové obrazy bez tohto vzorkovania. Miesto toho sa použije stredný obraz známy ako integrálny obraz. Pokiaľ teda máme obraz I a bod (x, y) , potom je integrálny obraz I_{Σ} vypočítaný ako (podľa [12])

$$I_{\Sigma}(x, y) = \sum_{i=0}^{i \leq x} \sum_{j=0}^{j \leq x} I(x, y)$$

Pre detekciu význačných bodov sa potom používa Hessian detektor. Ten je založený na výpočte Hessian matice, teda štvorcovej matice parciálnych derivácií druhého rádu funkcie f (podľa [12])

$$H(f(x, y)) = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial x \partial y} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix}$$

a jej determinant je potom (podľa [12])

$$\det(H) = \frac{\partial^2 f}{\partial x^2} \frac{\partial^2 f}{\partial y^2} - \left(\frac{\partial^2 f}{\partial x \partial y} \right)^2$$

a slúži na klasifikáciu minima a maxima funkcie podľa testu derivácie druhého rádu. Keďže determinant je produktom vlastných čísel Hessianu, môžeme na základe toho klasifikovať výsledok. Pokiaľ je determinant záporný, potom daný bod nie je lokálnym extrémom a naopak. [12]


Pri aplikácii tejto metódy na obrazové dáta sa nahrádzujú hodnoty funkcie $f(x, y)$ intenzitou pixlov $I(x, y)$. Následne sa druhé parciálne derivácie vypočítajú pomocou stupnicovo normalizovaného Gaussovho filtru druhého rádu. Pomocou neho možno konštruovať jadrá pre výpočet deriváciu v smeroch x , y a kombinovanom xy . Taktiež umožňuje zmenu vyhladenia počas konvolučnej fáze a teda umožňuje výpočet

determinantu v rozličných mierkach a keďže Gaussian je izotropická funkcia (rotačne symetrická), výstup konvolúcie nie je závislá na rotácii. Hessian H vypočítame teda ako funkciu priestoru $x = (x,y)$ a mierky σ (podľa [12])

$$H(x, \sigma) = \begin{bmatrix} L_{xx}(x, \sigma) & L_{xy}(x, \sigma) \\ L_{xy}(x, \sigma) & L_{yy}(x, \sigma) \end{bmatrix}$$

kde $L_{xx}(x,\sigma)$ je konvolúcia obrazového bodu $x = (x, y)$ a Gaussovej derivácie druhého rádu $\frac{\partial^2 g(\sigma)}{\partial x^2}$, podobne aj pre L_{yy} a L_{xy} . Tieto derivácie sú známe pod pojmom Laplacián Gaussiánu. S touto znalosťou možno vypočítať Hessian pre každý pixel obrazu a použiť túto hodnotu na nájdenie význačných bodov. [12]

Pre urýchlenie výpočtu aj za cenu menšej chyby, sa Laplacián Gaussiánu aproximuje reprezentáciou jadier filtrov pomocou „box“ filtrov. Táto aproximácia je postavená na princípe prahovania intenzít oblastí. V prípade D_{xy} filtra sú tmavé oblasti označené hodnotou 1 a svetlé pixle hodnotou -1. Zvyšné sú ponechané v pôvodnom stave. Podobne sú prahované aj D_{xx} a D_{yy} ale svetlé oblasti majú hodnotu -1 a tmavé hodnotu 2. [13]



Obrázok 4.7 Aproximácia Laplacian Gaussiánu, prevzaté z [12]

Obrázok 4.7 popisuje ako prebieha daná aproximácia. Horné tri obrázky zobrazujú druhé derivácie Gaussianu v smere x , y a xy . Tieto označujeme ako L_{xx} , L_{yy} a L_{xy} . Spodné tri obrázky potom zobrazujú aproximácie pomocou „box“ filtrov, ktoré označujeme ako D_{xx} , D_{yy} a D_{xy} . [12]


Po použití aproximovaného Gaussianu potom determinant Hessianu môžeme vypočítať ako (podľa [13])

$$\det(H_{approx}) = D_{xx}D_{yy} - (0,9D_{xy})^2$$

pričom tento determinant je známy ako odozva na filter v mieste $x = (x, y, \sigma)$. Z hľadania maxima tejto funkcie v priestore ako aj v rôznych susedných stupňoch vyhladenia dostaneme význačné body v obraze. [12]

K tomu aby bolo možné tieto body vyhodnotiť je potreba vytvoriť niekoľko rôzne vyhladených obrazov. U SIFT sa mení veľkosť obrazu podvzorkovaním a aplikovaním filteru jednej veľkosti. SURF deskriptor používa len jeden integrálny obraz ktorého veľkosť sa nemení, avšak mení sa veľkosť konvolučnej masky. [12]

Tento rozdiel znázorňuje Obrázok 4.8




Obrázok 4.8 Získavanie rôzne vyhladených obrazov u SIFT (vľavo) a SURF (vpravo)

Minimálny rozmer masky filteru pomocou ktorého získavame vyhladené obrázky je 9×9 , čo korešponduje s reálnou hodnotou Gaussianu $\sigma = 1,2$. Ďalšie obrázky sa získavajú zväčšovaním masky, pričom zväčšujúcou sa maskou možno reálnu hodnotu Gaussianu vypočítať ako

$$\sigma_{approx} = \text{Aktuálna veľkosť masky filteru} \cdot \frac{\text{Základná hodnota Gaussianu}}{\text{Základná veľkosť masky filteru}}$$

$$\sigma_{approx} = \text{Aktuálna veľkosť masky filteru} \cdot \frac{1,2}{9}$$

Keďže každá maska filteru má tri hlavné regióny ako je naznačené na obrázku Obrázok 4.8, musí sa každý región masky zväčšiť tak, aby bol vždy jasne definovaný stred daného regiónu. To znamená že každý región sa musí zväčšiť minimálne o 2 pixle, čiže celá maska sa musí zväčšiť vždy o 6 pixlov (Obrázok 4.9).



Obrázok 4.9 Znáozornenie princípu zväčšovania masky filtra, prevzaté z [12]

Po týchto operáciách už nasleduje proces hľadania samotných význačných bodov podobný postupu ako u SIFT deskriptora. Najskôr sa jednotlivé odozvy na filtre porovnávajú s prahom a tie ktoré ho nedosiahnu sú odstránené. Zvyšovanie prahu znižuje počet detekovaných význačných bodov a ponecháva len tie s najväčšou hodnotou informácie a naopak. Následne je vykonané potlačenie nemaximálnych hodnôt. Toto je podobne ako u SIFT vykonávané porovnávaním bodu s jeho 26 susedmi (Obrázok 4.5). Posledným krokom je interpolácia okolitých dát kvôli nájdeniu umiestnenia v mierke ako aj v priestore obrazu s presnosťou väčšou ako jeden pixel. K tomuto použijeme vyjadrenie Hessian funkcie, $H(x,y,\sigma)$, ako Taylorove rozšírenie kvadratických výrazov sústredených na detekované miesto. [13][14]

Toto vyjadríme podľa [14] ako:

$$H(\mathbf{x}) = H + \frac{\partial H^T}{\partial \mathbf{x}} \mathbf{x} + \frac{1}{2} \mathbf{x}^T \frac{\partial^2 H}{\partial \mathbf{x}^2} \mathbf{x}$$

Interpolované umiestnenie extrémov, $\hat{\mathbf{x}} = (x, y, \sigma)$, je potom nájdené výpočtom derivácie tejto funkcie pričom ju položíme rovnú nule podľa [14] takto:

$$\hat{\mathbf{x}} = - \frac{\partial^2 H^{-1} \partial H}{\partial \mathbf{x}^2 \partial \mathbf{x}}$$

Derivácie sú potom aproximované konečnými rozdielmi susediacich pixlov. Pokiaľ je $\hat{\mathbf{x}}$ väčšie ako 0,5 v smeroch x , y alebo σ je spravená korekcia umiestnenia a znova je vykonaná interpoláciu. Toto je opakované až pokiaľ nie je $\hat{\mathbf{x}}$ menšie ako 0,5 alebo

pokiaľ sme nedosiahli maximálny nastavený počet interpolačných krokov. Body ktoré nedosiahnu tejto podmienky sú vyradené a zostávajú len najstabilnejšie. [12][13]

Po získaní význačných bodov sa tieto následne popíšu SURF deskriptorom. Ten popisuje, ako sú rozložené intenzity pixlov v okolí význačného bodu detekovaného Hessian funkciou ktoré sú závislé na stupni vyhladenia filtrom. Toto sa deje v dvoch krokoch. V prvom sa určí ku každému význačnému bodu reprodukovateľná hlavná orientácia. K tejto orientácii bude potom priradený popis jednotlivých elementov deskriptora. K tomuto účelu sú použité odozvy na Haar-ove vlnky (Obrázok 4.10) veľkosti 4σ ktoré sú vypočítané pre súbor pixlov vzdialených maximálne o polomer 6σ od nájdeného význačného bodu, pričom σ symbolizuje stupeň vyhladenia, v ktorom bol tento bod nájdený. Hlavná orientácia je potom nájdená pomocou rotácie výrezu kruhu o uhle $\frac{\pi}{3}$ okolo pôvodného bodu. V každej pozícii je vypočítaná suma odoziev jednotlivých bodov z ktorej je následne odvodený vektor dĺžky danej sumy. Najdlhší vektor tak určí primárnu orientáciu bodu. [12][13]




Obrázok 4.10 Haar-ove vlnky, ľavý filter vypočítava odozvy v ose x a pravý v ose y

Na základe tejto orientácie je vytvorené okno okolo význačného bodu o veľkosti 20σ . Toto okno je rozdelené na maticu rovnakých regiónov 4×4 . V každom z týchto regiónov je vypočítaná odozva na Haar-ove vlnky pre 25 regulárne rozprestretých obrazových bodov. Tieto hodnoty budeme označovať ako dx (pre x smer) a dy (pre y smer). [12]

Potom pre 25 obrazových bodov dostaneme (podľa [12])

$$v_{region} = [\sum dx, \sum dy, \sum |dx|, \sum |dy|]$$

Teda každý región prispeje štyrmi hodnotami do vektora deskriptora, čím je vytvorený deskriptor o dĺžke $4 \times 4 \times 4 = 64$ hodnôt.




Obrázok 4.11 Ilustrácia výpočtu SURF deskriptora závislého na hlavnej orientácii bodu, prevzaté z [13]

4.1.7. FAST detektor

Features from Accelerated Segment Test detektor je relatívne nový, avšak veľmi jednoduchý a výkonný spôsob detekovania význačných bodov. Pracuje na princípe vyhodnocovania intenzity okolitých bodov daného bodu, ktorý chceme označiť ako význačný.

Najskôr sa uvažuje kruh 16 pixlov okolo kandidátskeho bodu p na význačný bod. Zistí sa intenzita I_p daného bodu a porovnáva sa s intenzitami okolitých šestnástich bodov. Intenzity týchto bodov sa potom porovnávajú s nastavenou prahovou hodnotou. Pokiaľ je aspoň n po sebe nasledujúcich bodov svetlejších alebo tmavších ako intenzita bodu, plus alebo mínus nastavená prahová hodnota, tak je tento bod označený ako význačný. Toto možno vidieť na Obrázok 4.12 nižšie pre $n = 12$. [15]



Obrázok 4.12 Bodové testovanie segmentov okolia bodu pre $n = 12$, prevzaté z [15]

Tento test sa za daných podmienok dá urýchliť za pomoci porovnávania len segmentov v štyroch hlavných orientáciách, teda segmentov 1, 5, 9 a 13. Pre to aby bol bod označený ako význačný, musia aspoň tri body zo štyroch splňovať danú podmienku prekročenia prahovej hodnoty. Tento test vykazuje veľmi dobré vlastnosti čo sa týka ako rýchlosti spracovania, tak aj výkonu pri detekovaní význačných bodov, avšak má isté slabosti, ktorými sú: [15]

1. Urýchlený test sa nedá použiť pre $n < 12$
2. Výber a usporiadanie rýchleho testu obsahuje predpokladá určité implicitné distribúcie intenzít bodov
3. Získané znalosti z prvých štyroch testov sú zničené a v ďalšom testovaní sa budú počítajú znovu
4. Mnoho význačných bodov môže byť detekovaných vo veľmi malej vzájomnej vzdialenosti.

Riešenie týchto štyroch obmedzení je popísané v [16] pomocou strojovo vytvoreného, „naučeného“ detektoru význačných bodov. Toto spočíva vo výpočte význačných bodov pomocou FAST techniky pre počet $n = 16$ s použitím vhodne zvolenej prahovej hodnoty v sérií testovacích obrazcov (zvolených najlepšie z cieľovej oblasti použitia detektora). Pre každý pixel na relatívnej pozícii x k bodu p sa priradí hodnota $S_{p \rightarrow x}$ takto (podľa [16]):

$$S_{p \rightarrow x} = \begin{cases} d, & I_{p \rightarrow x} \leq I_p - t & \text{(tmavšie)} \\ s, & I_p - t < I_{p \rightarrow x} < I_p + t & \text{(podobné)} \\ b, & I_p + t \leq I_{p \rightarrow x} & \text{(svetlejšie)} \end{cases}$$

Takto sa postupuje pre všetky testovacie obrazy pre všetky $p \in P$ (súbor všetkých pixlov vo všetkých testovacích obrazoch) a rozdelí P do troch podskupín P_d, P_s, P_b , kde každé p je priradené ku $P_{S_{p \rightarrow x}}$. Týmto je ukončená prvá fáza vytvárania detektoru. [16]

V druhej fáze sa použije algoritmus ID3 [17], definuje sa booleová premenná K_p a vyberie sa x , ktoré poskytuje najvyššiu mieru informácie o tom či bod je význačný alebo nie. Táto miera je definovaná entropiou K_p , ktorá je daná (podľa [16]):

$$H(P) = (c + \bar{c}) \log_2 (c + \bar{c}) - c \log_2 c - \bar{c} \log_2 \bar{c}$$

kde $c = |\{p|K_p \text{ je pravda}\}|$ (počet význačných bodov)
 a $\bar{c} = |\{p|K_p \text{ je nepravda}\}|$ (počet nevýznačných bodov)

Potom teda vybrané x udáva informáciu (podľa [16])

$$H(P) - H(P_d) - H(P_s) - H(P_b)$$

Podľa tohto sa vyberie x ktoré udáva najväčšiu mieru informácie a proces je rekurzívne aplikovaný na všetky tri podskupiny. Teda x_b je vybrané z podskupiny P_b do $P_{b,d}$, $P_{b,s}$, $P_{b,b}$ a x_s je vybrané z podskupiny $P_{s,d}$, $P_{s,s}$, $P_{s,b}$ atď., kde každé x je vybrané tak, aby poskytovalo maximum informácie k podskupine z ktorej sa vyberá. Proces je ukončený keď je entropia podskupiny rovná nule. Teda keď všetky p v podskupine majú rovnakú hodnotu K_p a teda všetky sú vyhodnotené ako význačné body alebo ako nevýznačné body. Z tohto sa potom vytvorí rozhodovací stromový diagram, v ktorom sú definované všetky možné kombinácie význačných bodov, ktoré zodpovedajú pravidlám FAST detektora pre daný počet n a následne sa strojovo prekonvertuje do programovacieho jazyka. [16]

Týmito postupmi boli adresované prvé tri uvedené problémy.

4.2. Hľadanie rovnakých párov význačných bodov

Nájdenie význačných bodov v obraze je prvým krokom v algoritme sledovania týchto bodov. Samotné nájdenie týchto bodov v dvoch obrazoch by nemalo prakticky žiadny zmysel bez toho, že by sme vedeli ktoré body v obrazoch si navzájom zodpovedajú. K stanoveniu týchto dvojíc sa používa mnoho metód, od korelačných techník, cez hľadanie najmenších odchýlok súradníc význačných bodov či vyhľadávanie špecifických tvarov postupností pixlov v oblasti detekovaného význačného bodu. Táto práca sa bude zaoberať dvoma z nich, a konkrétne použitia korelačného koeficientu lokálnej oblasti a metódou najmenších Euklidových vzdialeností.

4.2.1. Korelačný koeficient lokálnej oblasti - LACC

Korelácia ako taká udáva mieru podobnosti medzi dvoma objektmi, ktorá je vyjadrená jedným číslom. Čím je toto číslo väčšie tým je miera podobnosti medzi týmito objektmi väčšia. Pri hľadaní párov v obraze sa toto číslo nazýva korelačný koeficient lokálnej oblasti LACC (Local Area Correlation Coefficient). Ten je daný vzťahom (podľa [18])

$$c_{ij} = \sum_{k=-n}^n \sum_{l=-m}^m \frac{[I_1(u_i^1 + k, v_i^1 + l) - \bar{I}_1(u_i^1, v_i^1)] \times [I_2(u_j^2 + k, v_j^2 + l) - \bar{I}_1(u_j^2, v_j^2)]}{(2n + 1)(2m + 1) \sqrt{\sigma_i^2(I_1) \times \sigma_j^2(I_2)}}$$

kde I_1 a I_2 sú intenzity obrazov, (u_i^1, v_i^1) a (u_j^2, v_j^2) sú i-té a j-té význačné body ktoré majú byť navzájom porovnané, m a n sú polovicou plávajúceho porovnávaného okna. Štandardný rozptyl okna c_{ij} je v rozmedzí -1 až 1 a udáva podobnosť od najmenej po najväčšiu. Tieto hodnoty sú následne porovnávané s prahovou hodnotou a všetky možné zhody ktorých koeficient LACC je väčší ako táto hodnota sa stávajú kandidátmi na správne spárovanie. Body ktoré majú koeficienty LACC menšie ako nastavená prahová hodnota sú vynulované a ďalej s nimi neuvažujeme ako o možných kandidátoch pre spárovanie s aktuálne spracovávaným bodom. [18]

To, že koeficient LACC bude mať veľké hodnoty je len prvým predpokladom k úspešnému spárovaniu bodov. Keby bol použitý len tento parameter tak by vo výsledku mohlo dôjsť k vysokému percentu chybných spárovaní. Preto je potrebné použiť isté obmedzenia pri tomto procese.

Najpriamejším obmedzením ktoré môžeme použiť je obmedzenie rozdielnosti umiestnenia jednotlivých bodov. Keďže budeme pracovať so sériou obrázkov zachytených po sebe vo veľmi krátkom časovom úseku, bod v druhom obraze zodpovedajúci bodu v prvom obraze bude zobrazený v relatívne malej oblasti okolia pôvodného obrazu. Takže je možné nastaviť radiálnu oblasť v ktorej budeme druhý bod hľadať a LACC ostatných bodov ktoré nie sú v tejto oblasti nastavíme na 0. [19]

Toto obmedzenie nie je vždy dostatočné, pretože v jednej oblasti obrazu môže byť vysoká hustota detekovaných význačných bodov. No keďže sú obrazy snímané po sebe v krátkom časovom intervale, tak môžeme predpokladať, že zmena hĺbky obrazu medzi dvoma po sebe nasledujúcimi snímkami nebude veľmi veľká. Z toho možno usúdiť, že relatívna pozícia medzi navzájom si korešpondujúcimi bodmi bude v celom obraze rovnaká. Teda relatívna vzdialenosť medzi význačnými bodmi m_i^1 a m_j^1 v prvom a druhom obraze bude rovnaká ako relatívna vzdialenosť medzi bodmi m_i^2 a m_j^2 v týchto obrazoch. [18]

To je možné zapísať ako (podľa [18])

$$d_{ij}^r = m_i^r - m_j^r$$

a teda d_{ij}^1 by malo byť rovnaké ako d_{ij}^2 . Na popis podobnosti medzi dvoma bodmi vo vybraných oblastiach obrazov použijeme operátor (podľa [18])

$$\xi_{ijkl} = \frac{d_{ik}^1 * d_{jl}^2}{\max(\|d_{ik}^1\|, \|d_{jl}^2\|)}$$

ktorý udáva, ako ostatné význačné body v okolí bodov m_i^1 a m_j^2 podporujú ich zhodu. Pokiaľ je ξ_{ijkl} kladné, nazývame kandidátsky pár m_j^1 a m_k^2 podporným k páru m_i^1 a m_j^2 . Inak povedaná, ak sú body m_i^1 a m_j^2 naozaj zhodným párom, budú mať veľa podporných párov, a rovnako naopak. Samozrejme možno povedať, že táto podporná hodnota klesá s rastúcou vzdialenosťou od blízkych význačných bodov k tým, ktoré majú byť navzájom si korešpondujúce. [18]

Preto je definovaná funkcia ktorá zohľadňuje túto skutočnosť: (podľa [18])

$$df_{ik} = \frac{1}{1 + \|m_i - m_k\|^2}$$

Navyše, ak je $\xi_{ijkl} < 0$ potom kandidátsky pár dostane „protivníka“. V niektorých prípadoch, ako je pravidelne sa opakujúca textúra, aj keď má kandidátsky pár niekoľko podporných párov, stále ho nemožno prehlásiť za zhodu, pretože má nezanedbateľné množstvo protivníkov. Preto použijeme koeficient r_n na vyjadrenie percentuálneho zastúpenia protivníkov kandidáta. Potom čím viac protivníkov kandidát má, tým menšiu podporu dostane aj keď sa vedľa neho nachádza veľké množstvo podporovateľov. [18]

Táto metóda je označená ako sila zhody (match strength) medzi dvoma bodmi a je definovaná ako (podľa [12])

$$ms_{ij} = c_{ij} \left(\sum_{m_k \in \mu_1(m_j)} \max_{m_k \in \mu_2(m_j)} \{c_{kl} \xi_{ijkl} df_{ik}\} + \sum_{m_k \in \mu_2(m_j)} \max_{m_k \in \mu_1(m_j)} \{c_{kl} \xi_{ijkl} df_{il}\} \right) (1 - r_n)$$

kde $\mu_1(m_i)$ a $\mu_2(m_j)$ sú susedné oblasti bodov m_i respektíve m_j . Výsledky tejto operácie sú taktiež porovnávané s nastavenou prahovou hodnotou, a ak je parameter ms_{ij} menší ako táto hodnota tak je tento parameter nastavený pre daný význačný bod na 0. Tento algoritmus sily zhody možno analogicky popísať ako hlasovanie. Kandidát ktorý má najväčšie množstvo podporovateľov vyhráva a vytvorí pár s bodom z prvého obrazu.

4.2.2. Metóda najmenších Euklidových vzdialeností

Táto metóda je založená na predpoklade toho, že body detekované v dvoch po sebe nasledujúcich obrazoch nezmenili svoju polohu, alebo ju zmenili len veľmi nepatrne. Toto je vo väčšine prípadov registrácie obrazov v medicíne splnené, nakoľko v oblastiach kde sa používajú registračné metódy je snaha zachytiť obraz v čo najkratších intervaloch. Vďaka tomu sa význačné body v obraze nachádzajú buď na rovnakom mieste, alebo len veľmi málo posunuté.

Po získaní dvoch súborov význačných bodov, kde každý prislúcha k jednému obrazu, sa vyberú súradnice jedného detekovaného bodu z prvého obrazu. Následne sa iteračnou metódou vypočítava jeho vzdialenosť k súradniciam všetkých význačných bodov z druhého obrazu pomocou Euklidovej vzdialenosti podľa vzorca:

$$l = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

Po vypočítaní vzdialenosti prvého páru sa táto uloží ako prahová hodnota. Po každom výpočte sa porovnáva vypočítaná vzdialenosť s touto hodnotou. Ak je táto menšia ako nastavený prah je zrejmé, že sa jedná o bod v druhom, ktorý lepšie korešponduje s pôvodným miestom bodu v prvom obraze. Vypočítaná vzdialenosť sa potom nastaví ako nová prahová hodnota a súradnica daného bodu sa priradí k súradnici bodu v prvom obraze. Tento proces sa opakuje vždy keď sa nájde bod v druhom obraze, ktorý má menšiu vzdialenosť k bodu v prvom obraze, ako predošlý bod ktorým bol definovaný prah.

K tomuto priradzovaniu dochádza systémom jedna k jednej, teda k jednému bodu v prvom obraze môže byť priradený len jeden bod z druhého obrazu. Preto ak v prvom obraze bolo detekované menšie množstvo význačných bodov ako v druhom, postup párovania bodov sa otočí a teda nepárujú sa body z druhého obrazu k prvému, ale z prvého obrazu k druhému.

4.3. Eliminácia nekorešpondujúcich si párov

V úvode kapitoly bolo spomenuté, že v súčasnosti veľmi úspešnou metódou na elimináciu chýb je eliminácia pomocou najmenšieho mediánu štvorcov. Táto metóda pracuje na základe odhadovania parametrov pri riešení minimalizačného problému (podľa [20])

$$\min med_i r_i^2$$

čiže musíme odhadnúť najmenšiu hodnotu mediánu štvorcových rezíduí vypočítaných pre celý súbor dát. Ako sa ukazuje táto metóda je veľmi odolná voči zlým detekciám ako aj chybným priradeniam, no táto metóda nemôže byť redukovaná na obyčajný vážený problém najmenších štvorcov. Preto je takmer nemožné jasne definovať nejakú všeobecnú rovnicu na riešenie tohto problému a preto musí byť riešený za pochodu a prispôbený aktuálnym podmienkam. Pre daný problém registrácie obrazov sa teda problém eliminácie pomocou tejto metódy rieši nasledovne. [20]

Z aktuálneho súboru bodov sa vyberie m vzoriek, pričom každá vzorka sa skladá z ôsmich hodnôt. Počet vzoriek m sa vyberá podľa odhadovaného percenta zle určených párov význačných bodov z vybraného súboru pomocou nasledujúcej rovnice: (podľa [20])

$$P = 1 - [1 - (1 - \varepsilon)^8]^m$$

kde ε je odhadované množstvo zle určených párov a P je pravdepodobnosť že vo vybranom súbore m vzoriek bude aspoň jeden korešpondujúci si pár, teda P by malo byť blízke hodnote 1. Následne sa vypočíta fundamentálna matica, napríklad J používajúca 8-bodový algoritmus ktorého výsledkom je F_J kde $J = 1, 2, \dots, m$. Pre každé F_J sa potom vypočíta skupina štvorcových rezíduí z celého súboru dát a vyberie sa ich medián M_J (podľa [20])

$$M_J = \underset{i = 1, \dots, n}{med} [d^2(m_i^2, F_J m_i^1) + d^2(m_i^1, F_J^T m_i^2)]$$

kde m_i^1 a m_i^2 sú i -tý pár zhodných význačných bodov a d je vzdialenosť pre líniu medzi týmito bodmi. Ďalej sa nájde maximum spomedzi mediánov M_J s a označíme ho M_M , pričom jeho korešpondujúca fundamentálna matica je F_M . Potom sa vypočíta takzvaná robustná štandardná deviácia (podľa [20])

$$\hat{\sigma} = 1,4826 \left[1 + \frac{5}{n-8} \right] \sqrt{M_M}$$

a priradí sa váha ku každej nájdenej zhode (podľa [20])

$$w_i = \begin{cases} 1 & ak \quad r_i^2 \leq (2,5\hat{\sigma})^2 \\ 0 & inak \end{cases}$$

kde

$$r_i = d^2(m_i^2, F_M m_i^1) + d^2(m_i^1, F_M^T m_i^2)$$


Teda body, ktorých váhy zodpovedajú nulovej hodnote sú chybne spárované a teda budú z ďalšieho výpočtu. Teraz keď už poznáme hodnotu koeficientu r_i , tak môžeme vyriešiť nasledujúcu optimalizačnú úlohu pomocou metódy najmenších štvorcov (podľa [20])

$$\min \sum_i w_i r_i^2$$

pričom po jej vyriešení eliminujeme všetky spárované význačné body, ktoré si navzájom nekorešpondujú.

5. Realizovaný program

V predchádzajúcich častiach práce bola vysvetlená problematika registrácie obrazov z teoretického hľadiska. Niektoré z opísaných techník registrácie boli vybrané a následne implementované v prostredí Matlab R2009a. Hlavnou príčinou výberu tohto prostredia k realizácii samotného programu je hlavne jeho nesporná jednoduchosť pri programovaní, intuitívnosť a predovšetkým možnosť spracovávať obrazová dáta na vysokej úrovni. Toto sa deje za pomoci rôznych vývojových balíčkov (toolboxov), predovšetkým pomocou Image Processing Toolbox, ktorý poskytuje špecializované funkcie pre spracovanie obrazov. Nevýhodou tohto pracovného prostredia je však relatívna pomalosť oproti iným programovacím jazykom ako aj vyššia pamäťová náročnosť. Z toho vyplýva, že vykonávanie rovnakej funkcie v programovom prostredí Matlab potrvá dlhšie ako v vykonávanie tej istej funkcie v inom programovacom jazyku.



Obrázok 5.1 Grafické prostredie programu na registráciu obrazov

Hlavným cieľom tejto práce je preskúmať možnosti registrácie obrazu, vyhodnotiť výkon jednotlivých metód a účinnosť registrácie ako aj časovú náročnosť jednotlivých metód. Z tohto dôvodu bol program realizovaný prevažne pre funkciu v textovom režime, kde je možno meniť ľubovoľne podrobne parametre procesu. Pre zjednodušenie

ovládania a názornosť bolo vytvorené aj jednoduché grafické prostredie (Obrázok 5.1) so základnými voľbami krokov registrácie. To je členené do štyroch logických panelov v závislosti na funkcii jednotlivých elementov. V nasledujúcich kapitolách budú popísané jednotlivé voľby a bude objasnený spôsob fungovania im priradených algoritmov.

5.1. Panel Načítanie súborov

Prvý panel zaisťuje načítavanie sekvencie súborov, ktoré chceme vzájomne medzi sebou registrovať. Po kliknutí na tlačidlo si užívateľ v sprievodcovi pre výber priečinku vyberie priečinku, kde sú umiestnené súbory k registrácii. Povinným údajom ktorý sa musí zadať manuálne je typ súborov (jeho koncovka), v ktorom sú uložené obrazy (napríklad: .jpg .tif .png .bmp .jp2).

Jedinou podmienkou pri načítaní súborov do programu je ich pomenovanie. Pomocou názvu súboru sa musí dať jednoznačne určiť, koľký je daný súbor v poradí v sekvencii. Príklad sekvencie pomenovania – image001.***, image002.***, image003.***, atď.

V pridružených súboroch funkcií nie sú žiadne nastavenia ktoré by sa dali (alebo museli) meniť.

5.2. Panel Spustenie registrácie

V tomto paneli má užívateľ možnosť výberu typu detektora význačných bodov a taktiež možnosť výberu metódy párovania týchto bodov. U typu detektora má na výber z možností:

1. Harris detektor – má priradenú funkciu harris.m
2. Shi – Tomasi detektor – má priradenú funkciu ST_detect.m v ktorej možno nastaviť počet bodov ktoré budú detekované. Týmto dôjde k prepísaniu predvolenej hodnoty 100 bodov.
3. FAST detektor – má priradenú funkciu fast9.m ktorá je strojovo generovaná a použitá v súlade s BSD licenciou z [16] a [21]. Vo funkcii je možno zapínať a vypínať potlačenie nemaximálnych hodnôt a meniť hodnotu prahu pre porovnávanie intenzít pixlov. Predvolená hodnota je 120. Algoritmus je strojovo generovaný a preto ho nie je možné bližšie popísať.

4. Lokálna entropia – má priradenú funkciu `local_entropy.m` a má možnosť zmeny rádiusu pre výpočet lokálnej entropie bodu
5. SIFT deskriptor – má priradenú funkciu `SIFT.m` s ďalšími podfunkciami. Daný deskriptor je voľne dostupný pod BSD licenciou z [22]. Vo funkcii je možno meniť parametre detekcie a výpočtu deskriptorov. Ich vplyv na funkciu je popísaný priame v súbore.

U metód párovania význačných bodov má užívateľ na výber z:

1. Euklidova vzdialenosť – má priradenú funkciu `match_FP_distance.m` a funkcia pracuje plne automaticky bez nutnosti nastavovania akýchkoľvek parametrov
2. Lokálny korelačný koeficient (LACC) – má priradenú funkciu `match_LACC.m` a taktiež sa u nej nenastavuje žiadny parameter.
3. LACC + obmedzenie vzdialenosti FP – má priradenú funkciu `LACC_distance_matching.m` bez nutnosti nastavenia akéhokoľvek parametru.

5.2.1. Popis algoritmu funkcie `harris.m`

Algoritmus tohto detektora vychádza z teoretických znalostí popísaných v kapitole 4.1.2. Pred samotným vykonávaním algoritmu má užívateľ možnosť zvoliť si zo štyroch detekčných masiek na výpočet hranovej odozvy bodu. Toto je možné priamo v zdrojovom súbore funkcie v sekcii `premenne`. Ďalej má užívateľ možnosť nastaviť polomer okolia bodu. Týmto parametrom je nepriamo ovplyvnený počet detekovaných bodov v obraze, keďže udáva minimálnu vzdialenosť dvoch detekovaných bodov. Priamo ovplyvniť počet bodov je možné nastavením dolnej a hornej hranice počtu bodov.

Po zavolaní funkcie z hlavného programu sa začína vykonávať automaticky algoritmus funkcie. Zo vstupu sa uloží do premennej `obraz` v ktorom budú detekované význačné body. Po načítaní potrebných parametrov prebehne konvolúcia detekčnej masky a jej invertovanej varianty so vstupným obrazom, čím sa získajú prvé derivácie v smere X a Y. Vytvorí sa Gaussov izotropný filter ktorý sa použije na výpočet matice lokálnej štruktúry z ktorej filtráciou pomocou nastaveného prahu vyberú význačné body.

5.2.2. Popis algoritmu funkcie ST_detect.m

Algoritmus funkcie je veľmi podobný s funkciou harris.m. Na začiatku si však užívateľ volí len približný počet. Počiatočný algoritmus je zhodný s harris., avšak miesto štandardných detekčných filtrov sa použije gaussov vyhladzovací filter a s použitím HOG gradientu. Matica lokálnej štruktúry sa potom vypočítava použitím funkcie výpočtu vlastných čísel, ktorá sa nachádza v rovnakom súbore.

5.2.3. Popis algoritmu funkcie local_entropy.m

Jedinou možnosťou nastavenia akú má funkcia je nastavenie vzájomnej vzdialenosti jednotlivých bodov. Na začiatku funkcie sa definuje detekčná maska pre výpočet lokálnej entropie ktorý je realizovaný pomocou príkazu entropyfilt v Matlabe. Po výpočte entropie v celom obraze sa tieto hodnoty filtrujú pomocou funkcie hľadania lokálneho maxima, ktorá je vložená priamo v tomto súbore. Filtrácia sa prevádza príkazom ordfilt2 za použitia masky nastaveného priemeru.

5.2.4. Popis algoritmu funkcie match_FP_distance.m

Na začiatku algoritmu sa zistí, v ktorom obraze bol detekovaný menší počet význačných bodov. V prípade že je toto v druhom obraze tak sa budú priradzovať význačné body z prvého obrazu k význačným bodom z druhého. V situácii keď ich je detekovaných viac sa toto obráti. Funkcia používa bublinkovú metódu porovnávania vzdialenosti bodov na základe porovnávania súradníc. Toto prebieha v dvoch do seba vnorených cykloch, keď prvý nám definuje bod, ku ktorému budú porovnávané všetky ostatné body z druhého obrazu, a druhý definuje ktorý bod sa k nemu bude porovnávať. Porovnávanie prebieha výpočtom Euklidových vzdialeností podľa vzorca uvedeného v teoretickej časti. Prvá vypočítaná vzdialenosť sa uloží do premennej a do druhej sa uložia súradnice obidvoch porovnávaných bodov. Každá ďalšia vypočítaná hodnota euklidovských vzdialeností sa potom porovnáva s touto hodnotou. Ak je nová hodnota vzdialenosti bodov menšia ako tá, ktorá je uložená v premennej, tak sa ňou nahradí a zároveň sa prepíšu aj súradnice bodu, ktorý bude nahradený, súradnicami bodu s menšou euklidovskou vzdialenosťou.

5.2.5. Popis algoritmu funkcie match_LACC.m

Rovnako ako funkcia match_FP_distance.m používa bublinkovú metódu na rovnakom princípe porovnávania každý s každým. Avšak v jednotlivých cykloch sa vyberá oblasť v okolí každého bodu, ktorý sa aktuálne porovnáva, rovnako ako sa vyberie oblasť

rovnakej veľkosti okolo bodu s ktorým daný bod porovnávame. Následne sa pre dve vybrané oblasti vypočíta pomocou funkcie corr2 lokálny korelačný koeficient. Tento sa porovnáva s nastaveným prahom. Ak je táto hodnota vyššia ako nastavené minimum zapíšu sa do premennej súradnice daných dvoch bodov. Pokiaľ sa však počas druhého cyklu nájde bod, ktorý má s bodom ku ktorému hľadáme pár väčšiu hodnotu korelačného koeficientu ak už zaznamenaný bod, tak súradnice predošlého bodu sa prepíšu súradnicami nového bodu.

5.2.6. Popis algoritmu funkcie LACC_distance_matching.m


Algoritmus tejto funkcie je vlastne kombináciou algoritmu funkcie match_FP_distance.m a algoritmu funkcie match_LACC.m. Algoritmus porovnávania lokálnych korelačných koeficientov je rovnaký ako vo funkcii match_LACC.m. Po získaní dvojíc bodov sa však ešte porovnávajú vzdialenosti dvoch spárovaných bodov ich vzdialenosti pomocou podobného algoritmu ako vo funkcii match_FP_distance.m s tým rozdielom, že vzdialenosti sa n

5.3. Panel Vykresľovanie a Zobrazenie

V paneli Vykresľovanie má užívateľ možnosť meniť typ vykresľovania a typ geometrickej transformácie ktorá sa použije vždy na druhý (registrovaný) obraz. Pri type vykresľovania je možnosť voľby z:

1. Originál + FP + registrovaný + FP
2. Originál + registrovaný + spárované FP
3. Originál s FP + registrovaný s FP + Sparovane FP
4. Originál so znázornením posunutia FP v registrovanom
5. Originál + registrovaný + transformácia registrovaného + šachovnicové prekrytie originálu a transformovaného
6. Originál + registrovaný + transformácia registrovaného + prekrytie originálu a transformovaného
7. Šachovnicové prekrytie originálu a transformovaného obrazu – chybový obraz
8. Prekrytie originálu a transformovaného obrazu – výsledok registrácie

Pri voľbách 5 a 7 sa šachovnicovým prekrytím obrazov rozumie zobrazenie chybového obrazu. Týmto spôsobom je lepšie rozoznateľné chybné registrovanie a chybná transformácia registrovaného obrazu. Ďalšou voľbou ktorú užívateľ môže nastaviť je typ geometrickej transformácie, ktorá bude použitá na registrovaný obraz. Voľby 6 a 8 potom zobrazia prekrytie originálneho a registrovaného obrazu bez šachovnicovej masky. Na základe nastaveného parametra sa potom v paneli zobrazenie vykreslia požadované obrazy spolu s popisom, ktorý obraz čo predstavuje.



Obrázok 5.2 Znázornenie rozdielu medzi chybovým obrazom a finálnym registrovaným obrazom

6. Testovanie naprogramovaných metód

Na všetky testovania procesov registrácie bol použitý prenosný počítač Asus F3Sc s konfiguráciou:

Procesor:	Intel Core 2 Duo T7100, 1,80 GHz
Chipset::	Intel PM965
RAM:	2 GB, DDR2 677MHz
Pevný disk	WD Scorpio Blue WDC5000BPVT, 500 GB, 5400 ot./min.
Grafická karta:	Nvidia GeForce 8400M G, 128MB VRAM
Operačný systém:	MS Windows 7 Professional SP1

6.1. Porovnanie detekcie význačných bodov pomocou jednotlivých metód

V tejto kapitole bude popísaný výkon jednotlivých detektorov význačných bodov z hľadiska času potrebného na detekovanie bodov v jednom obraze, stálosti tohto času, počte detekovaných bodov ako aj stálosti detekovaných bodov pri rôznych podmienkach detekcie. Toto bude overené testami zašumeného a rozostreného obrazu. Metóda SIFT bola pri porovnávaní rýchlosti detekcie jednotlivých metód vynechaná, keďže má vlastnú funkciu párovania význačných bodov a tvorí teda komplexnú registračnú metódu. Z tohto dôvodu bude jej rýchlosť porovnávaná až v rámci porovnania rýchlosti metód párovania význačných bodov.

6.1.1. Testovanie rýchlosti detektorov

Na test rýchlosti detekcie a počtu detekovaných význačných bodov bola vybraná sekvencia 90 snímok pohybujúcej sa dvojice ľudí (Obrázok 3.1). Rozmery snímok sú 320×240 pixlov (768000 pixlov) pri šedotónovej farebnej hĺbke 8 bitov. Súbor sekvencie sú súčasťou elektronickej prílohy. Proces detekcie bodov bol trikrát zopakovaný kvôli odstráneniu náhodnej chyby a teda celkovo bolo získaných 270 časových údajov. Počas testu rýchlosti sa na počítači nepracovalo, bol odpojený od akejkoľvek sieťovej aktivity a na pozadí neboli spustené žiadne procesy, ktoré by mohli ovplyvniť výsledky.



Obrázok 6.1 Ukážka snímku z testovacej sekvencie

Tabuľka 1: Čas detekcie FP v jednom obraze pomocou rôznych detektorov


	Harris	Shi – Tomasi	FAST	Lokálna entropia
Priemer 1. cyklus [s]	0,0857	0,1048	0,4069	0,9939
Priemer 2. cyklus [s]	0,0842	0,1031	0,4062	0,9902
Priemer 3. cyklus [s]	0,0860	0,0920	0,4069	0,9945
Celkový priemer [s]	0,0849	0,099	0,4067	0,9929
Rozptyl [$s \cdot 10^{-3}$]	0,0360	0,0992	0,0725	0,2108
Smerodajná odchýlka [s]	0,0060	0,0099	0,0085	0,0136

Ako možno vidieť z výsledkov v tabuľke najrýchlejšou detekciou význačných bodov disponuje Harrisov detektor spolu s detektorom Shi – Tomasi. Tento malý rozdiel je pochopiteľný, z dôvodu veľkej podobnosti princípov oboch detektorov. Harrisov detektor sa ukázal aj ako časovo najstálejší, keďže má najmenšiu hodnotu smerodajnej odchýlky. Naopak časovo najnestálejší je detektor založený na lokálnej entropii.

6.1.2. Test a vyhodnotenie počtu a stability detekovaných význačných bodov

Stabilitou detektora môžeme rozumieť jeho odolnosť voči nepriaznivým artefaktom v obraze akými sú rôzne druhy šumu či rozostrenia. Túto odolnosť možno chápať tak, že nech by sa v snímku nachádzali akékoľvek rušivé elementy, detektor by aj tak dokázal správne detekovať význačné body na tých miestach, kde by ich inak detekoval v obraze bez týchto artefaktov.

K testovaniu stability detektorov bola použitá jedna snímka, ktorá bola pomocou funkcií v Matlabe zašumená niekoľkými druhmi šumu s premennými parametrami, ako aj rozostrená priemerovacím filtrom s rôznymi stupňami rozostrenia. Príklady použitých snímok sú na Obrázok 6.2, v poradí – Gaussov šum, šum „Salt and Pepper“ (SaP), „speckle“ šum a rozostrenie pomocou priemerovacieho filtra.



Obrázok 6.2 Upravené snímky použité na testovanie stability detektorov

Pre každý typ rušenia boli zvolené rôzne úrovne intenzity nasledovne:

- Gaussov šum – zmena rozptylu (variance) – 0.01, 0.02, 0.04, 0.08, 0.16
- SaP – zmena hustoty šumu (noise density) – 0.01, 0.02, 0.04, 0.08, 0.16
- Speckle šum – zmena rozptylu (variance) – 0.01, 0.02, 0.04, 0.08, 0.16
- Rozostrenie – rozmer priemerovacieho filtra (N×N) – 2, 3, 5, 7

Odolnosť detektora voči rušeniu bude vyhodnotená podľa množstva bodov, ktoré boli v zarušenom obraze detekované na mieste, na ktorom boli pôvodne detekované v originály, teda ich vzdialenosť je 0. Druhým parametrom bude počet bodov detekovaných do vzdialenosti 2 pixlov od pôvodne detekovaného bodu v originály. Tieto dve podmienky boli zvolené k overeniu miery stability detekcie význačného bodu. Pri daných rozmeroch testovacích snímok, posunutie význačného bodu o ± 2 pixle pri spárovaní s iným bodom posunutým o 2 pixle do opačného smeru spôsobí pri výpočte geometrickej transformácie chybu, s maximálnou hodnotou


$$\delta = \frac{a^2}{M \cdot N} \cdot 100 = \frac{5^2}{240 \cdot 320} \cdot 100 = 0,0326 \%$$

kde δ je vypočítaná odchýlka, a je s rozmer strany štvorca v ktorom sa maximálne môže význačný bod nachádzať tak aby bol v tolerancii a M N sú rozmery snímku v ktorom boli detekované význačné body.

Podrobné výsledky testovania sú uvedené v tabuľkách v Príloha I, v Príloha II a v Príloha III. Jednotlivé stĺpce reprezentujú počet detekovaných bodov, $d = 0$ je počet bodov ktoré presne zodpovedajú originálnemu obrazu, $d \leq 2$ je počet bodov ktoré spĺňajú podmienku minimálnej vzdialenosti a stĺpec FP OK reprezentuje percento použiteľných bodov zo všetkých detekovaných.


Z výsledkov je vidno, že ako najviac citlivý na šum v obraze a na rozostrenie je detektor založený na výpočte lokálnej entropie. U rozostrenia obrazu je toto pochopiteľné, keďže daný detektor pracuje na miere neusporiadanosti okolia, a po aplikácii gaussovho vyhladzovacieho filtru sa okolie bodu homogenizuje a teda znižuje sa jeho entropia. Toto je potvrdené takmer nulovou správnosťou detekcie pôvodných bodov a veľmi malou hodnotou bodov detekovaných v tolerančnom okolí. Rovnako je detektor citlivý aj na celo snímkový Gaussov aj Speckle šum. Toto opäť potvrdzujú nulové hodnoty detekovaných pôvodných bodov. Naopak vysoké hodnoty u počtu detekovaných FP naznačujú zvýšenie celkovej entropie obrazu. To logicky vyplýva z náhodnosti šumu,

ktorý do snímku vnáša vysokú mieru neurčitosti v rozhodovaní (kapitola 4.1.4). Avšak detektor podáva vynikajúce výsledky pri detekcii snímku zašumených šumom SaP. Počty detekovaných význačných bodov sú veľmi blízke počtu bodov v originálnom obraze. Zároveň počet bodov ktoré ležia v tolerancii a tým pádom by sa dali použiť k registrácii obrazu, je pre hodnoty intenzity šumu do 0.08 minimálne 50% z celkového počtu bodov.




Obrázok 6.3 Rozdiel v detekcii význačných bodov pri rozostrení obrázka – $N = 7$, výpočet pomocou lokálne entropie

Za druhý najcitlivejší detektor na skreslenia obrazu možno označiť FAST. U šumového skreslenia je toto tvrdenie podložené počtom detekovaných bodov, keď u skreslenia typu SaP detekoval v prípade najväčšej intenzity šumu až 3158 význačných bodov, avšak len 86 bodov bolo použiteľných v definovanej tolerancii, teda len približne 2,72% (Obrázok 6.4). Toto je opäť dané vlastnosťami detektora ktorý porovnáva intenzitu pixlu s intenzitou okolitých bodov. U tohto typu skreslenia je vysoká pravdepodobnosť, že n po sebe nasledujúcich pixlov v okolí šumového bodu bude mať nižšiu alebo vyššiu hodnotu intenzity ako je hodnota snímaného bodu \pm nastavený prah (kapitola 4.1.7). Na základe toho je teda väčšina zašumených pixlov vyhodnotená chybné ako význačný bod. Tento detektor je rovnako citlivý aj na rozostrenie (vyhladenie) snímku, keďže rozdiely medzi intenzitami v definovanom okolí sa vyrovnávajú a postupne žiadny bod neprekročí nastavenú prahovú hodnotu. Z toho možno usúdiť, že daný typ detektora nie je vhodný pre detekciu význačných bodov v zašumených alebo rozostrených snímkach.



Obrázok 6.4 Ukážka chybného vyhodnotenia šumu za význačné body, FAST detektor


Na rovnakej úrovni citlivosti na skreslenie v obraze sú detektory Harris a Shi-Tomasi. Toto je pochopiteľné, keďže druhý menovaný principiálne vychádza z prvého a líšia sa len v spôsobe prahovania význačných bodov. V prípade celo snímkového šumu sú ich detekčné schopnosti značne ovplyvnené týmto šumom, keďže pracujú na princípe výpočtu hranovej odozvy, môže sa stať, že detektor vyhodnotí odozvu šumu namodulovaného na homogénnu plochu ako odozvu hrany a podľa toho túto odozvu označí ako význačný bod. V prípade Shi – Tomasi detektora je týchto zlých priradení menej ako v prípade Harris detektora, čo je spôsobené hlavne jeho metódou váhovania význačných bodov pomocou vlastných hodnôt čísel týchto bodov. To je nesporná výhoda Shi – Tomasi detektora, keď aj pri obraze zašumenom Speckle 0.10 detekoval približne 41,6% použiteľných význačných bodov oproti 15,4% u Harris detektora (Obrázok 6.5).



Obrázok 6.5 Ukážka detekcie bodov pri zašumení snímku šumom Speckle – 0.08, hore Harris detektor, dole Shi – Tomasi detektor

Špeciálnym prípadom v tomto teste je SIFT deskriptor. Výstupom z algoritmu jeho funkcie sú priamo spárované dvojice význačných bodov dvoch snímok. Tento údaj teda nemôže byť použitý pre priame vyhodnotenie stability detekcie význačných bodov. Význačné body ku ktorým sa nespáruje žiadny iný bod z druhého obrazu sú totiž odstránené a neposielajú sa na výstup. Porovnanie daných párov bodov s ostatnými metódami by tak došlo ku skresleniu výsledkov. Je tu však možnosť porovnať ako pracuje systém deskriptora ako celok v závislosti na šume a artefaktoch v snímkach. Ako by sa dalo predpokladať, počet spárovaných bodov v závislosti na zvyšujúcom sa šume klesá. U metódy SaP ako u jedinej nedošlo k žiadnej detekcii ani párovaniu a proces skončil chybou. SIFT deskriptor pravdepodobne nevie správne popísať detekované body za prítomnosti dvoch alebo viacerých ostrých extrémov, akými je šum SaP charakteristický. Preto je pre snímky s týmto typom šumu nepoužiteľný. Pri použití s ostatnými zašumenými obrazmi prehol celý proces v poriadku. Pri detekcii so všetkým druhmi šumu dosahuje relatívne vysoký počet správne priradených párov a preto je viac ako vhodný k registrácii obrazov s vysokou hodnotou šumu (mimo šum SaP). V Príloha III sú pre ilustráciu uvedené aj počty detekovaných párov ktoré vyhovujú podmienkam

stability a celkové percentuálne podiely podobne ako u zvyšných detektorov. Z nich možno vidieť že deskriptor vykazuje vysokú stabilitu takmer pri všetkých typoch šumu s ktorými dokáže pracovať.



Obrázok 6.6 Ukážka detekcie bodov pri zašumení snímku šumom Gauss – 0.08, SIFT detektor

6.2. Porovnanie metód párovania význačných bodov

U metód párovania význačných bodov je možné taktiež, podobne ako u metód získavania význačných bodov, hodnotiť rýchlosť tohto procesu ako aj ohodnotiť výsledky spárovania pomocou vizuálnej kontroly. Toto je totiž najefektívnejšia metóda vyhodnotenia výsledkov, keďže sú hneď jasné zle spárované body, ktorých spojnice má výrazne iný smer vektoru ako bodov dobre spárovaných.

6.2.1. Časová náročnosť párovania význačných bodov

Na vyhodnotenie časovej náročnosti párovania bodov bola použitá sekvencia 26 snímok z MRI o rozmeroch 256×256 pixlov a bol použitý Harrisov detektor na detekciu význačných bodov. Celkovo sa teda v každom cykle vytvorilo 25 dvojíc význačných bodov. Proces párovania bodov bol opakovaný pre každú metódu 5 krát aby sa zabránilo náhodnej chybe. Keďže bol použitý rovnaký detektor pre nájdenie význačných bodov pre každú metódu párovania, tak každá pracuje s rovnakým počtom vstupných bodov. Priemerne to činí 302 bodov s rozptylom 11,737 a smerodajnou odchýlkou 3,354. Do porovnania v tabuľke bol zahrnutý aj celkový čas procesu registrácie pomocou SIFT detektora. Počas testu rýchlosti sa na počítači nepracovalo, bol odpojený od akejkoľvek sieťovej aktivity a na pozadí neboli spustené žiadne procesy, ktoré by mohli ovplyvniť výsledky.


Tabuľka 2: Čas potrebný na spárovanie význačných bodov pomocou rôznych metód

	Euklidova vzdialenosť	LACC	LACC + obmedzenie	SIFT
Priemer 1. cyklus [s]	0,0259	2,7024	3,2232	17,1594
Priemer 2. cyklus [s]	0,0244	2,7549	3,1965	17,0956
Priemer 3. cyklus [s]	0,0242	2,6903	3,1849	18,5244
Priemer 4. cyklus [s]	0,0244	2,6906	3,1977	18,8752
Priemer 5. cyklus [s]	0,0245	2,6926	3,1980	17,9379
Celkový priemer [s]	0,0247	2,7062	3,2001	17,9189
Rozptyl [s]	$0,0124 \cdot 10^{-3}$	0,0089	0,0110	5,003
Smerodajná odchýlka	0,0035	0,0942	0,1044	2,2278

Z tabuľky možno vidieť, že z hľadiska rýchlosti párovania význačných bodov je daných metód najrýchlejšia metóda párovania na základe Euklidových vzdialeností, ktorá zároveň dosahuje aj najmenšiu smerodajnú odchýlku času párovania. Čas výpočtu lokálneho korelačného koeficientu je niekoľkonásobne väčší, keďže matematické operácie ktoré toto prevádzajú sú omnoho zložitejšie a časovo náročnejšie na výpočet ako jednoduché aritmetické operácie u predošlej metódy. Rovnako aj u metódy párovania pomocou LACC s obmedzením vzdialenosti sa zväčšil čas potrebný k výpočtu párov oproti metóde bez tohto obmedzenia. To je dané zvýšeným počtom krokov algoritmu o porovnávanie vzdialenosti bodov.


6.2.2. Porovnanie a zhodnotenie párovania význačných bodov

Zhodnotenie výsledkov párovania bude prevádzané pomocou vizuálneho porovnania. Význačné body boli detekované pomocou lokálnej entropie.




Obrázok 6.7 Najmenšia euklidovská vzdialenosť

U metódy najmenšej euklidovskej vzdialenosti je spárovanie bodov prevedené s minimálnymi chybami. Nájde sa však malý počet nesprávne priradených bodov, čo možno vidieť na Obrázok 6.7. Zlé priradenia sa vyskytujú v oblasti kde bolo v originálnom obraze detekovaných viac bodov ako v registrovanom. Toto je možno dobre vidieť na vertikálnom naznačení kde sa v ľavej strane zbiehajú štyri body do jedného. Celkovo je však v obraze vidieť aj vysoké množstvo správnych priradení.




Obrázok 6.8 LACC párovanie

U lokálneho korelačného koeficientu na Obrázok 6.8 je možno vidieť vysoké množstvo nesprávne priradených význačných bodov. Toto je potvrdenie teoretických znalostí o tejto metóde z kapitoly 4.2.1 kde bolo správne definované, že daná metóda sama o sebe bez nejakých obmedzení nevedie vždy k správne výsledku spárovania. Avšak ako je z obrázku jasné, nachádza sa tu aj niekoľko dobre priradených význačných bodov, avšak počet zlých priradení by vo výslednej registrácii prevýšil počet tých dobrých a registrácia by bola neúspešná.



Obrázok 6.9 LACC s obmedzením vzdialenosti

Na Obrázok 6.9 je možno vidieť že po aplikovaní vzdialenostného obmedzenia bodu došlo už k správne spárovaniu väčšiny význačných bodov. Existujú však aj nesprávne spárované body, hlavne v oblasti s vysokou koncentráciou bodov. Je to možno vidieť v ľavom dolnom rohu, kde 3 body z originálneho obrazu boli priradené k jednému bodu z registrovaného obrazu. Tomuto by sa dalo zabrániť tým, že po priradení jedného bodu k druhému by sme následne tieto body odstránili z algoritmu hľadania párov.




Obrázok 6.10 SIFT

U deskriptora SIFT je možno vidieť takmer bezchybné výsledky priradenia význačných bodov v originálnom obraze k význačným bodom v registrovanom obraze. Avšak aj pri tejto pokročilej metóde registrácie obrazov je možno vidieť dvojité priradenie jedného význačného bodu v origináli; k dvom iným bodom v registrovanom obraze. Toto však pri množstve dobre registrovaných bodov nemá na výsledný proces registrácie takmer žiadny vplyv.

7. Výsledky registrácie snímku

Výslednú registráciu snímku po získaní spárovaných bodov prevádzame voľbou typu geometrickej transformácie ktorá bude vypočítaná z nájdených párov a následne aplikovaná na registrovaný obraz. K vyhodnoteniu kombinácií metód registrácie, teda detektor význačných bodov a metóda párovania, boli použité dva obrázky z výrezu MRI snímku, pričom jeden bol posunutý v oboch osiach o 25 pixlov vpravo a o 27 pixlov nahor a orezaný na rovnakú veľkosť ako má pôvodný snímok.



Obrázok 7.1 Obrázky MRI na vyhodnotenie registrácie

Dané obrázky boli zvolené z dôvodu vysokého kontrastu v scéne a potenciálneho dostatočného množstva detekovaných bodov. Po procese párovania a detekcie význačných bodov bol zvolený rôzny typ geometrickej transformácie, ktorá sa použila na registrovaný obraz. Výsledky jednotlivých rôznych kombinácií je možno vidieť na nasledujúcich stránkach. Ku každej kombinácii detektor – metóda párovania je uvedený vždy najlepší výsledok a geometrická transformácia ktorá bola k tomuto použitá. V žiadnej metóde neboli robené žiadne nastavenia, teda výsledky sú z predvoleného stavu metód. Pod popisom zistených výsledkov sú uvedené príslušné obrázky. S registrovaným obrazom je uvedený aj obraz s vektormi posunutia spárovaných bodov, ktoré by v tomto prípade mali mať rovnakú orientáciu.

1. Obrázok 7.2 Harris + Euklidovské vzdialenosti - transformácia podobnosť

Táto kombinácia detektoru a metódy párovania sa pre dané dva snímky nedá vôbec použiť. Ako vidieť na hore uvedenom obrázku, vektory spárovania význačných bodov nie sú usporiadané v jednom smere ako by mali byť, ale chaoticky spárované. Táto metóda teda nie je najvhodnejšia pre obrazy ktoré sú moc posunuté alebo zmenené, pretože potom sa poloha význačných bodov zmení tak radikálne že spárovanie pomocou najmenších vzdialeností nemá zmysel. Preto s ňou v ďalších krokoch nebudeme uvažovať.

2. Obrázok 7.3 Harris + LACC - Rigidná transformácia

Na obrázku je jasná zlá registrácia spôsobená niekoľkými zle spárovanými bodmi ktoré sú jasne vidieť na tom istom obrázku vpravo. Toto zlé priradenie by sa dalo odstrániť buď optimalizačnou funkciou alebo obmedzením vzdialeností bodov.

3. Obrázok 7.4 Harris + LACC s obmedzením vzdialenosti

Výsledná registrácia obrazov je takmer úspešná, pričom chybu v registrácii má na svedomí pár zle priradených bodov v spodnej časti obrazu. Toto by sa opäť dalo odstrániť optimalizačnou metódou.

4. Obrázok 7.5 Shi – Tomasi detektor + LACC – afinná transformácia

Výsledná registrácia obrazov je v tejto kombinácii neúspešná kvôli zle stanovenej transformácii. Toto je opäť spôsobené zlým párovaním význačných bodov. To mohlo nastať z dôvodu veľkého množstva detekovaných význačných bodov a teda vysokej pravdepodobnosti zlého priradenia.

5. Obrázok 7.6 Shi – Tomasi detektor + LACC s obmedzením vzdialeností – polynomiálna transformácia

Výsledná registrácia obrazov za použitia týchto metód je takmer bezchybná. Zlá transformácia registrovaného obrazu v spodnej časti je dôsledkom príliš veľkého množstva detekovaných a následne zle spárovaných bodov. Avšak oproti predchádzajúcej kombinácii metód je registrácia omnoho úspešnejšia.

6. Obrázok 7.7 FAST + LACC – transformácia miestny vážený priemer

Registrácia obrazov je v tomto prípade takmer úspešná, keď úspešnému registrovaniu obrazov zabráňuje len zlé priradenie jedného bodu. Toto by zlé priradenie v tomto prípade by malo byť odstránené obmedzením vzdialenosti.

7. Obrázok 7.8 FAST + LACC s obmedzením vzdialenosti – transformácia miestny vážený priemer

Pri tejto kombinácii metód bol odstránený predošlý zle priradený bod, avšak objavil sa nový zle priradený pár. Dĺžka vektoru ktorý spája tieto dva body je však aj na väčšia ako dĺžka ostatných vektorov, preto by tento bod mohlo odstrániť dodatočné nastavenie prahovej hodnoty vzdialenosti a registrácia by bola úspešná.


8. Obrázok 7.9 Lokálna entropia + LACC – transformácia podobnosť

V kombinácii týchto dvoch metód je registrácia obrazov úspešná, čo možno vidieť aj na obraze s vektormi posunutia, keď ku každému význačnému bodu v originály bol priradený správny bod v registrovanom obraze. Zároveň neexistuje žiadna dvojica nesprávne priradených bodov. Obmedzenie vzdialenosti teda v tomto prípade nemá žiadny zmysel, pretože výsledok transformácie bude rovnaký ako je možno vidieť na Obrázok 7.10.


9. Obrázok 7.11 Obrázok 7.11 SIFT deskriptor – transformácia typu miestny vážený priemer

Táto metóda vykazuje vysokú mieru úspešnosti registrácie, čo dokazuje aj daný obrázok. V ňom sú síce zrejme aj zle spárované body, avšak počet dobre spárovaných bodov je natoľko vysoký, že toto zlé spárovanie nehrá žiadnu rolu a tieto chybné body sú automaticky odstránené v transformácii.


Zo všetkých hore uvedených metód registrácie jednoznačne najlepšie výsledky dosahuje kombinácia detekcie význačných bodov pomocou lokálnej entropie a metóda LACC pre párovanie nájdených bodov (respektíve v kombinácii detekcia lokálnej entropie a LACC s obmedzením vzdialenosti) a metóda SIFT deskriptoru. Obidve metódy podávajú zhodne dobré výsledky, aj keď odlišným prístupom. Prvá kombinácia podáva dobré výsledky pri párovaní bodov, keď ako jediná metóda nepodáva žiadne chybné spárované body. Metóda SIFT chybné spárované body vykazuje, ale sú vyvážené veľkým množstvom správne spárovaných bodov a pri použití správnej geometrickej transformácie podáva takmer rovnaké výsledky.




Obrázok 7.2 Harris + Euklidovské vzdialenosti - transformácia podobnosť




Obrázok 7.3 Harris + LACC - Rigidná transformácia




Obrázok 7.4 Harris + LACC s obmedzením vzdialenosti – polynomiálna transformácia




Obrázok 7.5 Shi – Tomasi detektor + LACC – afinná transformácia




Obrázok 7.6 Shi – Tomasi detektor + LACC s obmedzením vzdialeností – polynomiálna transformácia




Obrázok 7.7 FAST + LACC – transformácia miestny vážený priemer




Obrázok 7.8 FAST + LACC s obmedzením vzdialenosti – transformácia miestny vážený priemer



Obrázok 7.9 Lokálna entropia + LACC – transformácia podobnosť



Obrázok 7.10 Lokálna entropia + LACC s obmedzením vzdialenosti – transformácia podobnosť



Obrázok 7.11 SIFT deskriptor – transformácia typu miestny vážený priemer

8. Záver

Cieľom tejto diplomovej práce bolo zoznámiť sa s metódami registrácie medicínskych obrazov so zameraním sa na metódy registrácie pomocou metód sledovania príznakov. V práci boli uvedené jednotlivé kritéria pomocou ktorých je možno registračné metódy jednoznačne klasifikovať. Následne boli v práci popísané matematické princípy základných geometrických transformácií, ktoré sa používajú pri registrácii nielen medicínskych obrazov. V ďalšej teoretickej časti tejto práce boli podrobne popísané jednotlivé metódy registrácie obrazov so zameraním sa na registráciu pomocou sledovania príznakov, alebo tiež registráciu pomocou sledovania význačných bodov.

Boli opísané rôzne metódy detekcie význačných bodov s rôznymi prístupmi k danej problematike. Následne boli podrobne opísané princípy funkčnosti rôznych intenzitných metód pre detekciu význačných bodov, konkrétne detektor SUSAN, Harrisov detektor, detektor Shi – Tomasi (taktiež známy ako KLT detektor), detekcia význačných bodov pomocou lokálnej entropie, detektor FAST a deskriptory bodov SIFT a SURF. V ďalšej teoretickej časti boli potom opísané dve metódy párovania nájdených význačných bodov a to metóda párovania pomocou výpočtu najmenších euklidovských vzdialeností a metóda korelačného koeficientu lokálnej oblasti LACC, ako aj optimalizačná metóda najmenšieho mediánu štvorcov.

Na základe týchto znalostí a zistení bol naprogramovaný program pre registráciu medicínskych obrazov v prostredí Matlab verzia R2009b. V tomto programovom prostredí boli naprogramované funkcie pre detekciu a párovanie význačných bodov, konkrétne Harrisov detektor, Shi – Tomasi detektor, detekcia význačných bodov pomocou lokálnej entropie, detektor FAST, deskriptor SIFT, párovanie význačných bodov pomocou najmenších Euklidovských vzdialeností, párovanie bodov pomocou lokálneho korelačného koeficientu LACC a metóda LACC s obmedzením maximálnej vzdialenosti bodov. Všetky tieto metódy boli naprogramované s využitím funkcií v programe Matlab, alebo pomocou voľne dostupných funkcií so zdrojmi citovanými v práci.

Na záver boli v práci tieto implementované metódy otestované a porovnané z hľadiska výkonu a času, ktorý je potrebný k registrácii pomocou týchto metód. Získané výsledky sú uvedené v práci spolu s obrazovou dokumentáciou a ukážkami výsledkov registrácie naprogramovaných metód.

Zoznam použitej literatúry

- [1] FITZPATRICK, J. Michael, Derek L.G. HILL a Calvin R. MAURER Image Registration: Chapter 8. BEUTEL, Jacob. Handbook of medical imaging: Volume 2, Medical Image Processing and Analysis. Bellingham, Wash.: SPIE Press, c2000, s. 488-496. ISBN 0-8194-3622-4.
- [2] MAINTZ, J.B.Antoine a Max A. VIERGEVER. A survey of medical image registration. Medical Image Analysis. 1998, roč. 2, č. 1, s. 1-36. ISSN 13618415. DOI: 10.1016/S1361-8415(01)80026-8. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1361841501800268>
- [3] Geometrické transformace ve 2D, Základy počítačové grafiky, prezentace přednášek, Ústav počítačové grafiky a multimédií Fakulta informačních technologií VUT v Brně
- [4] SMITH, Stephen. Feature Based Image Sequence Understanding. Oxford, 1992. PhD. thesis. University of Oxford.
- [5] KITCHEN, Les a Azriel ROSENFELD. Gray-level corner detection. Pattern Recognition Letters. 1982, roč. 1, č. 2, s. 95-102. ISSN 01678655. DOI: 10.1016/0167-8655(82)90020-4. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0167865582900204>
- [6] HARRIS, Chris a Mike STEPHENS. A combined corner and edge detector. In: Alvey Vision Conference. London: Controller HMSO, 1988, s. 147-151. Dostupné z: <http://www.assembla.com/spaces/robotics/documents/abzMnAOEer3zB7ab7jnrAJ/download/harris88.pdf>.
- [7] MACIEL, João a João COSTEIRA. Robust Point Correspondence by Concave Minimization. In: *Proc. 11th British Machine Vision Conf.* Bristol: BMVA, 2002, s. 626-635. DOI: 10.1.1.108.3411. Dostupné z: http://welcome.isr.ist.utl.pt/img/pdfs/751_tr1199.pdf

- [8] SCHOOL OF COMPUTER SCIENCE & SOFTWARE ENGINEERING THE UNIVERSITY OF WESTERN AUSTRALIA. Computer Vision CITS4240: Corner Detection and Tracking [online]. Crawley, Perth, 2008 [cit. 12.5.2012]. Dostupné z: <http://undergraduate.csse.uwa.edu.au/units/CITS4240/Lectures/tracking.pdf>
- [9] SHI, Jianbo a Carlo TOMASI. Good features to track. In: Proceedings / CVPR, IEEE Computer Society Conference on Computer Vision and Pattern Recognition [online]. 1994. ISSN 1063-6919. DOI: 10.1109/CVPR.1994.323794. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=323794&isnumber=7716>
- [10] SHANNON, Claude Elwood a Warren WEAVER. The mathematical theory of communication. Chicago: University of Inninois Press, 1998, 125 s. ISBN 978-0-252-72546-3.
- [11] LOWE, David G. Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision,. 2004, č. 2, s. 91-110. Dostupné z: <http://www.cs.ubc.ca/~lowe/papers/ijcv04.pdf>
- [12] EVANS, Christopher. Notes on the OpenSURF Library. Notes on the OpenSURF Library [online]. 2009, CSTR-09-001. Dostupné z: <http://www.cs.bris.ac.uk/Publications/Papers/2000970.pdf>
- [13] BAY, Herbert, Tinne TUYTELAARS a Luc Van GOOL. SURF: Speeded Up Robust Features. In: Proceedings of the ninth European Conference on Computer Vision. Graz, 2006, s. 404-417.
- [14] LOWE, Matthew. Invariant features from interest point groups. In: British Machine Vision Conference. Cardiff, Wales: BMVC 2002, 2002, s. 656-665. Dostupné z: <http://www.cs.ubc.ca/~lowe/papers/brown02.pdf>
- [15] ROSTEN, Edward a Tom DRUMMOND. Fusing points and lines for high performance tracking. In: Proceedings / IEEE International Conference on Computer Vision [online]. 2005. ISSN 1550-5499. Dostupné z: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1544896&isnumber=32976>
- [16] ROSTEN, Edward a Tom DRUMMOND. Machine Learning for High-Speed Corner Detection. In: LEONARDIS, Aleš, Horst BISCHOF a Axel PINZ.

- Computer vision--ECCV 2006: 9th European Conference on Computer Vision, Graz, Austria, May 7-13, 2006 : proceedings. New York: Springer, 2006, s. 430-443. ISBN 978-3-540-33832-1. DOI: 10.1007/11744023_34. Dostupné z: http://dx.doi.org/10.1007/11744023_34
- [17] QUINLAN, John Ross. Induction of decision trees. *Machine Learning*. 1986, roč. 1, č. 1, s. 81-106. Dostupné z: <http://www.ncbi.nlm.nih.gov/pubmed/17050186>
- [18] ZHOU, Ji a Jiaoying SHI. A robust algorithm for feature point matching. *Computers*. 2002, roč. 26, č. 3, s. 429-436. ISSN 00978493. DOI: 10.1016/S0097-8493(02)00086-9. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0097849302000869>
- [19] VINCENT, Étienne a Robert LAGANIÈRE. Matching feature points in stereo pairs: a comparative study of some matching strategies. *Machine GRAPHICS & VISION*. 2001, roč. 10, č. 3, s. 237-259. Dostupné z: <http://www.site.uottawa.ca/~laganier/publications/matchingMGV01.pdf>
- [20] ZHANG, Zhengyou, Rachid DERICHE, Olivier FAUGERAS a Quang-Tuan LUONG. A robust technique for matching two uncalibrated images through the recovery of the unknown epipolar geometry. *Artificial Intelligence*. 1995, roč. 78, 1-2, s. 87-119. ISSN 00043702. DOI: 10.1016/0004-3702(95)00022-4. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/0004370295000224>
- [21] ROSTEN, Edward, Reid PORTER a Tom DRUMMOND. Faster and better: A machine learning approach to corner detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence (to appear)*. 2008, č. 10. Dostupné z: <http://lanl.arXiv.org/pdf/0810.2434>
- [22] KOVNATSKY, Artion. Feature points in image, Keypoint extraction. *Matlab Central: File Exchange* [online]. 2010 [cit. 2012-05-15]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/29004-feature-points-in-image-keypoint-extraction>

Príloha I: Tabuľka výsledkov testu počtu a stability detekovaných význačných bodov – Harris detektor, Shi – Tomasi detektor

	Harris				Shi - Tomasi			
	Počet FP	d = 0	d ≤ 2	FP OK [%]	Počet FP	d = 0	d ≤ 2	FP OK [%]
Originál	157	-	-	-	183	-	-	-
Gauss – 0.01	206	68	60	62,1	183	76	96	94,0
Gauss – 0.02	264	44	74	44,7	247	63	100	66,0
Gauss – 0.04	426	30	70	23,5	294	41	116	53,4
Gauss – 0.08	547	20	68	16,1	377	22	120	37,7
Gauss – 0.10	626	12	53	10,4	795	20	111	16,5
SaP – 0.01	200	98	33	65,5	183	139	43	99,5
SaP – 0.02	229	69	52	52,8	202	110	63	85,6
SaP – 0.04	344	60	62	35,5	231	91	78	73,2
SaP – 0.08	508	33	70	20,3	283	53	101	54,4
SaP – 0.10	571	21	66	15,2	406	33	113	36,0
Speckle – 0.01	154	91	46	89,0	183	98	73	93,4
Speckle – 0.02	191	70	63	69,6	202	76	92	83,2
Speckle – 0.04	261	62	68	49,8	217	70	88	72,8
Speckle – 0.08	447	35	74	24,4	263	41	106	55,9
Speckle – 0.10	628	25	72	15,4	355	36	112	41,7
Rozostrenie – 2	162	37	111	91,4	179	31	144	97,8
Rozostrenie – 3	154	58	66	80,5	162	74	62	84,0
Rozostrenie – 5	155	11	78	57,4	112	17	62	70,5
Rozostrenie – 7	163	1	52	32,5	89	2	48	56,2

Príloha II: Tabuľka výsledkov testu počtu a stability detekovaných význačných bodov – FAST detektor, Lokálna entropia

	FAST				Lokálna entropia			
	Počet FP	d = 0	d ≤ 2	FP OK [%]	Počet FP	d = 0	d ≤ 2	FP OK [%]
Originál	74	-	-	-	46	-	-	-
Gauss – 0.01	92	37	27	69,6	123	1	14	12,2
Gauss – 0.02	101	24	29	52,5	212	0	7	3,3
Gauss – 0.04	220	12	41	24,1	204	0	3	1,5
Gauss – 0.08	618	13	30	7,0	149	0	1	0,7
Gauss – 0.10	1024	6	30	3,5	63	0	1	1,6
SaP – 0.01	415	68	13	19,5	48	44	1	93,8
SaP – 0.02	658	65	21	13,1	43	29	8	86,0
SaP – 0.04	1232	54	27	6,6	51	24	12	70,6
SaP – 0.08	2170	46	40	4,0	24	6	6	50,0
SaP – 0.10	3158	31	55	2,7	46	10	6	34,8
Speckle – 0.01	71	48	20	95,8	114	4	15	16,7
Speckle – 0.02	69	45	19	92,8	91	1	12	14,3
Speckle – 0.04	71	28	27	77,5	151	0	10	6,6
Speckle – 0.08	107	22	23	42,1	169	1	7	4,7
Speckle – 0.10	352	12	19	8,8	136	1	4	3,7
Rozostrenie – 2	33	7	26	100,0	63	1	14	23,8
Rozostrenie – 3	6	1	5	100,0	52	1	6	13,5
Rozostrenie – 5	0	0	0	0,0	47	0	4	8,5
Rozostrenie – 7	0	0	0	0,0	33	0	3	9,1

Príloha III: Tabuľka výsledkov testu počtu a stability detekovaných význačných bodov – SIFT detektor

	SIFT			
	Počet FP	d = 0	d ≤ 2	FP OK [%]
Originál	-	-	-	-
Gauss – 0.01	125	100	19	95,2
Gauss – 0.02	95	76	16	96,8
Gauss – 0.04	63	46	12	92,1
Gauss – 0.08	31	18	8	83,9
Gauss – 0.10	19	9	6	78,9
Speckle – 0.01	167	149	15	98,2
Speckle – 0.02	146	118	20	94,5
Speckle – 0.04	95	83	7	94,7
Speckle – 0.08	69	52	11	91,3
Speckle – 0.10	37	26	5	83,8
Rozostrenie – 2	192	122	57	93,2
Rozostrenie – 3	173	122	40	93,6
Rozostrenie – 5	81	36	36	88,9
Rozostrenie – 7	42	11	17	66,7