



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

REGISTRACE FOTOGRAFIÍ DO 3D MODELU TERÉNU

REGISTRATION OF PHOTOS TO 3D MODEL

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. JAROMÍR DEÁK

VEDOUCÍ PRÁCE

SUPERVISOR

Doc. Ing. MARTIN ČADÍK, Ph.D.

BRNO 2017

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2016/2017

Zadání diplomové práce

Řešitel: **Deák Jaromír, Bc.**

Obor: Počítačová grafika a multimédia

Téma: **Registrace fotografií do 3D modelu terénu**

Registration of Photos to 3D Model

Kategorie: Počítačová grafika

Pokyny:

1. Seznamte se s metodami pro automatickou lokalizaci obrázků v horském terénu.
2. Vytipujte postupy vhodné pro zvýšení robustnosti existujících lokalizačních metod.
3. Rozšiřte existující systém pro lokalizaci obrázků o vámi navržené řešení.
4. Experimentujte se systémem, vyhodnoťte dosažené výsledky a diskutujte možnosti budoucího vývoje.

Literatura:

- L. Baboud, M. Čadík, E. Eisemann, H.-P. Seidel: Automatic Photo-to-Terrain Alignment for the Annotation of Mountain Pictures.
- Russell, B.C., Sivic, J., Ponce, J., Dessales, H.: Automatic alignment of paintings and photographs depicting a 3D scene.
- G. Baatz: Visual location recognition in man-made and natural environments, 2013.
- Dalla Mura, M. and Zanin, M. and Andreatta, C. and Chippendale, P.: Augmented reality: Fusing the real and synthetic worlds.
- Jesse Levinson, Sebastian Thrun: Automatic Online Calibration of Cameras and Lasers.

Při obhajobě semestrální části projektu je požadováno:

- Body 1 až 3 zadání.

Podrobné závazné pokyny pro vypracování diplomové práce naleznete na adrese

<http://www.fit.vutbr.cz/info/szz/>

Technická zpráva diplomové práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap, které byly vyřešeny v rámci dřívějších projektů (30 až 40% celkového rozsahu technické zprávy).

Student odevzdá v jednom výtisku technickou zprávu a v elektronické podobě zdrojový text technické zprávy, úplnou programovou dokumentaci a zdrojové texty programů. Informace v elektronické podobě budou uloženy na standardním nepřepisovatelném paměťovém médiu (CD-R, DVD-R, apod.), které bude vloženo do písemné zprávy tak, aby nemohlo dojít k jeho ztrátě při běžné manipulaci.

Vedoucí: **Čadík Martin, doc. Ing., Ph.D.**, UPGM FIT VUT

Datum zadání: 1. listopadu 2016

Datum odevzdání: 24. května 2017

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta informačních technologií
Ústav počítačové grafiky a multimédií
612 56 Brno, Božetěchova 2



doc. Dr. Ing. Jan Černocký
vedoucí ústavu

Abstrakt

Tato práce se zabývá existujícími řešeními a možnostmi registrace fotografie do 3D modelu terénu na základě znalosti geografické polohy pořízení fotografie. Přínosem této práce je otevření nových možností řešení této úlohy za použití grafových algoritmů. V této oblasti se práce zabývá problematikou detekcí vhodných význačných bodů ve vstupních datech, vystavění grafů a možnostmi vyhledání jejich korespondence.

Abstract

This work refers existing solutions and options for the task registration of photos to 3D model based on the previous knowledge of the geographic position of the camera. The contribution of the work are new ways and possibilities of the solution with the usage of graph algorithms. In this area, the work interests are useful points of interest detection in input data, a construction of graphs and graph matching possibilities.

Klíčová slova

fotografie, výšková mapa terénu, grafové algoritmy, korespondence grafů, SIFT, Shape Context, elastická registrace

Keywords

photograph, digital elevation map, graph algorithms, graph matching, SIFT, Shape Context, elastic registration

Citace

DEÁK, Jaromír. *Registrace fotografií do 3D modelu terénu*. Brno, 2017. Diplomová práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Čadík Martin.

Registrace fotografií do 3D modelu terénu

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana docenta Martina Čadíka. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....

Jaromír Deák
22. května 2017

Poděkování

Rád bych poděkoval panu docentovi Martinu Čadíkovi za pomoc a odborné vedení při řešení tohoto projektu. Dále patří dík panu profesorovi Janu Kybicovi za odbornou konzultaci. Martinu Šimonovskému a Miguelovi Amávelu Pinheirovi děkuji za podporu a poskytnutí jejich zdrojových kódů.

Obsah

1	Úvod	6
2	Teorie	7
2.1	Definice úlohy	7
2.2	Podobná řešení	7
2.3	Graf	9
2.4	Vystavění grafů	9
2.4.1	Vrcholy ve vstupní fotografii	10
2.4.2	Vrcholy v modelu	11
2.4.3	Ohodnocení vrcholů - deskriptor	11
2.4.4	Vytvoření a ohodnocení hran	11
2.5	Vyhledání korespondence grafu	12
2.5.1	Definice korespondence grafů	12
2.5.2	Obecný postup	12
2.5.3	Přehled existujících metod	14
3	Návrh řešení	18
3.1	Návrh obecného řešení	18
3.2	Detekce význačných bodů	19
3.2.1	Uniformní rozložení význačných bodů na mřížce	19
3.2.2	Náhodné rozmístění význačných bodů	20
3.2.3	Detektor SIFT	20
3.2.4	Detektor KAZE	22
3.2.5	Detektor rohů	22
3.2.6	Detekce rohů pomocí operátoru Compass	22
3.2.7	Lokální extrémní linie horizontu	23
3.3	Deskriptor význačného bodu	23
3.3.1	Shape context	24
3.3.2	Locatev2	25
3.4	Detekce hran grafu	25
3.4.1	Spojení vrcholů hranami	25
3.4.2	Detekce hran v obraze	26
3.5	Deskriptor hran	26
3.6	Vyhledání korespondence grafů	27
3.6.1	Vliv podobností vrcholů a hran	28
3.6.2	Výběr algoritmu	29
3.6.3	Řešení chybných korespondencí	31
3.7	Výpočet transformace	32

3.8	Zarovnání fotografie do panoramatu	33
3.9	Navržené konkrétní postupy řešení	34
3.9.1	Uniformní význačné body, Locatev2, SMAC	34
3.9.2	Náhodné význačné body, Locatev2, SMAC	34
3.9.3	KAZE, Locatev2, SMAC	34
3.9.4	Význačné body v lokálních extrémech, Locatev2, SMAC	35
3.9.5	KAZE, Locatev2, Dual decomposition	35
3.9.6	Uniformní význačné body, Shape context, SMAC	35
3.9.7	Rohy pomocí operátoru Compass, DGM	35
3.9.8	Rohy pomocí operátoru Compass, GMMC	35
3.9.9	Geometrie hran, GMMC	36
4	Realizace	37
4.1	Použité nástroje	37
4.1.1	Práce s grafy	37
4.1.2	Dual decomposition	38
4.1.3	Graph matching using Monte Carlo tree search	38
4.1.4	Scale invariant feature transform	38
4.1.5	Pokročilá detekce rohů operátorem Compass	38
4.1.6	Deskriptor Shape context	39
4.1.7	Deskriptor Locatev2	39
4.2	Implementace navržených řešení	39
4.3	Řešené podproblémy	40
4.3.1	Převod na odstíny šedi	40
4.3.2	Extrakce, oprava a segmentace hran	40
5	Experimenty	41
5.1	Porovnání algoritmů pro vyhledání korespondence grafů	41
5.2	Využití vrcholů hor jako vrcholů grafu	43
5.3	Elastická registrace	43
5.4	Rohy pomocí operátoru Compass, SMAC	44
5.5	KAZE, Locatev2, SMAC	45
5.6	Uniformní význačné body, Locatev2, SMAC	46
5.7	Náhodné význačné body, Locatev2, SMAC	47
5.8	Význačné body v lokálních extrémech, Locatev2, SMAC	47
5.9	KAZE, Locatev2, Dual decomposition	48
5.10	Uniformní význačné body, Shape context, SMAC	48
5.11	Rohy pomocí operátoru Compass, GMMC	50
5.12	Rohy pomocí operátoru Compass, DGM	50
5.13	Edge geometry GMMC	51
5.14	Porovnání metod	52
6	Diskuse	56
6.1	Aktuální stav řešení	56
6.2	Klíčové problémy	56
6.2.1	Detekce význačných bodů	57
6.2.2	Algoritmus vyhledání korespondence grafů	57
6.3	Návrh dalšího vývoje	58

7 Závěr	59
Literatura	61

Seznam obrázků

2.1	Popis detekovaného rohu: (x, y) pozice, β úhel otevření rohu, σ velikost, θ orientace[34]	10
2.2	Příklad popisu tvaru pomocí deskriptoru Shape context[40]	11
2.3	Korespondence grafů: náhled porovnávaných grafů, K_P matice podobnosti vrcholů, K_q matice podobnosti hran, K globální matice podobnosti[41]	13
2.4	Spojité řešení korespondence dvou grafů	13
2.5	Diskrétní řešení korespondence dvou grafů	14
2.6	Princip hran a superhran algoritmu Graph matching using Monte Carlo tree search[31]	16
3.1	Diagram navrženého obecného řešení	19
3.2	Uniformně rozmístěné význačné body ve fotografii	20
3.3	Náhodně rozmístěné body ve fotografii	20
3.4	Význačné body detekované algoritmem SIFT na fotografii a jejím výřezu	21
3.5	Význačné body detekované algoritmem SIFT na umělém panorama a fotografii	21
3.6	Význačné body detekované jako rohy	22
3.7	Význačné body detekované pokročilým detektorem rohů	23
3.8	Význačné body detekované jako lokální extrémy	23
3.9	Rozdělení okolí význačného bodu na sektory	24
3.10	Porovnání způsobů rozmístění hran na deformovaném grafu	25
3.11	Závislost výsledku korespondence na rozložení hodnot podobnosti hran	27
3.12	Histogram rozložení hodnot podobností vrcholů, Histogram rozložení hodnot podobností hran	28
3.13	Výsledek korespondence při zanedbání podobnosti vrcholů a hran	28
3.14	Výsledek korespondence při využití podobnosti vrcholů	29
3.15	Výsledek korespondence při využití podobnosti hran	29
3.16	Výsledek korespondence při využití podobnosti vrcholů i hran	29
3.17	SMAC, Maďarský algoritmus na fotografii a jejím výřezu	30
3.18	Diagram navrženého řešení při použití algoritmu Graph matching using Monte Carlo tree search	32
3.19	Porovnání význačných bodů ve vstupních obrazech	32
3.20	SMAC, Maďarský algoritmus na fotografii a jejím výřezu	33
3.21	Odstranění přiřazení s nižší vahou než práh 0.6	33
3.22	Znázornění výpočtu translace příslušící korespondujícím vrcholům	34
5.1	Algoritmy pro vyhledání korespondence grafů	42
5.2	Ručně anotovaná vstupní data	43
5.3	Výsledek registrace pomocí detekce vrcholů hor	43
5.4	Výsledek elastické registrace	44

5.5	Vypočtená korespondence grafů při použití pokročilé detekce rohů a algoritmu SMAC	44
5.6	Úspěšné vyhledání korespondence grafů při využití neuronové sítě Locatev2 a algoritmu SMAC	45
5.7	Úspěšné vyhledání korespondence grafů při využití neuronové sítě Locatev2, podobnosti hran a algoritmu SMAC	45
5.8	Detail rozdílných podgrafů	46
5.9	Výsledek experimentu: Uniformní význačné body, Locatev2, SMAC	46
5.10	Výsledek experimentu: Náhodné význačné body, Locatev2, SMAC, pouze podobnost vrcholů	47
5.11	Lokální extrémy linie horizontu, Locatev2, SMAC	47
5.12	Význačné body v lokálních extrémech, Locatev2, SMAC	48
5.13	Nalezená korespondence algoritmem Dual decomposition	48
5.14	Korespondence vypočtená algoritmem Dual decomposition	49
5.15	Porovnání význačných bodů pomocí deskriptoru Shape context	49
5.16	Korespondence nalezená kombinací Compass GMMC	50
5.17	Korespondence nalezená kombinací Compass DGM	51
5.18	Korespondence nalezená metodou Edge geometry DGM	52
5.19	Porovnání odchylek od správného řešení	53
5.20	Porovnání celkového času výpočtu	54
5.21	Porovnání průměrných časů jednotlivých kroků výpočtu	54

Kapitola 1

Úvod

Smyslem této zprávy je dokumentovat řešení diplomové práce, která je součástí magisterského studia na Fakultě informačních technologií Vysokého učení technického v Brně. Předmětem tohoto projektu je úloha registrace fotografií do 3D modelu terénu. Konkrétními cíli jsou seznámení se s existujícími řešeními, návrh a aplikace jejich vylepšení.

Motivací tohoto snažení je fakt, že oblasti robotiky, autonomních systémů a rozšířené reality se aktuálně velmi silně rozvíjejí a jejich produkty jsou lidskou společností velmi žádané. Jedním z úzkých hrdel brzdících postup v těchto odvětvích je počítačové vidění, které se potýká s problémy přesnosti, robustnosti a výpočetní náročnosti. Důležitým podproblémem počítačového vidění je právě tato úloha automatické registrace fotografií do 3D modelu terénu. Uspokojivé řešení této úlohy může mít pozitivní dopad například na vylepšení navigace autonomních dopravních prostředků či řízení robotů. V literatuře se lze také setkat s použitím registrace fotografie do modelu terénu za účelem ověření pravosti fotografie či tvrzení spojených s objekty na fotografii.

Druhá kapitola tohoto dokumentu prezentuje přehled již existujících řešení registrace fotografií do 3D modelu terénu a souvisejících úloh. Vzhledem k záměru využít pro registraci grafových algoritmů, tato kapitola také pojednává o možnostech zpracování vstupních dat s cílem vystavění grafů nad těmito vstupními daty. V neposlední řadě také přibližuje obecnou teorii a existující možnosti vyhledání korespondence grafů. Následující kapitola již představuje konkrétní kroky a postupy, které byly navrženy jako možnosti k dosažení specifikovaného cíle. Na kapitolu zabývající se návrhem navazuje kapitola, která prezentuje použité nástroje a důležité implementační detaily řešení. Experimenty provedené k ověření funkčnosti realizovaných částí či vyzkoušení možností plánovaných kroků jsou včetně jejich výsledků představeny v kapitole páté. Před samotným závěrem je diskutován výsledný stav řešení, dosažené výsledky a doporučení pro další rozvoj.

Tato diplomová práce přímo navazuje na semestrální projekt, který této diplomové práci předcházel. Diplomová práce přejímá ze semestrálního projektu přehled existujících metod pro automatickou lokalizaci obrázků v horském terénu, teoretický základ a možné postupy vhodné pro řešení úlohy. Tyto informace lze nalézt v kapitole 2. Dále je využito návrhu obecného řešení popsaného v kapitole 3 označené jako Návrh řešení. Spolu s obecným návrhem byly do diplomové práce zapracovány předem provedené experimenty zaměřené na podporu návrhu. Ty jsou prezentovány v úvodních sekcích kapitoly Experimenty.

Kapitola 2

Teorie

Tato kapitola obsahující teoretické poznatky je základním kamenem pro úspěšnou cestu k cíli této práce. Jak má daný cíl vypadat je obecně definováno v popisu úlohy na samém začátku této kapitoly. Po definici úlohy kapitola nabídne pohled na existující více či méně úspěšná řešení. Následující podkapitoly potom prezentují teoretický základ nutný k porozumění dané problematice a přehled možností řešení, které již byly publikovány v literatuře.

2.1 Definice úlohy

Úloha registrace fotografie do 3D modelu terénu je definována následovně. Vstupy úlohy jsou fotografie, zeměpisná poloha kamery při pořízení fotografie a 3D model terénu v okolí místa pořízení fotografie. Fotografií rozumíme standardní fotografický snímek v elektronické podobě v barevném či šedotónovém formátu. Zeměpisnou polohou může být jakýkoliv popis definující zeměpisné a výškové souřadnice pořízení fotografie, který je použitelný pro specifikaci polohy v 3D modelu terénu. 3D modelem terénu se rozumí elektronický model popisující minimálně výškový průběh zemského povrchu v okolí místa pořízení fotografie.

Požadovaným výstupem úlohy je určení orientace kamery. Součástí je vizualizace panoramatu 3D modelu s vloženou fotografií zaregistrovanou do patřičné pozice.

Daná úloha je navázáním na předchozí řešení pomocí korelace kontur nalezených ve fotografii a snímku vyrenderovaném z 3D modelu[4]. Na rozdíl od zmíněného předchozího řešení je k registraci fotografie využito grafových algoritmů.

Definovanou úlohu lze stručně rozdělit na následující očekávané podúlohy, které je třeba vyřešit. Těmito podúlohami jsou:

- Detekce vrcholů grafu nad fotografií
- Detekce vrcholů grafu nad 3D modelem
- Vystavění obou grafů
- Nalezení korespondence vstupních grafů
- Vypočtení orientace a vizualizace fotografie v renderovaném panoramatu

2.2 Podobná řešení

Jak již bylo zmíněno, diplomová práce je inspirována řešením Automatic photo-to-terrain alignment for the annotation of mountain pictures[4], která řeší stejnou úlohu registrace

fotografií do 3D modelu terénu, nicméně pro registraci využívá korelace siluet terénu nalezených ve fotografii se siluetami existujícími v panoramatu vyrenderovaném z 3D modelu. Siluety použité ke korelaci jsou získané jako vektorizované hrany získané hranovým detektorem, ze kterých jsou vyfiltrovány hrany, které nejsou součástí siluety terénu. Výsledkem této práce je robustní algoritmus automatické registrace fotografie dosahující velké přesnosti.

O rok mladší článek *Augmented reality: Fusing the real and synthetic worlds*[27] prezentuje možnost využití korespondence fotografie s terénem v rozšířené realitě. Jako příklad uvádí možnost označit ve fotografii význačné geografické body. Jako možný postup prezentuje právě zmíněný princip[4].

Podobnou úlohou určení směru pořízení fotografie horského terénu a následného geografického označení se zabývá magisterská práce *Mountain Peak Detection in Online Social Media*[18]. Spojení se sociálními sítěmi je zamýšleno jako možnost získání dalších znalostí díky zpracování fotografií vložených na sociální sítě jejich uživateli. Představená metoda pro vyhledání korespondence mezi terénem na fotografii a modelem terénu silně vychází z již zmíněné práce *Automatic photo-to-terrain alignment for the annotation of mountain pictures*[4].

Na právě zmíněnou práci[18] autor se svými kolegy navazuje metodou pro automatické označení horských vrcholů na fotografiích, u kterých je znám zeměpisný popis místa pořízení, získaných ze sociálních sítí[19]. Princip dané metody je opět založen na [4], tj. korelace v tomto případě linií horizontu nalezených na fotografii a výškovém modelu. Následně je provedeno zpřesnění nalezené registrace a označeny známé vrcholy hor. Autor uvádí, že jde o automatickou metodu, která správně označila známé vrcholy s úspěšností 75% testovaného vzorku získaného na sociálních sítích.

V kontextu forenzního přezkoumání zda jsou informace o fotografii pravdivé řeší úlohu také článek *Geo-positional Image Forensics through Scene-Terrain Registration*[12]. V tomto případě bylo opět využito již představené korelace siluet terénu a modelu[4], ale řešení je navíc doplněné o vyhledání korespondence hloubkových map vypočtených z fotografie a modelu. Výsledkem je tedy fotografie registrovaná do 3D modelu, přičemž každý její pixel má určenou geografickou pozici. Autor výsledek své metody prezentuje tvrzením, že fotografie horolezce je ve skutečnosti pořízena z jiného místa, než uvedl sám horolezec. Dále také ukazuje, příklad jak lze prezentovanou metodou odhalit dodatečné úpravy fotografie. Konkrétně byla nalezena neshoda pozice a velikosti měsíce pro dané místo a čas pořízení fotografie.

Georges Baatz a ostatní[3] publikovali metodu, která je schopna vyhledat místo a orientaci fotografie i bez předchozí znalosti pozice pořízení fotografie. Metoda je testována na území o rozloze 40 000 km². Metoda nejdříve provede segmentaci vstupní fotografie tak, aby oddělila terén od oblohy. Tímto způsobem získá linii horizontu, jejíž tvar následně zakóduje. Poté danou linii horizontu vyhledá ve výškové mapě prohledávaného území.

Úlohou nalezení pozice a orientace kamery dle snímku bez předchozí znalosti místa pořízení se zabývá také starší práce *Estimating Camera Position and Orientation from Geographical Map and Mountain Image*[28]. Na této metodě je zajímavý způsob, jakým metoda popíše data v obraze a následně použije k vyhledání v databázi vytvořené z digitální výškové mapy. Základem je nalezení linie horizontu pomocí neuronové sítě. Na této linii jsou poté nalezeny vrcholy hor pomocí podobnosti s Gaussovou křivkou[23].

Naopak novějším článkem prezentujícím novou metodu pro vyhledání orientace i místa pořízení fotografie je *Camera geolocation from mountain images*[11]. Tato metoda k vyhledání korespondence využívá siluety terénu doplněné o další význačné body jako například vrcholy hor.

Jak lze vidět, v literatuře je možné najít mnoho předchozích prací s cílem obdobným cíli této práce. V následujícím textu je také doklad mnoha možností vyhledání korespondence grafů například pro úlohu sestavení panoramatu s několika fotografií. Obdobné práce, které by byly kombinací obou, tedy použily korespondence grafů k registraci fotografie do 3D modelu terénu, v literatuře nalezeny nebyly.

2.3 Graf

Graf G je uspořádaná trojice $G = (V(G), E(G), \psi_G)$ složená z neprázdné množiny vrcholů $V(G)$, množiny hran $E(G)$, která je disjunktí od množiny vrcholů $V(G)$, a incidentní funkce $\psi(G)$, která každé hraně grafu G přiřazuje neuspořádanou dvojici vrcholů grafu G . Pokud e je hrana a u, v jsou vrcholy splňující vztah $\psi(e) = uv$, potom o hraně e říkáme, že hrana e spojuje vrcholy u a v . Vrcholy u, v jsou nazývány koncovými vrcholy hrany e [37].

V případě, že incidentní funkce $\psi(G)$ přiřazuje každé hraně e grafu G uspořádanou dvojici vrcholů (u, v) , hovoříme o orientovaném grafu. Prvý vrchol, u , nazýváme počátečním vrcholem hrany. O druhém vrcholu, v , hovoříme jako o koncovém vrcholu hrany. V opačném případě, kdy incidentní funkce $\psi(G)$ přiřazuje každé hraně e grafu G neuspořádanou dvojici vrcholů (u, v) , jde o graf neorientovaný [16].

Pro tuto práci jsou důležité některé speciální typy grafů. Těmi jsou zejména podgraf a bipartitní graf. Podgraf G' je takový graf, který vznikne z grafu G vynecháním nějakých (nebo žádných) vrcholů a hran. Nutnou podmínkou je, aby vzniklý podgraf byl sám také grafem, tedy každá hrana měla oba koncové vrcholy [16].

Bipartitní graf je takový graf G , jehož množina vrcholů $V(G)$ je disjunktím sjednocením dvou množin S, T a platí $E(G) = W_G(S)$. Tedy každá hrana má jeden koncový vrchol v S a druhý v T . Množiny S, T nazýváme stranami bipartitního grafu. V případě úplného bipartitního grafu je každá dvojice vrcholů $s \in S, t \in T$ spojena právě jednou hranou [16].

Terminologie v grafové teorii není v literatuře vždy jednotná. Pojmenování *vrchol* vychází z anglického výrazu *vertex*. V češtině lze kromě označení *vrchol* užívat také označení *uzel*, *prvek*, *styčník* či *bod*. Obdobně *hrana*, anglicky *edge*, může být přeložena jako *vazba* či *šipka* [16].

2.4 Vystavění grafů

Vzhledem ke zvolenému postupu využití grafových algoritmů pro vyhledání korespondence modelu a fotografie, jako první krok je třeba dané grafy nad modelem a fotografií nejdříve vystavět. Samotné vystavění grafů je úloha, která vyžaduje vyřešení několika dalších podúloh.

První podúlohou je nalezení význačných bodů či jiných příznaků, které budou následně reprezentovat vrcholy grafu. Druhou podúlohou je získání hodnot vrcholů grafů, což v tomto případě pravděpodobně znamená užití nějaké charakteristiky význačného bodu. Vzhledem k faktu, že vstupy úlohy (tj. fotografie a 3D model terénu) jsou s největší pravděpodobností reprezentovány různými datovými typy, bude třeba první dvě podúlohy řešit pro každý vstup zvlášť s ohledem na vlastnosti daných dat.

Třetí podúlohou je spojení vytvořených vrcholů hranami do grafu společně s určením způsobu ohodnocení hran.


2.4.1 Vrcholy ve vstupní fotografii

Jak je možné si všimnout v podkapitole 2.2, většina představených existujících řešení ve svém jádru používá korelaci linií nalezených ve vstupních datech. Tudíž zde není prezentováno mnoho způsobů, jak zvolit význačný bod, který by mohl představovat vrchol požadovaného grafu. Přesto autoři uvádí i možnosti využití popisu lokálních charakteristik. Zjištění lokálních charakteristik považuje za výchozí bod řešení problému rozpoznání místa z fotografie terénu i Georges Baatz ve své disertační práci [2].

Jednou z velmi významných a slavných metod pro detekci a popis lokálních charakteristik je SIFT detektor[26]. Tento je hojně používaný například pro sestavení panoramatu z několika souvisejících fotografií[10, 9, 22]. Využití SIFT detektoru pro detekci význačných bodů za účelem vyhledání korespondence mezi 3D modelem a historickou malbou uvažuje článek[32]. Stejně tak jako pravděpodobně v našem případě, autor využití SIFT detektoru zahrne z důvodu různých datových typů 3D modelu a historické malby.

Dalším detektorem významným pro vyhledání korespondence dvou obrázků je detektor rohů, jež byl realizován v mnoha podobách. Známé detektory rohů jsou Harrisův detektor a Shi and Tomasi detektor, jež jsou implementovány a popsány v dokumentaci knihovny OpenCV[30]. Souvisejícím příkladem může být například projekt Local feature matching[21].

Pro účely řešené úlohy by bylo vhodnější využít jako vrchol grafu bod nesoucí i sémantickou informaci, kterou bude možné nalézt v obou případech vstupních dat. Na tuto myšlenku je možné opakovaně narazit i v literatuře. Často je o možnost použití vrcholů hor jako přirozených lokálních příznaků pro následné porovnání. Z tohoto pohledu by mohl být užitečný zmíněný detektor rohů, který ovšem dovolí více specifikovat požadovaný roh. Pokročilou detekcí rohů se zabývají Mark A. Ruzon a Carlo Tomasi[34]. Jejich detekce využívá informaci ze všech tří barevných složek, tak aby nedocházelo ke ztrátě informace převodem do odstínu šedi. Zároveň výsledek jejich metody poskytuje informace o pozici, orientaci, velikosti i úhlu detekovaného rohu. Informace o detekovaném rohu je na obrázku 2.1.

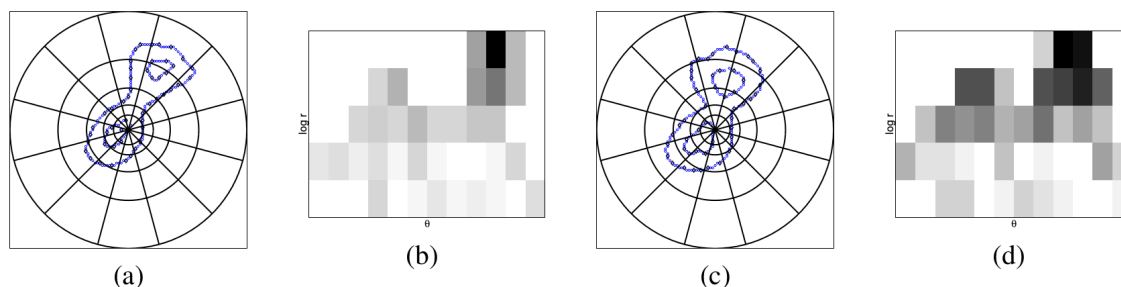


Obrázek 2.1: Popis detekovaného rohu: (x, y) pozice, β úhel otevření rohu, σ velikost, θ orientace[34]

Na problém vyhledání vrcholů hor se zaměřil také Prospero C. Naval[28], který využívá podobnosti vrcholu hory s Gaussovou křivkou. Tuto podobnost s Gaussovou křivkou se autor snaží nalézt na vyextrahované linii horizontu a vybrat tak místa podobného tvaru jako vrchol hory.

Specifikací a porovnáním tvarů v obraze se zabývá také metoda Shape context[6, 5, 7, 8]. Zjednodušeně, metoda Shape context rozdělí kruhové okolí zkoumaného na sektory, ve kterých spočítá všechny jejich náležící body. Tento zjištěný stav okolí je popsán histogramem, který lze využít k porovnání. Příklad popisu tvaru pomocí Shape context ilustruje

obrázek 2.2. Shape context je využit například pro zpřesnění výsledku registrace historické malby na 3D model v práci [32].



Obrázek 2.2: Příklad popisu tvaru pomocí deskriptoru Shape context [40]

2.4.2 Vrcholy v modelu

Pro vystavění grafu nad modelem lze využít přímo data získaná z modelu nebo jednodušeji použít obraz panoramatu vypočteného z 3D modelu, který je následně zpracován pomocí metod pro práci s obrazem obdobně jako vstupní fotografie.

2.4.3 Ohodnocení vrcholů - deskriptor

Ne bezpodmínečně nutnou, ale v tomto kontextu užitečnou a očekávanou informací o každém vrcholu je souřadnice jeho umístění v rovině, případně prostoru. Společně s informací o umístění může být každý vrchol ohodnocen zvolenými atributy. Typ atributů vrcholu grafu je možné libovolně definovat. Může to být libovolné číslo, vektor či matice. Příkladem zmíněným i v [41] je použití deskriptoru SIFT jako ohodnocení vrcholu. Stejně tak to může například třetí souřadnice v případě použití grafu ve tří-dimenzionálním prostoru.

2.4.4 Vytvoření a ohodnocení hran

Pokud byly vygenerovány vrcholy obou grafů, je třeba definovat sousedství a vytvořit tak hrany grafu. Tyto hrany jsou důležité pro reprezentaci topologie a geometrických vlastností daného grafu.

Každá z hran je určena právě dvěma vrcholy, které hrana spojuje. Díky znalosti těchto vrcholů můžeme určit pozici hrany, délku hrany a azimut hrany ke svislé či vodorovné ose. Dle typu grafu může být hrana orientovaná či neorientovaná.

Vytvoření hran grafu má hned několik řešení. První možností je vzájemným spojením všech vrcholů vytvořit úplný graf. Výhodou úplného grafu je zachování všech vzájemných geometrických vztahů mezi vrcholy, což by mělo přispět ke zpřesnění výsledného řešení. Značnou nevýhodou je velký počet hran, který má výrazný efekt na zhoršení výpočetní náročnosti.

Dalšími možnostmi jak vytvořit hrany grafu je spojit daný bod s k nejbližšími sousedy nebo se všemi sousedy ležícími v okolí do definované vzdálenosti ϵ . Tyto možnosti značně uspoří počet operací algoritmu vyhledávajícího korespondenci obou grafů.

Speciální možností je využití Delaunayho triangulace. Tato metoda spojí vrcholy grafu takovými hranami tak, že všechny hrany tvoří trojúhelníky, pro které platí, že žádný vrchol

neleží ve vnitřním prostoru žádného z trojúhelníků. Zároveň metoda zajistí takové vytvoření trojúhelníků, jež mají nejmenší možnou velikost všech úhlů.

2.5 Vyhledání korespondence grafu

Po získání grafů vystavěných nad fotografií a 3D modelem terénu je třeba vyhledat jejich korespondenci. Konkrétně hledáme graf vstupní fotografie G_f jako podgraf v grafu modelu terénu G_m . Zde by se nabízelo specifikovat úlohu jako hledání takového podgrafu náležitěmu grafu modelu G_m , který je isomorfní grafu fotografie G_f . Takto úlohu popsat nelze, protože takový isomorfní podgraf nemusí a ve většině případů nebude existovat. Důvodem jsou vrcholy a hrany v obou grafech, které nemusí mít svůj protějšek. Úlohu je tedy nutné specifikovat obecněji, tedy jako vyhledání maximálního společného podgrafu. Jde o maximální isomorfní graf, který lze nalézt jako podgraf v obou vstupních grafech.

Samotné nalezení takové korespondence je potom úlohou párování v úplném bipartitním grafu $K_{n,m}$. Konkrétně hledáme nejlevnější maximální párování v úplném bipartitním grafu G , jehož strany X a Y nemají stejný počet vrcholů, tj. $|X| \neq |Y|$. Množina vrcholů X je tvořena vrcholy vstupního grafu G_f . Množina vrcholů Y je tvořena vrcholy vstupního grafu G_m . Hrany grafu G jsou všechna přípustná přiřazení vrcholů z množiny X na vrcholy z množiny Y , tedy vrcholy grafu G_f na vrcholy grafu G_m .

2.5.1 Definice korespondence grafů

Zhou, F.[41] definuje korespondenci grafů následujícím způsobem tak, aby vyhovovala specifikované úloze a zároveň mohla být vstupem pro algoritmy sloužící pro hledání požadované korespondence. Graf s n vrcholy a m hranami, je čtveřice $\mathcal{G} = \{P, Q, G, H\}$, kde P je vektor ohodnocení vrcholů, Q je vektor ohodnocení hran, $G, H \in \{0, 1\}^{n \times n}$ jsou dvě matice z nichž jedna udává vrcholy, kde hrany začínají a druhá, kde hrany končí. Do algoritmu hledání korespondence grafů vstupují dva tyto grafy $\mathcal{G}_1 = \{P_1, Q_1, G_1, H_1\}$ a $\mathcal{G}_2 = \{P_2, Q_2, G_2, H_2\}$. Výsledkem operace vyhledání korespondence grafů je potom matice $X \in \{0, 1\}^{n_1 \times n_2}$, která určuje korespondenci vrcholů mezi oběma grafy.

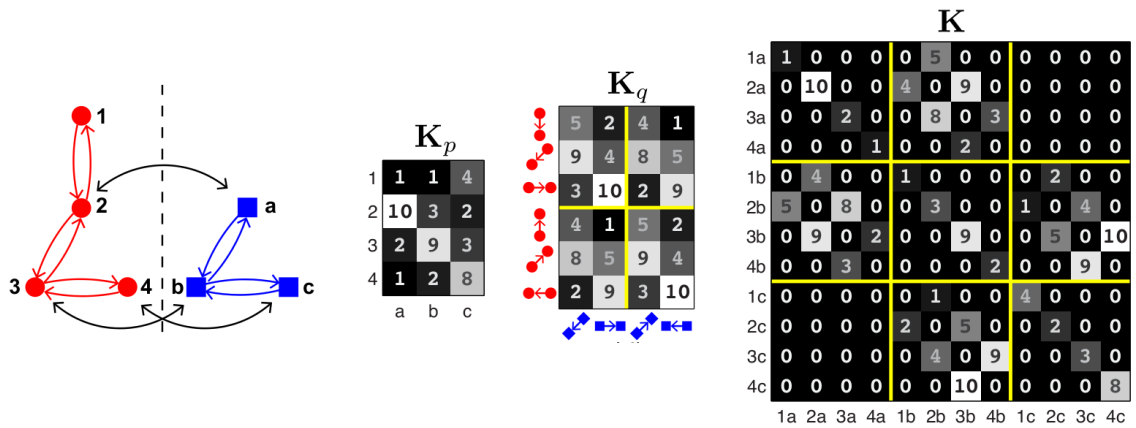
Algoritmus vyhledávající korespondenci mezi vstupními grafy \mathcal{G}_1 a \mathcal{G}_2 využívá k porovnání vrcholů a hran matici $K_p \in \mathbb{R}^{n_1 \times n_2}$ udávající podobnost vrcholů obou grafů a matici $K_q \in \mathbb{R}^{m_1 \times m_2}$ udávající podobnost hran obou grafů. Hodnoty v této matici jsou definovány jakkoliv je třeba dle dané úlohy. Z uvedených matic K_p a K_q lze vypočítat globální matici podobností $K \in \mathbb{R}^{n_1 n_2 \times n_1 n_2}$, nad kterou pracují některé algoritmy pro korespondenci grafů. Ilustrováno na obrázku 2.3.

Cílem vyhledání korespondence mezi grafy nalezení matice X , která určuje korespondenci vrcholů obou grafů. Tato matice může mít spojitou podobu, kdy každý prvek matice určuje míru podobnosti daných dvou vrcholů. Příklad spojitě matice podobnosti X_C je ilustrován obrázkem 2.4.

Jako výsledek však často požadujeme matici X , která poskytuje diskrétní řešení korespondence dvou grafů. Tato je ilustrována obrázkem 2.5.

2.5.2 Obecný postup


Postup pro vyhledání korespondence dvou grafů lze obecně rozdělit do několika základních kroků. Přesný postup je však vždy závislý na konkrétní použité metodě, takže některé kroky se mohou lišit či chybět úplně.



Obrázek 2.3: Korespondence grafů: náhled porovnávaných grafů, K_p matice podobnosti vrcholů, K_q matice podobnosti hran, K globální matice podobnosti[41]

$$X_C = \begin{bmatrix} 0,005 & 0,061 & 0,008 & 0,619 \\ 0,039 & 0,017 & 0,093 & 0,023 \\ 0,003 & 0,005 & 0,001 & 0,047 \\ 0,773 & 0,001 & 0,016 & 0,001 \end{bmatrix}$$

(a) Matice



(b) Vizualizace

Obrázek 2.4: Spojité řešení korespondence dvou grafů


Předpokladem je existence dvou grafů \mathcal{G}_1 a \mathcal{G}_2 , mezi nimiž požadujeme nalezení korespondenční matice X . Před započtením výpočtu je třeba připravit vstupy pro zvolený algoritmus. Těmi jsou matice podobnosti vrcholů a hran (K_p , K_q). Pokud to daný algoritmus vyžaduje, je třeba pomocí těchto matic vypočítat globální matici podobnosti K . Krokem následujícím po přípravě vstupů je inicializace matice korespondence X_{init} . Po inicializaci následuje krok, který nad inicializovanou maticí korespondence X_{init} vypočte spojité řešení X_C . Třetí krok slouží k diskretizaci matice X_C obsahují spojité řešení pro získání diskretního řešení v podobě matice X .

Příprava vstupních matic Tato fáze vypočte matice podobnosti vrcholů a hran (K_p , K_q) dle předem zvolené specifikace či funkce. Vzhledem k tomu, že tato funkce může uvažovat libovolné informace, její specifikace je obvykle na autorovi. Z těchto matic (K_p , K_q) je v některých případech spočítat globální matici podobnosti K .

Inicializace Inicializace znamená naplnění budoucí výsledné matice korespondence vrcholů X_{init} počátečními hodnotami. Ty mohou být uniformní s předdefinovanou konstantou nebo vypočteny s použitím pokročilejší metody[41]. Takovými metodami mohou být například Spectral matching[24] či Spectral Matching with affine constraint[15].

$$X = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

(a) Matice



(b) Vizualizace

Obrázek 2.5: Diskrétní řešení korespondence dvou grafů

Spojité řešení Volitelným krokem mohou být například metody Graduate assignment[20] či Re-weighted random walk matching[13], jež jsou schopny vypočítat výslednou matici X_C specifikující spojité řešení. Pokud je tento krok vynechán, matice $X_C = X_{init}$.

Diskretizace Nalezení diskrétního řešení X v matici spojitěho řešení X_C je možné běžným Madarským algoritmem[16]. Kromě něj lze také použít pokročilejší Integer fixed point algoritmus[25].

2.5.3 Přehled existujících metod

Conte, D. v dokumentu vydaném v roce 2004[14], který je přehledem tehdejších metod pro vyhledání korespondencí grafů, dělí metody pro registraci grafů na exaktní metody a metody aproximující přesné řešení. Exaktní metoda nalezne vždy nejlepší řešení úlohy, za zpravidla velkou cenu výpočetní náročnosti. Aproximující metoda nalezne některé z lokálních řešení, avšak za výrazně nižší cenu z hlediska výpočetní náročnosti[14].

Autor také definuje několik způsobů jak uvažovat úlohu exaktní registrace grafů. Prvním způsobem je vyhledání isomorfismu grafů, který zachovává všechny existující hrany a je bijektivním zobrazením. Volnějši úlohou exaktní registrace je vyhledání isomorfismu podgrafu. Cílem této úlohy je vyhledání takového podgrafu, který bude isomorfní s vyhledávaným grafem. Dalšími možnostmi jsou vyhledání monomorfismu, případně homomorfismu daných dvou grafů. Jako význačný cíl úlohy autor zmiňuje vyhledání maximálního společného podgrafu¹. Maximální společný podgraf je maximální isomorfní graf, který lze nalézt jako podgraf v obou vstupních grafech. Kromě vyhledání isomorfismu grafů, kde to ještě nebylo prokázáno, jsou všechny úlohy NP-úplné[14].

Velké množství algoritmů pro hledání exaktního řešení je založena na prohledávání stavového prostoru reprezentovaného stromem[14]. Další algoritmy jsou založeny například na principu canonical labeling. Zjednodušeně, canonical labeling rozděljuje graf na podgrafy, které dle rozděljuje do skupin dle isomorfismu[38].

Vysoká výpočetní náročnost metod hledajících optimální řešení je jeden z důvodů pro užití rychlejších metod, které optimální řešení aproximují. Kromě efektivity výpočtu je důvodem pro užití aproximujících metod i fakt, že exaktní metody nefungují pro značnou část reálných dat, která jsou přirozeně zatížena šumem či jinak vzniklými chybami ve vstupních datech. V takovém případě je vhodné využít metodu, která řešení aproximuje i bez ohledu na přítomné nepřesnosti[14]. Tyto metody jsou tedy vhodné i pro širší okruh úloh například v oblasti zpracování obrazu.

¹maximum common subgraph (MCS)

Protože aproximující metody se ne vždy ukončí nalezením optimálního řešení, jejich činnost je často řízena měřením chyby řešení či jinou veličinou umožňující posouzení stavu výpočtu. Stejně jako exaktní metody, jedním z principů aproximačních metod je prohledávání stromu. Dalším způsobem je uchopení úlohy jako problému optimalizace. Příkladem jsou metody využívající princip relaxation labeling, který vrcholům grafů systematicky přiřazuje ohodnocení, pomocí kterého je nakonec určena korespondence vrcholů. Dalším přístupem k řešení pomocí optimalizace je princip Weighted graph matching (WGM). V tomto případě metoda porovnává podgrafy na základě vah hran. Omezením tohoto přístupu je, že vrcholy nemohou mít atributy a hrany mohou mít pouze váhu. Příklady mohou být Graduated assignment nebo Fuzzy graph matching vzniklý zjednodušením WGM.

Spektrální metody jsou založeny na pozorování, které zjišťuje, že vlastní hodnoty a vlastní vektory matice podobnosti jsou invariantní k permutaci vrcholů. Tedy dva grafy jsou izomorfní pokud jejich matice podobnosti mají stejné vlastní hodnoty a vlastní vektory.

Jako další možnosti řešení Conte, D.[14] zmiňuje dekompoziční metody, neuronové sítě, genetické algoritmy, metody založené na bipartite matching a local properties.

Factorized graph matching (FGM) Feng Zhou a Fernando De la Torre představili metodu Factorized graph matching[41]. V dalším textu je dále užívána také zkratka FGM. Ta pracuje s faktem, že globální matice podobnosti (affinity matrix) lze faktorizovat jako Kronecker product menších matic. Díky tomu stačí vytvořit matice podobnosti vrcholů a hran (K_p, K_q) a není třeba počítat globální matici podobnosti K . Matice korespondence je iniciována pseudonáhodnými čísly. Řešení je získáno pomocí path-following optimalizace. Tato metoda je implementována v podobě pro orientovaný i neorientovaný graf.

Modifikací metody Factorized graph matching autoři vytvořili metodu Deformable graph matching[42], která je robustní vůči globálním geometrickým transformacím.

Spectral matching (SM) M. Leordeanu a M. Hebert vytvořili metodu Spectral matching for quadratic assignment[24]. Jde o metodu, která využívá pozorování, že v místech silné korespondence půjde pravděpodobně nalézt další možné správné korespondence. Takto náhodným způsobem prohledává možný prostor řešení. Metoda je zaměřena na 2D a 3D rozpoznání objektů. Snaží se využít jak geometrické struktury grafu, tak i dalších atributů, které mohou být přiřazeny vrcholům a hranám grafu. Metoda sama o sobě řeší inicializační krok matice korespondence. Je tedy možné ji využít samostatně či jako inicializační metodu.

Spectral matching with affine constraints (SMAC) Metoda Spectral matching představená autory Timothee Cour, Praveen Srinivasan a Jianbo Shi[15] je velmi blízká představené metodě Spectral matching. Rozdílem je, že SMAC respektuje afinní omezení. Díky tomu by dle autorů měla poskytovat přesnější aproximaci než SM (autor dokládá provedenými experimenty) avšak se zachováním rychlosti a škálovatelnosti spektrálních metod. Stejně tak jako metodu SM je možné SMAC použít samostatně nebo jako inicializační metodu.


Graduate assignment (GA) Metoda Graduated assignment[20] byla prezentována v roce 1996. Ve své době šlo dle autorů o rychlo a přesnou metodu i v případě velkého velkého zašumění. Metoda pracuje nad uniformně inicializovanou maticí. Jejím výstupem je matice se spojeným řešením.

Re-weighted random walk matching (RRWM) Algoritmus aplikuje na problém vyhledání korespondence grafů princip náhodné procházky. Z důvodů respektování omezení z hlediska korespondence obou grafů metoda umožňuje skoky. Představena autory Minsu Cho, Jungmin Lee a Kyoung Mu Lee[13].

Graph matching using Monte Carlo tree search (GMMC) Z pohledu řešení úlohy registrace fotografií do syntetického panoramatu pomocí vyhledání korespondence grafů je metoda Graph matching using Monte Carlo tree search[31], která byla vytvořena za účelem zpracování obrazových dat, které přirozeně obsahují grafové struktury. Příkladem je hledání korespondence cévní struktury sítnice či linií v mapě. Klíčovými vlastnostmi této metody jsou její přirozené udržení spojitosti grafu a respektování globálního geometrického modelu, který zajišťuje geometrickou kompatibilitu vyhledaných korespondencí.

Metoda pracuje na principu prohledávání stavového prostoru, v tomto případě konkrétně postupném prohledávání vstupních grafů a postupné sestavení výsledné korespondence přidáváním jednotlivých korespondencí vyhovujících topologii grafů a globálnímu geometrickému modelu. V případě rozvinutí chybné sekvence je aplikován backtracking.

Pro efektivní porovnání grafů vystavěných nad obrazy nesourodých datových typů metoda nepoužívá ohodnocení vrcholů grafů, nýbrž porovnání geometrických vlastností hran spojujících vrcholy. Pro porovnání hran je použit přímo popis tvaru hrany. Tento popis má formu navazujících lineárních úseků nebo aproximací B-spline křivkami. Pro vyšší robustnost algoritmu vůči chybějícím vrcholům či hranám ve vstupních grafech algoritmus používá principu hran, superhran a virtuálních superhran. Hrana grafu reprezentuje existující hranu mezi existujícími vrcholy. Superhrana je uměle vytvořená hrana grafu, která spojí několik reálných hran a simuluje tak případ chybějícího vrcholu. Tento důležitý princip je ilustrován na obrázku 2.6, který byl přejat z publikace autora algoritmu. Zde V je množina vrcholů, E je množina hran a S je množina superhran. Třetím zmíněným typem hrany je virtuální super hrana, která spojuje původně oddělené komponenty grafu, což je nutné pro nalezení korespondence grafů o více komponentách procházením grafu po hranách.



Obrázek 2.6: Princip hran a superhran algoritmu Graph matching using Monte Carlo tree search[31]

Dual decomposition (DD) V roce 2013 byl publikován algoritmus Dual decomposition[36], který řeší úlohu vyhledání korespondence příznaků v obrazech jako optimalizační úlohu hledání maximálního ohraničení funkce energie. Pro výpočet používá podobnost příznaků,

geometrickou kompatibilitu korespondencí a prostorovou koherenci korespondujících příznaků. Jak uvádí sám autor, jde tedy o úlohu vyhledání korespondence grafů. Pro zachování geometrie korespondujících grafů metoda Dual decomposition neuvažuje globální geometrický model. Geometrická podobnost jednotlivých korespondencí je sledována pouze lokálně u sousedních korespondencí. Vstupem metody je iniciované spojitě řešení. Výstupem algoritmu je požadované diskrétní řešení korespondence.

Integer projected fixed point method (IPFP) Metoda prezentována článkem An integer projected fixed point method for graph matching and map inference[25]. Dle [41] tato metoda slouží k vylepšení jakéhokoliv nalezeného spojitě řešení.

Maďarský algoritmus Maďarský algoritmus je metoda, která slouží k nalezení nejlevnějšího párování v úplném bipartitním grafu, jehož hrany jsou ohodnoceny cenami[16]. Za předpokladu, že na řešený problém korespondence dvou grafů G_1, G_2 se díváme jako na problém nalezení optimálního párování vrcholů v úplném bipartitním grafu K , kdy vrcholy grafu G_1 jsou levou množinou vrcholů grafu K , vrcholy grafu G_2 jsou pravou množinou vrcholů grafu K a všechny přípustné korespondence vrcholů grafů G_1, G_2 tvoří hrany grafu K , můžeme Maďarský algoritmus použít pro nalezení optimálního párování mezi grafy G_1 a G_2 . Díky matici spojitěho řešení X_C , jsou známy potřebné váhy hran úplného bipartitního grafu K . Vyhledané optimálního párování je zároveň diskrétním řešením korespondence grafů G_1 a G_2 získaným ze spojitěho výsledku korespondence grafů G_1, G_2 .

Kapitola 3

Návrh řešení

Tato kapitola na základě předchozí kapitoly nesoucí teoretické informace o existujících možnostech detailně představí návrh několika způsobů, jakými řeší stanovenou úlohu právě tato práce. Nejdříve bude navržen obecný postup práce, který se sestává z několika důležitých kroků. Následně budou představeny metody uvažované pro jeden každý krok řešení. V závěru této kapitoly zabývající se návrhem budou představeny konkrétní postupy řešení úlohy tak, jak jsou implementovány.

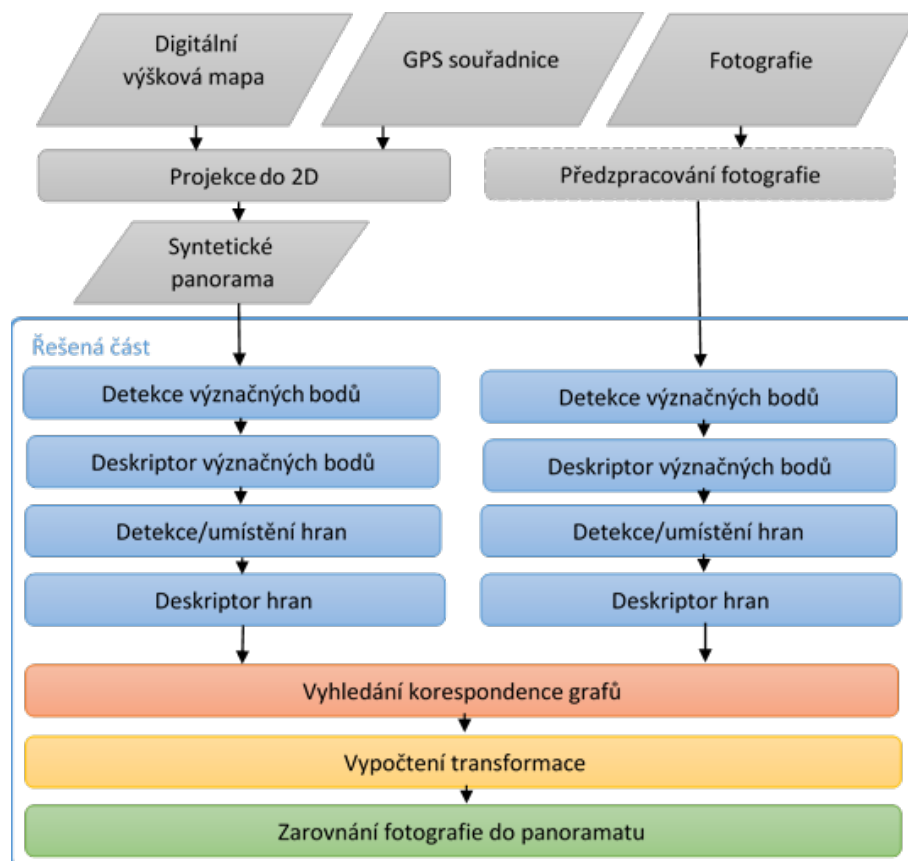
3.1 Návrh obecného řešení

Pro řešení úlohy registrace fotografie do 3D modelu horského terénu bude využito postupu, který pro zjednodušení úlohy využije dostupné projekce 3D modelu terénu (digitální výškové mapy) a převede tak řešenou úlohu do dvou rozměrů. Provedením této projekce modelu terénu na základě znalosti zeměpisné souřadnice se původní vstupy úlohy, kterými jsou digitální výšková mapa a zeměpisná souřadnice pořízení fotografie redukuje na syntetický obraz představující panorama viditelné z místa pořízení snímku a nezměněnou fotografii. Vzhledem k tomu, že data v požadovaném vstupním formátu jsou již k dispozici, jako vstupy úlohy uvažujeme pouze dvojici fotografie a příslušné panorama, jež mají předem vyřešené problémy jako je rozdílné rozlišení obou vstupních obrazů, a lze tedy zahájit hledání jejich korespondence.

Vhodným, ale ne bezpodmínečně nutným, krokem je předzpracování vstupní fotografie. Vhodným úkonem přípravy fotografie je segmentace oblohy a její odstranění z fotografie. Obloha je segmentem fotografie, který nenesou žádnou informaci vyhledatelnou v modelu, ale díky mrakům a jiným útvarům může způsobovat problémy algoritmům pro vyhledávání význačných bodů. Výhodou také je, že segmentací oblohy se automaticky odhalí linie horizontu (*skyline*), která může být použita v dalších krocích vyhledání korespondence.

Na základě připravených a předzpracovaných vstupních dat je zahájena detekce význačných bodů, které budou použity jako vrcholy budoucích grafů sloužících pro vyhledání korespondence. Z důvodu rozdílného typu vstupních obrazů probíhá detekce význačných bodů rozdílně pro fotografii a panorama, tak aby byla přizpůsobena konkrétnímu typu dat. Detekce význačných bodů je logicky následována získáním deskriptoru popisujícího detekované význačné body pro účely jejich následného porovnávání.

V okamžiku, kdy jsou známy význačné body představující vrcholy grafu, je třeba vrcholy propojit hranami a získat deskriptor hran. Jak detekce tak popis hran a bodů jsou základní



Obrázek 3.1: Diagram navrženého obecného řešení

kroky, které zpravidla vyžadují další operace provedené nad vstupními obrazy. Ty budou konkrétně představeny v rámci detailního popisu základních kroků řešení.

Nad vystavěnými grafy probíhá vyhledání korespondence obou grafů. Výstupem tohoto klíčového kroku je matice korespondence nesoucí informaci o korespondujících párech vrcholů. Na závěr je na základě matice korespondence vrcholů vypočtena transformace fotografie do syntetického panorama a provedení jeho jejich zarovnání.

Celý obecný návrh je ilustrován diagramem 3.1.

3.2 Detekce význačných bodů

Cílem detekce význačných bodů ve vstupním obrazu je získat geometrické souřadnice bodů, které je možné využít jako vrcholy požadovaného grafu. Detekce význačných bodů je možná postupy, které jsou představeny v následujících odstavcích.

3.2.1 Uniformní rozložení význačných bodů na mřížce

Nejjednodušším způsobem volby význačných bodů je jejich uniformní rozmístění na pravidelné mřížce. To může být provedeno s oběma vstupními obrazy shodně. Výhodou tohoto rozložení je pravidelné plné pokrytí vstupních obrazů. Nevýhodou je, že pro další postup je nutné mít silný deskriptor, který umožní porovnání takových význačných bodů. Jako deskriptor předpokládáme funkci, která charakterizuje význačný bod na základě jeho okolí.


Přesnost takového porovnání všech význačných bodů je ovlivněna měrou posunutí mřížek ve vstupních obrazech vůči sobě, což je parametr, který lze velmi obtížně ovlivnit. Příklad uniformního rozložení je na obrázku 3.2.



Obrázek 3.2: Uniformně rozmístěné význačné body ve fotografii

3.2.2 Náhodné rozmístění význačných bodů

Problém uniformně rozmístěných význačných bodů, kdy nepříznivé posunutí mřížek ovlivní přesnost porovnání všech význačných bodů, lze teoreticky eliminovat jejich stochastickým rozmístěním. V takovém případě budou některé z význačných bodů vůči svému protějšku posunuty naprosto nevhodně, ale některé body budou svému protějšku naopak velmi blízko. Z následného porovnání lze tedy vybrat takové korespondence, jež se vyznačují silnou pozitivní odezvou. Příklad náhodného rozmístění význačných bodů je ilustrován obrázkem 3.3.



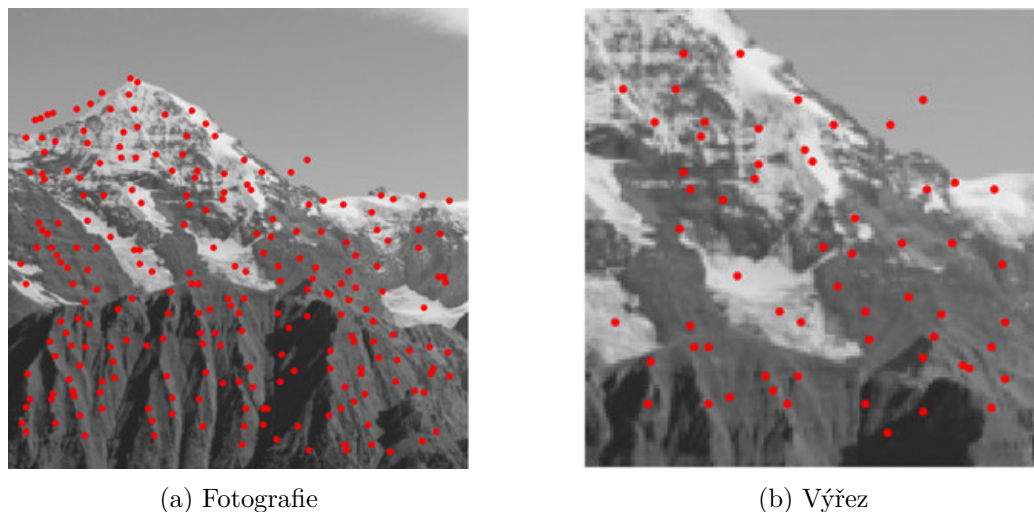
Obrázek 3.3: Náhodně rozmístěné body ve fotografii

3.2.3 Detektor SIFT

Jako jedna z možností detekce význačných bodů je využití Scale invariant feature transform detektoru představeného Lowem[26], jež je algoritmus pro detekci a deskripci význačných


bodů invariantní vůči změně měřítka a rotaci. Tento detektor je původně určen k detekci příznaků ve fotografiích, které obsahují stejné nebo alespoň velmi podobné oblasti. Lze tedy očekávat, že tento algoritmus nebude příliš dobře fungovat na vstupních datech jimiž jsou fotografie a syntetické panorama. Nicméně práce zvažuje i tuto možnost.

Z hlediska testování je tento detektor vhodným kandidátem pro zjištění funkcionality dalších kroků úlohy v případě použití vstupních dat shodného typu. To dokládá výsledek detekce, který je ilustrován na obrázcích 3.4. Na zmíněné ilustraci lze vidět, že význačné body detekované pomocí algoritmu SIFT si na vstupní fotografii i jejím výřezu odpovídají. Jsou tedy v tomto případě použitelné pro vystavení grafu a následné vyhledání korespondence.



Obrázek 3.4: Význačné body detekované algoritmem SIFT na fotografii a jejím výřezu

Cílem úlohy je však vystavení grafu nad fotografií a panoramatem, který je vygenerovaný z 3D modelu. V případě aplikování SIFT detektoru na umělé panorama se umístění detekovaných význačných bodů výrazně liší od umístění význačných bodů detekovaných na fotografii. Tento fakt je ilustrován na obrázcích 3.5b a 3.5a. Detektor SIFT tedy není vhodný pro vyhledání korespondence mezi fotografií a 3D modelem.



Obrázek 3.5: Význačné body detekované algoritmem SIFT na umělém panorama a fotografii


3.2.4 Detektor KAZE

Další možností detekce význačných bodů je detektor KAZE[1]. Tato možnost je inspirována předchozí prací Martina Šimonovského, který detektor KAZE využil pro obdobný účel ve svém software Locatev2¹.

3.2.5 Detektor rohů

Vzhledem k nesouladu vykreslení fotografie a uměle vygenerovaného panorama, je vhodné využít informací, které jsou shodné nebo alespoň podobné ve vstupní fotografii i v panoramatu vygenerovaném z modelu. Takovou informací jsou například některé z rohů v obraze. Tohoto faktu využívá například [21], pro vyhledání korespondence ne zcela stejných fotografií.

Možností je umístit význačné body na pozice, kde jsou detekovány rohy. Pro detekci rohů je známo mnoho existujících metod. V tomto konkrétním případě jsou oba vstupní obrazy převedeny do stupňů šedi. Následně jsou z obou šedotónových vstupních obrazů extrahovány hrany pomocí Cannyho hranového detektoru. Nad hranovou reprezentací byly pomocí Harrisova detektoru vyhledány rohy v obraze. Tento jednoduchý postup ovšem nedetekoval spolehlivé množiny význačných bodů. Sémanticky význačnější rohy, jako jsou například vrcholy hor, zůstaly nedetekovány na rozdíl od nevýznamných rohů. Získaný výsledek je na obrázcích 3.6.

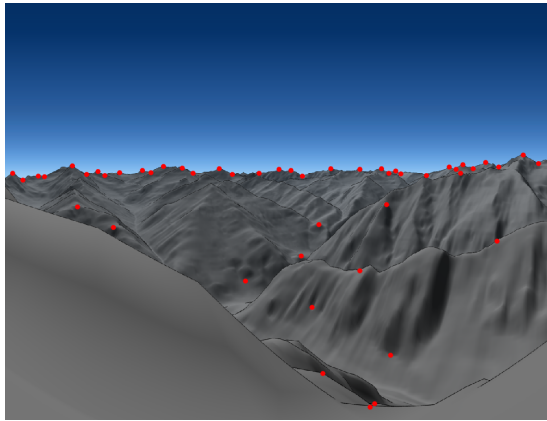


Obrázek 3.6: Význačné body detekované jako rohy

3.2.6 Detekce rohů pomocí operátoru Compass

Přestože detekce jednoduchých rohů nevykazuje přesvědčivé výsledky, jako vhodný kandidát pro detekci význačných bodů přichází v úvahu pokročilý detektor rohů[34] pracující nad operátorem Compass[33]. Díky tomu, že je možné nastavit úhel rozevření, orientaci a rádius detekovaného rohu, byl tento detektor použit pro přibližnou detekci vrcholů hor, sedel a míst, kde se opticky kříží svahy kopců. Příklad detekovaných bodů na ilustraci 3.7. Velkou nevýhodou užití tohoto detektoru je vysoká výpočetní náročnost operátoru Compass.

¹Dostupné z <https://github.com/mys007/locatev2> (20.3. 2017)



(a) Syntetický obraz




(b) Fotografie

Obrázek 3.7: Význačné body detekované pokročilým detektorem rohů


3.2.7 Lokální extrémů linie horizontu

Poslední navrženou možností pro získání sémanticky významnějších význačných bodů je detekce vrcholů a sedel (případně údolí) jako lokálních extrémů linie horizontu. Stejně jako v případě detekce rohů, pro určení lokálních extrémů je ze vstupního obrazu užita jasová složka, ze které je následně Cannyho detektorem získána hranová reprezentace. Na horizontálních hranách jsou potom vyhledány všechny lokálních extrémů. Příklad vyhledaných lokálních extrémů je na obrázku 3.8.

Výhodou těchto význačných bodů je, že reprezentují informaci, kterou nesou oba typy vstupních obrazů. Nevýhodou je velká nespolehlivost vyhledání lokálních extrémů z důvodu nepřesnosti extrakce hran, možnému narušení hran mraky a nestabilita vůči rotaci vstupního obrazu.



(a) Panorama



(b) Fotografie

Obrázek 3.8: Význačné body detekované jako lokální extrémů

3.3 Deskriptor význačného bodu

Ke zpřesnění algoritmu vyhledání korespondence grafů může výrazně pomoci využít deskriptor význačných bodů, který je následně využit pro vypočtení matice podobnosti vrcholů grafu. Nejjednodušším popisem, který se nabízí jsou geometrické souřadnice význačného bodu vzhledem k souřadnému systému obrazu. Tento popis je však z důvodu nejednotného

počátku souřadnic vstupních obrazů z principu nevhodný. Vhodnějšími se zdají deskriptory, které pro popis význačného bodu využívají jeho okolí.


3.3.1 Shape context

Takovým deskriptorem, který popisuje význačný bod na základě jeho okolí, je deskriptor Shape context [6, 5, 7, 8]. Shape context popisuje tvar okolí histogramem, který reprezentuje rozložení bodů obrazu v okolí význačného bodu.

Pro účely této práce je deskriptor Shape context vypočten z hranové reprezentace vstupních obrazů. Prvním krokem pro získání hranové reprezentace vstupní fotografie je převedení barevné reprezentace na jasovou. Vzhledem k tomu, že fotografie přirozeně obsahuje značné množství hran, které se v syntetickém panoramatu nevyskytují, je vstupní fotografie vyhlazena Gaussovým filtrem, aby méně významné hrany byly eliminovány. Z vyhlazené fotografie ve stupních šedi je hranová reprezentace získána Cannyho hranovým operátorem. V případě syntetického panoramatu je hranová reprezentace získána přímo při renderování obrazu z digitální výškové mapy.

Získaná hranová reprezentace je následně převedena na seznam souřadnic bodů náležících hranám. Deskriptor Shape context je nad těmito body vypočten s využitím zdrojového kódu převzatého z ukázkové aplikace pro Shape context².

Pro výpočet deskriptoru každého bodu je využito okolí význačného bodu o rozměrech 128x128 pixelů. Parametry Shape context algoritmu byly ponechány dle ukázkové aplikace. Konkrétně je vypočtení Shape context histogramu provedeno za pomoci logaritmicko-polárního okolí rozděleného do 60 sektorů, které zajistí, že bližší okolí zkoumaného bodu má vyšší váhu v následném porovnání. Sektory vznikly jako 5 soustředných mezikruží v logaritmické vzdálenosti od středu, přičemž každé jednotlivé je dále děleno na 12 výsečí. Nastavení rozdělení do sektorů je ilustrováno obrázkem 3.9.



Obrázek 3.9: Rozdělení okolí význačného bodu na sektory

Pro získání podobnosti význačných bodů C_S je užito porovnání histogramů pomocí metriky \mathcal{X}^2 vzdálenost. Pro histogramy $g(k)$ a $h(k)$ je \mathcal{X}^2 vzdálenost dána vztahem 3.1 [5].

$$C_S = \frac{1}{2} * \sum_{k=1}^K \frac{[g(k) - h(k)]^2}{g(k) + h(k)} \quad (3.1)$$

²Dostupné z https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/shape/sc_digits.html (31.3.2017)

3.3.2 Locatev2

Další možností pro porovnání význačných bodů je využití neuronové sítě natrénované pro porovnání okolí význačného bodu ve fotografii vůči okolí bodu detekovaného v syntetickém obraze. K tomu byl využit software Locatev2³.


Program Locatev2 pracuje následujícím způsobem. Vstupy programu jsou fotografie a syntetický obraz reprezentovaný sadou obrazů vyrenderovaných s různým nastavením osvětlení. Prvním krokem je detekce význačných bodů v obou vstupních obrazech, které se v ideálním případě shodují. Každému detekovanému význačnému bodu je přiřazeno jeho čtvercové okolí o rozměrech 128x128 pixelů. Následně jsou všechny body detekované ve fotografii porovnány pomocí neuronové sítě s body získanými ze syntetických dat na základě okolí bodů. Výsledkem této operace porovnání bodů není sada deskriptorů pro význačné body, ale přímo matice udávající chybu podobnosti význačných bodů. Ta koresponduje s maticí K_p , která nese podobnost vrcholů grafu, vstupující do algoritmu pro vyhledání korespondence grafů.

3.4 Detekce hran grafu

Pro sestavení grafu nad vstupním obrazem jsou kromě vrcholů grafu třeba také jeho hrany. Získání hran je možné dvěma způsoby. Jejich volba závisí na konkrétním postupu konstrukce grafu. V případě, že graf je sestaven na základě množiny předem stanovených vrcholů, hrany jsou získány jejich systematickým spojením. V opačném případě jsou ze vstupních obrazů nejdříve extrahovány hrany, jejichž koncové body jsou vrcholy grafu.

3.4.1 Spojení vrcholů hranami

Jak bylo zmíněno v kapitole 2.4.4, vyhledané vrcholy je třeba spojit a vytvořit tak hrany grafu. Jako výchozí řešení knihovny Factorized graph matching[41], je použití Delaunayho triangulace. Tato metoda velmi dobře pokrývá vytvořený graf, ale v případě deformovaného grafu či chybějících vrcholů může dojít k velkým rozdílům v rozmístění hran mezi oběma grafy. Tento problém je možné potlačit spojením K nejbližších bodů. Rozdílná strategie vytváření hran je ilustrována na obrázku 3.10. Obdobně lze vytvořit hrany ke všem vrcholům ležícím do vzdálenosti ϵ . Tato možnost je však nepraktická z důvodu chybějící informace o hustotě rozložení vrcholů. V rámci experimentů se však neukázal žádný výrazný rozdíl.



Obrázek 3.10: Porovnání způsobů rozmístění hran na deformovaném grafu

³Dostupné z <https://github.com/mys007/locatev2> (20.3. 2017)

3.4.2 Detekce hran v obraze

Algoritmus Graph matching using Monte Carlo tree search[31] pro vyhledání korespondence grafů neuvažuje ohodnocení vrcholů grafu, ale pro svou funkci využívá primárně hran a jejich geometrických vlastností. Přestože samotný algoritmus funguje nad grafy vzniklými spojením vrcholů přímými hranami, vhodnější přístup je vystavět graf na základě hran, aby nedošlo k zanedbání podstatného principu algoritmu.

Pro získání hran grafu včetně jejich geometrické charakteristiky je možné využít hran existujících v obraze jako siluety terénu. V případě syntetického panorama je problém jednodušší, protože hranová reprezentace siluet modelu je k dispozici přímo. Extrakce hran ve vstupní fotografii již vyžaduje složitější postup. Z fotografie je nejdříve získána jasová složka, která je pomocí Cannyho hranového detektoru převedena na hranovou reprezentaci. Protože fotografie zpravidla obsahuje mnohem více hran než syntetické panorama a zároveň požadované hrany trpí mnoha poškozeními, je třeba provést jejich opravu. V prvním kroku opravy jsou hrany propojeny v místech krátkých přerušení v řádu jednotek pixelů. Druhým krokem je filtrace všech krátkých hran, které vzhledem ke své délce pravděpodobně nejsou součástí siluety terénu na fotografii a nemají tedy svůj protějšek v panoramatu. Opravené hrany extrahované ze vstupních obrazů jsou segmentovány a na koncové body každé z nich je umístěn vrchol grafu.


3.5 Deskriptor hran

Většina uvažovaných algoritmů umožňuje zohlednit také ohodnocení hran, které do algoritmu vstupuje v podobě matice podobnosti hran K_q . Nastavení výpočtu této matice je jedním z klíčových parametrů pro následující úspěšné vyhledání korespondence grafů. Popis hrany, který je následně využit pro konstrukci matice K_q , je volen tak, aby reprezentoval její geometrické vlastnosti. Konkrétně jde o kombinaci délky a orientaci vůči vodorovné ose. Výpočet hodnoty podobnosti k_{ij} hran m_i, m_j je dán vztahem 3.2


$$k_{ij} = \exp(-(|d_i - d_j| + |\theta_i - \theta_j|) * c) \quad (3.2)$$

převzatým ze vzorové aplikace pro Factorized graph matching[41]. Ve vztahu 3.2 hodnota $d_{i,j}$ reprezentuje délku hran m_i, m_j a hodnota $\theta_{i,j}$ představuje úhel mezi hranami m_i, m_j a vodorovnou osou. Rozdíl délek porovnávaných hran je přičten k rozdílu orientací. Výsledek představuje chybu podobnosti hran. Ta je následně upravena zvoleným koeficientem c , převrácena a vynesena na exponenciální křivku, čímž je vypočtena hodnota podobnosti hran ležící v intervalu $< 0, 1 >$. V případě, že je třeba neuvažovat podobnosti hran pro vyhledání korespondence grafů, je matice K_q vynulována.


Velký vliv na přesnost vyhledané korespondence má volba zmíněného koeficientu c upravujícího vypočtenou chybu podobnosti hran ve vztahu 3.2. Vzorový příklad knihovny Factorized graph matching[41] používá koeficient $c = 0,5$. Výsledek vyhledání korespondence při zachování originální hodnoty včetně histogramu je ilustrován na obrázku a histogramu 3.11. Změnou koeficientu na hodnotu $c = 2$ se výrazně změnilo rozložení hodnot podobností hran a došlo ke znatelnému zpřesnění výsledku. Opět doloženo ilustrací 3.11. Autor článku Factorized graph matching[41] neuvádí jakým způsobem je koeficient volen, nicméně dle provedeního experimentu je vhodné docílit takového rozložení hodnot podobnosti hran, kdy je mezi nejsilnějšími kandidáty a zbytkem výrazný rozdíl v hodnotě podobnosti hrany. Příklad takového nastavení je vidět na histogramu 3.11d.




(a) Korespondence (koeficient 0,5)



(b) Histogram hodnot podobnosti hran (koeficient 0,5)



(c) Korespondence (koeficient 2)



(d) Histogram hodnot podobnosti hran (koeficient 2)


Obrázek 3.11: Závislost výsledku korespondence na rozložení hodnot podobnosti hran

3.6 Vyhledání korespondence grafů

Na základě informací o vrcholech a hranách grafů získaných ze vstupních obrazů je již možné vystavět grafy, které jsou použity pro vyhledání korespondence. Dostatečnou znalostí pro vystavění samotného grafu jsou informace o pozicích vrcholů grafu a jejich propojení hranami. Pro správnou funkci však všechny uvažované algoritmy s výjimkou Graph matching using Monte Carlo tree search[31] vyžadují jako své vstupy navíc i matici podobností vrcholů K_p a matici podobností hran K_q jež jsou klíčové pro úspěšné vyhledání korespondence grafů. Hodnoty těchto matic K_p a K_q jsou vypočteny funkcí, která umožňuje porovnání hrany či význačného bodu v závislosti na užitém deskriptoru. Pro všechny případy je matice K_p normalizována tak, aby její členy nabývaly hodnot v intervalu $\langle 0, 1 \rangle$. V případě, že žádný deskriptor pro hranu či vrchol není použit, je příslušná matice vynulována, aby její hodnoty neovlivňovaly výpočet algoritmu pro hledání korespondence grafů.


3.6.1 Vliv podobností vrcholů a hran

Citlivost algoritmů na nastavení matic podobností vrcholů a hran je ilustrován následujícím příkladem, který porovnává výsledky vyhledání korespondence grafů v závislosti na použití podobností hran a vrcholů. Ukázkový příklad je z důvodu spolehlivých vstupních dat proveden na jedné fotografii, nad kterou je graf vystavěn pomocí detektoru a deskriptoru SIFT[26]. Vyhodnocení je provedeno algoritmem SMAC[15]. Na histogramech 3.12 lze vidět rozložení hodnot v maticích K_p a K_q příslušící příkladu.




Obrázek 3.12: Histogram rozložení hodnot podobností vrcholů, Histogram rozložení hodnot podobností hran

Ilustrace 3.13 zobrazuje, že při zanedbání podobností vrcholů i hran je výsledek vyhledání velmi neuspokojivý. Uvážením podobností vrcholů vypočtených na základě deskriptoru SIFT se výsledek porovnání výrazně zlepší, ale stále obsahuje chybné korespondence. To lze vidět na obrázku 3.14. Jak si lze všimnout na ilustraci 3.15, uspokojivý výsledek korespondence se podařilo získat při užití podobností hran. Spolehlivý výsledek lze najít i v posledním příkladu 3.16, který uvažuje porovnání podobností vrcholů i hran. Proto je vždy využito kombinace informací o podobnosti vrcholů i hran, pokud jsou tyto informace v daném případě dostupné.



Obrázek 3.13: Výsledek korespondence při zanedbání podobnosti vrcholů a hran




(a) Korespondence



(b) Výsledek

Obrázek 3.14: Výsledek korespondence při využití podobnosti vrcholů




(a) Korespondence



(b) Výsledek

Obrázek 3.15: Výsledek korespondence při využití podobnosti hran



(a) Korespondence



(b) Výsledek

Obrázek 3.16: Výsledek korespondence při využití podobnosti vrcholů i hran

3.6.2 Výběr algoritmu

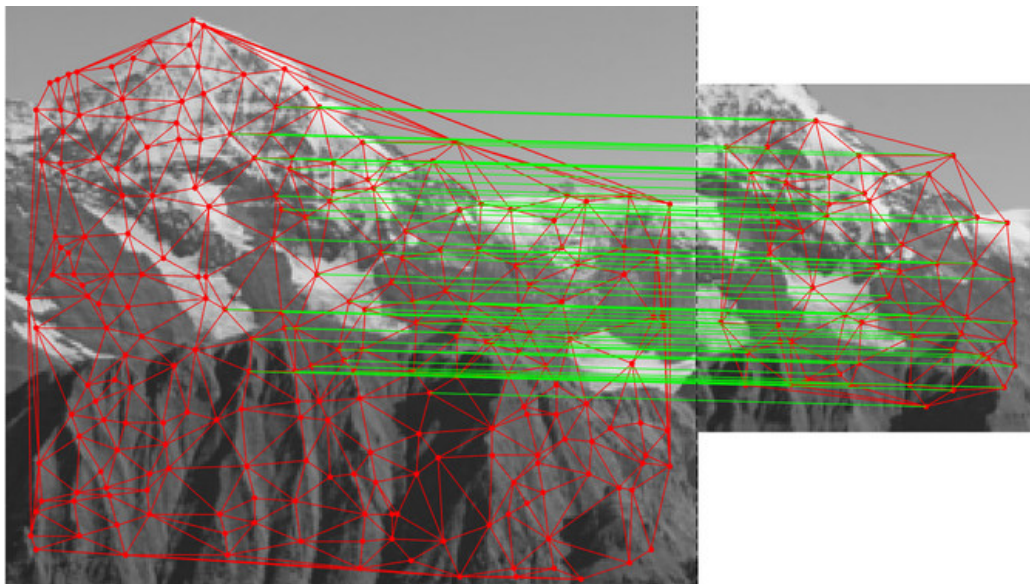
Výběr algoritmu pro samotný výpočet korespondence grafů je klíčovým krokem celé posloupnosti vedoucí k registraci fotografie do syntetického panoramatu. Nutnou podmínkou použitého algoritmu je jeho schopnost vyhledat korespondenci grafů včetně zachování

geometrických závislostí ve vyhledávaném a vyhledaném grafu. Nesmí docházet k rotaci části vyhledaného grafu či rozdělení grafu do několika vzdálených komponent. V ideálním případě by algoritmus měl uvažovat vstupní podobnosti hran i vrcholů. Dalšími požadavky jsou výpočet v rozumném čase a schopnost odstranit chybně detekované korespondence.

Pro tuto práci byly uvažovány algoritmy Graduate assignment[20], Spectral matching[24], Spectral matching with affine constraints[15], Integer projected fixed point method[25], Re-weighted random walk matching[13], Concave optimization, Probabilistic matching[39], Factorized graph matching[41], Deformable graph matching[42], Dual decomposition[36] a Graph matching using Monte Carlo tree search[31]. Po prozkoumání těchto algoritmů byly pro další práci a experimenty vybrány algoritmy:

- Spectral matching with affine constraints[15]
- Deformable graph matching[42]
- Dual decomposition[36]
- Graph matching using Monte Carlo tree search[31]

Spectral matching with affine constraint Spectral matching with affine constraint[15] je rychlý algoritmus, který podporuje porovnání podobností hran a vrcholů. Jeho nevýhodou je, že neobsahuje vnitřní geometrický model a výsledná korespondence může být deformovaná a rozdělená do několika nesouvisejících komponent. Protože výstupem algoritmu je spojitá matice korespondence, diskrétní výsledek je získán Maďarským algoritmem. Po získání diskrétního výsledku je znovu využit spojitý výsledek pro odstranění chybných korespondencí. Příklad vyhledání korespondence grafů pomocí algoritmu Spectral matching with affine constraints na ilustraci 3.17.



Obrázek 3.17: SMAC, Maďarský algoritmus na fotografii a jejím výřezu

Deformable graph matching Deformable graph matching[42] je výrazně pomalejší algoritmus než uvedený SMAC[15]. Jeho silnou stránkou je, že zachovává geometrii vyhledané

korespondence a nedochází k deformacím a dělení na komponenty. Problémem tohoto algoritmu je, že samotný algoritmus končí s již diskrétním nebo téměř diskrétním řešením a je obtížné vyloučit nadbytečné a chybné korespondence.

Dual decomposition Dual decomposition[36] patří mezi pomalejší algoritmy, ale zároveň částečně udržuje geometrické závislosti vyhledaného řešení. V případě větších nepřesností také dochází k jejich porušení.

Graph matching using Monte Carlo tree search Graph matching using Monte Carlo tree search[31] byl vybrán pro svou nativní vlastnost udržení geometrických závislostí. Velmi dobrou vlastností je také automatické vyřazení chybných korespondencí. Algoritmus GMMC[31] nepodporuje porovnání ohodnocení vrcholů grafu. Důraz tohoto algoritmu je kladen na porovnání hran pomocí jejich detailních popisů.

Protože algoritmus GMMC[31] je zaměřen na porovnávání hran grafu, pro plné využití možností algoritmu je v tomto případě změněn postup řešení úlohy uvedený v kapitole 3.1 do následující podoby. Vstupy jsou shodně panorama a fotografie, ve kterých je nejdříve provedena detekce hran, tak jak je popsáno v kapitole 3.4.2. Výstupem detekce hran je seznam obsahující přesný popis všech hran detekovaných v obraze. V dalším kroku jsou hrany ohodnoceny odpovídajícím deskriptorem definovaným algoritmem GMMC ve formě popisu hrany jako cesty[31]. Na koncové body získaných hran jsou umístěny vrcholy grafu. Ohodnocení vrcholů není algoritmem podporováno.

Grafy získané z hranové reprezentace jsou velmi nesouvislé a obsahují mnoho samostatných hran. Nedostatečná souvislost je řešena doplněním umělých hran mezi všemi blízkými vrcholy. Posledním úkonem před samotným vyhledáním korespondence je předzpracování grafu pro vyhledání superhran a virtuálních superhran, tak jak je třeba pro algoritmus GMMC. Pozměněný diagram vyhovující užití algoritmu GMMC je na obrázku 3.18.

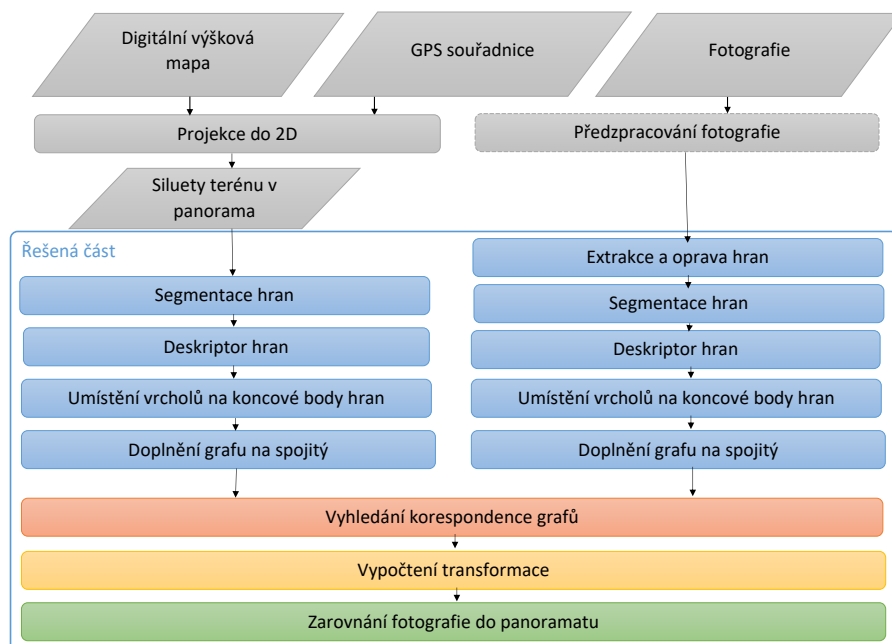
3.6.3 Řešení chybných korespondencí

Oproti obrázku 3.17, kde algoritmus našel optimální řešení, stejně nastavený algoritmus pro jiná vstupní data obsahuje několik chybných korespondencí. Situace je ilustrována obrázkem 3.20. Při bližším zkoumání lze zjistit, že příčinou chybných korespondencí je v tomto případě absence význačných bodů v jednom ze vstupních obrázků. Porovnání je ilustrováno na obrázku 3.19.

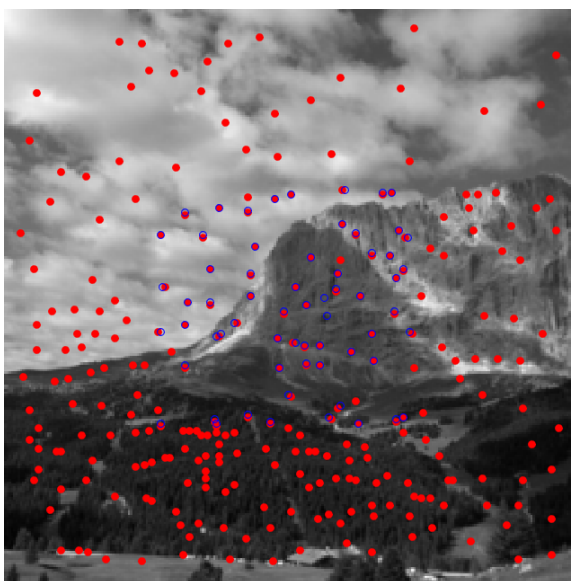
V tomto případě bylo způsobeno nepřesností detekce SIFT z důvodu malého rozlišení vstupních obrazových dat, nicméně k rozdílům v umístění význačných bodů bude s velkou pravděpodobností docházet u většiny detektorů význačných bodů.

Algoritmus SMAC tedy pro přebytečný vrchol vyhledal nejvíce podobný vrchol v druhém grafu, který ovšem nutně leží mimo požadovanou oblast. To jednoduše proto, že algoritmus vyhledá injektivní zobrazení grafu s menším počtem vrcholů do grafu s větším počtem vrcholů.

Tento problém je řešen pomocí odstranění pravděpodobně chybných korespondencí na základě váhy tohoto přiřazení ve spojitě matici korespondence X_C . Toho je dosaženo oprahováním členů matice spojitě výsledku X_C tak, aby korespondence se slabší vahou byla odstraněna. Jako vhodná mez pro prahování se ukázalo odstranění všech korespondencí, které mají o 30-40% slabší váhu než nejsilnější korespondence. Uvedený postup je ilustrován na obrázku 3.21. Diskrétní řešení X se stane maskou pro spojitě řešení X_C . Tím vznikne



Obrázek 3.18: Diagram navrženého řešení při použití algoritmu Graph matching using Monte Carlo tree search




Obrázek 3.19: Porovnání význačných bodů ve vstupních obrazech

matice X_D , která obsahuje váhy vybraných přiřazení. Díky této matici můžeme z výsledné matice X odstranit ta přiřazení, která mají svou váhu nižší než nastavený práh.

3.7 Výpočet transformace

Vstupem do tohoto kroku řešení úlohy jsou pozice vrcholů obou porovnávaných grafů a matice korespondence X , která nese informaci o párech korespondujících vrcholů. Cílem kroku



Obrázek 3.20: SMAC, Maďarský algoritmus na fotografii a jejím výřezu

$$\begin{array}{c}
 XC = \\
 \begin{bmatrix} 0.9 & 0.2 & 0.1 & 0.2 \\ 0.1 & 0.4 & 0.1 & 0.3 \\ 0.2 & 0.2 & 0.2 & 0.8 \\ 0.1 & 0.1 & 0.9 & 0.1 \end{bmatrix}
 \end{array}
 \quad
 \begin{array}{c}
 X = \\
 \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}
 \end{array}
 \quad
 \begin{array}{c}
 XD = \\
 \begin{bmatrix} 0.9 & 0 & 0 & 0 \\ 0 & 0.4 & 0 & 0 \\ 0 & 0 & 0 & 0.8 \\ 0 & 0 & 0.9 & 0 \end{bmatrix}
 \end{array}
 \quad
 \begin{array}{c}
 X' = \\
 \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}
 \end{array}$$

Obrázek 3.21: Odstranění přiřazení s nižší vahou než práh 0.6

je zjistit transformaci, která vyjadřuje vztah mezi korespondujícími vrcholy. Výsledkem je tedy množina translací, z nichž každá je přiřazena konkrétnímu korespondujícímu páru.

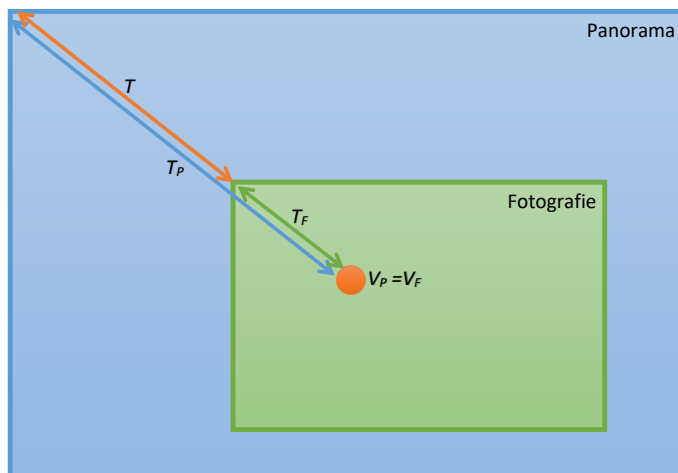
Výpočet této translace je třeba provést pro každý korespondující pár zvlášť. Požadovanou translací konkrétní transformace je taková translace T , jež zajistí posunutí počátku souřadného systému fotografie vůči souřadnému systému panoramatu tak, aby oba korespondující vrcholy V_F a V_P ležely ve shodném bodě. Tato translace je vypočtena ze znalosti translace (T_F) vrcholu V_F od počátku souřadnic fotografie a translace (T_P) vrcholu V_P od počátku souřadnic panoramatu. Tento vztah je znázorněn na obrázku 3.22.

3.8 Zarovnání fotografie do panoramatu

Znalost translace, která vyjadřuje vztah mezi vrcholy v každém korespondujícím páru, již umožňuje samotné umístění fotografie do umělého panoramatu. Pro tento krok jsou možné dva postupy.

Méně přesným řešením je agregace získaných translací do jedné výsledné translace, která je přímo aplikována na fotografii. Uvažovanou agregační funkcí je aritmetický průměr. Nevýhodou je nepřesné navázání obsahu fotografie na umělé panorama. Na druhou stranu je tento postup robustnější vůči nepřesně vypočteným translacím.

Druhou možností je aplikovat na fotografii warping, který na základě translace každé korespondence deformuje fotografii tak, aby byla vhodně navázána na umělé panorama. Výhodou je větší přesvědčivost výsledku. Nevýhodami jsou citlivost na přesnost translace



Obrázek 3.22: Znázornění výpočtu translace příslušící korespondujícím vrcholům

každé jednotlivé korespondence a možná nevhodná deformace fotografie v oblastech nízkého pokrytí význačnými body.

3.9 Navržené konkrétní postupy řešení

Pro každý krok řešení úlohy registrace fotografie do syntetického panoramatu bylo navrženo několik možností řešení. V této sekci budou představeny posloupnosti již konkrétních kroků, které byly vybrány jako realizovatelné a vhodné pro řešení úlohy. Tyto vybrané posloupnosti byly realizovány a podrobeny následnému otestování experimentální formou.

3.9.1 Uniformní význačné body, Locatev2, SMAC

Jako první postup byl zvolen algoritmus SMAC, který pracuje nad uniformně detekovanými vrcholy, které jsou ohodnoceny deskriptorem Locatev2. Hrany jsou v tomto případě doplněny Delaunayho triangulací. Porovnány jsou na základě směrnice a délky. Korespondence grafů vypočtená algoritmem SMAC je diskretizována Maďarským algoritmem.

Je zde využito rovnoměrného vzorkování vstupních obrazů s kombinací poměrně spolehlivého deskriptoru. Výsledek není negativně ovlivněn nevhodným detektorem význačných bodů.

3.9.2 Náhodné význačné body, Locatev2, SMAC

Variantou předchozího postupu je algoritmus SMAC pracující nad množinou náhodně umístěných vrcholů ohodnocených deskriptorem Locatev2. Tento postup se snaží zmírnit chybu způsobenou případným nevhodným posunutím všech význačných bodů.

3.9.3 KAZE, Locatev2, SMAC

Tento postup vychází z původního nastavení programu Locatev2, který složí pro porovnání dvou význačných bodů na základě výřezu jejich okolí. Význačné body jsou v tomto případě detekovány KAZE detektorem. Podobnost bodů je udána maticí $Score$ vyjadřující chybu podobnosti význačných bodů získanou deskriptorem Locatev2. Hodnota chyby $Score_{ij}$ je

převedena na hodnotu podobnosti vrcholu $K_{p_{ij}}$ dle vztahu $K_{p_{ij}} = \exp(-Score_{ij}/k)$, přičemž konstanta k je zvolena tak, aby zastoupení hodnot podobnosti zvýhodňovalo význačné body s malou chybou. Hrany byly doplněny Delaunayho triangulací. Matice podobností hran je vypočtena z topologie grafu vztahem 3.2. Toto nastavení vychází z pozorování nastavení ukázkové aplikace pro Factorized graph matching[41]. Spojité řešení vyhledání korespondence grafů je vypočteno algoritmem SMAC. Diskrétní řešení je získáno pomocí Maďarského algoritmu.

3.9.4 Význačné body v lokálních extrémech, Locatev2, SMAC

Další možností jak přizpůsobit předchozí postup je detekce význačných bodů v místech lokálních extrémů vodorovně orientovaných hran. Vybrané význačné body jsou opět popsány deskriptorem Locatev2. Korespondence vypočtena algoritmem SMAC a diskretizována Maďarským algoritmem.

3.9.5 KAZE, Locatev2, Dual decomposition

Díky schopnosti algoritmu Dual decomposition částečně udržet geometrické vlastnosti vyhledávaného grafu byl navržen postup, který nad vrcholy umístěnými za pomoci KAZE detektoru a ohodnocenými neuronovou sítí Locatev2, vystaví grafy, které jsou zpracovány algoritmem Dual decomposition.

3.9.6 Uniformní význačné body, Shape context, SMAC

Dle literatury úspěšným deskriptorem okolí význačného bodu je Shape context. Principem jeho využití je v tomto případě porovnání uniformně vzorkovaných význačných bodů pomocí Shape context popisu. Význačné body v panoramatu jsou vzorkovány s rozestupy o velikosti jednoho okolí význačného bodu. Význačné body ve fotografii jsou vzorkovány v mnohem menších vzdálenostech. Výsledek porovnání těchto význačných bodů je použit jako informace o podobnosti vrcholů. Hrany jsou doplněny Delaunayho triangulací a porovnány na základě jejich směrnice a délky. Korespondence grafů je vypočtena kombinací algoritmu SMAC a Maďarského algoritmu.

3.9.7 Rohy pomocí operátoru Compass, DGM

Významným navrženým postupem se stala kombinace detektoru rohů založeném na operátoru Compass a algoritmu Deformable graph matching. Ta slibuje spojení dle zkušenosti nejspolehlivějšího detektoru význačných bodů společně s algoritmem hledající korespondence šetrně vzhledem ke geometrii vyhledávané korespondence. Pro zlepšení výsledku byla přidána informace o vertikální orientaci detekovaných rohů jako ohodnocení vrcholů grafu.

3.9.8 Rohy pomocí operátoru Compass, GMMC

Druhým možným algoritmem, který je postaven na nejspolehlivějším navrženém detektoru, je algoritmus Graph matching using Monte Carlo tree search. Tento algoritmus již ze svého principu udržuje geometrické závislosti vyhledávaného podgrafu. Nevýhodou tohoto přístupu je, že nelze využít informace o vertikální orientaci význačných bodů.

3.9.9 Geometrie hran, GMMC

Poslední navržený postup vychází z originálního nastavení algoritmu GMMC[31], který vyhledává korespondenci s využitím detailního geometrického popisu hran v grafu. Základem tedy není detekce význačných bodů, nýbrž získání hran existujících v obraze. Tyto hrany jsou poté spojeny do grafu, který je doplněn umělými hranami do grafu souvislého. Takto připravené grafy jsou porovnány algoritmem GMMC. Výsledkem je korespondence složená z výběru možných přiřazení vyhovujících vnitřnímu geometrickému modelu algoritmu GMMC, což zaručuje neexistenci chybných přiřazení.

Kapitola 4

Realizace

Jak již bylo detailně popsáno předchozí kapitolou, návrh řešení úlohy uvažuje použití mnoha rozličných metod. Tato kapitola představí konkrétní realizaci navržených řešení. Realizace je zde popsána jak z pohledu využitých nástrojů, tak některých důležitých implementačních detailů.

4.1 Použité nástroje

Jako hlavní nástroj pro vývoj testovací aplikace byl zvolen Matlab¹ od společnosti MathWorks. Ten byl zvolen pro možnost efektivně tvořit prototypy řešení a nad nimi provádět experimenty. Svými vlastnostmi a nástroji je vhodný pro práci v oblasti zpracování obrazu a počítačového vidění. Matlab je také kompatibilní s velkým množstvím existujícího softwaru v potřebné oblasti, protože byl často pro stejný účel použit v předchozích výzkumech.

Jako alternativy k programu Matlab pro práci na řešení úloze registrace fotografií do 3D modelu terénu byly dále zvažovány nástroje jazyk C++ či Python s podporou knihoven OpenCV.

Kromě nástroje Matlab bylo využito i mnoho hotových řešení pro Matlab i mimo něj. Tyto jsou popsány v následujících odstavcích.

4.1.1 Práce s grafy

Pro obecnou práci s grafy ve smyslu jejich vytváření, modifikací a vizualizace v prostředí Matlabu bylo využito knihovny příslušící k publikaci Factorized graph matching[41]. Ta kromě základních nástrojů s grafy obsahuje také implementaci několika významných aproximačních metod pro hledání korespondence grafů, které jsou uvedeny na následujícím seznamu.

- Graduate assignment
- Spectral matching
- Spectral matching with affine constraints
- Integer projected fixed point method
- Re-weighted random walk matching

¹<https://www.mathworks.com/products/matlab.html>

- Concave optimization
- Probabilistic matching
- Factorized graph matching
- Deformable graph matching

4.1.2 Dual decomposition

Pro testování algoritmu Dual decomposition bylo využito knihovny² publikované spolu s článkem Feature Correspondence via Graph Matching: Models and Global Optimization[35]. Jde o knihovnu napsanou v jazyce C++, která byla volána z prostředí Matlab jako externí nástroj. Výsledek je uložen do souboru a načten zpět do Matlabu pro vyhodnocení výsledku a vizualizaci.

4.1.3 Graph matching using Monte Carlo tree search

Implementace algoritmu GMMC³ byla ve formě knihovny s příklady získána přímo od autorů metody publikované vědeckým článkem Geometrical graph matching using Monte Carlo tree search[31].

Z této knihovny byl využit kód pro úpravu datové struktury grafu do podoby potřebné pro běh metody GMMC a také samotný algoritmus pro vyhledání korespondence grafů.

Extrakce, oprava a segmentace hran Pro extrakci hran z jasové složky obrazu bylo užito interní funkce `edge` softwaru Matlab. Tato funkce byla nastavena tak, aby bylo použito Cannyho hranového detektoru s hysterezí. Získaná hranová reprezentace byla před užitím opravena a segmentována na jednotlivé hrany za využití knihovny Edge linking and line segment fitting autora Peter Kovese⁴.

4.1.4 Scale invariant feature transform

Pro detekci význačných bodů pomocí SIFT algoritmu byla nejdříve využita přejatá implementace SIFT feature extraction[17]. Ta se ukázala jako nevhodná z důvodu spolehlivosti a nutnosti použití rozšíření prostředí Matlab. Ve výsledném řešení je proto nahrazena implementací SIFT (Scale invariant feature transform) algorithm od autora Cheggoju Naveen[29].

4.1.5 Pokročilá detekce rohů operátorem Compass

Jako jeden z detektorů význačných bodů byl využit pokročilý detektor rohů, který pracuje s hranovým operátorem Compass[34]. Při implementaci bylo využito přímo autorova zdrojového kódu⁵.

²Dostupné z <http://vlg.cs.dartmouth.edu/software.html> (8.5.2017)

³Dostupné z <http://cmp.felk.cvut.cz/~amavemig/gmmc/> (8.5.2017)

⁴Dostupné z <http://www.peterkovesi.com/matlabfns/index.html> (8.5.2017)

⁵Dostupné z <http://robotics.stanford.edu/~ruzon/compass/> (8.5.2017)

4.1.6 Deskriptor Shape context

Výpočet a porovnání deskriptoru význačných bodů pomocí metody Shape context byly provedeny díky softwarové knihovně Shape context demo⁶ vydané autory metody Shape context.

4.1.7 Deskriptor Locatev2

Porovnání ohodnocení vrcholů grafu není triviální úlohou, protože jde o porovnání dvou výřezů obrazových dat, jež jsou naprosto rozdílného typu. Prvním je fotografie. Druhým je výřez ze syntetického panoramatu. Užítým řešením pro toto netriviální porovnání je neuronová síť Locatev2 vytvořená přímo pro tento účel. Implementace softwaru Locatev2⁷ v programovacím jazyce Lua včetně již existující natrénované neuronové sítě byla poskytnuta autorem Martinem Šimonovským.

Poskytnutá implementace je připravena pro běh ve frameworku pro vědecké výpočty Torch⁸. Zároveň pro svůj běh vyžadovala technologii CUDA pro matematické výpočty na grafické kartě NVidia. Pro odstranění této omezující podmínky byl zdrojový kód rozšířen tak, aby bylo možné jej spustit i v režimu výpočtu na procesoru.

Další provedenou úpravou bylo rozšíření vstupů a výstupů softwaru. Přidaným vstupem je možnost načtení souboru obsahujícího souřadnice význačných bodů detekovaných pomocí externích nástrojů, protože originální implementace obsahuje pouze vybrané detektory příznaků knihovny OpenCV. Stejně tak byl přidána možnost exportu informace o podobnosti porovnaných význačných bodů do souboru, který může být dále zpracován externími nástroji. Formát vstupních a výstupních souborů je shodný s formátem pro uložení a načtení maticových dat softwaru Matlab. Konkrétně jsou tedy hodnoty na řádku matice oddělené čárkou a jednotlivé řádky matice jsou odděleny znakem konce řádku.

4.2 Implementace navržených řešení

Navržená řešení jsou realizována ve formě několika nezávislým skriptů pro prostředí Matlab. Každý skript realizuje konkrétní provedený experiment. Pro měření kvantitativních výsledků je v některých případech vytvořen skript pro Bash, který umožňuje daný experiment spustit jako dávkou.

Implementované experimenty ke svému fungování využívají knihovny implementující požadované funkce. Tyto knihovny jsou přiloženy a používány v nezměněném formátu tak, jak byly získány od jejich autorů či vydavatelů. Pro případy, kdy bylo třeba provést změny ve využitých knihovnách, případně vytvořit chybějící funkcionalitu, byla vytvořena a přiložena vlastní knihovna implementující tyto pozměněné či nové funkce.

V případě nástrojů Locatev2 a Dual decomposition, které jsou externími programy, bylo nutné řešit jejich propojení se skriptem provádějícím experiment. Byl zvolen postup využívající exportu zadání a importu řešení ve formě textových souborů a zavolání externího nástroje přímo ze skriptu pro Matlab.

⁶Dostupné z https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/shape/sc_digits.html (8.5.2017)

⁷Dostupné z <https://github.com/mys007/locatev2> (8.5.2017)

⁸<http://torch.ch/> (8.5.2017)

4.3 Řešené podproblémy

Většina klíčové implementace přímo vychází z provedeného návrhu. V této části tedy budou popsána konkrétní řešení dílčích podproblémů, které bylo třeba v průběhu realizace řešit.

4.3.1 Převod na odstíny šedi

Mnoho algoritmů pro zpracování obrazu pracuje pouze nad šedotónovým obrazem. Tento krok předzpracování je realizován standardní funkcí `rgb2gray`, která je součástí základní knihovny programu Matlab.

4.3.2 Extrakce, oprava a segmentace hran

Vhodnou charakteristikou při porovnání fotografie s umělým panoramatem jsou hrany v obraze. Těmi nejužitečnějšími hranami, které lze najít v obou vstupních obrazech, jsou siluety zachyceného terénu. Díky digitální výškové mapě modelu lze hranovou reprezentaci siluet terénu získat přímo a s velkou přesností. V případě fotografie je extrakce dostatečně spolehlivých hran výrazně složitější. Prvním problémem je nižší kvalita získané hranové reprezentace. Druhým problémem je segmentace hran a rozlišení užitečných hran.

Jako první krok při získání hran z fotografie je její převod do jasové složky. Jasová složka je zpracována Cannyho detektorem hran za využití hystereze pro prahování dle intenzity hrany. Získaná hranová reprezentace zpravidla obsahuje mnoho porušení. Malá porušení jsou opravena pomocí doplnění chybějících úseků hran.

Dalším krokem je segmentace hran a získání popisu každé hrany. Pokročilé znalosti o každé jednotlivé hraně je využito pro odstranění nezajímavých hran. Jako nepotřebné jsou odstraněny všechny krátké hrany. Kromě krátkých hran jsou také odstraněny hrany tvořící samostatnou kružnici, protože ty se jako siluety terénu téměř nevyskytují.

Kapitola 5

Experimenty

V rámci řešení této práce bylo provedeno několik experimentů, jež slouží jako ověření očekávaného chování, podpora návrhu, testování jednotlivých kroků řešení a vyhodnocení hotového řešení jako celku. Některé z těchto experimentů budou představeny v této kapitole. Úvodem to budou drobnější experimenty zaměřené na ověření hypotéz a rozhodování v rámci návrhu. Ve zbytku kapitoly potom bude prezentováno podrobné zhodnocení navržených a realizovaných řešení.

5.1 Porovnání algoritmů pro vyhledání korespondence grafů

Tento experiment byl využit k porovnání dostupných algoritmů pro vyhledání korespondence grafů. Jako vstupní data byla využita fotografie o rozměrech 256x256 pixelů a její výřez o velikosti 128x128 pixelů, ve kterých byly význačné body detekované algoritmem SIFT. Tato umělá vstupní data byla zvolena proto, aby se omezil vliv detektoru význačných bodů a výsledek porovnání závisel opravdu na algoritmu pro vyhledání korespondence. Nad vstupními daty byly vystavěny poměrně rozsáhlé grafy obsahující 63 a 267 vrcholů. Pro porovnání vrcholů bylo užito deskriptoru SIFT. Při porovnání hran bylo uvažováno jejich délky a orientace tak jak bylo vysvětleno v kapitole 3.5. Nastavení porovnání stejně tak jako vstupní data byly shodné pro běh každého algoritmu.


Tabulka 5.1: Algoritmy pro vyhledání korespondence grafů

Běh	Inicializace	Spojité řešení	Diskretizace	Čas [s]	Správné kor.	Odchyłka [px]
GA	Uniform	GA	Hungarian	0,285240	36/54	15
PM	—	PM	Hungarian	0,981933	0/54	42
SM	SM	—	Hungarian	0,243343	54/54	2
SMAC	SMAC	—	Hungarian	0,369955	54/54	1
IPFP	Uniform	—	IPFP	283,89	37/54	7
SM+IPFP	SM	—	IPFP	558,20	36/54	5
RRWM	Uniform	RRWN	Hungarian	10,61	53/54	1
FGM	—	FGM	—	3523.23	0/54	32
DGM	—	DGM	—	2851.78	53/54	4
GMMC	—	—	GMMC	13.89	20/54	0
DD	—	DD	—	1391.80	0/54	56

Provedený experiment sledoval veličiny počet správně určených korespondencí, odchylku od referenčního řešení určenou eukleidovskou vzdáleností a čas trvání výpočtu. Detailní

výsledky včetně času potřebného pro výpočet jsou uvedeny v tabulce 5.1. Vizuální výsledek nalezených korespondencí je ilustrován obrázky 5.1.

Jako vhodné algoritmy se z hlediska přesnosti zdají Spectral matching, Spectral matching with affine constraint, Deformable graph matching a Graph matching using Monte Carlo tree search. V případě algoritmu GMMC je vhodné dodat, že vysoká přesnost zarovnání společně s menším počtem správně zvolených korespondencí není chybou, ale důsledkem globálního geometrického modelu metody, který striktně vybírá pouze vyhovující korespondence. Z hlediska časové náročnosti jsou poté vítězi testu algoritmy na principu Spectral matching, které jsou velmi citlivé na přesnost vstupních grafů.




Obrázek 5.1: Algoritmy pro vyhledání korespondence grafů


5.2 Využití vrcholů hor jako vrcholů grafu

Cílem tohoto experimentu je ověřit možnost využití vrcholů hor jako význačných bodů pro vyhledání korespondence mezi fotografií a uměle vyrenderovaným panoramatem. Hypotézou je, že pokud se ve fotografii i v panoramatu pomocí blíže nespecifikované detekce detekují vrcholy hor, pomocí grafů postavených nad těmito význačnými body bude možné vyhledat správnou korespondenci grafů a zaregistrovat tak fotografii do 3D modelu terénu.

Jako vstupní data jsou použity ručně anotovaná fotografie a část panoramatu, ve kterém se fotografie nachází. Obrazová vstupní data jsou zobrazena na obrázku 5.2. Pro vyhledání korespondence bylo využito algoritmu SMAC tak, jak je popsáno v kapitole 3. Dle výsledku doloženého obrázkem 5.3 lze usuzovat, že má smysl implementovat registraci fotografie do umělého panoramatu na základě detekce vrcholů hor.



Obrázek 5.2: Ručně anotovaná vstupní data




Obrázek 5.3: Výsledek registrace pomocí detekce vrcholů hor

5.3 Elastická registrace

Hypotéza dalšího experimentu říká, že díky geometrickým závislostem v grafech by mělo být možné použít registraci fotografie do 3D terénu i v případě, že některá vstupní data mohou být značně zdeformovaná. Toto by měla být citelná výhoda například oproti algoritmům, které pro vyhledání korespondence využívají homografii.


Pro tento experiment byla připravena ručně anotovaná vstupní data (umělé panorama a deformovaná fotografie). Nad těmito vstupními daty byla spuštěn algoritmus Spectral matching with affine constraint. Dle výsledku ilustrovaném obrázkem 5.4 lze vidět, že i algoritmus si poradil se značně deformovanými daty, přestože tato deformace nebyla předem známa.




Obrázek 5.4: Výsledek elastické registrace

5.4 Rohy pomocí operátoru Compass, SMAC

Tento provedený experiment si klade za cíl analyzovat navrženou metodu Compass SMAC. Tato metoda pomocí operátoru Compass detekuje ve vstupních obrazech rohy jako význačné body, které mohou svým tvarem a orientací odpovídat vrcholům a údolím. Nad těmito body byly v obou vstupech vystavěny grafy. Matice podobnosti hran K_q byla vypočtena dle vztahu 3.2 tak, aby uvažovala délku a orientaci hran. Hodnoty v matici podobnosti vrcholů byly stanoveny tak, aby rozlišily vrcholy náležící vrcholům hor, které jsou orientovány směrem vzhůru, od vrcholů náležícím sedlům orientovaným dolů. Takto připravená data byl vyhodnocena algoritmem Spectral matching with affine constraint.



(a) Úspěšné vyhledání korespondence



(b) Neúspěšné vyhledání korespondence

Obrázek 5.5: Vypočtená korespondence grafů při použití pokročilé detekce rohů a algoritmu SMAC


Výsledky této metody nejsou dostatečně spolehlivé. Jak lze vidět na ilustraci 5.5, tento postup v některých případech nalezne použitelné řešení. Tento postup není robustní. Dochází k deformaci a rozdělení korespondujícího podgrafu na více nesouvislých komponent,

tak jak je ilustrováno na obrázku 5.5b. Kvůli operátoru Compass je navíc velmi výpočetně náročný. Tato metoda tedy není zařazena do následného kvantitativního porovnání.

5.5 KAZE, Locatev2, SMAC


Obdobou předchozího experimentu je vypočtení korespondence algoritmem SMAC, avšak nad grafy vystavenými nad význačnými body detekovanými detektorem KAZE. Pro větší robustnost je užito neuronové sítě Locatev2 pro získání matice podobností vrcholů.

V prvním kroku byla otestována samotná matice podobností vrcholů K_p tak, že algoritmus SMAC byl spuštěn aniž by byly uvažovány podobnosti hran grafu. V tomto případě, kdy algoritmus pro vyhledání korespondence grafů uvažoval pouze informace o podobnosti vrcholů, výsledek směřoval k referenčnímu řešení. Tedy podobnost význačných bodů získaná neuronovou sítí Locatev2 lze považovat za spolehlivou informaci. Příklad lze najít na obrázku 5.6.




Obrázek 5.6: Úspěšné vyhledání korespondence grafů při využití neuronové sítě Locatev2 a algoritmu SMAC

V druhém běhu experimentu, tedy po přidání porovnání délky a orientace hran grafů, je však získané řešení u všech testovacích vzorků dalece vzdálené od referenčního řešení a dochází k nežádoucím jevům rozpadání výsledné korespondence na nesouvisějící komponenty. Chyba je dobře patrná na ilustraci výsledků vyhledání korespondence grafů 5.7.



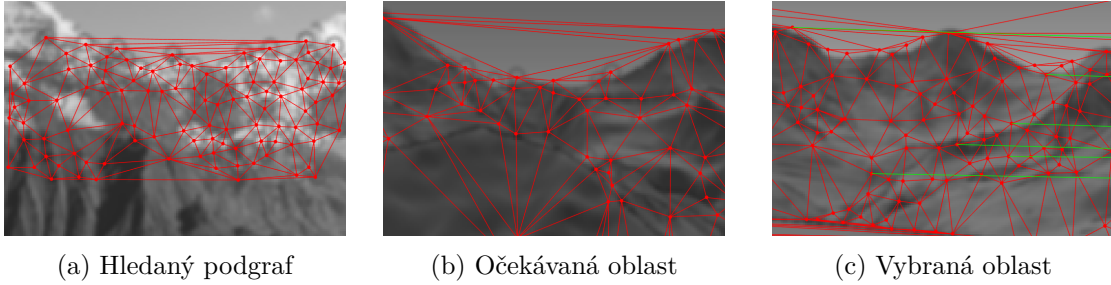
(a) Vyhledání korespondence grafů



(b) Vyhledání korespondence grafů v detailu

Obrázek 5.7: Úspěšné vyhledání korespondence grafů při využití neuronové sítě Locatev2, podobnosti hran a algoritmu SMAC

Při bližším porovnání topologie obou grafů si lze všimnout, že důvodem je pravděpodobně značně rozdílný graf ve fotografii 5.8a oproti podgrafu v místě očekávaného řešení 5.8b. Výrazně podobnější podgraf byl ovšem nalezen v úplně jiné oblasti, jejíž výřez zachycuje obrázek 5.8c. Ostatní testovací vzorky trpěly obdobným problémem. Za nespolehlivé rozložení vrcholů, potažmo význačných bodů, je zodpovědný detektor KAZE. Tato navržená metoda není zahrnuta v pokročilém kvantitativním porovnání kvůli nespolehlivé detekci význačných bodů.




Obrázek 5.8: Detail rozdílných podgrafů

5.6 Uniformní význačné body, Locatev2, SMAC

Protože dle předchozího experimentu geometrické informace o hranách grafu vystavěného nad nedostatečně spolehlivými význačnými body výsledek korespondence ve většině případů zhoršil, tento experiment uvažuje umístění význačným bodů uniformně na mřížku. Tím se omezí vliv samotného detektoru na výsledek se zachováním schopnosti vyhledat souvislý podgraf. Negativním jevem tohoto přístupu je, že obecně pro význačný bod nemusí existovat vhodný protějšek v porovnávaném obraze a porovnávaná okolí mají pouze částečný překryv. To může výrazně ovlivnit efektivitu algoritmu Locatev2, který pomocí neuronové sítě počítá podobnost vrcholů.


Matice podobnosti vrcholů K_p je tak jako v předchozím případě získána na základě výsledků porovnání programem Locatev2. Podobnost hran grafů v tomto případě nedává smysl, protože až na výjimku, kterou jsou okraje grafů, jsou vlastnosti hran v obou grafech stejné. Výsledek vyhodnocení algoritmem SMAC je ilustrován na 5.9. Zde je možné si všimnout několika korespondencí mířících do levé části umělého panorama, kde se nachází oblast očekávaného řešení i přesto, že bylo užito uniformně rozložených význačných bodů. Výsledná korespondence obsahuje také množství korespondencí úplně mimo očekávanou oblast, navíc úplně oddělenou od výsledného podgrafu.



Obrázek 5.9: Výsledek experimentu: Uniformní význačné body, Locatev2, SMAC

5.7 Náhodné význačné body, Locatev2, SMAC

Obdobou předchozího experimentu, který užívá význačné body rozložené dle pravidelné mřížky, je tento experiment, který naopak umísťuje význačné body pseudonáhodně s užitím rovnoměrného rozložení. Zbytek experimentu užívá stejného nastavení, kdy podobnost vrcholů vychází z výsledku porovnání programem Locatev2 a hrany neuvažujeme, protože jsou z principu různé. Na ilustraci 5.10 je zobrazen výsledek tohoto experimentu. Za zmínku stojí, že přes naprosto rozdílně umístěné význačné body, y má výsledek obdobné charakteristiky jako předchozí experiment.




Obrázek 5.10: Výsledek experimentu: Náhodné význačné body, Locatev2, SMAC, pouze podobnost vrcholů

5.8 Význačné body v lokálních extrémech, Locatev2, SMAC


Jako jednoduchý a alespoň trochu spolehlivý detektor význačných bodů se jeví vyhledání lokálních extrémů na linii horizontu, případně i dalších vodorovných hran. Nevýhodou této detekce je, že určení extrémů není invariantní vůči rotaci obrazu.

Podobnost vrcholů je získána algoritmem Locatev2. V tomto případě jsou vrcholy umístěny na základě alespoň slabé sémantické informace. Proto jsou uvažovány také podobnosti hran grafů. Takto specifikovaný problém je, obdobně jako v předchozích případech, řešen algoritmem SMAC. Výsledek nalezené korespondence pro význačné body na linii horizontu je ilustrován obrázkem 5.11. Výsledná korespondence pro význačné body ve všech lokálních extrémech potom na obrázku 5.12.




Obrázek 5.11: Lokální extrémy linie horizontu, Locatev2, SMAC

Ani v jednom případě nedošlo ke spolehlivému řešení, které by se přiblížilo očekávanému správnému výsledku. Nalezená korespondence trpí přílišnými deformacemi případně vyhledáním korespondence zcela mimo očekávanou oblast.



(a) Nalezená korespondence




(b) Nalezená korespondence

Obrázek 5.12: Význačné body v lokálních extrémech, Locatev2, SMAC

5.9 KAZE, Locatev2, Dual decomposition

Další experiment je zaměřen na použití algoritmu Dual decomposition[36] pro vyhledání korespondence grafů. Tento algoritmus byl spuštěn nad význačnými body detekovanými pomocí detektoru KAZE. Pro získání podobnosti význačných bodů je užito deskriptoru Locatev2. Graf je sestaven pomocí Delaunayho triangulace a převeden do reprezentace požadované algoritmem Dual decomposition. Podobnost vrcholů vstupuje do algoritmu jako hodnota ovlivňující výběr dané korespondence vrcholů. Podobnosti hran nejsou použity, protože algoritmus Dual decomposition je neuvažuje.

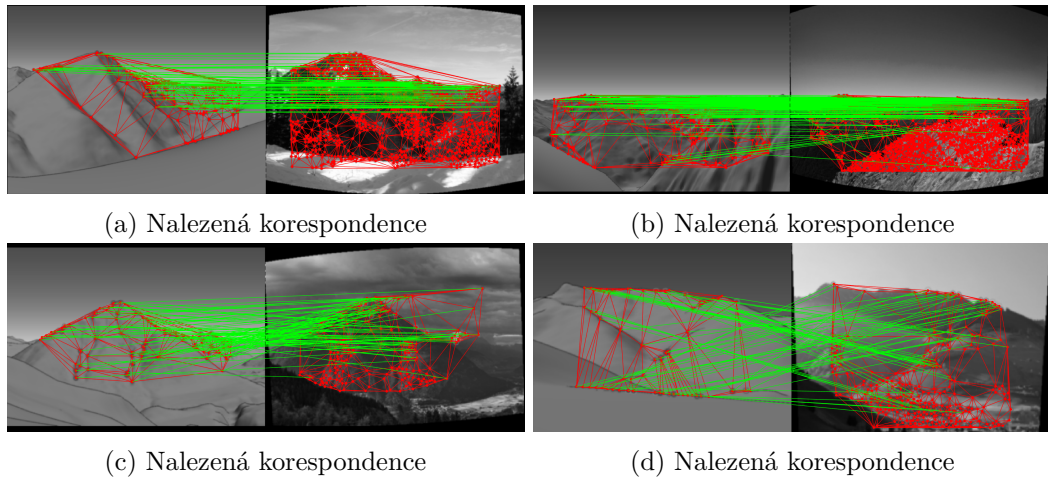


Obrázek 5.13: Nalezená korespondence algoritmem Dual decomposition


Ani tento výsledek nesvědčí o použitelnosti této navržené metody. Jak lze vidět na ilustracích 5.13 a 5.14, vypočtené korespondence jsou porušeny deformacemi a rozdělením výsledných korespondencí na nesouvisející komponenty. Zároveň tato navržená metoda vyžaduje užití deskriptoru Locatev2 společně s algoritmem Dual decomposition, jež způsobuje velkou časovou náročnost výpočtu.

5.10 Uniformní význačné body, Shape context, SMAC


Cílem tohoto experimentu je zjistit, jak se bude řešení chovat při využití deskriptoru význačného bodu Shape context místo doposavad testovaného deskriptoru Locatev2. Experiment pracuje s uniformně rozmístěnými význačnými body v umělém panoramatu vždy ve vzdálenosti shodné s velikostí jednoho okolí význačného bodu. Význačné body ve fotografii jsou vzorkovány v menších vzdálenostech. Pro každý bod je vypočten deskriptor Shape context, který je použit pro výpočet matice podobnosti vrcholů K_p . Jako vrcholy grafu jsou vybrány pouze ty význačné body pro které existuje alespoň jeden dostatečně podobný protějšek.



Obrázek 5.14: Korespondence vypočtená algoritmem Dual decomposition



(a) Význačné body ve fotografii



(b) Význačné body v panoramatu


Obrázek 5.15: Porovnání význačných bodů pomocí deskriptoru Shape context

Výsledek tohoto experimentu ukázal, že tento způsob nevede ani k přibližnému řešení. Při analýze výsledku po jeho jednotlivých krocích bylo zjištěno, že problém nastává již při výběru vrcholů pomocí porovnání význačných bodů pomocí Shape context deskriptoru. Význačných bodů, které jsou vybrány jako kandidáti na vrcholy grafu, je nedostatečný počet a jsou rozmístěny v nevhodných shlucích. Z důvodu nedostatečné přesnosti není tento navržený postup vhodný k dalšímu rozvíjení a nebude zahrnut do celkového porovnání otes-


tovaných řešení. Ukázka výsledku je na ilustraci 5.15, kde červeně jsou vykresleny všechny význačné body a modře kandidáti na vrcholy grafu.

5.11 Rohy pomocí operátoru Compass, GMMC

Další navrženou kombinací kroků pro řešení úlohy je vyhledání rohů pomocí operátoru Compass a následné zpracování algoritmem Graph matching using Monte Carlo tree search. Ukázka výsledku provedeného testu je na obrázku 5.16. Při manuální analýze se ukázalo, že v některých případech je tato metoda schopna nalézt řešení blízké požadovanému výsledku. Vyhledané korespondence nejsou výrazně deformovány ani rozloženy do oddělených nesouvisajících komponent. Zároveň vybrané korespondence jsou omezeny pouze na takové, které vyhovují geometrickému modelu a není třeba je následně filtrovat pro odstranění nevhodných korespondencí. Tato navržená metoda byla na základě manuální analýzy vybrána pro podrobné otestování a porovnání s ostatními metodami.



(a) Korespondence nalezená kombinací Compass GMMC



(b) Výsledek zarovnání zjištěný kombinací Compass GMMC

Obrázek 5.16: Korespondence nalezená kombinací Compass GMMC


5.12 Rohy pomocí operátoru Compass, DGM

Rohy v obraze detekované pomocí operátoru Compass byly význačnými body také pro vyhledání korespondence algoritmem Deformable graph matching. I v tomto případě se získané výsledky v některých případech blíží očekávanému řešení a metoda tedy byla následně zahrnuta do kvantitativního porovnání.

V případě této metody je důležité manuální přezkoumání vypočtených korespondencí. Jak je vidět na obrázku 5.17, tak i relativně úspěšný výsledek obsahuje mnoho chybných korespondencí, které negativně ovlivňují přesnost řešení. Všechny nalezené korespondence jsou součástí optimálního řešení pro vyhledání korespondence grafů z obecného hlediska.

Pouze některé z nich jsou smysluplné a použitelné z pohledu úlohy registrace fotografie do umělého panoramatu. Chybné korespondence jsou ve výsledku přítomny z důvodu vyšší hustoty význačných bodů ve vstupní fotografii než v syntetickém panoramatu. Algoritmus Deformable graph matching potom nalezne maximální společný podgraf, který obsahuje i nevhodné korespondence.

Lze očekávat, že odstraněním přebytečných korespondencí, například na základě spojitého řešení jak bylo popsáno v kapitole 3.6.3, by se přesnost získaného výsledku výrazně zvýšila. Tato úprava se do tohoto algoritmu nepodařila zapojit.



(a) Korespondence nalezená kombinací Compass DGM



(b) Výsledek zarovnání zjištěný kombinací Compass DGM

Obrázek 5.17: Korespondence nalezená kombinací Compass DGM


5.13 Edge geometry GMMC

Poslední navržená metoda je založena na vyhledání korespondence grafů algoritmem Graph matching using Monte Carlo tree search při využití geometrie hran detekovaných ve vstupních obrazech. Stejně tak jako v předchozích případech, byla metoda otestována na několika vzorcích dat. Příklad výsledku je na obrázku 5.18.


Dle provedených testů a měření tato metoda v některých případech vypočte korespondenci, která je zatížena poměrně velkou chybou, ale z celkového pohledu se k blíží oblasti očekávaného řešení. Takový příklad je ilustrován obrázkem 5.18a.

Takové řešení je založeno na značně chybné korespondenci grafů. Příkladem je ilustrace 5.18b. Vyhledané korespondence jsou vybrány z korektní oblasti, ale velká část je vybrána chybně. Tento jev je nejspíše způsoben velmi nespolehlivým výběrem vrcholů. Přestože se metoda snaží o vylepšení hranové reprezentace a doplnění grafu o chybějící hrany, význačné body jsou umístěny příliš odlišně. Tento jev je ilustrován na obrázku 5.18c, který je detailem vybraným z obrázku 5.18a. Vlevo je hranová reprezentace získaná z panoramatu. Vpravo je stejná oblast extrahovaná ze vstupní fotografie. Zde je vidět výrazný rozdíl v segmentaci hran, která má vliv na umístění význačných bodů. Následkem je velmi rozdílné umístění vrcholů grafů a také deskriptor hrany, který je vypočten z jiného úseku hrany.


Vzhledem k tomu, že se metoda v několika případech přiblížila očekávanému řešení, byla zahrnuta do kvantitativního porovnání.



(a) Výsledek registrace fotografie do panoramatu



(b) Nalezená korespondence grafů panoramatu a fotografie



(c) Detailní porovnání segmentace hran a umístění význačných bodů

Obrázek 5.18: Korespondence nalezená metodou Edge geometry DGM


5.14 Porovnání metod

Na základě předchozích experimentů byla vybrána tři navržená řešení jako vhodná pro podrobnější zkoumání a další výzkum. Těmito návrhy jsou představené kombinace algoritmů Compass s DGM, Compass s GMMC a GMMC hledající korespondenci na základě geometrie hran. Porovnání bylo zaměřené na přesnost vyhledání korespondence a čas výpočtu.

Tři zvolená řešení byla otestována na počítači s konfigurací procesoru Intel i5 Ivy Bridge 2,4GHz a 16GB operační paměti na testovací množině 62 příkladů. Velikost vstupních panoramat v testovací sadě byla vždy shodně 4096x1094 pixelů. Korespondence byla vyhledávána s fotografiemi o velikosti 438x438 a v několika případech 312x210 pixelů. K dispozici metodám byly syntetické panorama, hranová reprezentace siluet modelu terénu a fotografie, jejíž rozlišení bylo srovnáno dle měřítka panoramatu.

Přesnost vyhledání korespondence byla vyhodnocena jako odchylka od referenčního řešení měřená pomocí eukleidovské vzdálenosti referenčního a vypočteného umístění fotografie v panoramatu. Tato vzdálenost je udávána v pixelech. Největší možnou odchylkou je vzdálenost 4239 pixelů, což odpovídá délce úhlopříčky panoramatu. Výsledek měření přesnosti vyhledání korespondence je ilustrován grafem 5.19. Svislá osa udává odchylku od referenč-

ního řešení v pixelech. Na vodorovné ose jsou vyneseny jednotlivé testy. Pro každý test graf znázorňuje výsledek pro všechny tři naměřené metody, které jsou odlišeny barevně. Kromě jednotlivých výsledků graf také zobrazuje průměrnou přesnost metody pomocí linie v odpovídající barvě.



Obrázek 5.19: Porovnání odchylek od správného řešení

Jak si lze všimnout, průměrné hodnoty přesnosti zarovnání fotografie na základě vyhledání korespondence se u všech metod pohybují mezi 600 a 900 pixely, což v praxi není použitelná přesnost. Vzhledem k tomu, že výsledky mají velký rozptyl hodnot, průměrná odchylka vzdálenosti od referenčního řešení není nejlepší variantou jak vyhodnotit přesnost metody. Významnější údaj než průměrná přesnost je rozhodnutí, zda se metoda zachovala pouze nepřesně, ale její výsledek odpovídá očekávání nebo jde o naprosto chybnou korespondenci. Pro získání této podrobnější informace byly výsledky testů ještě dodatečně ručně analyzovány. V případě, že se výsledek blíží referenčnímu řešení a odchylka je způsobena nepřesností některých korespondencí, je výsledek ohodnocen jako úspěšný. Naopak v případě, že je malé odchylky dosaženo pouze příznivou konstelací chybných korespondencí, například vlivem průměrování, takový výsledek je považován za neúspěšný. V případě metody Compass DGM, jejíž výsledek je vždy zkrácen velkým množstvím nadbytečných korespondencí, je za úspěch považováno, když výsledek obsahuje nezanedbatelné množství správných korespondencí. Tyto údaje změřené na základě ruční analýzy jsou uvedeny v tabulce 5.2.

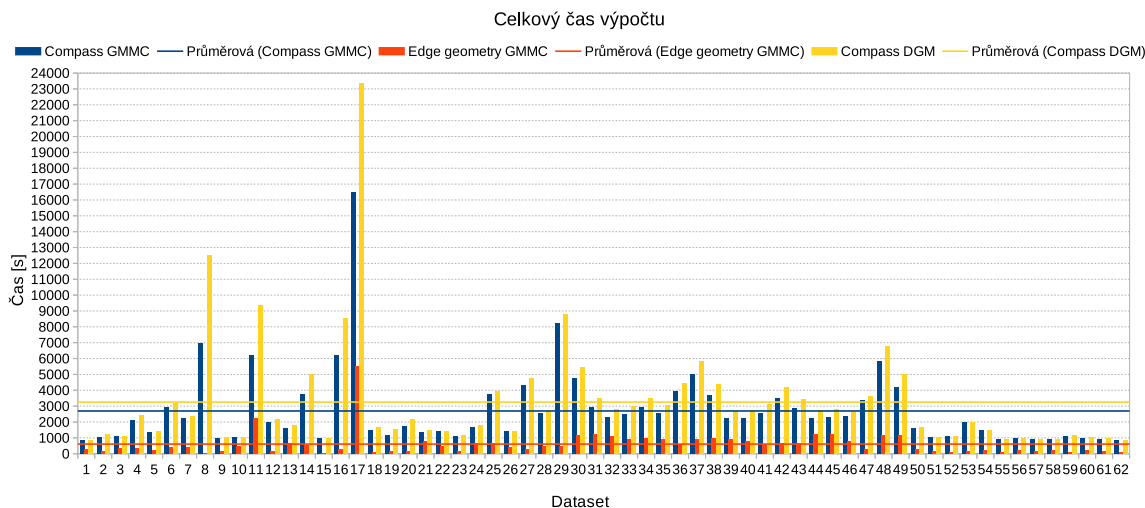
Tabulka 5.2: Ručně analyzované porovnání metod

Metoda	Úspěšná řešení	Neúspěšná řešení	Úspěšnost
Compass GMMC	19	43	30,6%
Edge geometry GMMC	4	58	6,5%
Compass DGM	20	42	32,2%

Nejpřesnější měřenou metodou je metoda Compass DGM, která dosáhla nejvyšší přesnosti jak při měření pomocí odchylky od referenčního řešení, tak při manuální analýze. Zároveň je nutné dodat, že jak již bylo uvedeno dříve v kapitole 5.12, změřené výsledky metody Compass DGM jsou výrazně ovlivněny nadbytečnými korespondencemi, které se


nepodařilo přijatelným způsobem odfiltrovat. Lze tedy předpokládat, že možnosti této metody jsou daleko větší, než jak prezentuje toto srovnání.

Druhou sledovanou charakteristikou je čas výpočtu, která je ilustrována na grafu 5.20. Celkový čas výpočtu je součtem času detekce význačných bodů, vystavení grafu včetně jeho předzpracování a délka běhu algoritmu pro vyhledání korespondence. Z pohledu doby běhu výpočtu je nejlepší volbou metoda Edge geometry GMMC, jejíž průměrný čas je násobně nižší.



Obrázek 5.20: Porovnání celkového času výpočtu

Pohledem na porovnání průměrných časů jednotlivých kroků výpočtů na grafu 5.21 lze zjistit, že za větší časovou náročnost dvou pomalejších metod může zejména detekce rohů za využití operátoru Compass, která byla užita v obou metodách a vyžádala si většinu času výpočtu. Vlivy kroku pro vystavení grafů a algoritmu pro samotné vyhledání korespondence nejsou v porovnání s detekcí význačných bodů zdaleka tak výrazné.



Obrázek 5.21: Porovnání průměrných časů jednotlivých kroků výpočtu

Při uvážení všech sledovaných veličin lze v případě tří porovnávaných metod pozorovat přímou úměru mezi časovou náročností a přesností. Nejrychleji avšak s nejmenší přesností pracovala metoda Edge geometry GMMC. Významně přesněji a zároveň také výrazně pomaleji pracovaly metody Compass GMMC a Compass DGM. Nejlepších výsledků z hlediska přesnosti potom v nejdelším čase dosáhla metoda Compass DGM.

Při detailnějším pohledu na jednotlivé kroky výpočtu a uvážení informace, že byly použity kombinace dvou typů detektorů pro extrakci příznaků a dvou metod pro vyhledání

korespondence, je možné si všimnout, že výrazně přesnější výsledek poskytly metody pracující nad význačnými body detekovanými jako rohy s využitím operátoru Compass. Naopak výběr metody pro vyhledání korespondence nevykazuje tak výrazný vliv na přesnost výsledku.

Kapitola 6

Diskuse

Cílem práce představené tímto dokumentem je registrace fotografií do 3D modelu terénu v prostředí hor. Přesněji jde o návrh a experimentální ověření možností pro vylepšení existujících metod. Zvoleným postupem pro dosažení cíle úlohy je využití grafů a grafových algoritmů pro vyhledání korespondence fotografie a umělého panorama.

Řešená úloha ve zvoleném formátu se ukázala být netriviálním problémem přesahujícím rozsah této práce. Tato kapitola tedy pojednává o stavu provedené práce a znalostech, které práce přinesla. Na základě těchto znalostí také doporučuje, jakým způsobem je vhodné danou problematiku dále řešit.

6.1 Aktuální stav řešení

V rámci práce se podařilo zmapovat některá základní řešení pro lokalizaci obrázků v horském terénu, které již byla v minulosti prezentována. Na základě této znalosti bylo navrženo několik nových postupů pro řešení úlohy. Navržená řešení byla implementována a experimentálně zkoumána. Dle provedených experimentů většina z nich nepřinesla velký přínos do řešené problematiky.

Za nejúspěšnější navržená a ve formě prototypu realizovaná řešení lze pokládat dvě představené metody, které konstruuji grafy nad vstupními daty na základě pokročilé detekce rohů využívající operátor Compass. První z nich vyhledá korespondenci mezi grafy pomocí algoritmu Deformable graph matching. Druhá využívá Graph matching using Monte Carlo tree search. Přestože tyto dvě metody jsou nejúspěšnější z navržených, obě byly vyhodnoceny jako funkční pouze ve 30% testovacích vzorků a to při značné nepřesnosti a časové náročnosti. V porovnání s již existujícími metodami, které využívají převážně principu korelace siluet terénu, nepřinášejí navržené metody vylepšení.

Z důvodu dosažené přesnosti navržených řešení není řešení robustní vůči rotaci fotografie. Zároveň výstupem není fotografie registrovaná do umělého panoramatu pomocí warpingu, nýbrž fotografie umístěná na základě průměrné transformace.

6.2 Klíčové problémy

Z provedené práce vyplývá, že pro řešení úlohy na dané úrovni jsou klíčové dva kroky, které mají obrovský vliv na výsledek. Těmi klíčovými kroky jsou detekce význačných bodů ve vstupních obrazech a algoritmus provádějící vyhledání korespondence grafů. O něco méně

významnými úlohami jsou předzpracování vstupních dat, způsob porovnávání vrcholů a hran grafů. Také je nutné řešit umístění fotografie do panoramatu.

6.2.1 Detekce význačných bodů

Detekce vhodných význačných bodů ve vstupních obrazech, kterými jsou typově naprosto odlišná data, se ukázala být velmi těžkým problémem. Zároveň však z porovnání navržených metod vyplývá, že právě tento krok má největší vliv na výsledek celé úlohy.

Vhodnými kandidáty pro detekci význačných bodů jsou takové příznaky v obraze, které nesou nějakou sémantickou hodnotu a nacházejí se shodně ve fotografii i umělém panoramatu. Takovými příznaky jsou například siluety terénu, které využívá většina existujících řešení, nebo hory a údolí, jež byly vyzkoušeny v rámci této práce.

Dle naměřených výsledků se nejlepším uvažovaným detektorem stal detektor rohů pracující díky operátoru Compass. Tento způsob detekce je výpočetně velmi náročný a proto jej nelze použít v časově kritických aplikacích. Na druhou stranu právě tento způsob detekce má potenciál ke zlepšení přesnosti i velké rezervy pro optimalizaci náročnosti výpočtu.

Nejúspěšnějšími příznaky pro porovnání vstupních obrazů, které byly užity v existujících metodách, jsou siluety terénu. Využití samotných hran pro vystavení grafů se neukázalo být vhodným řešením. Pravděpodobně se snahou o popis hran pomocí grafu ztrácí příliš mnoho užitečných informací. Další rozvoj metody založené na hranách extrahovaných ze vstupních obrazů má pravděpodobně smysl pouze při dosažení velké přesnosti detekce a segmentace hran tak, aby hrany představovaly vstupní data vyhovující algoritmu Graph matching using Monte Carlo tree search. To znamená, že při umístění vrcholů grafu do styčných bodů a použitím hran spojujících styčné body vznikne souvislý graf.

6.2.2 Algoritmus vyhledání korespondence grafů

Druhým klíčovým problémem pro řešení úlohy je algoritmus, provádějící vyhledání korespondence mezi vstupními grafy. Tento algoritmus musí pro účely úlohy splňovat několik základních vlastností. První požadovanou vlastností je vyhledání korespondujícího grafu, který je souvislý a nerozpadá se na nezávislé komponenty. Druhou nutnou charakteristikou je vyhledání pouze těch korespondencí, které mají podobné geometrické vlastnosti. Například vyhovují globálnímu geometrickému modelu. Zároveň by algoritmus neměl vyhledávat chybné korespondence. Pokud takovou vlastnost nemá již ze svého principu, potom musí existovat způsob, jak tyto korespondence identifikovat a filtrovat. Tato práce se zaměřila převážně na tři algoritmy pro hledání korespondence grafů. Jsou jimi Spectral matching with affine constraint, Deformable graph matching a Graph matching using Monte Carlo tree search.

První zmíněný, algoritmus Spectral matching with affine constraint, byl využíván převážně v prvních etapách práce. Jde o rychlý algoritmus s možností vylepšení výsledku pomocí prahování na základě spojitého řešení, které poskytuje. Tento algoritmus se ukázal být nevhodným, protože nesplňuje podmínky vyhledání spojitého grafu a zachování dostatečné podobnosti geometrických vlastností vyhledaných korespondencí. Užití tohoto algoritmu pro další práci na úloze není ideální. Algoritmus by bylo třeba upravit tak, aby uvažoval globální geometrický model, vůči kterému by vybrané korespondence ověřoval.

Algoritmus Deformable graph matching je již výrazně vhodnější volbou pro další práci na úloze. Přestože ve svém původním provedení trpí nadbytečnými chybnými korespondencemi, které mají negativní vliv na výsledek, je algoritmus dle provedených experimentů

použitelný a jeho další zkoumání má smysl. Potenciál algoritmu lze zásadně zvýšit nalezením efektivní metody k odstranění chybných korespondencí. Pravděpodobně by mělo být možné využít mezivýsledky jednotlivých iterací algoritmu, které mají podobu spojitého řešení korespondence. Za tímto účelem byla také provedena snaha o konzultaci s autory algoritmu, která však zůstala bez odezvy.

Poslední algoritmus, který se ukázal být využitelný, je Graph matching using Monte Carlo tree search. Ten byl pro účely úlohy využit po osobní konzultaci s jeho autory. Výhodnou tohoto algoritmu je jeho rychlost, globální geometrický model a přirozené udržení spojitosti korespondujícího grafu. Zároveň se ve výsledku algoritmu nenacházejí chybné korespondence společně se správnými. Nevýhodou je, že výsledek obsahuje pouze malé množství korespondencí, které sice určí správnou korespondenci, ale nepokrývají dostatečně plochu porovnávaných vstupních obrazů. Pravděpodobně také nebyl využit plný potenciál algoritmu, protože jedním z důležitých principů algoritmu je využití deskriptoru hran, které se nepodařilo získat v dostatečně přesně. Zde je tedy stále prostor pro vylepšení.

6.3 Návrh dalšího vývoje

Jak již zaznělo a vyplynulo z výsledků provedených experimentů, navržená řešení úlohy neposkytují vylepšení oproti zmapovaným již existujícím řešením. Přesto se ukázalo, že navržený princip v některých případech může fungovat a má tedy smysl v řešení úlohy pokračovat.

Prvním krokem vhodným pro další postup je jednoznačně vytvoření spolehlivého detektoru význačných bodů. Zde může být užitečné rozvíjet pokročilou detekci rohů, případně zvolit jiný způsob detekce vrcholů hor a sedel. Dále je vhodné zapracovat na větší přesnosti a spolehlivosti algoritmů pro vyhledání korespondence grafů. Oba navržené kandidáty, kterými jsou Graph matching using Monte Carlo tree search a Deformable graph matching, stále poskytují prostor pro vylepšení. Následně by bylo vhodné pracovat na předzpracování vstupních dat například segmentací oblohy, které může výrazně zjednodušit práci a zpřesnit výsledek. Stejně tak bude v případě dostatečně přesných korespondencí vhodné zaměřit jednoduché vložení fotografie do panoramatu za warping.

Kapitola 7

Závěr

V této zprávě byla zdokumentována diplomová práce, která se zabývá řešením úlohy registrace fotografií do 3D modelu terénu se zaměřením na využití grafových algoritmů. Počátek práce byl věnován důležitým teoretickým základům a přehledu existujících řešení úlohy, jež lze nalézt v literatuře. Tyto teoretické informace byly poté doplněny o možnosti řešení úlohy zejména z hlediska obecného postupu a jednotlivých krocích úlohy, kterými jsou detekce význačných bodů ve vstupních obrazových datech, konstrukce grafů a možnosti vyhledání jejich korespondence. Na základě těchto informací bylo prezentováno několik návrhů řešení úlohy. Představené návrhy byly implementovány za účelem jejich experimentálního ověření. K implementaci se vztahují popis implementačních detailů a přehled použitých nástrojů, které byly zdokumentovány v kapitole Realizace. Následující kapitola detailně popsala provedené experimenty včetně získaných výsledků. Poslední kapitola je věnována diskusi stavu řešení, zhodnocení dosažených výsledků a detailním doporučením pro další rozvoj úlohy.

V rámci diplomové práce se podařilo projít některá existující řešení úlohy. Převážná většina z těchto zdrojů používá k řešení úlohy korelaci siluet terénu na fotografii a v modelu. Na rozdíl od tohoto postupu bylo navrženo využití korespondenci grafů postavených nad vstupními daty a úlohu registrace dvou obrazů řešit jako problém vyhledání korespondence grafů. Proto bylo třeba se seznámit s možnostmi detekce význačných bodů v obraze, problematikou grafů a algoritmů pro vyhledání jejich korespondence.

Na základě těchto nabytých znalostí podporených průběžnými experimenty byl navržen obecný postup řešení. Pro každý krok obecného řešení bylo navrženo několik možností. Dosazením smysluplných kombinací uvažovaných možností do obecného řešení vzniklo devět konkrétních pracovních postupů, které byly následně implementovány ve formě skriptů za účelem jejich experimentálního ověření.

Pomocí provedených experimentů bylo zjištěno, že pouze tři z navržených řešení jsou alespoň v ojedinělých případech schopny dosáhnout požadovaného výsledku. Tyto tři metody byly následně změřeny kvantitativním testem, který na základě přibližně 30% úspěšnosti označil dvě metody jako vhodné pro další zkoumání.

Přínosem práce je ověření, že úloha registrace fotografie do 3D modelu horského terénu je za příznivých podmínek řešitelná pomocí hledání korespondence grafů vystavených na fotografií a umělým panoramatem, což je pro tuto úlohu inovativní přístup.

V porovnání s již existujícími metodami jsou navržená řešení podprůměrná. Je zde ale velký prostor pro další rozvoj. Nejdůležitějším problémem, který je třeba řešit a který nejvíce negativně ovlivnil výsledky navržených metod, je vytvoření spolehlivého detektoru význačných bodů ve vstupních obrazech. Dále je vhodné se zaměřit na přesnost algoritmů pro vyhledání korespondence grafů. Výchozími body pro tento krok mohou být použité

algoritmy Factorized graph matching či Graph matching using Monte Carlo tree search. Následně bude vhodné vylepšit přesnost výsledku odstraněním oblohy ze vstupní fotografie a pro umístění fotografie do panoramatu užít warping místo rigidní transformace. Vhodným pokračováním po zvládnutí všech nastíněných vylepšení je rozšíření řešení tak, aby pracovalo ve tří-dimenzionálním prostoru.

Literatura

- [1] Alcantarilla, P. F.; Bartoli, A.; Davison, A. J.: KAZE features. In *European Conference on Computer Vision*, Springer, 2012, s. 214–227.
- [2] Baatz, G.: *Visual location recognition in man-made and natural environments*. Dizertační práce, Diss., Eidgenössische Technische Hochschule ETH Zürich, 2013.
- [3] Baatz, G.; Saurer, O.; Köser, K.; aj.: Large scale visual geo-localization of images in mountainous terrain. In *Computer Vision–ECCV 2012*, Springer, 2012, s. 517–530.
- [4] Baboud, L.; Čadík, M.; Eisemann, E.; aj.: Automatic photo-to-terrain alignment for the annotation of mountain pictures. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, IEEE, 2011, s. 41–48.
- [5] Belongie, S.; Malik, J.: Matching with shape contexts. In *2000 Proceedings Workshop on Content-based Access of Image and Video Libraries*, 2000, s. 20–26, doi:10.1109/IVL.2000.853834.
- [6] Belongie, S.; Malik, J.; Puzicha, J.: Shape context: A new descriptor for shape matching and object recognition. In *NIPS*, ročník 2, 2000, str. 3.
- [7] Belongie, S.; Malik, J.; Puzicha, J.: Matching shapes. In *Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001*, ročník 1, 2001, s. 454–461 vol.1, doi:10.1109/ICCV.2001.937552.
- [8] Belongie, S.; Malik, J.; Puzicha, J.: Shape matching and object recognition using shape contexts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 24, č. 4, Apr 2002: s. 509–522, ISSN 0162-8828, doi:10.1109/34.993558.
- [9] Brown, M.; Lowe, D. G.: Recognising panoramas. In *ICCV*, ročník 3, 2003, str. 1218.
- [10] Brown, M.; Lowe, D. G.: Automatic panoramic image stitching using invariant features. *International journal of computer vision*, ročník 74, č. 1, 2007: s. 59–73.
- [11] Chen, Y.; Qian, G.; Gunda, K.; aj.: Camera geolocation from mountain images. In *Information Fusion (Fusion), 2015 18th International Conference on*, IEEE, 2015, s. 1587–1596.
- [12] Chippendale, P.; Zanin, M.; Dalla Mura, M.: Geo-positional Image Forensics through Scene-terrain Registration. In *VISAPP (2)*, Citeseer, 2013, s. 41–47.
- [13] Cho, M.; Lee, J.; Lee, K. M.: Reweighted Random Walks for Graph Matching. In *Computer Vision – ECCV 2010: 11th European Conference on Computer Vision*,

Heraklion, Crete, Greece, September 5-11, 2010, Proceedings, Part V, Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, ISBN 978-3-642-15555-0, s. 492–505, doi:10.1007/978-3-642-15555-0_36.

- [14] Conte, D.; Foggia, P.; Sansone, C.; aj.: Thirty years of graph matching in pattern recognition. *International journal of pattern recognition and artificial intelligence*, ročník 18, č. 03, 2004: s. 265–298.
- [15] Cour, T.; Srinivasan, P.; Shi, J.: *Balanced Graph Matching*. MIT Press, 2007, s. 313–320.
- [16] Demel, J.: *Grafy a jejich aplikace*. Academia, 2002.
- [17] Di, X.: *SIFT Feature Extraction*. MathWorld–File exchange, [Online; navštíveno 20.11.2016].
URL <https://www.mathworks.com/matlabcentral/fileexchange/50319-sift-feature-extreaction>
- [18] Fedorov, R.: *Mountain peak detection in online social media*. Diplomová práce, Politecnico di Milano, 2013.
- [19] Fedorov, R.; Fraternali, P.; Tagliasacchi, M.: Mountain peak identification in visual content based on coarse digital elevation models. In *Proceedings of the 3rd ACM International Workshop on Multimedia Analysis for Ecological Data*, ACM, 2014, s. 7–11.
- [20] Gold, S.; Rangarajan, A.: A graduated assignment algorithm for graph matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 18, č. 4, Apr 1996: s. 377–388, ISSN 0162-8828, doi:10.1109/34.491619.
- [21] Gudimella, A.: *Project 2: Local Feature Matching*. [Online; navštíveno 16.11.2016].
URL <http://www.cc.gatech.edu/~hays/compvision/results/proj2/html/agudimella3/index.html>
- [22] Jia, J.; Tang, C.-K.: Image stitching using structure deformation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 30, č. 4, 2008: s. 617–631.
- [23] Lavin, M.: Analysis of scenes from a moving viewpoint. *Artificial intelligence: An MIT perspective*, ročník 2, 1979: s. 185–207.
- [24] Leordeanu, M.; Hebert, M.: A spectral technique for correspondence problems using pairwise constraints. In *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*, ročník 2, Oct 2005, ISSN 1550-5499, s. 1482–1489 Vol. 2, doi:10.1109/ICCV.2005.20.
- [25] Leordeanu, M.; Hebert, M.; Sukthankar, R.: An integer projected fixed point method for graph matching and map inference. In *Advances in neural information processing systems*, 2009, s. 1114–1122.
- [26] Lowe, D. G.: Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, ročník 60, č. 2, 2004: s. 91–110.

- [27] Mura, M. D.; Zanin, M.; Andreatta, C.; aj.: Augmented reality: Fusing the real and synthetic worlds. In *2012 IEEE International Geoscience and Remote Sensing Symposium*, July 2012, ISSN 2153-6996, s. 170–173, doi:10.1109/IGARSS.2012.6351610.
- [28] Naval Jr, P. C.; Mukunoki, M.; Minoh, M.; aj.: Estimating camera position and orientation from geographical map and mountain image. In *38th Research Meeting of the Pattern Sensing Group, Society of Instrument and Control Engineers*, Citeseer, 1997.
- [29] Naveen, C.: *SIFT (Scale invariant Feature Transform) Algorithm*. MathWorld–File exchange, [Online; navštíveno 29.11.2016].
URL <https://www.mathworks.com/matlabcentral/fileexchange/43723-sift-scale-invariant-feature-transform--algorithm>
- [30] OpenCV: *2D Features framework*. [Online; navštíveno 16.11.2016].
URL http://docs.opencv.org/2.4/doc/tutorials/features2d/table_of_content_features2d/table_of_content_features2d.html#table-of-content-feature2d
- [31] Pinheiro, M. A.; Kybic, J.: Geometrical graph matching using Monte Carlo tree search. In *Image Processing (ICIP), 2015 IEEE International Conference on*, IEEE, 2015, s. 3145–3149.
- [32] Russell, B. C.; Sivic, J.; Ponce, J.; aj.: Automatic alignment of paintings and photographs depicting a 3D scene. In *2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*, Nov 2011, s. 545–552, doi:10.1109/ICCVW.2011.6130291.
- [33] Ruzon, M. A.; Tomasi, C.: Color edge detection with the compass operator. In *Computer Vision and Pattern Recognition, 1999. IEEE Computer Society Conference On.*, ročník 2, IEEE, 1999, s. 160–166.
- [34] Ruzon, M. A.; Tomasi, C.: Edge, junction, and corner detection using color distributions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 23, č. 11, Nov 2001: s. 1281–1295, ISSN 0162-8828, doi:10.1109/34.969118.
- [35] Torresani, L.; Kolmogorov, V.; Rother, C.: Feature correspondence via graph matching: Models and global optimization. *Computer Vision–ECCV 2008*, 2008: s. 596–609.
- [36] Torresani, L.; Kolmogorov, V.; Rother, C.: A dual decomposition approach to feature correspondence. *IEEE transactions on pattern analysis and machine intelligence*, ročník 35, č. 2, 2013: s. 259–271.
- [37] Wallis, W. D.: Graph Theory with Applications (J. A. Bondy and U. S. R. Murty). *SIAM Review*, ročník 21, č. 3, 07 1979: s. 429–1, copyright - Copyright] © 1979 Society for Industrial and Applied Mathematics; Last updated - 2012-03-05; CODEN - SIREAD.
URL <https://search.proquest.com/docview/926177522?accountid=17115>

- [38] Weisstein, E. W.: *Canonical Labeling*. MathWorld—A Wolfram Web Resource, [Online; navštíveno 26.12.2016].
URL <http://mathworld.wolfram.com/CanonicalLabeling.html>
- [39] Zass, R.; Shashua, A.: Probabilistic graph and hypergraph matching. In *2008 IEEE Conference on Computer Vision and Pattern Recognition*, June 2008, ISSN 1063-6919, s. 1–8, doi:10.1109/CVPR.2008.4587500.
- [40] Zhang, H.; Malik, J.: Learning a discriminative classifier using shape context distances. In *2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2003. Proceedings.*, ročník 1, June 2003, ISSN 1063-6919, s. I-242–I-247 vol.1, doi:10.1109/CVPR.2003.1211360.
- [41] Zhou, F.; De la Torre, F.: Factorized Graph Matching. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2012.
- [42] Zhou, F.; De la Torre, F.: Deformable Graph Matching. In *2013 IEEE Conference on Computer Vision and Pattern Recognition*, 2013.