# AUTOMATIZOVANÉ FOTOGRAMETRICKÉ METÓDY V PROCESE DIGITALIZÁCIE KULTÚRNEHO DEDIČSTVA





Marián Marčiš



**SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE** STAVEBNÁ FAKULTA



# AUTOMATIZOVANÉ FOTOGRAMETRICKÉ METÓDY V PROCESE DIGITALIZÁCIE KULTÚRNEHO DEDIČSTVA

Marián Marčiš

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE 2019

Všetky práva vyhradené. Nijaká časť textu nesmie byť použitá na ďalšie šírenie akoukoľvek formou bez predchádzajúceho súhlasu autorov alebo vydavateľstva.

© Ing. Marián Marčiš, PhD.

Recenzenti: prof. Dr. Ing. Karel Pavelka prof. Ing. Pavel Bartoš, PhD.

Schválila Edičná rada Stavebnej fakulty STU v Bratislave.

ISBN 978-80-227-4895-7

# OBSAH

PR	DSLOV	5
1	DIGITALIZÁCIA KULTÚRNEHO DEDIČSTVA	7
	1.1 Platná legislatíva pri ochrane pamiatkového fondu SR	7
	1.2 Koncepty dokumentácie kultúrneho dedičstva	8
	1.3 Meračské metódy dokumentácie historických objektov	9
	1.4 Výstupy meračskej dokumentácie	13
2	FOTOGRAMETRICKÉ METÓDY VYUŽITEĽNÉ PRI DIGITALIZÁCII	
	KULTÚRNEHO DEDIČSTVA	14
	2.1 Konvenčné fotogrametrické metódy	15
	2.1.1 Jednosnímková fotogrametria	15
	2.1.2 Stereofotogrametria	16
	2.1.3 Panoramatická fotogrametria	18
	2.1.4 Viacsnímková konvergentná fotogrametria	19
	2.2 Automatizované neselektívne fotogrametrické metódy	21
	2.2.1 Automatizovaná rekonštrukcia povrchu s prirodzenou textúrou	21
	2.2.2 Skenovanie pomocou štruktúrovaného svetla	24
3	AUTOMATIZOVANÁ REKONŠTRUKCIA SCÉNY A OBJEKTOV ZO SNÍMOK	26
	3.1 Rekonštrukcia scény	27
	3.1.1 Interest operátory	28
	3.1.2 Detektory významných bodov	29
	3.1.3 RANSAC	35
	3.1.4 SFM	38
	3.2 Podrobná rekonštrukcia snímaného povrchu	48
	3.2.1 Lokálne stereo-algoritmy	50
	3.2.2 Globálne stereo-algoritmy	51
	3.2.3 Multi-view stereo	53

	3.2.4 Zoznam aktuálnych stereo- a MVS-algoritmov	58
4	PRAKTICKÉ APLIKÁCIE SFM V OBLASTI KULTÚRNEHO DEDIČSTVA	64
	4.1 Miniatúrne objekty	64
	4.1.1 Hlinená nádoba	65
	4.1.2 Kamenné pečatidlo	67
	4.2 Archeológické náleziská	67
	4.2.1 Sondy	68
	4.2.2 Hroby, kostry	70
	4.3 Fasády historických budov	72
	4.4 Geodetická dokumentácia historickej budovy	73
	4.5 Využitie RPAS pre dokumentáciu hradov a pamiatok veľkých rozmerov	76
5	TESTOVANIE SYSTÉMU AGISOFT PHOTOSCAN	78
	5.1 Základnicový pomer	79
	5.2 Uhol osi záberu voči snímkovanej ploche	82
	5.3 Spracovanie ostrých hrán	84
	5.3.1 Prípad s rovnakou ohniskovou vzdialenosťou a premenlivým GSD	88
	5.3.2 Prípad s premenlivou ohniskovou vzdialenosťou – rovnaké GSD	92
	5.4 Zhrnutie poznatkov z jednotlivých testov	93
6	NÁVRH ZBERU ÚDAJOV PRE RÔZNE TYPY OBJEKTOV	96
	6.1 Ploché objekty	97
	6.1.1 Dlhé líniové objekty	99
	6.2 Objekty uzatvorené zvonka	101
	6.3 Objekty uzatvorené zvnútra	103
7	ZOZNAM POUŽITEJ LITERATÚRY	106

#### PREDSLOV

Nasledujúci učebný text by mal slúžiť najmä študentom bakalárskeho a inžinierskeho stupňa štúdia odboru Geodézia a kartografia, pretože svojim obsahom sa úzko dotýka problematiky preberanej v rámci predmetov Fotogrametria 1, Fotogrametria 2 a Aplikovaná blízka fotogrametria. Zároveň je určený aj študentom, ktorí v rámci svojich bakalárskych a diplomových prác potrebujú získať prehľad o aktuálnom stave automatizovanej tvorby 3D modelov na báze fotogrametrického spracovania digitálnych snímok. Nosnou témou je síce digitalizácia kultúrneho dedičstva, avšak uvedené technológie a algoritmy nachádzajú uplatnenie v nespočetnom množstve iných odvetví hospodárstva, ktoré vyžadujú priestorovú rekonštrukciu povrchu objektov.

Text obsahuje nielen teoretické základy automatickej orientácie snímok a generovania podrobných mračien bodov, ale sú v ňom uvedené aj konkrétne praktické príklady využiteľnosti digitálnej fotogrametrie pri dokumentácii rôznorodých objektov kultúrneho dedičstva. S touto diverzitou súvisí aj potreba akceptovania základných podmienok a obmedzení, ktoré má každá meračská metóda, fotogrametriu nevynímajúc, a tak je samostatná časť venovaná aj testovaniu limitov súčasných fotogrametrických technológií a voľbe optimálnych postupov pri fotogrametrickom meraní a spracovaní.

Autor d'akuje lektorom prof. Dr. Ing. Karlovi Pavelkovi a prof. Ing. Pavlovi Bartošovi, PhD., za trpezlivosť s prípravou textov a za upozornenia na chyby a nedostatky a doc. Ing. Marekovi Fraštiovi, PhD., za odborné rady a pripomienky.

Učebný text vznikol vďaka podpore grantového projektu agentúry KEGA MŠVVŠ SR č. 037STU-4/2016 "Modernizácia a rozvoj technologických zručností vo výučbe geodézie a fotogrametrie".

V Bratislave, október 2018

Ing. Marián Marčiš, PhD.

# 1 DIGITALIZÁCIA KULTÚRNEHO DEDIČSTVA

Vzhľadom na široké uplatnenie digitálnej fotogrametrie pri digitalizácii kultúrneho dedičstva, je na úvod vhodné uviesť aj širší pohľad na problematiku kultúrneho dedičstva ako takého. Pod pojmom kultúrne dedičstvo sa totiž rozumejú rôznorodé objekty, ktoré súvisia napr. s knižnicami, múzeami, archívmi, galériami, pamiatkami alebo audiovíziami. Dokumentácia týchto objektov v digitálnej podobe so sebou prináša veľa nesporných výhod oproti doteraz zaužívaným dokumentačným postupom. Tým sa myslí nielen na zjednodušenie a zefektívnenie bibliografických činností, kde bol rozsah a obsah bibliografického textu limitovaný, ale aj na oblasti, v ktorých je potrebné zaznamenať vzhľad a tvar dokumentovaných objektov v podobe obrazových dát a 3D modelov. Cieľom digitalizácie v rámci informatizácie v poznatkovej spoločnosti sa teda stáva jednak uchovávanie, ale aj sprístupňovanie a najmä využívanie digitálneho obsahu v rôznych oblastiach – ekonomiku, vedu, inovácie, vzdelanie a kultúru nevynímajúc (KATUŠČÁK, 2008).

#### 1.1 Platná legislatíva pri ochrane pamiatkového fondu SR

Ochrana a obnova kultúrneho dedičstva je z hľadiska slovenskej legislatívy riešená Zákonom o ochrane pamiatkového fondu č. 49/2002 Z. z., ktorý je vykonávaný Vyhláškou č. 253/2010 Z. z. v znení neskorších predpisov.

Ochrana pamiatkového fondu je v tomto zmysle súhrnom činností a opatrení zameraných na identifikáciu, výskum, evidenciu, zachovanie, obnovu, reštaurovanie, regeneráciu, využívanie a prezentáciu kultúrnych pamiatok a pamiatkových území.

Medzi orgány štátnej správy na ochranu pamiatkového fondu patria:

- a) Ministerstvo kultúry Slovenskej republiky,
- b) Pamiatkový úrad Slovenskej republiky,

c) krajské pamiatkové úrady.

Pri ochrane kultúrnej pamiatky sa kladie dôraz na predchádzanie jej ohrozeniu, poškodeniu, zničeniu alebo odcudzeniu, na trvalé udržanie jej dobrého stavu, vrátane jej prostredia a na taký spôsob využívania a prezentácie, ktorý zodpovedá jej pamiatkovej hodnote a technickému stavu.

Pod pojmom obnova kultúrnej pamiatky sa myslí súbor špecializovaných odborných činností, ktorými sa vykonáva údržba, konzervovanie, oprava, adaptácia a rekonštrukcia kultúrnej pamiatky alebo jej časti. Pre tieto činnosti je však vždy potrebné vyhotoviť špecifickú formu dokumentácie. Výskumná dokumentácia pritom môže byť vyhotovená pre umelecko-historický, architektonicko-historický, urbanisticko-historický a archeologický výskum. Súčasťou umelecko-historického a architektonicko-historického výskumu je pri nehnuteľnostiach aj ich podrobné zameranie (Vyhláška 253/2010 Z. z. §8 ods. 1 písmeno c).

Na štandardizáciu vyhotovenia dokumentácie archeologického výskumu bola vypracovaná aj Metodická pomocná inštrukcia pre vypracovanie a posudzovanie dokumentácie z archeologických výskumov, platná od 1. apríla 2011.

Ešte v r. 1966 boli na zabezpečenie odbornosti, kvality a hospodárnosti meračskej dokumentácie Ústrednou správou geodézie a kartografie vydané "Smernice pre zameriavanie pamiatkových objektov a chránených častí prírody". V smerniciach boli podrobne rozvedené geodetické metódy a v krátkosti naznačená aj možnosť využitia fotogrametrie (GÁL a kol., 1967).

V nadväznosti na súčasné technológie, ktoré prinášajú množstvo výhod z pohľadu efektívnosti a podrobnosti merania, však žiadna záväzná smernica neexistuje.

#### 1.2 Koncepty dokumentácie kultúrneho dedičstva

Dôležitým faktom, na ktorý netreba zabúdať je, že dokumentácia je komplikovaný proces a zahŕňa široké spektrum aktivít obsahujúcich meranie, testovanie a monitorovanie a získavanie textových a iných informácií. Geometria objektu nie je jediným parametrom, ktorý je potrebné zaznamenať. Je potrebné brať ohľad na všetky špecifikácie, ktoré robia objekt jedinečným a sú zmysluplné, teda aj na všetky jeho potenciálne hodnoty – architektonické, umelecké, historické, vedecké a sociálne (www.photogrammetry.ethz.ch, 2011).

Smerodajné koncepty dokumentácie kultúrneho dedičstva možno napr. podľa (www.photogrammetry.ethz.ch, 2011) bližšie špecifikovať takto:

Objektivita – objektivita je garanciou pevných základov, na ktorých možno zhodnotiť možnosti dokumentácie. Použitie akéhokoľvek špecifického súboru údajov nutne ovplyvňuje každý rozhodovací proces – spôsob, akým je meranie vykonané, podstatne ovplyvňuje ďalšie činnosti.

Hodnota – voľba registrátora (archivára) je kritická. To, čo sa dnes môže považovať za nezaujímavé, môže byť zajtra extrémne hodnotné. Dôležitosť dôkladného zaznamenania je zdôrazňovaná bežnou stratou nepatrných detailov, ktoré sa môžu stratiť pri nových konzervačných prácach, vedúc ku strate celistvosti alebo historickej evidencie.

• Učebný proces – meranie je učebný proces a je potrebný určitý čas kontaktu medzi operátorom a objektom. Hlbšie poznanie objektu umožňuje precíznejšie rozhodnutia.

Kontinuita – na dokumentáciu by sa nemalo nahliadať ako na činnosť, ktorá sa vykonáva iba v určitom obmedzenom čase. Preto by základnou požiadavkou malo byť, aby výsledky dokumentácie boli dostupné pre budúce využitie.

Štruktúra – dokumentácia by sa nemala zastaviť na povrchu. Je potrebná integrácia s inými dokumentačnými technikami.

• Dokumentačné série – informácie získané dokumentáciou môžu mať veľký rozsah a rôznorodosť, preto je nutné organizovať dostupné informácie, pre ktoré je metrické meranie prirodzenou podporou. Môžu byť pripravené série tematických kresieb (geometria, materiál,...). Špecifická séria vytvorená jedným špecialistom môže viesť k hlbšiemu pohľadu pre iných špecialistov pracujúcich na iných sériách.

Nadbytočnosť – každá časť informácie je spojená s určitou neistotou. Dokumentačné údaje by mali byť doplnené informáciou o kvalite údajov. Kontrolné procedúry ponúkajú spôsob prístupu ku kvalite.

Z uvedeného je zrejmé, že dokumentácia kultúrneho dedičstva nie je jednoduchá záležitosť a vyžaduje si často spoluprácu odborníkov z rôznych disciplín. Metóda digitálnej fotogrametrie v tomto prípade ponúka svoje služby v rôznych úrovniach a vo všetkých možných kombináciách komplexnosti objektov, vedeckých procedúr, požiadaviek na kvalitu, využiteľnosti finálnych produktov a samozrejme časových a finančných obmedzení.

#### 1.3 Meračské metódy dokumentácie historických objektov

Využitie geodézie a fotogrametrie a ich metód pri dokumentácii historických objektov sa počas dlhých rokov ich používania ukázalo ako veľmi nápomocné pri snahe o čo najpresnejšie zaznamenanie ich tvaru a polohy. Či už je požiadavkou tvorba vektorového plánu, 3D modelu alebo fotoplánu, nachádza geodézia a metódy s ňou súvisiace svoje uplatnenie pri dokumentácii väčšiny pamiatok, od miniatúrnych sošiek, cez obrazy v galériách a nástenné reliéfy až po veľkorozmerné stavby v podobe hradov a zámkov. Nie každá metóda je však vhodná na meranie každého objektu, a teda výber vhodnej metódy podlieha špecifickým vlastnostiam predmetu merania, pri ktorom sa môžu prejaviť silné aj slabé stránky jednotlivých metód.

Existujú rôzne technologické alternatívy pre meračské metódy, pomocou ktorých možno vykonať merania historických objektov. Medzi ne môžeme radiť tieto:

Jednoduché meračské metódy – ide o o najpoužívanejší spôsob merania. V tomto systéme sú body merané priamymi vzájomnými vzdialenosťami (napr. meračským pásmom), táto metóda je veľmi efektívne využívaná pokiaľ je oblasť prístupná, nie príliš veľká a zároveň je prehľadná – vývoj príručných elektronických diaľkomerov s automatickou kontrolou meraní celý tento proces výrazne zjednodušil.

**Dotykové metódy** – sú založené na registrácii súradníc hrotu sondy dotýkajúceho sa bodu, ktorý treba odmerať. Ide predovšetkým o tzv. súradnicové meracie stroje, ktoré nachádzajú využitie pri menších objektoch, napr. archeologických artefaktoch.

**Tachymetria** – metóda využívajúca meranie priestorových súradníc bodu (priestorová polárna metóda) pomocou prístrojov na to určených – univerzálnych meracích staníc a pod. Najčastejšie sa pri meraní historických objektov používa bezhranolové meranie, kde sú merané údaje získavané bez dotyku s objektom.

**Blízka fotogrametria** – je metóda umožňujúca vykonávať merania na snímkach, počítačovo asistovaná analytická fotogrametria spôsobila revolučné zmeny v tomto odvetví. Digitálne snímky, či už zo CCD kamier alebo z naskenovaných fotografií, umožňujú vytvorenie digitálneho modelu objektu, čo je proces výrazne efektívnejší, než tradičná analógová fotogrametria.

**Skenery pre blízke vzdialenosti** – skenovanie je metóda získavania bodov z objektu automaticky bez priameho kontaktu s ním, s možnosťou vytvorenia jeho trojrozmerného modelu v počítači. Existuje veľa rôznych druhov skenerov, najznámejšie sú laserové skenery a fotogrametrické (tzv. triangulačné) skenery na báze štruktúrovaného svetla.

Globálne navigačné satelitné systémy (GNSS) – umožňujú získanie decimetrovej až milimetrovej presnosti v polohe meraných bodov v závislosti od použitej metódy merania a vybavenia. Veľmi užitočné sa ukázalo ich využitie pri meraní historických objektov

10

rozložených na rozľahlých oblastiach, resp. na meranie kontrolných (vlícovacích) bodov pre spracovanie fotogrametrických leteckých alebo satelitných snímok.

Letecká a bezpilotná fotogrametria – je uznávaná metóda merania štandardne pre oblasti s väčšou rozlohou. Je využívaná najmä pri topografickom mapovaní v rôznych mierkach.

**Diaľkový prieskum (***Remote Sensing***)** – je veľmi užitočná metóda merania pomocou satelitov, pokrývajúc rozľahlé oblasti. Snímkovacie a výpočtové techniky sa tu prekrývajú s digitálnou fotogrametriou.

**Mikrogravimetria** – geofyzikálna metóda zaoberajúca sa anomáliami v tiažovom poli na zemskom povrchu, využívaná najmä na prieskum podzemných dutín akéhokoľvek pôvodu.

**Pozemný prienikový radar (GPR)** – geofyzikálna metóda využívajúca radarové pulzy na zobrazenie oblastí pod povrchom na základe odrazených signálov elektromagnetického žiarenia v mikrovlnnom pásme rádiového spektra.

**Metóda geoelektrického odporu** – umožňuje rozlišovať horninové útvary na základe rozdielneho merného odporu, permitivity alebo elektrochemickej aktivity.

**Rádionuklidové metódy (gamma žiarenie)** – využívajú premeny jadier atómov, jadrové žiarenie a pôsobenie jadrového žiarenia na hmotu, opäť využiteľné aj pri geologických aplikáciách a archeológii.

Na Obr. 1.1 sú vybrané metódy merania zoradené podľa mierky finálneho dokumentu, ktorá je súčasne funkciou veľkosti objektu a dosiahnuteľnej úrovne detailov.



**Obr. 1.1.** Výber vhodných meračských metód v závislosti od veľkosti objektu a komplexnosti (BÖHLER, 2005)

Komplexnosť merania môže byť vyjadrená množstvom zaznamenaných bodov – od jedného bodu opisujúceho geografickú polohu artefaktu, cez tisícky bodov typické pre CADkresby budov alebo topografických situácií, až po milióny bodov na opísanie celkového povrchu sochy alebo digitálneho modelu terénu.

Okrem veľkosti objektu a komplexnosti vplývajú na výber vhodnej metódy merania aj iné faktory. Sem patria: požadovaná presnosť a rozlíšenie, prístupnosť objektu a možnosť ideálneho rozloženia observačných staníc, dostupnosť prístrojov a prísun energie, možnosť dotknúť sa objektu a povolenie použiť zvolenú metódu.

Vzhľadom na rôzne obmedzenia, či silné alebo slabé stránky jednotlivých metód, je vhodné metódy aj navzájom kombinovať, a tak použiť napr. terestrické laserové skenovanie na skenovanie interiéru pamiatky, fotogrametriu na meranie jej vonkajších fasád, priestorovú polárnu metódu na zvýšenie presnosti a súdržnosti jednotlivých meraných celkov pomocou vlícovacích bodov a GNSS meranie na transformáciu výsledného modelu do referenčného súradnicového systému.

Keďže táto práca sa zaoberá predovšetkým fotogrametrickými metódami využiteľnými pri dokumentácii historických objektov, podrobne sa bude v ďalších kapitolách venovať práve technológiám založeným na spracovaní obrazu.

#### 1.4 Výstupy meračskej dokumentácie

V súčasnosti v SR neexistuje nijaký metodický návod, ktorý by sa venoval výhradne meračskej dokumentácii objektov kultúrneho dedičstva. Možno vychádzať iba zo vzorov vypracovaných v minulosti špecializovanými inštitúciami, prípadne učebných textov napr. Fakulty architektúry STU v Bratislave. Pri vzoroch ide napr. o zamerania architektonických detailov, ktoré v 80. rokoch dvadsiateho storočia spracovával Projektový ústav kultúry Bratislava (dvere, kovania, mreže, brány, okenné výplne atď.) alebo zamerania kaštieľov vykonané n. p. Geodézia Bratislava.

Naproti tomu, v susednej Českej republike má dokumentácia objektov kultúrneho dedičstva pevné základy a možno sa tak oprieť aj o aktuálne publikácie, ako napr. (BEZDĚK & FROUZ, 2014), (VESELÝ, 2014) alebo (BEZDĚK a kol., 2011).

Výstupy zväčša predstavujú výkresy v rozličných mierkach v závislosti od typu a veľkosti objektu – digitálne 3D modely sa zatiaľ ako výstup bežne nepoužívajú, slúžia skôr len ako medziprodukt na dosiahnutie iných výsledkov (2D výkresová dokumentácia, ortofotomozaiky) a aj keď sa v oblasti dokumentácie slovenských pamiatok považujú za perspektívne, cieľovou skupinou je skôr len laická verejnosť.

V zásade to pre geodetov znamená, že k pamiatkovému objektu nemožno pristupovať iba ako k predmetu, ktorý je potrebné zamerať s určitým rozlíšením a presnosťou, ale je potrebné klásť dôraz aj na jeho funkčnú konštrukciu. Konzultácia s odborníkmi na daný objekt merania je v tomto prípade skutočne na mieste.

# 2 FOTOGRAMETRICKÉ METÓDY VYUŽITEĽNÉ PRI DIGITALIZÁCII KULTÚRNEHO DEDIČSTVA

Fotogrametria je už tradičná metóda pri snahe o rekonštrukciu historických objektov a umeleckých diel. Prvé architektonické aplikácie merania fasád pochádzajú už z roku 1860 od architekta Meydenbauera, ktorý sa na základe vlastnej nepríjemnej skúsenosti rozhodol, že dokumentovať fasády katedrál je bezpečnejšie meraním na snímkach a nie priamo na objekte. S postupným zdokonaľovaním technológií sa pri tejto metóde dosahuje stále vyššia presnosť, narastá kvalita a rýchlosť spracovania výsledkov.

V súčasnosti je výstupom zvyčajne 2D alebo 3D vektorový formát, priestorové súradnice meraných bodov a ortofotoplán, ktorého hodnota je o to vyššia, pretože poskytuje cenné informácie uschované v textúre povrchu (farba, drobné trhliny, poškodenia,...).

Na dokumentáciu historických objektov sa využíva najmä blízka pozemná fotogrametria, čiže snímkovanie zo vzdialeností v rozmedzí desiatok centimetrov až 300 m od objektu. Vďaka menším vzdialenostiam a vysokej rozlišovacej schopnosti súčasných digitálnych kamier možno dosiahnuť vysokú presnosť pri tvorbe 3D modelov. Základom použitia akejkoľvek fotogrametrickej metódy je však vždy nutnosť kalibrácie fotografického systému, pričom pod pojmom kalibrácia sa rozumie určenie prvkov vnútornej orientácie kamery, medzi ktoré patria: ohnisková vzdialenosť, súradnice hlavného bodu a prvky radiálnej a decentračnej distorzie, prípadne ďalšie prídavné parametre.

Existuje široké rozpätie fotogrametrických metód, pomocou ktorých možno určovať rovinné alebo priestorové súradnice bodov objektov. Ich presnosť je závislá od mierkového čísla snímky, od použitej kamery, zvolenej metódy ako takej, spôsobu kalibrácie kamery, presnosti referenčných bodov a samozrejme od spôsobu spracovania údajov.

Jednotlivé fotogrametrické metódy možno deliť podľa rôznych aspektov, napr. podľa polohy kamery voči objektu, podľa predmetovej vzdialenosti, podľa počtu kamier alebo podľa metodiky spracovania snímok. Vzhľadom na to, že cieľom tohto textu je oboznámiť čitateľa najmä s automatizovanými fotogrametrickými metódami, ktoré vo veľkej miere využívajú prirodzenú textúru snímaného povrchu, sú ostatné metódy uvedené iba v nasledujúcom stručnom prehľade a nosnej téme bude venovaná samostatná kapitola.

#### 2.1 Konvenčné fotogrametrické metódy

Keďže majoritná časť fotogrametrie súvisí so spracovaním obrazu a nielen s jeho zaznamenaním, za najzákladnejšie delenie fotogrametrických metód možno považovať delenie podľa použitých matematických modelov spracovania. Akékoľvek iné delenie, napr. podľa polohy kamery (letecká, pozemná,...) alebo predmetovej vzdialenosti (družicová, letecká, bezpilotná, blízka, veľmi blízka alebo makrofotogrametria) je z tohto pohľadu bezpredmetné a súvisí skôr len s podrobnosťou, presnosťou a aplikačnými oblasťami výstupov.

#### 2.1.1 Jednosnímková fotogrametria

Za najjednoduchšiu z fotogrametrických metód možno považovať jednosnímkovú fotogrametriu, inak nazývanú aj projektívnu. Využíva matematický model projektívnej transformácie medzi dvoma rovinami odvodený z projektívnej geometrie alebo centrálnej projekcie roviny:

$$X = \frac{a_0 + a_1 x + a_2 y}{1 + c_1 x + c_2 y},$$

$$Y = \frac{b_0 + b_1 x + b_2 y}{1 + c_1 x + c_2 y},$$
(2.1)

kde *x*, *y* sú obrazové súradnice,  $a_0 - c_2$  sú koeficienty projektívnej transformácie a *X*, *Y* sú referenčné súradnice bodov rovinného objektu. Referenčná presnosť  $m_{X,Y}$  je v prípade digitálnej snímky závislá od mierkového čísla snímky  $M_s$ , veľkosti obrazového elementu *P* na snímači, presnosti merania obrazového elementu  $m_{pix}$  a stočenia snímky voči pozorovanej rovine. V praxi je vždy snaha o dodržanie čo najmenších sklonov snímky, vďaka čomu možno docieliť konštantnú presnosť po celej ploche snímky. Možno ju vyjadriť prostredníctvom jednoduchého vzťahu (FRAŠTIA, 2008):

$$m_X = m_Y = M_S \cdot P \cdot m_{pix} \tag{2.2}$$

Keďže projektívna transformácia platí exaktne iba pre projektívny vzťah dvoch rovín, je potrebné vždy zvážiť aj vplyv nerovinnosti objektu. Všetky odchýlky objektu od roviny totiž spôsobujú radiálny posun na snímke, ktorý potom ovplyvňuje polohu bodov v referenčnom systéme (Obr. 2.1).



Obr. 2.1. Vplyv nerovinnosti objektu (LUHMANN, 2006)

Radiálnu odchýlku  $\Delta r$  možno podľa Obr. 2.1 vyjadriť týmto vzťahom (LUHMANN, 2006):

$$\Delta r = \Delta h \frac{r'}{c}, \qquad (2.3)$$

kde *c* predstavuje konštantu kamery (ohniskovú vzdialenosť), r' je radiálna vzdialenosť meraného bodu od stredu snímky v snímkovej rovine a  $\Delta h$  odľahlosť meraného bodu *P* od referenčnej roviny v smere osi záberu.

Jednosnímková fotogrametria teda nachádza uplatnenie predovšetkým pri tvorbe fotoplánov rovinných objektov, ako sú napr. fasády budov. V praxi sa možno stretnúť s rôznymi upravenými pomôckami na využitie jednosnímkovej fotogrametrie, napr. s rôznymi variantmi monopodických statívov a visutých ramien, pomocou ktorých je možné dostať zavesenú kameru do dostatočnej výšky (4 až 5 m) nad snímkovanú sondu archeologického náleziska, aby sa radiálny posun prejavil v akceptovateľnej miere.

#### 2.1.2 Stereofotogrametria

Pomocou stereofotogrametrie už možno vyhodnotiť body na snímkovanom objekte nielen rovinne, ale priestorovo. S ohľadom na vzájomnú orientáciu snímok stereodvojice môžu nastať tri rôzne prípady:

- normálny prípad (Obr. 2.2)
- stočený prípad,
- a mierne konvergentné, resp. divergentné snímky.

Najčastejšie sa v praxi využíva normálny prípad, pre svoju jednoduchosť analytického spracovania. Stereofotogrametria umožňuje merať priestorové súradnice priamo v referenčnom systéme a keďže súčasným trendom vo vývoji automatizovaných fotogrametrických systémov je práve minimalizácia zásahov vyhodnocovateľa do procesov tvorby priestorových modelov, sú vytvárané napr. digitálne modely plne automatizovane prostredníctvom špeciálnych digitálnych pracovných staníc (fotogrametrických softvérov) (FRAŠTIA, 2008).



Obr. 2.2. Normálny prípad stereofotogrametrie

Presnosť stereofotogrametrie pre normálny prípad možno vyjadriť podľa vzťahov:

$$m_{X,Z} = 0, 7 \cdot M_s \cdot P, \qquad (2.4)$$

$$m_{\gamma} = 0.5 \cdot M_s \cdot P \cdot \frac{y}{b}, \qquad (2.5)$$

kde y je predmetová vzdialenosť, b je dĺžka snímkovacej základnice, P je veľkosť obrazového elementu a  $M_s$  je mierkové číslo snímky.

#### 2.1.3 Panoramatická fotogrametria

V špeciálnych aplikáciách nachádzajú využitie tzv. panoramatické kamery. Pomocou nich je možné napr. zameranie uzavretých vnútorných priestorov alebo námestí. Princíp panoramatických kamier spočíva v 360° rotácii lineárneho CCD senzora a ďalšom spracovaní obrazových údajov prostredníctvom priestorového pretínania a transformácií medzi objektovým súradnicovým systémom, karteziánskym a valcovým s. s. kamery a pixelovým s. s. CCD senzora (Obr. 3.3 a 3.4) (LUHMANN, 2006).



Obr. 2.3. Znázornenie súr. systémov (LUHMANN, 2006)



Obr. 2.4. Znázornenie súr. systémov (LUHMANN, 2006)

Tvorba panoramatických snímok je v súčasnosti možná pravdaže aj s použitím bežnej digitálnej kamery so známymi prvkami vnútornej orientácie a špeciálneho softvéru, ktorý dokáže zo série snímok s dostatočným prekrytom vytvoriť ponoramatický obraz (Obr. 2.4). Na internete je dostupné nespočetné množstvo programov, ktoré sú buď priamo určené na tvorbu panoramatických fotografií, alebo ponúkajú túto možnosť ako doplnkovú funkciu.



**Obr. 2.5.** Panoramatická snímka interiéru kostola Sv. Petra v Salzburgu (wikimedia.org, 2009)

### 2.1.4 Viacsnímková konvergentná fotogrametria

V súčasnosti najpoužívanejšou fotogrametrickou metódou je konvergentné snímkovanie so všeobecnou orientáciou osi záberu. Ide o viacsnímkovú metódu (Obr. 2.6), ktorá vyžaduje pre analytické spracovanie špeciálny fotogrametrický softvér. Najväčšou výhodou konvergentného snímkovania, v porovnaní napr. so stereofotogrametriou, je práve spomínaná všeobecná poloha osí záberov kamier (pravdaže vždy v snahe o dodržanie dostatočného prekrytu snímok a aby objekt na snímkach zaberal čo najväčšiu plochu) a tak pomocou tejto metódy možno merať objekty ľubovoľných tvarov a rozmerov.



Obr. 2.6. Konvergentné snímkovanie (LUHMANN, 2006)

Využívaný je matematický model perspektívnej transformácie, ktorým je vyjadrená podmienka kolineárnosti:

$$x' = x'_{0} - c \frac{m_{11}(X - X_{0}) + m_{21}(Y - Y_{0}) + m_{31}(Z - Z_{0})}{m_{13}(X - X_{0}) + m_{23}(Y - Y_{0}) + m_{33}(Z - Z_{0})},$$
  

$$y' = y'_{0} - c \frac{m_{12}(X - X_{0}) + m_{22}(Y - Y_{0}) + m_{32}(Z - Z_{0})}{m_{13}(X - X_{0}) + m_{23}(Y - Y_{0}) + m_{33}(Z - Z_{0})},$$
(2.6)

kde x', y' sú snímkové súradnice, X, Y, Z, sú referenčné súradnice, x'<sub>0</sub>, y'<sub>0</sub> sú súradnice hlavného snímkového bodu,  $m_{11}$ - $m_{33}$  sú prvky ortogonálnej rotačnej matice a  $X_0$ ,  $Y_0$ ,  $Z_0$  sú súradnice projekčného centra.

Konvergentné snímkovanie je ako metóda zároveň aj najpresnejšia, pretože tu vzhľadom na väčší počet snímok dochádza k preurčeniu určovaných súradníc bodov. Z hľadiska prácnosti je však náročnejšia než napr. stereofotogrametria, avšak tento nedostatok je riešiteľný práve vďaka využitiu výhod digitálnej fotogrametrie a možnosti čiastočnej alebo úplnej automatizácie spracovania na digitálnej pracovnej stanici. Pod týmito výhodami sú myslené napr. automatické meranie umelých terčov, automatická identifikácia kódových terčov, automatické vyhľadanie identických bodov na rôznych snímkach alebo automatická tvorba TIN modelu (FRAŠTIA, 2008).

Ako už bolo povedané, presnosť konvergentného snímkovania sa zvyšuje s narastajúcim počtom snímok, predovšetkým z rôznych stanovísk. Výslednú polohovú presnosť možno teda vyjadriť podľa tohto vzťahu (FRAŠTIA, 2008):

$$m_{p} = M_{s} \cdot m_{px} \cdot (o + v \cdot p), \qquad (2.7)$$

kde  $m_{px}$  je presnosť merania obrazových súradníc, *o* je faktor kvality prieseku a závisí od uhla prieseku určujúcich lúčov a ich počtu na danom bode, *v* je deformačný faktor a určuje skrútenie a stočenie objektu ako voľnej siete a *p* je faktor počtu a rozloženia vlícovacích bodov.

Pokiaľ bude do úvahy braná aj skutočnosť, že z jedného stanoviska bolo vyhotovených viac snímok, bude pre presnosť  $m_p$  platiť podľa (HANZL & SUKUP, 2001) približný vzťah:

$$m_p = \frac{M_s \cdot m_{px} \cdot q}{\sqrt{k}},\tag{2.8}$$

kde q je konfiguračný faktor, ktorý vyjadruje tuhosť siete a pohybuje sa v hodnotách medzi 0,4 až 0,7 a k je počet snímok vyhotovených z jedného stanoviska.

Pri dodržaní optimálnych podmienok snímkovania však možno použiť na výpočet apriórnej presnosti zjednodušený vzťah:

$$m_p = M_s . P.m_{px} = \frac{h}{f} . P.m_{px},$$
 (2.9)

kde  $M_s$  je mierkové číslo snímky, P veľkosť pixelu na CCD senzore, h vzdialenosť snímkovania, f ohnisková vzdialenosť a  $m_{nx}$  presnosť určenia obrazových súradníc.

Pri manuálnom meraní obrazových súradníc sa presnosť merania pohybuje od 1 do 3 pixelov v závislosti od kvality signalizácie, pri automatickom meraní je presnosť merania 0,1 až 0,3 pixela.

#### 2.2 Automatizované neselektívne fotogrametrické metódy

Doteraz spomínané fotogrametrické metódy merania možno označiť pojmom "selektívne", keďže výber meraných bodov závisí od interpretácie vyhodnocovateľa v snahe o čo najhodnovernejšie vystihnutie tvaru objektu prostredníctvom lomových bodov, charakteristických hrán a plôch. S členitosťou objektu však prirodzene narastá prácnosť takéhoto spôsobu spracovania a využiť v tomto prípade možnosti čiastočnej alebo úplnej automatizácie zberu údajov sa pri digitálnej fotogrametrii ponúka ako vhodné riešenie. Vzhľadom na výsledný produkt takéhoto spracovania – mračno bodov – možno tieto metódy popísať aj ako "skenovanie obrazom", čiže vytvorenie skenov (podrobných mračien bodov) na základe spracovania obrazu. Aj táto technológia však pozná rôzne prístupy, a tak môžeme získať mračno bodov objektu buď čisto na základe spracovania jeho snímok, analýzou prirodzenej povrchovej textúry, alebo využiť napr. tzv. "štruktúrované svetlo" a trianguláciu medzi projektorom a kamerou, ktorá sníma objekt.

#### 2.2.1 Automatizovaná rekonštrukcia povrchu s prirodzenou textúrou

Technológia automatizovanej rekonštrukcie povrchu zo snímok umožňuje neselektívny zber údajov s vysokým rozlíšením, a to zväčša na princípe obrazovej korelácie medzi dvoma a viacerými paralelnými snímkami objektu. Výsledkom je potom priestorové mračno bodov opisujúce tvar povrchu objektu.

Cieľom obrazovej korelácie je nájsť polohu určovaného bodu na jednej aj druhej snímke stereoskopickej dvojice za predpokladu podobnosti obrazov. Pokiaľ by veľkosť hľadaného obrazového elementu bola 1 pixel, výsledkom by bolo enormné množstvo ďalších 1-pixelových elementov, pretože digitálne snímky sa zvyčajne skladajú z miliónov pixelov, medzi ktorými sa určite nájde veľa elementov s rovnakými alebo podobnými vlastnosťami (v závislosti od korelačného koeficientu). Teória korelácie obrazu teda vychádza z predpokladu, že každý z pixelov digitálneho obrazu má svoje špecifické okolie, ktoré je do

určitej miery jedinečné. Čím väčšie okolie sa vezme do úvahy, tým väčšia bude jeho jedinečnosť a o to jednoznačnejšie bude určenie polohy elementu. Ak je však objekt príliš členitý, príliš veľká vyhľadávacia matica môže produkovať chybné výsledky alebo nenájde dostatočný počet bodov kvôli nízkej korelácii. Nastavenia výpočtu korelácie obrazu teda treba prispôsobiť druhu objektu, ktorého model sa takýmto spôsobom snažíme získať a aj úrovni konvergencie v rámci stereoskopickej dvojice snímok.

Pre dosiahnutie hodnoverných a dostatočne presných výsledkov korelácie, pri spracovaní napr. v softvéri PhotoModeler Scanner, je potrebné dodržať niekoľko základných podmienok pri snímkovaní:

- snímky objektu musia byť vyhotovené s dostatočným prekrytom,
- osi záberov kamier musia byť približne paralelné, prípadne mierne konvergentné,
- pomer medzi snímkovacou základnicou b a vzdialenosťou od objektu h by sa mal pohybovať v rozmedzí b/h = 0,1 až 0,5 (ideálne 0,25 ako je na Obr.2.7)
- povrch objektu musí obsahovať nepravidelnú zreteľnú textúru,
- obe snímky by mali byť vyhotovené za rovnakých svetelných podmienok, podľa možnosti bez použitia blesku, aby nedošlo k zmene textúry alebo odleskom.



**Obr. 2.7.** Pomer medzi základnicou a objektovou vzdialenosťou pri obrazovom skenovaní

Princípy tzv. počítačového videnia (*computer vision*) však v súčasnosti umožňujú automatizovať nielen tvorbu mračna bodov z orientovanej dvojice snímok, ale spracovať aj krok predchádzajúci – vykonanie vonkajšej orientácie snímok a kalibrácie kamery. V tomto prípade je potrebné, aby celá séria susedných snímok spĺňala vyššie uvedené parametre, aby

softvér dokázal medzi snímkami nájsť dostatočné množstvo tzv. *features* (charakteristických bodov).

V závislosti od typu objektu je potom odporúčané zabezpečiť aj vhodnú polohu a orientáciu kamier. Zjednodušene možno rozdeliť základné typy objektov do týchto troch skupín:

- rovinné (fasády,...),
- uzatvorené (interiér,...),
- izolované objekty (sochy,...).

Polohy a orientácie kamier pre jednotlivé prípady sú znázornené na Obr. 2.8 až 2.10.



Obr. 2.8. Snímkovanie fasády (vľavo nesprávne, vpravo správne) (www.agisoft.com,

2018)



Obr. 2.9. Snímkovanie interiéru (vľavo nesprávne, vpravo správne) (www.agisoft.com,

2018)



**Obr. 2.10.** Snímkovanie izolovaného objektu (vľavo nesprávne, vpravo správne) (www.agisoft.com, 2018)

Nakoľko práve oblasť počítačového videnia má vo fotogrametrii sľubnú budúcnosť a v súčasnosti veľmi široké využitie, bude táto problematika rozobratá podrobnejšie v samostatnej kapitole č. 3: Automatizovaná rekonštrukcia scény a objektov zo snímok.

#### 2.2.2 Skenovanie pomocou štruktúrovaného svetla

Kombinácia fotogrametrie a projektovania tzv. štruktúrovaného svetla na objekt je jedna z ďalších možností ako získať trojrozmerný model meraného objektu na základe obrazových dát. Vzorka, ktorá je premietaná na povrch, sa meria a tým je definovaný model povrchu, pričom môžeme rozlíšiť dva hlavné prístupy (LUHMANN, 2006):

Aktívna projekcia vzorky – geometria projektovanej vzorky je známa a používa sa vo výpočte. Táto známa geometria zahŕňa vnútornú a vonkajšiu orientáciu projektora a informáciu o vzorke, napr. rozostup a vlnovú dĺžku projektovaných prúžkov. Minimálne jedna orientovaná kamera sa používa na registráciu signálu odrazeného od povrchu objektu. Tvar povrchu môže byť rekonštruovaný fázovým alebo paralaxovým meraním.

**Pasívna projekcia vzorky** – je požadovaná znalosť kalibrácie a orientácie projektora alebo geometrie povrchu. Vzorka jednoducho poskytuje viditeľnú štruktúru definujúcu povrch. Rekonštrukcia objektu je vykonávaná fotogrametricky porovnávaním snímok z minimálne dvoch kamier, ktoré zaznamenávajú reflektovaný povrch.



Obr. 2.11. Metóda merania so štruktúrovaným svetlom (LUHMANN, 2006)

Tieto dva prístupy môžu byť kombinované. Napríklad rýchla aktívna projekčná metóda môže byť aplikovaná na hrubé meranie povrchu, ktoré je potom zjemnené použitím viacerých kamier a pasívneho osvetlenia. Tak isto môžu byť tieto prístupy kombinované s bežnými bodovo založenými fotogrametrickými meracími metódami (LUHMANN, 2006).

Použitie štruktúrovaného svetla poskytuje absolútnu metódu merania prúžkovej projekcie. Projektor generuje *m* kódovaných prúžkov sekvenčne, takže kolmo na smer prúžkov  $x_p$  môže byť identifikovaných celkom  $2^m$  rôznych projekčných smerov prostredníctvom *m*-digitálnych kódových výrazov. Získaných *m* snímok je binarizovaných a sú uložené ako bitové údaje 0 alebo 1 *m*-bit-hlbokej pamäte. Preto každá sivá hodnota na pozícii (*x'*, *y'*) dáva špecifický smer projekcie  $x_p$  z  $O_p$  (LUHMANN, 2006).

Prístroje využívajúce technológiu štruktúrovaného svetla alebo projekcie laserovej vzorky sa nazývajú triangulačné skenery a sú veľmi často využívané v strojárenskom priemysle, pri reverznom inžinierstve, ale aj pri digitalizácii archeologických artefaktov. Ponuka skenerov založených na spracovaní obrazu je v súčasnosti na trhu veľmi široká. Spoločnou vlastnosťou týchto zariadení je, že sa používajú na skenovanie prevažne menších objektov, avšak vďaka špecializovanému príslušenstvu možno menšie skeny z krátkych vzdialeností spájať do väčších celkov. Pritom sa pri skenovaní bežne používa pracovná vzdialenosť od objektu v rozmedzí približne 0,3 až 1 m s ohľadom na použitú optickú sústavu kamery. Presnosť generovaného 3D modelu pritom môže dosahovať úroveň 0,1 až 0,01 mm a je teda vhodné ich v kultúrnom dedičstve využívať najmä na digitalizáciu drobných archeologických nálezov.



**Obr. 2.12.** Triangulačné skenery COMET L∃D (vľavo) (www.steinbichler.com) a GOM ATOS (vpravo) (www.gom.com)

# 3 AUTOMATIZOVANÁ REKONŠTRUKCIA SCÉNY A OBJEKTOV ZO SNÍMOK

Súčasné metódy spracovania obrazu do podoby 3D modelov už súvisia viac s programovaním, než so samotnou fotogrametriou. Zároveň si treba uvedomiť, že drvivá väčšina bežne používaných termínov v tejto oblasti vychádza z anglického jazyka a ich silený preklad do slovenčiny môže byť diskutabilný, viaczmyselný, a teda aj kontraproduktívny. Z tohto dôvodu budú názvy niektorých algoritmov ponechané len v pôvodnej anglickej forme, prípadne s približným slovenským významom.

Softvéry využívajúce tzv. počítačové videnie na tvorbu 3D modelov majú v súčasnosti veľmi široké uplatnenie v oblastiach od leteckého mapovania, tvorby DMP (digitálneho modelu povrchu) a ortofotoplánov, cez automatizovanú tvorbu textúrovaných 3D modelov ľubovoľných objektov (na ich rekonštrukciu, dokumentáciu alebo prezentáciu), až po vysoko presné neselektívne merania deformácií. Nespornou výhodou tohto spôsobu spracovania sú pomerne nízke finančné náklady na vybavenie (softvér + hardvér).

Ponuka softvérov umožňujúcich plne automatizované spracovanie snímok do podoby 3D modelov je na trhu veľmi pestrá, od voľne poskytovaných webových aplikácií (ARC3D Webservice, Regard3D, v minulosti aj Microsoft Photosynth, Autodesk 123D Catch alebo Hyper3D), cez samostatné programy distribuované pod GPL (*general public license*) ako je VisualSFM, *open source* riešenia ako napr. Meshroom, až po komerčné softvéry typu Agisoft PhotoScan, PhotoModeler Scanner, Autodesk ReCap Photo, Bentley Context Capture, Reality Capture, 3DF Zephyr a pod. Okrem softvéru už stačí vlastniť iba kvalitnú digitálnu kameru (najčastejšie digitálnu zrkadlovku) a dostatočne výkonný počítač. Napokon sa možno dostať k nákladom, ktoré často predstavujú iba zlomok ceny laserových alebo triangulačných skenerov. Pritom časová náročnosť spracovania závisí predovšetkým od výkonnosti počítača (najmä od procesora a pamäte RAM).

Celkový problém automatizovaného spracovania snímok do podoby 3D modelov možno rozdeliť na dve základné časti, ktoré budú podrobnejšie rozobraté v nasledujúcich podkapitolách:

> rekonštrukciu scény – čiže výpočet vzájomnej orientácie snímok, kalibráciu kamery a tvorbu zjednodušeného mračna tzv. spojovacích bodov (*tie points*), ktoré približne opisujú tvar objektu,

 a podrobnú rekonštrukciu snímaného povrchu – teda výpočet hustého mračna bodov pokrývajúceho objekt, ktoré možno z hľadiska podrobnosti porovnať napr. s laserovým skenovaním.

#### 3.1 Rekonštrukcia scény

Automatizácia orientácie snímok súvisí hlavne s termínom tzv. párovania snímok (*image matching*), počas ktorého sa identifikujú a jednoznačne párujú identické prvky objektu (body, vzorky, rohy,...) na dvoch alebo viacerých snímkach. V zahraničnej literatúre sa procedúry slúžiace na identifikáciu prirodzených korešpondencií medzi snímkami označujú ako *feature-based matching procedures*.

Analýza korešpondujúcich bodov/prvkov je jedna z najkomplikovanejších úloh počítačového videnia a je veľmi závislá od štruktúry snímaného objektu. Hľadanie korešpondencií môže byť pritom komplikované rôznymi problémami, ako napr.:

- z dôvodu zákrytu nemusia mať body na jednej snímke svoj korešpondujúci obraz na inej snímke,
- pri nejednoznačných povrchových štruktúrach alebo priehľadných povrchoch môže vzniknúť viacero kandidátov na obraz jedného bodu z referenčnej snímky,
- v oblastiach so slabou textúrou sa môže stať riešenie nestabilné alebo citlivé napr. voči šumu v obraze.

Rekonštrukcia scény je potom realizovaná v procese známom ako SfM (*Structure from Motion*), v ktorom je zo snímok spätne rekonštruovaná hrubá štruktúra scény na základe pohybu kamery voči vyhodnocovanému objektu. Na extrakciu významných prvkov sú využívané tzv. *interest* (záujmové) operátory, hranové operátory alebo tzv. detektory, ktoré priamo pridávajú špecifickú opisnú informáciu k významnému prvku, aby ho bolo možné identifikovať aj na iných snímkach. A keďže tieto merania často obsahujú hrubé chyby, resp. odľahlé merania, je potrebné do rekonštrukcie scény z takýchto dát zakomponovať aj filtrovacie a vyhladzovacie algoritmy ako je napr. RANSAC (*random sample consensus*). V ďalších podkapitolách budú teda najskôr vysvetlené jednotlivé čiastkové úlohy (detekcia významných prvkov, RANSAC), ktoré sú potrebné na rekonštrukciu scény a až záver bude venovaný samotnému procesu SfM.

#### 3.1.1 Interest operátory

*Interest* operátory sú algoritmy používané na extrakciu významných obrazových bodov, ktoré sú potenciálne vhodnými kandidátmi na párovanie snímok. Vhodnými kandidátmi sa myslia body, ktoré majú svoje charakteristické okolie (vzorky textúry v odtieňoch sivej farby) a je pravdepodobné, že budú podobne vyzerať aj na susedných snímkach. *Interest* operátory určujú pre každý pixel jeden alebo viac parametrov (tzv. *interest* hodnôt), ktoré môžu byť neskôr použité na hľadanie zhôd (v procese známom ako *feature matching*).

Jedným z prvých takýchto operátorov bol tzv. Moravcov operátor.

Moravcov operátor – bol predstavený Hansom Moravcom v roku 1977 (MORAVEC, 1977). Počíta stredné kvadratické sumy gradientov v štyroch hlavných smeroch okna s veľkosťou k x l. Pokiaľ hodnota prekročí určitú hranicu, ide o významný bod. Implementácia Moravcovho operátora je pomerne jednoduchá a nie je náročná na čas výpočtu. Nie je však invariantný voči rotácii a jeho presnosť sa pohybuje okolo 1 pixela.

**Plessy bodový detektor** – inak nazývaný aj Harrisov detektor hrán, bol predstavený v roku 1988 Harrisom a Stephensom (HARRIS & STEPHENS, 1988). Harrisov detektor vychádza z Moravcovho operátora, ktorý vylepšili tým, že diskrétne posuny a rotáciu vyriešili pomocou autokorelačnej funkcie, čím zvýšili aj presnosť lokalizácie.

Autokorelačná matica A je pritom počítaná sumarizáciou derivácií obrazovej funkcie f v oblasti  $\Omega$  okolo jedného bodu.

Sila bodu V je z matice A vyriešená na základe rovnice:

$$\mathbf{V} = \det(\mathbf{A}) - \mathbf{k} \cdot \operatorname{trace}(\mathbf{A})^2. \tag{3.1}$$

Aby bolo možné oddeliť hrany od významných bodov (keďže na jednej hrane je teoreticky nekonečne veľa významných bodov v jednej línii), volí sa k = 0,04. Týmto spôsobom sú pre body získané hodnoty pozitívne a pre hrany negatívne. Výsledkom lokálneho nemaximálneho potlačenia hrán je napokon poloha významného bodu.

**Förstnerov operátor** – Förstnerov operátor (FÖRSTNER & GÜLCH, 1977) určuje významné body aj v rámci autokorelačnej matice **A**, pričom je využívaný fakt, že matica  $A^{-1}$  zodpovedá kovariančnej matici, a teda udáva ako presne môže byť určená pozícia významného bodu (veľké gradienty v **A** vedú k malým varianciám, resp. kovarianciám v  $A^{-1}$ 

a tým k presnejšiemu určeniu). Osi a úseky osí zodpovedajúcich elíps stredných chýb korešpondujú s vlastnými vektormi a hodnotami  $\lambda_1$ ,  $\lambda_2$  matice  $A^{-1}$ . O dobrý významný bod ide, ak je elipsa chýb čo najmenšia a zároveň čo najokrúhlejšia. Naproti tomu disponuje elipsa chýb pozdĺž výraznej hrany veľmi malou a veľmi veľkou polosou ( $\lambda_1$  malé,  $\lambda_2$  veľké), bod by bol teda kolmo na hranu určený správne, no pozdĺž hrany nesprávne. Na základe týchto vlastností možno posúdiť vhodnosť významného bodu:

- významné body disponujú malými, okrúhlymi elipsami,
- rovné hrany možno detegovať cez dlhé polosi elíps stredných chýb,
- veľké elipsy sú charakteristické pre neštruktúrované, homogénne plochy (tzv. plochá textúra).

Förstner zároveň opísal aj výpočet významného bodu so subpixelovou presnosťou. Napriek tomu, že obrazová informácia sa nachádza iba v podobe rastra pixelov, môže byť vyhodnotená interpolovaná verzia operátora pre kontinuum pozícií a prostredníctvom toho lokalizovaný bod na hrane alebo v ťažisku so subpixelovou presnosťou (LUHMANN a kol., 2013).

#### **SUSAN** operátor

SUSAN (*smallest univalue segment assimilating nucleus*) operátor porovnáva intenzity pixelov v kruhovom okne s hodnotou sivosti centrálneho pixela označovaného ako *nucleus* (jadro). Významný bod je nájdený, keď počet podobných hodnôt šede v okne dosiahne určitú prahovú hodnotu (LUHMANN a kol., 2013).

#### **FAST** operátor

Podobne ako SUSAN operátor, aj FAST (*features from accelerated segment test*) operátor analyzuje intenzity pixelov v kruhovom okne. Významný bod je uvažovaný, ak je určitý počet susediacich pixelov s podobnou hodnotou sivosti nájdený v kruhu okolo centrálneho pixela. Dôvod tejto úpravy algoritmu je jednoduchý – analýza založená na kruhu je výrazne invariantná voči zmenám v mierke a rotácii (LUHMANN a kol., 2013).

#### 3.1.2 Detektory významných bodov

Detektory významných bodov (*feature detectors*) kombinujú detekciu kľúčových bodov (*interest points, key points*) s extrakciou tzv. deskriptorov. Deskriptory sú kompaktné

a zreteľné reprezentácie oblasti okolo kľúčového bodu. Deskriptor slúži ako vektor vlastností (*feature vector*) pre každý jeden kľúčový bod a môže byť priamo použitý na analýzu korešpondencií. Vo všeobecnosti môže byť akýkoľvek detektor kľúčových bodov použitý s ktorýmkoľvek deskriptorom (LUHMANN a kol., 2013).

# 3.1.2.1 SIFT

SIFT (*Scale-Invariant Feature Transform*) je algoritmus, ktorý deteguje a popisuje vlastnosti lokálnej obrazovej funkcie. Publikoval ho v roku 1999 David G. Lowe (LOWE, 1999). SIFT je schopný rozpoznávať významné body v obraze (tzv. feature), je čiastočne invariantný voči rotácii aj voči zmene mierky a šumu.

Algoritmus najskôr deteguje extrémy obrazovej funkcie, na základe rozdielov medzi obrazmi, ktoré vzniknú konvolúciou originálnej obrazovej funkcie a Gaussovského filtra pre mierku kσ.



**Obr. 3.1.** Originálna snímka (vľavo), prvé Gaussovské rozostrenie (v strede), druhé Gaussovské rozostrenie (vpravo) (MACH, 2012)

Odčítaním obrazov po aplikácii Gaussovského filtra je vytvorený rozdielový obraz (Obr. 3.2), v ktorom sú hľadané lokálne extrémy.



**Obr. 3.2.** Rozdielový obraz medzi rôznymi úrovňami Gaussovského rozostrenia a vyznačenie extrémov (MACH, 2012)

Čierne oblasti znamenajú nulový rozdiel – ide o hrany a veľké homogénne oblasti, ktoré nie sú z hľadiska jednoznačnej identifikácie bodu zaujímavé. Biele oblasti znamenajú veľký rozdiel – ide o oblasti vedľa hrán a stredy malých kruhov. Zjednodušene možno princíp vidieť na všeobecnej jednorozmernej funkcii na Obr. 3.3.



**Obr. 3.3.** Pôvodná funkcia (vľavo), aplikácia Gaussovského rozostrenia prvý- (v strede) a druhýkrát (vpravo) (MACH, 2012)

Rozdiel dvoch obrázkov s rôznou úrovňou Gaussovského filtra je zároveň aproximáciou druhej derivácie obrázku – Laplaciánu (zjednodušený príklad opäť na Obr. 3.4).



**Obr. 3.4.** Rozdiel funkcií po Gaussovskom rozostrení (vľavo) a druhá derivácia pôvodnej funkcie z obr. (vpravo) (MACH, 2012)

Ako už bolo spomenuté, tento proces je vykonaný na rôznych úrovniach mierky, je teda zostavený tzv. *scale space* (mierkový priestor). Obrazy sú vždy postupne zmenšené na polovicu a ku každému zmenšenému obrazu prislúcha sada Gaussovsky rozostrených obrazov (Obr. 3.5).



**Obr. 3.5.** *Scale space* (MACH, 2012)



Obr. 3.6. Rozdiely susedných obrazov (MACH, 2012)

Potom sú vybrané lokálne extrémy, teda pixely s hodnotou väčšou alebo menšou než susedné pixely (v rámci matice 3 x 3). Porovnanie sa však vykoná s rovnakým okolím aj na tom istom mieste v susedných obrazoch v rámci *scale space*.

Takto sú vybraní tzv. kandidáti, z ktorých sú vylúčené nestabilné body a body na hranách. Pre každý lokálny extrém je vyňaté jeho 3 x 3 okolie a je považovaný za funkciu  $R^2 \rightarrow R$  (Obr. 3.7 vľavo). Hodnotami je potom preložená trojrozmerná kvadratická funkcia (Obr. 3.7 vpravo).



**Obr. 3.7.** Funkcia lokálneho extrému s okolím 3 x 3 (vľavo) a ním preložená kvadratická funkcia (vpravo) (MACH, 2012)

Minimum (maximum) tejto kvadratickej funkcie je súčasne poloha významného bodu so subpixelovou presnosťou. Filtrácia nestabilných bodov (napr. slabý kontrast) a bodov na hranách sa vykoná na základe tvaru funkcie (Obr. 3.8).



**Obr. 3.8.** Kvadratická funkcia pri nestabilnom bode (vľavo) a bode pozdĺž hrany (vpravo) (MACH, 2012)

Na to, aby bolo ďalej možno spárovať významné body medzi jednotlivými snímkami je však najskôr potrebné každý významný bod opísať tzv. deskriptorom, na jeho identifikáciu na ďalších snímkach bez ohľadu na prípadnú rotáciu. Významným bodom je teda priradená orientácia  $\alpha$  a veľkosť L vychádzajúc z prvej derivácie obrazovej funkcie v mieste významného bodu (d<sub>x</sub>, d<sub>y</sub>) na rozostrenom obrázku:

$$\mathcal{L} = \sqrt{\mathbf{d}_{\mathbf{x}}^2 + \mathbf{d}_{\mathbf{y}}^2},\tag{3.2}$$

$$\alpha = \arctan\left(\frac{\mathrm{d}_{y}}{\mathrm{d}_{x}}\right). \tag{3.3}$$



Obr. 3.9. Orientácia a veľkosť významných bodov (MACH, 2012)

Výpočet deskriptoru významného bodu je potom vykonaný opísaním jeho okolia o veľkosti L relatívne vzhľadom k rotácii  $\alpha$ , čím je dosiahnutá invariantnosť voči rotácii obrazu. Pri deskriptoroch ide o 128-rozmerný vektor vypočítaný na základe gradientov v okolí významného bodu (deskriptor je vlastne histogramom týchto gradientov).

Keďže každý významný bod je opísaný svojim charakteristickým vektorom, možno vyhľadať na ďalších snímkach významný bod s čo najpodobnejším vektorom.



Obr. 3.10. Spárované významné body medzi snímkami (MACH, 2012)

#### 3.1.2.2 ASIFT

Zatiaľ čo SIFT je invariantný voči zmene polohy, rotácie a mierky, afinne invariantný SIFT je schopný obsiahnuť aj perspektívne skreslenie, ktoré môže byť lokálne aproximované afinnou transformáciou. SIFT na elimináciu efektov rotácie a translácie používa normalizáciu a s vplyvom mierky sa vysporiada vzorkovaním mierkového priestoru a uložením viacerých interpretácií jednej lokálnej záujmovej oblasti. ASIFT aplikuje podobný prístup k perspektívnym skresleniam, avšak vzorkovaním priestoru afinnej transformácie. No zatiaľ čo mierkový priestor má len jeden rozmer, afinná transformácia má 6 parametrov. Táto komplikácia je vyriešená započítaním posunu, rotácie a mierky zo SIFTu medzi 4 parametre affinných skreslení, vďaka čomu stačí dopočítať už len 2 parametre. Tie sú uvažované ako uhly kamery (v zmysle vonkajšej orientácie ide o uhly  $\Omega$  a  $\Phi$ ) umiestnenej na sfére, pričom os záberu kamery cieli do stredu tejto sféry. Vzorkovaním tohto priestoru dostávame ďalších *n* afinne skreslených *patchov* a SIFT deskriptory sú počítané pre každý jeden z nich. ASIFT je teda výpočtovo náročnejší než pôvodný SIFT (LUHMANN a kol., 2013).

#### 3.1.2.3 SURF

SURF (*Speed-Up Robust Features*) používa na detekciu záujmových bodov maximum determinatu Hessovej matice (tzv. Hessián). Okolie záujmového bodu je charakterizované deskriptorom s použitím histogramu odpovedí tzv. Haarovho waveletu. Invariantnosť voči mierke je dosiahnutá podobne ako pri SIFT vytvorením mierkového priestoru, ktorý je počítaný implicitne zmenou veľkosti filtrov (LUHMANN a kol., 2013).

#### 3.1.3 RANSAC

Algoritmus RANSAC (*random sample consensus*) umožňuje vyhladiť dáta s významným podielom hrubých chýb, a tak je často využívaný práve v oblasti počítačového videnia. RANSAC je iteratívnou metódou pre odhad parametrov matematického modelu zo sady meraných dát, ktoré obsahujú hrubé chyby (STRUTZ, 2016). Ide o nedeterministický algoritmus v tom zmysle, že produkuje primerané výsledky iba s určitou pravdepodobnosťou, pričom táto pravdepodobnosť rastie s počtom povolených iterácií. Prvýkrát bol tento algoritmus publikovaný v roku 1981 Martinom A. Fischlerom a Robertom C. Bollesom na SRI (*Stanford Research Institue*) International (FISCHLER & BOLLES, 1981).

Základný predpoklad je, že dáta pozostávajú z bodov, ktoré možno vyjadriť určitým modelom a bodov, ktoré tomuto modelu nevyhovujú. Dáta teda môžu disponovať šumom. Odľahlé merania môžu byť pritom dôsledkom buď extrémnych hodnôt v šume, chybných meraní alebo nesprávnej hypotézy o interpretácii dát.

Jednoduchým príkladom aplikácie RANSAC je preloženie dvojrozmernej priamky súborom bodov. Za predpokladu, že tento súbor obsahuje body približne vyhovujúce priamke aj odľahlé body, použitie jednoduchej MNŠ (metódy najmenších štvorcov) by vyprodukovalo priamku, ktorá sa s vyhovujúcimi bodmi dostatočne neprekrýva z dôvodu optimálneho prispôsobenia na všetky body v súbore, vrátane odľahlých bodov. RANSAC naopak vyprodukuje model, ktorý berie do úvahy iba body vyhovujúce priamke, s podmienkou, že pravdepodobnosť výberu iba vyhovujúcich bodov je dostatočne vysoká.



**Obr. 3.11.** Súbor meraní s veľkým počtom hrubých chýb (vľavo) a priamka prispôsobená vyhovujúcim bodom pomocou RANSAC (vpravo) (en.wikipedia.org, 2013)
Vstupom do RANSAC-algoritmu je súbor meraných dát, parametrizovaný model, ktorý môže vyjadrovať observácie a niekoľko konfidenčných parametrov. RANSAC iteratívne vyberá náhodné podmnožiny z pôvodných dát, tie sú považované za hypoteticky vyhovujúce a potom testované:

- 1. Model je prispôsobený na hypoteticky vyhovujúce body, všetky voľné parametre modelu sú vypočítané z týchto meraní.
- Všetky ostatné body sú potom testované voči prvotnému modelu a pokiaľ sa nejaký bod dostatočne primyká k modelu, je tiež považovaný za hypoteticky vyhovujúci.
- Odhadovaný model je považovaný za dobrý, ak dostatočne veľký počet bodov bol klasifikovaný ako vyhovujúcich.
- Model je prepočítaný zo všetkých hypoteticky vyhovujúcich bodov, keďže bol odhadnutý iba na základe vstupnej podmnožiny bodov.
- Nakoniec je model zhodnotený prostredníctvom odhadu chyby vyhovujúcich bodov relatívne vzhľadom k modelu.

Táto procedúra je opakovaná pevne stanoveným počtom, pričom zakaždým vyprodukuje buď model, ktorý je vylúčený kvôli malému počtu vyhovujúcich bodov alebo spresnený model s príslušnou relatívnou chybou. Napokon je ponechaný model, ktorého relatívna chyba je nižšia než naposledy uloženého modelu. Algoritmus môže byť doplnený o prerušenie výpočtu pokiaľ je nájdený dostatočne presný model, teda model s dostatočne malou relatívnou chybou.

RANSAC pritom obsahuje trojicu nešpecifikovaných parametrov:

- toleranciu chýb, ktorá sa používa na určenie, či je bod kompatibilný s navrhnutým modelom,
- stanovenie počtu podmnožín použitých na výpočet,
- a počet kompatibilných bodov na nájdenie správneho modelu určitú prahovú hodnotu.

# 3.1.3.1 LDP (location determination problem)

Základným problémom pri analýze obrazu je nájdenie korešpondencií medzi prvkami dvoch reprezentácií danej scény (napr. pri stereofotogrametrii). Jednou variáciou tohto problému je nájdenie priestorovej polohy, v ktorej bola snímka vyhotovená rozpoznaním sady

značiek alebo kontrolných bodov zobrazených na snímke (určenie prvkov vonkajšej orientácie). Riešenie je bežne hľadané cez MNŠ pri zapojení ľudského operátora, ktorý vykonáva prepojenie medzi značkami na snímke a trojrozmernou databázou korešpondujúcich kontrolných bodov. Pri plne automatizovanom systéme, kde sú jednotlivé korešpondencie založené na rozhodnutí kompetentného detektora významných bodov, však MNŠ nie je schopná poradiť si s hrubými chybami. V tomto prípade RANSAC reprezentuje zmenu paradigmy v odhade modelu a dochádza k opačnému postupu ako pri MNŠ – "začať s malou vzorkou a pridávať" (FISCHLER & BOLLES, 1981).

RANSAC algoritmus akceptuje tieto vstupné dáta:

- Zoznam L s počtom m 6-tíc, pričom každá 6-tica disponuje 3D súradnicami kontrolného bodu, jeho príslušnými 2D snímkovými súradnicami a voliteľnou hodnotou, ktorá udáva očakávanú chybu učenia polohy bodu na snímke (v pixeloch).
- 2. Ohnisková vzdialenosť a snímkové súradnice hlavného bodu.
- 3. Pravdepodobnost (1-w), že 6-tica obsahuje hrubú chybu.
- 4. Tzv. "konfidenčné" číslo G použité na nastavenie vnútornej prahovej hodnoty na akceptovanie čiastkových výsledkov, ktoré prispievajú k riešeniu. G = 1 spôsobí veľmi konzervatívne chovanie sa algoritmu, zatiaľ čo G = 0 označí takmer všetko za správne riešenie.

RANSAC/LD (location determination) produkuje vo výstupe informácie:

- 1. 3D súradnice projekčného centra a odhad príslušnej chyby.
- 2. Priestorovú orientáciu obrazovej roviny.

Algoritmus pri výpočte postupuje takto:

- Zo zoznamu L sú vybrané tri 6-tice metódou *quasirandom*, ktorá zabezpečí primerané priestorové rozloženie pre zodpovedajúce kontrolné body. Tento počiatočný výber je nazvaný S1.
- Projekčné centrum (nazvané *CP1*) zodpovedajúce výberu *S1* je určené uzavretou formou. Za viacnásobné riešenie možno považovať také, ak bolo získaných niekoľko projekčných centier z rôznych výberov v nasledujúcich krokov.
- Chyba odvodenej polohy *CP1* je odhadnutá narušením daných snímkových súradníc troch vybraných kontrolných bodov (buď podľa množstva stanoveného

v 6-ticiach, alebo pôvodnou hodnotou jedného pixela) a prepočítaním efektu, ktorý by to malo na polohu *CP1*.

- 4. Na určenie chyby odhadu *CP1* sú určené elipsy chýb (ich rozmer je stanovený podľa dodaného konfidenčného čísla) v obrazovej rovine pre každý z kontrolných bodov špecifikovaných v zozname *L*. Pokiaľ sa asociované obrazové súradnice nachádzajú v príslušnej elipse chýb, 6-tica je pripojená ku konsenzovej sade *S1/CP1*.
- 5. Ak veľkosť S1/CP1 sa rovná alebo presahuje určitú prahovú hodnotu t, konsenzová sada S1/CP1 je posunutá k procesu MNŠ pre záverečné určenie polohy CP a orientácie obrazovej roviny. V opačnom prípade sú predchádzajúce kroky opakované s novým náhodným výberom S2, S3,...
- 6. Ak počet iterácií predchádzajúcich krokov prekročí k = [log(1 G)]/ [log(1 – w<sup>3</sup>)], najväčšia konsezová sada aká bola nájdená je použitá na výpočet finálneho riešenia (alebo dôjde k zlyhaniu výpočtu, ak táto najväčšia konsezová sada obsahuje menej než 6 členov).

# 3.1.4 SFM

Vyššie spomenuté algoritmy ako SIFT alebo RANSAC nachádzajú uplatnenie v technológii známej v oblasti počítačového videnia pod skratkou SfM (*Structure from Motion*). Vo všeobecnosti ide o proces, pri ktorom sa hľadá trojrozmerná štruktúra objektu analyzovaním lokálnych pohybových signálov naprieč časom. V rámci počítačového videnia ide najmä o situáciu, keď je pozorovaná scéna stabilná a pohybuje sa iba kamera okolo objektu. Analýzou zmien medzi jednotlivými snímkami, hľadaním významných bodov a ich párovaním sa možno postupne dopracovať k trojrozmernej rekonštrukcii celej scény. Algoritmy ako napr. SIFT a RANSAC môžu byť do spracovania zapojené ako čiastkové úlohy, keďže vstupom do SfM sú 2D merania obsahujúce šum a hrubé chyby. Dvojrozmerná poloha významných bodov na snímke závisí od ich priestorových súradníc, relatívneho 3D pohybu medzi kamerou a scénou a prvkov vnútornej orientácie kamery.

Geometrická teória SfM umožňuje počítať súčasne projekčné matice aj 3D body s použitím iba korešpondujúcich bodov v jednotlivých pohľadoch. Formálne, ak máme daných *n* projektovaných bodov  $u_{i,j}$ ,  $i \in \{1 ... m\}$ ,  $j \in \{1 ... n\}$  na *m* snímkach, úlohou je nájsť jednak projekčné matice  $P_1...P_m$  a zároveň konzistentnú štruktúru  $X_1...X_n$ . Čo sa týka vyhľadávania korešpondencií medzi významnými prvkami (*features*) existujú dva základné prístupy, a to buď už spomínaný *feature-based* prístup (SIFT + RANSAC) alebo *pixel-based* prístup (registrácia na základe tzv. *patchov* s Lucas-Kanade algoritmom), ktorý je vhodnejší pre video sekvencie (CIPOLLA, 2008).

# 3.1.4.1 Dierková kamera

Najbežnejší model kamery je tzv. dierková (*pinhole*) projekcia a je pod pojmom *camera obscura* známa od čias čínskeho filozofa Mo Di (470-391 p.n.l.) a gréckeho polyhistora Aristotela (384 až 322 p. n. l.). Tento model je vhodnou aproximáciou pre väčšinu reálnych kamier, avšak môže byť spresnený doplnením napr. radiálnej distorzie. Z dierkovej projekcie vyplýva, že vzťah medzi 3D bodom a jeho 2D obrazovým bodom má tri komponenty opísané nižšie:

1. Prvý komponent je zhodnostná transformácia vyjadrujúca vzťah medzi bodmi v referenčnom súradnicovom systéme a bodmi v súradnicovom systéme kamery.

 Druhý komponent je transformácia z 3D do 2D, vyjadrujúca vzťah medzi 3D bodmi (v kamerovom súr. systéme) a 2D bodmi v obrazovej rovine kamery. Použitím podobnosti trojuholníkov možno odvodiť vzťahy:

$$\mathbf{x} = \mathbf{f} \frac{\mathbf{X}_{c}}{\mathbf{Z}_{c}},\tag{3.4}$$

$$y = f \frac{Y_c}{Z_c},$$
(3.5)

kde f je ohnisková vzdialenosť. Namiesto zmeny hodnoty f súvisiacej so zmenou mierky, môže byť položené f = 1 a započítať chýbajúci mierkový faktor do kalibračnej matice kamery.

3. Posledný komponent je 2D do 2D transformácia vyjadrujúca vzťah medzi bodmi v obrazovej rovine kamery a pixelovými súradnicami.



**Obr. 3.12.** Dierková projekcia priestorového bodu do obrazovej roviny kamery (CIPOLLA, 2008)

# 3.1.4.2 Kalibrácia kamery

Ako už bolo spomenuté v kapitole 3, pod pojmom kalibrácia sa rozumie určenie prvkov vnútornej orientácie kamery. Možno ich určiť na základe rozličných koncepcií kalibrácie (KRAUS, 1997):

- kalibrácia známym priestorovým zväzkom lúčov,
- kalibrácia na testovacom poli so známymi priestorovými súradnicami,
- kalibrácia na testovacom poli pomocou známych geometrických tvarov,
- kalibrácia na testovacom poli s neznámymi súradnicami.

Uvedené 4 koncepcie kalibrácie kamery sa využívajú pri kalibračných metódach, ku ktorým patrí laboratórna, súbežná a samokalibrácia. Okrem týchto metód je potrebné spomenúť ešte metódu priamej lineárnej transformácie, ktorá neprináša také presné výsledky ako ostatné spomenuté a používa sa pri určovaní priestorovej polohy bodov, pričom prvky vnútornej orientácie kamery sa riešia súčasne s neznámymi súradnicami určovaných bodov.

Vo väčšine softvérov využívajúcich princípy SfM je v súčasnosti používaná metóda samokalibrácie, pri ktorej sú na kalibráciu kamery používané priamo snímky objektu a do výpočtu prvkov vnútornej orientácie vstupujú významné body objektu.

K prvkom vnútornej orientácie je však najjednoduchšie dopracovať sa snímkovaním scény, ktorej parametre sú známe (kontrolovanej scény). Napr. možno umiestniť kameru tak, aby snímala kalibračný objekt (Obr. 3.13 vľavo) a automaticky extrahovať obrazové súradnice (v pixeloch) známych 3D bodov (Obr. 3.13 vpravo).



**Obr. 3.13.** Snímka kalibračného objektu (vľavo), z ktorého môžu byť extrahované obrazové súradnice známych 3D bodov (vpravo) (CIPOLLA, 2008)

Optická sústava objektívu nie je nikdy dokonalá a ideálna dierková projekcia je tak vždy ovplyvnená rôznymi formami distorzie, skresleniami objektívu. Najbežnejšou formou takéhoto skreslenia je radiálna distorzia, pri ktorej sú body premietnuté o určitú odchýlku radiálne okolo stredu distorzie.

Nech  $\tilde{\mathbf{x}} \sim [x \ y \ 1]^T$  predstavuje obrazový bod s polohou  $\tilde{\mathbf{u}} \sim [u \ v \ 1]^T$  v pixeloch. Za predpokladu, že poloha stredu distorzie je totožná s polohou hlavného bodu, radiálna distorzia môže byť opravená použitím nasledujúcich vzťahov (TSAI, 1987):

$$\hat{x} = x + L(r)x,\tag{3.6}$$

$$\hat{y} = y + L(r)y, \tag{3.7}$$

kde  $[\hat{x} \quad \hat{y}]^T$  je opravená poloha bodu pre  $[x \quad y]^T$  a  $r^2 = x^2 + y^2$ . L(r) je distorzná funkcia a môže byť aproximovaná napr. ako  $L(r) \approx k_1 r^2 + k_2 r^4$ . Koeficienty radiálnej distorzie,  $k_1$  a  $k_2$ , ktorých môže byť pravdaže viac v závislosti od použitého distorzného modelu, sú považované za súčasť prvkov vnútornej orientácie kamery a možno ich určiť práve počas kalibrácie. Najčastejšie používaný je tzv. Brownov distorzný model, ktorý rieši nielen radiálnu, ale aj tangenciálnu (decentračnú) distorziu.

# 3.1.4.3 Esenciálna matica

Ak na jednej snímke existuje priemet 3D bodu, potom jeho priemet na druhej snímke musí zodpovedať prislúchajúcej epipolárnej priamke.



Obr. 3.14. Epipolárna geometria pre dve kamery (CIPOLLA, 2008)

Ako vidieť z Obr. 3.14, všetky epipolárne priamky na snímke majú spoločný jeden bod – priemet druhého projekčného centra ( $\tilde{\mathbf{e}} \ a \ \tilde{\mathbf{e}}'$ ), ktorý sa nazýva epipól.

Epipolárna podmienka môže byť algebraicky formulovaná použitím esenciálnej matice E, vyjadrujúcej vzťah medzi prislúchajúcimi bodmi v dvoch obrazoch (FAUGERAS, 1993). Epipolárna podmienka je pre obrazové body **x** a **x**' vyjadrená:

$$\tilde{\mathbf{x}}^{\mathrm{T}}\mathbf{E}\tilde{\mathbf{x}}' = \mathbf{0}.$$
(3.8)

3 x 3 esenciálna matica E pritom závisí iba od rotačnej matice R a trojrozmerného vektora T a keďže mierka je ľubovoľná, obsahuje 5 parametrov.

# 3.1.4.4 Fundamentálna matica

Fundamentálna matica F je matica 3 x 3 s hodnotou 2 a 9 parametrami. Môže byť odhadnutá lineárne pomocou 8 alebo viac bodov (FAUGERAS, 1993). Značná pozornosť bola venovaná presnému odhadu fundamentálnej matice zo zašumených obrazových dát (HARTLEY, 1997) a robustne za prítomnosti odľahlých bodov (TORR, 1998, ZHANG, 1995).

Fundamentálna matica kompaktným spôsobom definuje geometriu korešpondencií medzi dvojicou snímok, kódovanie prvkov vnútornej orientácie a relatívne prvky vonkajšej orientácie dvoch kamier. Matica **F** identifikáciou bodu na jednej snímke umožňuje identifikáciu zodpovedajúcej epipolárnej priamky na druhej snímke, pričom epipól napr. pravej snímky možno získať položením pravej strany rovnej nule a epipól ľavej snímky položením ľavej strany rovnej nule.

42

Jednou z požiadaviek je dodržanie primeranej translácie projekčných centier, nakoľko v prípade prekrytu centier nie je možné zobraziť na snímkach epipolárnu priamku. Okrem toho musia byť snímkové súradnice normalizované ešte pred riešením lineárnych rovníc. Algoritmus využíva dekompozíciu singulárnych hodnôt, preto je dôležité snímkové súradnice normalizovať, inak by bol výpočet numericky nestabilný.

V prípade, že súbor korešpondencií obsahuje aj odľahlé merania, mohlo by byť riešenie MNŠ značne znehodnotené, preto je vhodné použiť algoritmus RANSAC, ktorý sa s týmto problémom dokáže vysporiadať.

# 3.1.4.5 Projekčné matice

Ako bolo ukázané vyššie, fundamentálna matica závisí od relatívnej polohy a orientácie dvoch pohľadov na jednu scénu a môže byť odhadnutá pomocou bodových korešpondencií. Ak sú známe kalibračné matice kamery, možno získanú fundamentálnu maticu tranformovať na esenciálnu maticu a dekomponovať túto maticu zodpovedajúcu translácii a ortonormálnu maticu prislúchajúcu rotácii medzi kamerami. Numerické riešenie vychádza z dekompozície singulárnych hodnôt esenciálnej matice.

Najbližšia esenciálna matica (v zmysle minimalizovania Frobeniovej normy medzi dvoma maticami) so správnymi vlastnosťami môže byť získaná, keď sú dve najväčšie singulárne hodnoty položené rovné ich priemeru a najmenšia sa rovná nule. Projekčné matice vychádzajú priamo zo získaných translácií a rotácií zarovnaním referenčného súradnicového systému s prvou kamerou. Zo štyroch možných riešení je to správne vybrané na základe predpokladu, že rekonštruované body ležia pred kamerami.

#### 3.1.4.6 Triangulácia

Ak poznáme projekčné matice, 3D body možno vypočítať z ich obrazových súradníc na dvoch alebo viacerých snímkach. Tento proces sa nazýva triangulácia (HARTLEY, 1994). V ideálnom prípade by mali 3D body ležať v prieseku určujúcich lúčov, no z dôvodu prítomného šumu sa lúče vo všeobecnosti nepretínajú. Z tohto dôvodu je potrebné 3D body nájsť takým spôsobom, aby bola minimalizovaná chyba určenia ich polohy.

Rekonštrukčný algoritmus minimalizuje sumu štvorcov opráv medzi meranými a predpokladanými polohami 3D bodov vo všetkých pohľadoch, v ktorých sú viditeľné. Za predpokladu, že šum v meraných obrazových súradniciach má Gaussovské rozdelenie, výsledkom tohto prístupu je najvhodnejšie riešenie pre X.



Obr. 3.15. Ilustrácia triangulácie (CIPOLLA, 2008)

V (HARTLEY, 1994) je oopísané neiteratívne riešenie pre dva pohľady (dve kamery). Pre viac než dva pohľady možno minimalizáciu vyriešiť iteratívne prostredníctvom nelineárnej optimalizácie. Tento prístup však vyžaduje dostatočne dobrú inicializáciu, inak môže zlyhať nájdením lokálneho minima.

# 3.1.4.7 SFM z viacerých snímok

Esenciálna a fundamentálna matica v sebe zahŕňajú geometrické obmedzenia pre dvojicu pohľadov. Keďže v praxi sa iba zriadkakedy stretávame s iba dvojicou snímok, je potrebné vyriešiť *structure* a *motion* problém (problém "štruktúry a pohybu") pre bežný počet snímok. Záverečným krokom sa potom stáva zväzkové vyrovnanie určujúcich lúčov, ktoré sa používa iteratívne na zjemnenie parametrov *structure* a *motion* minimalizáciou príslušnej funkcie.

Každopádne, vyrovnanie zväzku lúčov je kriticky závislé od vhodnej inicializácie – v opačnom prípade môže algoritmus zlyhať konvergovaním k lokálnemu minimu riešenia. Parametre SfM pritom možno riešiť dvoma algoritmami, a to sekvenčným a faktorziačným.

# Sekvenčné metódy

Sekvenčné algoritmy sa považujú za najpopulárnejšie. Pracujú na princípe zaraďovania postupných pohľadov jedného po druhom (Obr. 3.16). S každým registrovaným pohľadom je čiastočná rekonštrukcia rozšírená o výpočet všetkých 3D bodov, ktoré sú viditeľné na dvoch alebo viacerých snímkach pomocou triangulácie. Vhodná inicializácia je zvyčajne získaná dekomponovaním fundamentálnej matice vzťahujúcej sa k prvým dvom snímkam sekvencie (CIPOLLA, 2008).



Obr. 3.16. Ilustrácia sekvenčnej registrácie (CIPOLLA, 2008)

Existuje niekoľko stratégií pre registráciu postupných pohľadov:

- Epipolárne podmienky jedna z možností je využiť epipolárnu geometriu medzi dvojicou snímok, ktorá každú snímku v sekvencii vzťahuje k jej predchodcovi. Napr. ak sú známe prvky vnútornej orientácie kamery, môžu byť použité esenciálne matice. Esenciálne matice sú odhadnuté lineárne použitím 8 alebo viacerých korešpondencií a dekomponované pre získanie relatívnej orientácie kamery a smer kamerovej translácie. Miera translácie môže byť opravená použitím snímky v novom pohľade jediným známym 3D bodom, teda bodom, ktorý už bol rekonštruovaný v predchádzajúcich pohľadoch.
- Pretínaním inou možnosťou je určiť pozíciu každého ďalšieho pohľadu za použitia už rekonštruovaných 3D bodov. 6 alebo viac 3D voči 2D korešpondencií dovoľuje lineárne riešenie dvanástich prvkov projekčnej matice.
- Spájanie čiastočných rekonštrukcií ďalšou alternatívou je spojiť čiastočné rekonštrukcie na základe korešpondujúcich 3D bodov. Typicky sú získané 2 až 3 pohľadové rekonštrukcie použitím susedných snímkových párov alebo tripletov, ktoré sú potom zlúčené na základe zodpovedajúcich si 3D bodov.

Tieto sekvenčné registračné schémy však majú niekoľko dôležitých obmedzení. V kontexte interaktívnych modelovacích systémov je veľká nevýhoda, že v každom pohľade musí byť definované veľké množstvo korešpondujúcich bodov. Pre nekalibrovanú rekonštrukciu komerčné fotogrametrické softvéry zvyčajne vyžadujú minimálne 7 korešpondencií pre každý pohľad (aj viac pre vyššiu presnosť). Keďže korešpondujúce body musia byť viditeľné zvyčajne v troch alebo viacerých pohľadoch, znamená to potrebu

významného prekrytu medzi snímkami. Pre dlhé sekvencie snímok (napr. pozdĺž ulice) môže byť táto požiadavka problematická. Ďalšou komplikáciou môže byť, že tu existujú rôzne druhy degeneratívnych *structure* a *motion* konfigurácií, pre ktoré štandardné algoritmy zlyhajú. Napr. rotácia kamery s absenciou translácie, rovinné scény, 3D bod ležiaci na línii spájajúcej optické centrá kamier, v ktorých je viditeľný. V praxi nemusí byť ľahké vyhnúť sa uvedeným obmedzeniam, obzvlášť ak sú snímky vyhotovované bez pozorného plánovania.

#### Faktorizačné metódy

Opakom sekvenčných metód sú hromadné (*batch*) metódy, ktoré fungujú na princípe výpočtu polohy kamery a geometrie scény za použitia všetkých snímok naraz. Jedna z výhod je, že rekonštrukčné chyby sú distribuované zmysluplne cez všetky merania, teda sa možno vyhnúť hrubým chybám z uzavretia sekvencie.

Medzi *batch* SfM algoritmy patria aj faktorizačné metódy (TOMASI & KANADE, 1992). Rýchle a robustné lineárne metódy založené na SVD (*Singular-Value Decomposition*) faktorizácii meraní obrazových bodov boli vyvinuté pre rôzne druhy zjednodušených lineárnych (afinných) kamerových modelov - žiaľ žiadna z týchto metód nie je vo všeobecnosti aplikovateľná na scény v skutočnom svete, nakoľko reálne objektívy kamier sú príliš širokouhlé a nemôžu byť aproximované ako lineárne.

Tak či tak, jedno z hlavných obmedzení všetkých týchto algoritmov je existencia degeneratívnych konfigurácií *structure* a *motion*, pre ktoré výpočet zlyhá. Ďalší fakt je, že si neporadia s chýbajúcim dátami – každý 3D bod musí byť viditeľný v každom pohľade.

#### 3.1.4.8 Zväzkové vyrovnanie určujúcich lúčov

Zväzkové vyrovnanie je posledný krok pred tvorbou mračien bodov metódami obrazovej korelácie. Jeho úloha je súčasné vyrovnanie všetkých parametrov, teda pozícií aj rotácií kamier a súradníc bodov. Z obrazových *features*  $\mathbf{u}_{ij}$ , sú na základe SfM získané vstupné odhady projekčných matíc  $\mathbf{P}_i$  a 3D bodov  $\mathbf{X}_j$ . Zvyčajne je potrebné zjemniť tieto odhady použitím iteratívnej nelineárnej optimalizácie na minimalizáciu príslušnej funkcie (BROWN, 1976). Zväzkové vyrovnanie pracuje na princípe minimalizácie funkcie vztiahnutej k váženej sume štvorcov reprojekčných chýb. Bežne je používaná Gaussova-Newtonova iterácia pre rapídnu konvergenciu. Cieľom zväzkového vyrovnania je určiť optimálny odhad súboru parametrov  $\theta$ , ak je daný súbor zašumených pozorovaní. Väčšina parametrov zväzku nemôže byť pozorovaných priamo, ako napr. projekčné matice a 3D súradnice bodov. Miesto toho dovoľujú vytvoriť predikcie kvantít, ktoré byť pozorované môžu, napr. merané pixelové súradnice obrazových bodov.

Nech súbor predikcií je  $\mathbf{z}(\boldsymbol{\theta})$  súbor korešpondujúcich pozorovaní  $\overline{\mathbf{z}}$ . Potom reziduálna predikovaná chyba  $\Delta \mathbf{z}$  je:

$$\Delta \mathbf{z} = \bar{\mathbf{z}} - \mathbf{z}(\boldsymbol{\theta}). \tag{3.9}$$

Vo všeobecnosti môže byť vektor pozorovaní  $\overline{z}$  rozdelený do súboru štatisticky nezávislých meraní  $\overline{z}_1 ... \overline{z}_N$  s asociovanými predikciami  $\overline{z}_1(\theta) ... \overline{z}_N(\theta)$ . Zväzkové vyrovnanie pokračuje minimalizáciou príslušnej funkcie. Na maximálne pravdepodobný odhad parametrov, by mala funkcia odrážať pravdepodobnosť reziduí  $\Delta z$ . Za predpokladu Gaussovského rozloženia šumu meraní, príslušná funkcia je sumou štvorcov chýb:

$$f(\boldsymbol{\theta}) = \frac{1}{2} \sum_{i} \Delta \mathbf{z}_{i}(\boldsymbol{\theta})^{\mathrm{T}} \mathbf{W}_{i} \Delta \mathbf{z}_{i}(\boldsymbol{\theta}), \qquad (3.10)$$

$$\Delta \mathbf{z}_i(\boldsymbol{\theta}) = \bar{\mathbf{z}}_i - \mathbf{z}_i(\boldsymbol{\theta}), \tag{3.11}$$

kde  $\Delta \mathbf{z}_i(\boldsymbol{\theta})$  je predikovaná chyba *features* a  $\mathbf{W}_i$  je symetrická pozitívne konečná váhová matica zvolená kvôli aproximácii inverznej kovariancie šumu meraní súvisiaceho s meraniami  $\overline{\mathbf{z}}_i$ .

Keďže vzťahy medzi snímkovými a priestorovými súradnicami nie sú lineárne, je potrebné ich najskôr linearizovať rozvojom do Taylorovho rádu so zanedbaním členov vyšších rádov. Nasledujúci výpočet prebieha iteratívne, napr. pomocou numerickej Newtonovej metódy iterovaním tzv. Newtonovho kroku  $\delta \theta$ , kde je v každej iterácii hľadaný posun parametra  $\theta \rightarrow \theta + \delta \theta$ , ktorý minimalizuje  $f(\theta)$ .

Nakoľko Newtonova metóda môže zlyhať v konvergencii k minimálnemu riešeniu (môže konvergovať napr. do sedlového bodu, miesto do minima) je potrebné pridať vhodnú kontrolu krokov. Každý krok musí vykazovať klesajúci smer a pod.

# 3.2 Podrobná rekonštrukcia snímaného povrchu

Akonáhle je zrekonštruovaná základná scéna, všetky snímky sú vzájomne zorientované a kamery skalibrované, najčastejší ďalší krok býva výpočet hustého mračna bodov, ktoré pokrýva povrch snímaného objektu. Podrobná rekonštrukcia priestorových objektov zo snímok, najmä zo stereopárov, je dôležitou požiadavkou v mnohých aplikáciách. Veľmi často sa tu pritom potýkame s rôznymi komplikáciami, ako je napr. zahladzovanie ostrých hrán, nerovnomerné osvetlenie alebo neželané odrazy na lesklých povrchoch, ktoré spôsobujú, že korešpondujúce pixely majú rozličnú intenzitu. Navyše sa kladie veľký dôraz na rýchlosť výpočtov, keďže sú často vyžadované buď tzv. aplikácie v reálnom čase, alebo je potrebné spracovať veľké množstvo snímok s vysokým rozlíšením.

Existuje široká škála stereo-algoritmov, ktoré umožňujú podrobnú rekonštrukciu snímaného povrchu. Lokálne metódy založené na obrazovej korelácii môžu mať veľmi efektívne implementácie, ktoré vyžadujú výpočty v reálnom čase (HIRSCHMÜLLER a kol., 2002), avšak tieto metódy predpokladajú konštantné rozdiely v rámci korelačného okna, čo je na ostrých hranách nesprávne a dochádza tak k rozmazaniu okrajov objektu. *Pixelwise matching* (párovanie na báze pixelov) sa s týmto problémom nepotýka, no potrebuje odlišné podmienky na zabezpečenie jednoznačného párovania (napr. tzv. *piecewise smoothness –* vyhladenie po častiach) (HIRSCHMÜLLER, 2005). Techniky dynamického programovania (*Dynamic Programming*) si môžu tieto podmienky efektívne vynútiť, no iba v rámci individuálnych vyhľadávacích línií (tzv. *scanlines*) (BIRCHFIELD & TOMASI, 1998), čo vedie k znehodnoteniu výsledkov formou neželaných pruhov. Naproti tomu globálne techniky ako *Graph Cuts* (BOYKOV a kol., 2001) a *Belief Propagation* (SUN a kol., 2003) sú schopné vynútiť si párovacie podmienky v dvoch smeroch. Oba prístupy sú však náročné na pamäť počítača a technika *Graph Cuts* je navyše trochu pomalá.

Väčšina metód súvisiacich s hľadaním korešpondencií medzi stereosnímkami počíta tzv. rozdielovú funkciu (*disparity function*) d(x, y) voči referenčnej snímke, ktorou je buď jedna z dvojice snímok, alebo tzv. "kyklopský" záber umiestnený niekde medzi týmito snímkami (SCHARSTEIN & SZELISKI, 2002). Rozdielová funkcia v oblasti počítačového videnia priamo súvisí s konceptom tzv. rozdielového priestoru (*disparity space (x, y, d)*). Z fotogrametrického hľadiska sa týmito rozdielmi myslí horizontálna paralaxa, teda horizontálny rozdiel v polohe objektov pozorovaných ľavým a pravým okom (rozdiel x-ových snímkových súradníc). Z predchádzajúcich pojmov potom priamo vychádza tzv. obraz

rozdielového priestoru (DSI – *disparity space image*), ktorý môže byť ľubovoľným obrazom alebo funkciou definovanou nad spojitým alebo diskretizovaným variantom rozdielového priestoru (*x*, *y*, *d*). Inak povedané, DSI predstavuje istotu alebo pravdepodobnosť (resp. tzv. náklady – *cost*) nájdenia konkrétnej zhody.

S pojmom *disparity* sa možno stretnúť ešte pri termíne *disparity map* (rozdielová mapa), ktorý si netreba pliesť s termínom *depth map* (hĺbková mapa). Vizuálne sa síce môžu javiť podobne, avšak hĺbková mapa už reprezentuje určitý variant DMP v odtieňoch sivej farby z pohľadu konkrétnej snímky – vzdialenosť pixelu od kamery je reprezentovaná úrovňou intenzity. Na druhej strane *disparity map* je vlastne len iné označenie pre DSI. Medzi funkciou rozdielov (*disparity*) a funkciou hĺbky (*depth*) platí inverzný vzťah (ULÉN, 2014).

Vo všeobecnosti možno odsledovať, že väčšina stereo-algoritmov vykonáva tieto kroky (SCHARSTEIN & SZELISKI, 2002):

- Výpočet nákladov párovania najčastejšie SD (squared differences), SSD (sumof-squared-differences), AD (absolute intensity differences), MSE (meansquared error), MAD (mean absolute difference) a iné.
- Agregácia nákladov párovania sumarizácia alebo priemerovanie skrz dvojalebo trojrozmernú podpornú oblasť (*support region*).
- 3. Výpočet rozdielov (paraláx), resp. optimalizácia lokálne metódy, globálna optimalizácia, dynamické programovanie, príp. kooperatívne algoritmy.
- Zjemnenie rozdielov (paraláx) subpixelové odhadovanie paraláx, detegovanie zákrytových oblastí cez krížovú kontrolu, vyčistenie nesprávne priradených zhôd aplikáciou mediánového filtra a pod.

Postupnosť uvedených krokov nemusí byť striktne kompletná a závisí od jednotlivých algoritmov. Niektoré algoritmy môžu mať jednotlivé kroky zlúčené, napr. lokálne algoritmy kombinujú prvé dva kroky a používajú náklady párovania založené na normalizovanej krížovej korelácii (BOLLES a kol., 1993).

Výpočet nákladov párovania zvyčajne vychádza z rozdielov intenzity, čo môže byť necitlivé voči vzorkovaniu (BIRCHFIELD & TOMASI, 1998). Párovanie na základe intenzity je veľmi citlivé voči rozdielom v zázname a osvetlení, odrazoch a pod. Z tohto dôvodu vznikla v oblasti počítačového videnia technika tzv. vzájomných informácií (*Mutual Information*), aby bolo možno párovať snímky s komplexnými vzťahmi korešpondujúcich

intenzít, prípadne snímky z rozličných senzorov (VIOLA & WELLS, 1997). Vzájomné informácie už boli použité na *stereo matching* s princípmi obrazovej korelácie alebo v technike *Graph Cuts*, pričom bolo dokázané, že je robustná voči mnohým komplexným zmenám intenzity a dokonca aj voči odrazom (KIM a kol., 2003).

#### 3.2.1 Lokálne stereo-algoritmy

Lokálne stereo-algoritmy sú štatistickými metódami zvyčajne založenými na obrazovej korelácii. Pri podrobnej rekonštrukcii objektov sa aplikujú tzv. *area-based* metódy, ktoré na nájdenie vhodných zhôd medzi snímkami používajú okolie vybraného pixelu, resp. hodnoty intenzity týchto pixelov vo vybranom okne (*window*). Počas párovania takýchto okien sa najčastejšie využívajú techniky tzv. normalizovanej krížovej korelácie (NCC – *normalized cross-correlation*), sumy absolútnych rozdielov (SAD – *sum of absolute differences*) alebo sumy kvadratických rozdielov (SSD – *sum of squared differences*).

Výsledky tzv. *area-based* (na vybranej oblasti založených) stereo-algoritmov sú výrazne ovplyvňované tvarom a veľkosťou vyhľadávacieho okna. Na dosiahnutie vysokého výpočtového výkonu sa najčastejšie používajú okná pravouhlého tvaru. Veľkosť okna určuje počet pixelov použitých na výpočet korelácie. Na dosiahnutie spoľahlivých výsledkov musí byť okno dostatočne veľké, aby obsiahlo potrebné zmeny intenzity, no zároveň musí byť dostatočne malé, aby zahŕňalo len pixely s rovnakou hodnotou horizontálnej paralaxy (*disparity value*). Avšak zatiaľ čo príliš veľké vyhľadávacie okno rozmazáva okraje a detaily objektov, príliš malé okno vedie k nespoľahlivým výsledkom v oblastiach s nevýraznou povrchovou textúrou. Z uvedeného vyplýva, že pri členitých objektoch nemusí byť jedna veľkosť okna postačujúca a vzniká tak potreba rôznych tvarov a veľkostí okien naprieč rôznymi pixelmi v tej istej snímke.

(KANADE & OKUTOMI, 1994) navrhli adaptívnu metódu založenú na vyhľadávacích oknách, ktorá začína s prvotným odhadom rozdielovej mapy, ktorú potom iteratívne aktualizuje pre každý bod výberom veľkosti a tvaru okna, až kým riešenie neprestane konvergovať. Na výber okna s najmenšou neistotou používa zmenu intenzity a paralaxy, metóda je však citlivá na prvotný odhad rozdielovej mapy.

Iné metódy zahŕňajú buď premenlivú veľkosť okna (BOYKOV a kol., 1998) alebo prístup s viacerými vyhľadávacími oknami (FUSIELLO a kol., 1994). (HIRSCHMÜELLER a kol., 2002) tiež použili techniku viacerých vyhľadávacích okien s rôznou veľkosťou, no

algoritmus navyše doplnili o špeciálny filter na opravu korešpondencií po okrajoch objektu. (VEKSLER, 2003) navrhol algoritmus s výpočtom korelačných koeficientov pre viacero rôzne veľkých okien v pozícii jedného vybraného pixela, pričom výsledná akceptovaná veľkosť okna je určená na základe najmenšej chyby nájdenia zhody.

Ďalší prístup ku lokálnym stereo-algoritmom zaujali (YOON & KWEON, 2006), keď počítajú tzv. podporné váhy (*support weights*) pre každý pixel v podpornom okne na základe rozdielnosti ich farieb a vzdialenosti od centrálneho pixela. Tieto váhy regulujú vplyv pixela v procese párovania.

#### 3.2.2 Globálne stereo-algoritmy

Korelačné metódy a iné *area-based* metódy hľadajú zhodu medzi štvorcovými oblasťami dvoch stereosnímok. Táto oblasť alebo okno však pôsobí ako fotografický *low-pass* filter a rozmazáva diskontinuity v hĺbke (v smere osi záberu). Výsledkom je DSI-obraz s rozmazanými hranami objektov. Čím väčšie je porovnávacie okno, tým väčšia je úroveň rozostrenia a naopak. V tomto prípade by teda bolo ideálne hľadať zhody iba na úrovni jednotlivých pixelov a nie celých oblastí. Intenzitu samostatných pixelov však nemožno považovať za dostatočnú informáciu pre zmysluplné párovanie a tak je nutné doplniť ďalšie podmienky na zabezpečnie konzistencie výsledkov.

## 3.2.2.1 Global matching

Situáciu párovania ľavej snímky  $I_l$  k pravej snímke  $I_r$  možno vyjadriť ako energetickú funkciu, ktorú je potrebné minimalizovať:

$$E(D) = \sum_{p} C(p, d_{p}) + \sum_{q \in N_{p}} P\left[\left|d_{p} - d_{q}\right| \ge 1\right]$$

$$(3.12)$$

Nákladová funkcia *C* vyjadruje náklady potrebné na nájdenie zhody pixela *p* z ľavej snímky s paralaxou (*disparity*)  $d_p$ , čiže spárovanie tohto pixela s korešpondujúcim pixelom na pravej snímke vo vzdialenosti  $d_p$  pozdĺž epipolárnej priamky. V prvej časti funkcie sú sumarizované tieto náklady pre všetky pixely *p* pravej snímky. Keďže sú porovnávané individuálne pixely, na výpočet nákladov sú použité len hodnoty intenzity. Jednoduchšie prístupy na výpočet nákladov používajú absolútne rozdiely intenzít, avšak lepšie výsledky možno dosiahnuť za použitia techniky vzájomných informácií (*Mutual Information*). V druhej časti energetickej funkcie sa voči paralaxám (*disparities*) vynucuje tzv. lokálne vyhladenie

(*local smoothness*). Podmienka *P* pritom penalizuje paralaxy všetkých pixelov *q* z okolia  $N_p$  pixela *p*, ktoré sú väčšie než 1 pixel. Podmienka penalizácie môže viesť k odmietnutiu nájdenia zhody napriek tomu, že hodnoty intenzity  $I_l(p)$  a  $I_r(q)$  sú si veľmi podobné, ale ich paralaxa je veľmi odlišná voči susedným pixelom. V takýchto prípadoch môže byť preferované nájdenie zhody, ak sú si hodnoty intenzity menej podobné, no paralaxa súhlasí (LUHMANN a kol., 2013).

Paralaxy  $d_p$  pre všetky pixely p sú zvyčajne uložené do obrazu D s rovnakými rozmermi ako má snímka  $I_l$ . Na vyriešenie párovacieho problému musia byť určené všetky paralaxy  $d_p$ pri dodržaní minimálnej E(D). Penalizačná podmienka vyhladenia P prepája paralaxu v pozícii pixela p k paralaxe v susednej pozícii q, ktorá je potom prepojená k ďalším susedom atď. Tento proces efektívne prepojí všetky pixely v obraze navzájom – z tohto dôvodu sa o tomto prístupe hovorí ako o tzv. globálnom párovaní (*global matching*).

# 3.2.2.2 Semi-global matching

Výpočtová náročnosť metódy *global matching* rastie exponenciálne s veľkosťou vstupných dát, a tak sa tento prístup stáva nevyužiteľným v mnohých aplikáciách.

Metóda SGM je v tomto smere výrazne rýchlejšia než klasické globálne párovanie, pretože kompromituje globálne optimum riešenia, aby dosiahlo výpočtovú efektivitu. Miesto toho, aby počas minimalizácie E(D) uvažovalo všetky pixely súčasne, do úvahy je braných len osem lineárnych ciest naprieč snímkou. Cesty vedú radiálne symetricky od okrajov snímky a stretávajú sa v pixeli *p*. Potom sú sumarizované individuálne náklady pre každú cestu a je vybraná paralaxa  $d_p$  s najnižšími nákladmi. Vďaka uvedenému postupu môže výpočtová náročnosť narastať už len lineárne s počtom pixelov a povoleným rozsahom paraláx.

Zjednoodušene povedané, metóda SGM (*Semi-Global Matching*) je založená na párovaní vzájomných informácií na báze pixelov a aproximovaní globálnej 2D vyhladzovacej podmienky kombináciou mnohých 1D podmienok (HIRSCHMÜLLER, 2005). Výsledkom SGM je napokon rozdielová mapa (*disparity map*) D (Obr. 3.17) a potom aj podrobná hĺbková mapa (*depth map, resp. dense range map*) – ideálne s jednou hodnotou hĺbky pre každý pixel snímky  $I_r$ . Je nutné dodať, že SGM počíta zhody iba v stereopároch a pri viac-snímkovej fotogrametrii tak nachádza uplatnenie iba formou fúzie hĺbkových máp získaných z viacerých stereopárov snímok.



**Obr. 3.17.** Ľavá snímka zo stereopáru (vľavo) a DSI-obraz získaný metódou SGM (vpravo) (HIRSCHMÜLLER, 2005).

#### 3.2.3 Multi-view stereo

Pri hľadaní zhôd len v pároch snímok často dochádza k zákrytovým oblastiam, keď spojitý povrch objektu nie je kompletne viditeľný na oboch snímkach. Výsledné mračno bodov je potom neúplné a obsahuje diery. Nájdenie zhody zároveň nemusí znamenať, že povrch objektu bude zrekonštruovaný exaktne, neexistuje totiž metóda resistentná voči chybám párovania, keď porovnávame iba dve susedné snímky. Odstránenie zákrytových oblastí a zvýšenie spoľahlivosti nájdených zhôd je možné dosiahnuť iba pridaním ďalších snímok z iného stanoviska kamery. Uvedená technika sa nazýva MVS (*Multi-view stereo*) (Obr. 3.18).



Obr. 3.18. Princip Multi-view stereo (HAAVARDSHOLM, 2016)

MVS algoritmy môžu byť založené na rôznych prístupoch k analýze korešpondencií, napr.:

- Výpočet hĺbkových máp pre viacero stero-párov a následujúca fúzia viacerých mračien bodov.
- Objemové stereo (Volumetric stereo) orezávanie priestoru podľa diskrétnej mriežky.
- Plošná expanzia podrobné párovanie významných bodov v textúre (*dense feature matching*).

Pri výpočte hĺbkových máp sa najčastejšie používa normalizovaná krížová korelácia medzi párovanými oknami, pričom jej výsledky slúžia v týchto algoritmoch na vyjadrenie spoľahlivosti 3D bodu. Odhad optimálnej polohy 3D bodu sa potom dosiahne iteratívnym výpočtom hodnôt normalizovanej krížovej korelácie so zmenou jedného alebo viacerých parametrov 3D bodu, napr. hĺbky alebo normály. (GOESELE a kol., 2006) navrhli odhad spoľahlivej hĺbkovej mapy kumulovaním korelačných hodnôt počítaných z viacerých snímkových párov so zmenou hĺbky. Presnejšie výsledky možno dosiahnuť použitím výsledkov párovania získaných zo susedných pixelov, z dôvodu odstránenia odľahlých meraní (CAMPBELL a kol., 2008). (BRADLEY a kol., 2008) však na dosiahnutie robustného párovania snímok použili transformáciu párovacieho okna nielen podľa hĺbky, ale aj podľa normály 3D bodu.

Metóda *volumetric stereo* sa používa na modelovanie kompaktných uzavretých objektov zo snímok (napr. sôch). V porovnaní s inými stereo-algoritmami pritom nie je nutné, aby sa susedné snímky na seba výrazne podobali, nejde totiž o tradičné hľadanie zhôd na základe obrazovej korelácie. Podstatné je len, aby okraje objektu (jeho silueta) boli zo snímok jednoznačne extrahovateľné a potom sa v diskrétnej mriežke tzv. voxelov hľadá priestorový tvar objektu, ktorému by zodpovedali priemety tohto zjednodušeného vizuálneho obalu (*visual hull*) na jednotlivých snímkach (Obr. 3.19). Metóda bola predstavená ešte v 80. rokoch minulého storočia (BAUMGART, 1974), no v súčasnosti existuje množstvo rôznych algoritmov, ktoré ju dopĺňajú o ďalšie rozšírenia kvôli zvýšeniu kvality výsledných 3D modelov.



Obr. 3.19. Tvorba vizuálneho obalu v metóde Volumetric stereo (SONG a kol., 2010)

(FURUKAWA & PONCE, 2009) metódu napr. doplnili aj o lokálne a globálne optimalizačné techniky, aby dosiahli vynútenie fotometrických aj geometrických podmienok konzistencie. V prvom kroku je použitý algoritmus navrhnutý v (LAZEBNIK, 2002) na vytvorenie kombinatorického opisu modelu vizuálneho obalu v zmysle mnohostenných pásov rozbalených kužeľov (*cone strips*) a ich vzájomných vzťahov. Potom je tento hrubý model zjemnený v troch krokoch:

- Najskôr sú pomocou dynamického programovania identifikované povrchové hrany objektu, ktoré sa prekrývajú s vizuálnym obalom.
- Potom je vizuálny obal orezávaný pomocou techniky *Graph Cuts*, aby sa globálne minimalizovala obrazová diskrepancia povrchu a zrekonštruovali sa aj konkávne oblasti, ktoré vo vizuálnom obale nie sú zachytené.
- Napokon je použitá iteratívna (lokálna) minimalizácia energetickej funkcie, aby sa vynútili fotometrické aj geometrické podmienky a boli zrekonštruované jemné povrchové detaily.

Vizuálna ukážka uvedeného postupu spracovania je znázornená na Obr. 3.20.



**Obr. 3.20.** Zľava doprava: vstupná snímka, vizuálny obal, kužeľové pásy na okrajoch vizuálneho obalu, identifikované hranové segmenty a výsledný model po aplikácii techniky *Graph Cuts* (FURUKAWA & PONCE, 2009)

Podrobná rekonštrukcia povrchu je však v MVS možná aj s využitím významných prvkov v textúre (*features*). (FURUKAWA & PONCE, 2007) na tento účel využívajú tzv. povrchovú expanziu. Najskôr extrahujú významné prvky (*features*), aby získali riedke mračno bodov – súbor prvotných korešpondencií. Potom iteratívne rozširujú nájdené zhody do blízkeho okolia. Nesprávne priradené zhody sa odfiltrujú pomocou podmienok viditeľnosti a napokon sa pristúpi k finálnej rekonštrukcii povrchu (Obr. 3.21). Technológia MVS je využívaná napr. v softvéri PMVS (*Patch Based Multi-View Stereo*) (FURUKAWA & PONCE, 2010), ktorý sa často využíva v spojení so softvérom VisualSFM.



Obr. 3.21. Postup povrchovej expanzie podľa (FURUKAWA & PONCE, 2007)

Počas finálnej rekonštrukcie povrchu vo forme 3D modelu však môžu nastať komplikácie v oblastiach, kde je povrchová textúra nevýrazná. (JANCOSEK & PAJDLA, 2011) predpokladajú, že *zložité povrchy* môžu v scéne existovať spolu s *jednoduchými povrchmi*, ktoré majú kvalitnú textúru a môžu byť teda presne zrekonštruované tradičnými technikami založenými na štandardných stereo-algoritmoch. Povrch, ktorý je podrobne vzorkovaný vstupnými 3D bodmi, je považovaný za *jednoduchý povrch*. Na Obr. 3.22 sú bledomodrou farbou znázornené kužele voľného priestoru s tzv. silnou podporou – ide o časť priestoru, ktorá sa nachádza medzi *jednoduchým povrchom* a asociovanými kamerami.



**Obr. 3.22.** Rekonštrukcia objektov s nezreteľnou povrchovou textúrou podľa (JANCOSEK & PAJDLA, 2011)

Idea metódy vizuálneho obalu vychádza z faktu, že silueta objektu rozdelí snímku na dve základné oblasti – popredie a pozadie. Silueta spolu s projekčným centrom kamery definuje siluetový kužeľ, ktorý obsahuje objekt. Ak je teda k dispozícii viacero takýchto snímok so siluetami, možno scénu obmedziť na prieniky jednotlivých kužeľov. Autori dodatočne zadefinovali povrchy s tzv. slabou podporou (zelená farba na Obr. 3.22) ako špecifické časti *zložitého povrchu*. Povrchy so slabou podporou sú veľmi riedko pokryté 3D bodmi a nachádzajú sa poblíž hraníc kužeľov voľného priestoru so silnou podporou. Cieľom autorov teda bolo najskôr vytvoriť prvotný povrch a ten neskôr zjemniť na úroveň vysokých detailov. Na dosiahnutie tohto cieľa pristupujú k rekonštrukcii povrchu ako k problému minimalizácie energetickej funkcie, ktorý môže byť globálne optimalizovaný výpočtom tzv. *minimálneho s-t rezu v s-t grafe* (ide o špecifickú oblasť programovania v sieťach, kde je potrebné poznať zdroj (*source - s*) a smer (*sink - t*)). V prvom rade počítajú úroveň podporou a napokon upravujú *t-váhy* grafu, aby mohli zrekonštruovať aj povrchy so slabou podporou.

Pre všetky kamery v scéne je teda najskôr potrebné vypočítať hĺbkové mapy a z nich 3D mračná bodov. Potom je generovaná Delaunayho tetrahedralizácia (3D ekvivalent triangulácie) mračna bodov v snahe o identifikáciu tetrahedrónov ako prázdnych alebo obsadených, čo je vykonané nájdením už spomínaného *minimálneho s-t rezu* 

korešpondujúceho *grafu*. Uvedeným spôsobom možno dosiahnuť veľmi kvalitné výstupy aj na povrchoch s nekvalitnými texturálnymi informáciami (Obr. 3.23).



**Obr. 3.23.** Zľava doprava: vstupná snímka, vstupné 3D mračno bodov, výsledný model (JANCOSEK & PAJDLA, 2011)

# 3.2.4 Zoznam aktuálnych stereo- a MVS-algoritmov

Algoritmy využívané na podrobnú rekonštrukciu povrchu zo snímok sa neustále vyvíjajú, a tak prístupy uvedené v predchádzajúcich kapitolách reprezentujú iba hrubú vzorku rôznych možností ako pristupovať k tejto problematike. No pre predstavu o jej rozsahu je vhodné uviesť napr. zoznamy dostupné na webových stránkach (vision.middlebury.edu, 2018), samostatne pre stereo-algoritmy (Tab. 3.1) a pre MVS-algoritmy (Tab. 3.2). Na týchto webových stránkach totiž možno jednotlivé algoritmy porovnávať na základe vyhodnotenia vzorových setov snímok.

Referencie na jednotlivé algoritmy sú z praktických dôvodov uvedené priamo v nasledovných tabuľkách a nie sú súčasťou zoznamu použitej literatúry na konci tejto práce. Stereo-algoritmov bolo na webstránke iba ku dňu 5. 10. 2018 uvedených celkom 98. Pre technológiu MVS bolo k rovnakému dátumu uvedených 92 rozličných metód.

**Tabul'ka. 3.1.** Výber zo zoznamu stereo-algoritmov k dátumu 5. 10. 2018 od marca 2018 (vision.middlebury.edu, 2018)

Dátum	Metóda	Referencie
		Anonymous. Depth from motion for smartphone AR. SIGGRAPH
07/31/18	MotionStereo	Asia 2018 submission 242.
		Anonymous. Semi-dense stereo matching using dual CNNs.
06/27/18	DCNN	WACV 2019 submission 385.
		Anonymous. Cascaded multi-scale and multi-dimension
		convolutional neural network for stereo matching. PRICAI 2018
06/14/18	MSMD_ROB	submission 41.
		C Wu. CBMB: A crop-based multi-branch network for matching
06/05/18	CBMBNet	cost computation. Bachelors thesis, Fuzhou University, 2018.
06/01/18	PDISCO ROB	Anonymous. Depth inference from stereo image pair using

58

		stacked network based refinement. ROB 2018 submission.
		Anonymous. A hybrid pipeline for robust stereo disparity
06/01/18	NaN_ROB	computation. ROB 2018 submission.
06/01/19	DDSimNat DOD	Anonymous. Robust stereo matching with dot product similarity.
00/01/18	DPSIIIINet_KOB	KOB 2018 Subilitission.
		bidirectional matching volume for disparity estimation CVPR
05/31/18	CBMV ROB	2018. ROB 2018 submission.
	_	Anonymous. Learning for disparity estimation through feature
05/31/18	iResNet_ROB	constancy. ROB 2018 submission.
		B. Wiberg. Stereo matching with neural networks. Bachelors
05/31/18	FBW_ROB	thesis, TU Munich 2018. ROB 2018 submission.
05/20/10		Anonymous. Deep learning combination on disparity maps. ROB
05/30/18	DLCB_ROB	2018 Submission.
05/28/18	PWCDC ROB	submission
03/20/10		Anonymous Superpixel alpha-expansion and normal adjustment
05/26/18	NOSS ROB	for stereo matching. ECCV 2018 submission 500.
	_	Anonymous. Edge enhanced end to end neural network for
05/25/18	XPNet_ROB	disparity estimation. ROB 2018 submission.
		Anonymous. End to end refined estimation for depth. Submitted
05/25/18	ETED_ROB	to ROB 2018.
05/24/18	LALA_ROB	Anonymous. Robust depth estimation. ROB 2018 submission.
05/22/18	DN-CSS_ROB	Anonymous. DN-CSS_ROB. ROB 2018 submission.
		Anonymous. Practical deep stereo (PDS): Toward applications-
05/18/18	PDS	friendly deep stereo matching. NIPS 2018 submission 2833.
05/05/19	WCMA DOD	Anonymous. Multi-scale random walk for stereo matching with
03/03/18	WCMA_KOD	A nonymous Byramid starso matching network. To appear at
05/01/18	PSMNet ROB	CVPR 2018
00,01,10		R. Hamzah, A. Kadmin, M. Hamid, S. Fakhar, A. Ghani, and H.
		Ibrahim. Improvement of stereo matching algorithm for 3D
		surface reconstruction. Signal Processing: Image Communication
04/17/18	ISM	65:165-172, 2018.
02/26/10		A. Geiger, M. Roser, and R. Urtasun. Efficient large-scale stereo
03/26/18	ELAS_ROB	matching. ACCV 2010.
03/23/18	AVERAGE ROB	challenge
03/23/10	AVERAGE_ROD	Median disparity over all training images of the ROB 2018 stereo
03/23/18	MEDIAN ROB	challenge.
	_	Anonymous. The domain transform solver. ECCV 2018
03/14/18	DTS	submission 1189.
		Anonymous. Learning to aggregate costs from multiple scanline
02/11/10		optimizations in semi-global matching. ECCV 2018 submission
03/11/18	SGM-Forest	1095. II Uirashmuellar Starso processing by somi alabel metaling and
		mutual information PAMI 30(2):328_341_2008_ROB_2019
03/09/18	SGM ROB	submission.
52,09/10		Anonymous. Superpixel stereo matching based on normal
03/06/18	NOSS	optimization. ECCV 2018 submission 500.

**Tabul'ka. 3.2.** Zoznam MVS-algoritmov k dátumu 5. 10. 2018 (vision.middlebury.edu, 2018)

Názov metódy	Referencie
	Anonymous. Efficient multiview stereo by random-search and propagation.
3DV2014_25	3DV 2014 submission 25.
	A. Auclair, L. Cohen, and N. Vincent. Using point correspondences without
Auclair	projective deformation for multi-view stereo reconstruction. ICIP 2008.
	M. Beljan, R. Klowsky, and M. Goesele. A multi-view stereo implementation
Beljan	on massively parallel hardware. Technical Report, U Darmstadt, 2011.
	D. Bradley, T. Boubekeur, and W. Heidrich. Accurate multi-view
Bradley	reconstruction using robust binocular stereo and surface meshing. CVPR 2008.
	J. Schönberger, E. Zheng, M. Pollefeys, and JM. Frahm. Pixelwise view
	selection for unstructured multi-view stereo. ECCV 2016. [Renamed from
COLMAP_ROB	"Schoenberger" to "COLMAP_ROB" for submission to ROB 2018.]
	Anonymous. Photometric bundle adjustment for dense multi-view modeling.
CVPR2014_1287	CVPR 2014 submission 1287.
	N. Campbell, G. Vogiatzis, C. Hernandez, and R. Cipolla. Using multiple
Campbell	hypotheses to improve depth-maps for multi-view stereo. ECCV 2008.
	J. Chang, H. Park, I. Park, K. Lee, and S. Lee. GPU-friendly multi-view stereo
	reconstruction using surfel representation and graph cuts. CVIU 115(5):620-
Chang	634, 2011.
	Z. Li, K. Wang, W. Zuo, D. Meng, and L. Zhang. Detail-preserved and content-
	aware variational multi-view stereo reconstruction. Submitted to IEEE TIP,
DCV	2014.
	A. Delaunoy, E. Prados, P. Gargallo, JP. Pons and P. Sturm. Minimizing the
Delaunoy	multi-view stereo reprojection error for triangular surface meshes. BMVC 2008.
	Y. Deng, Y. Liu, Q. Dai, and Z. Zhang. Depth maps fusion for multi-view
Deng	stereo via matrix completion. Submitted to TPAMI 2011.
	Y. Xi and Y. Duan. An integrated depth fusion approach for multi-view stereo.
Depth Fusion	CGI 2011.
	Anonymous. Robust multi-view stereo via matrix recovery. ECCV 2014
ECCV2014_1338	submission 1338.
	S. Fuhrmann and M. Goesele. Floating scale surface reconstruction.
Fuhrmann-SG14	SIGGRAPH 2014.
	Y. Furukawa and J. Ponce. High-fidelity image-based modeling. Technical
Furukawa	Report 2006-02, UIUC, 2006.
	Y. Furukawa and J. Ponce. Accurate, dense, and robust multi-view stereopsis.
Furukawa 2	CVPR 2007.
	Y. Furukawa and J. Ponce. Accurate, dense, and robust multi-view stereopsis.
Furukawa 3	Submitted to PAMI 2008.
C 11 <sup>°</sup>	S. Galliani, K. Lasinger, and K. Schindler. Massively parallel multiview
Galliani	stereopsis by surface normal diffusion. ICCV 2015.
Carra alla	P. Gargallo, E. Prados, and Peter Sturm. Minimizing the reprojection error in
Gargano	Surface reconstruction from images. ICC v 2007.
Conoralized SSD	F. Calakii, A. Ulusoy, M. Restrepo, G. Taubin, and J. Mundy. High resolution
Generalized-SSD	L Zhang X. Zuo, L Dan, and C. Wang, Multiple denth many integration for 2D.
	J. Zheng, A. Zuo, J. Ken, and S. wang. Multiple depth maps integration for 5D
Geodesic CC	Engineering and Knowledge Engineering 2014
	L Gerussoni D Sturm and D Brochard Efficient don'th man fusion for CDU
	based real-time dense 3D reconstruction from monocular or binocular image
Gervasoni	sequences. Submitted to MVA 2016
Joi vusoini	1 sequences. Submitted to 111 11 2010.

Goesele	M. Goesele, B. Curless, and S. Seitz. Multi-view stereo revisited. CVPR 2006.
	M. Goesele, N. Snavely, B. Curless, H. Hoppe, and S. Seitz. Multi-view stereo
Goesele 2007	for community photo collections. ICCV 2007.
	JY. Guillemaut and A. Hilton. Joint Multi-Layer Segmentation and
~	Reconstruction for Free-Viewpoint Video Applications. IJCV, 93(1):73–100,
Guillemaut	2011.
TT 11 1	M. Habbecke and L. Kobbelt. A surface-growing approach to multi-view stereo
Нарреске	reconstruction. CVPR 2007.
Hornondoz	C. Hernandez Esteban and F. Schmitt. Sinouelle and stereo fusion for 3D object modeling. (VIII. 06(3):267, 202, 2004
Hernandez	V Hongying G Li V Li C Long Multi view reconstruction using hand
	graph-cuts Journal of Computer Aided Design & Computer Graphics 2010
Hongxing	22(4): 605-611.
	A. Hornung and L. Kobbelt. Hierarchical volumetric multi-view stereo
	reconstruction of manifold surfaces based on dual graph embedding. CVPR
Hornung	2006.
	Anonymous. Variational PatchMatch multiview reconstruction and refinement.
ICCV2015_1020	ICCV 2015 submission 1020.
	Anonymous. Joint camera clustering and surface segmentation for large-scale
ICCV2015_293	multi-view stereo. ICCV 2015 submission 293.
	S. Liu and D. Cooper. Statistical inverse ray tracing for image-based 3D
IRAY	modeling. Submitted to TPAMI 2013.
Jancosek-	M. Jancosek, A. Shekhovtsov, and I Pajdla. Scalable multi-view stereo. 3DIM
3DIM09	2009. M. Janagaly and T. Baidla, Exploiting visibility information in surface
	M. Jancosek and T. Pajdia. Exploiting visibility information in surface
Jancosek2014	Research Notices 2014
Juneosek2011	M Jancosek and T Paidla Segmentation based multi-view stereo CVWW
JancosekCVWW	2009.
	Z. Kang and G. Medioni. Fast dense 3D reconstruction using an adaptive
Kang	multiscale discrete-continuous variational method. WACV 2014.
	R. Khuboni and B. Naidoo. Adaptive segmentation for multi-view stereo. IET
Khuboni	Computer Vision 2017.
	R. Khuboni and H. Xu. From sparse to dense reconstruction. Submitted to IET
Khuboni2	Computer Vision 2018.
	K. Kolev, M. Klodt, T. Brox, and D. Cremers. Propagated photoconsistency and
TZ 1	convexity in variational multiview 3D reconstruction. ICCV PACV workshop
Kolev	2007. K. Kalan M. Kladt T. Dura and D. Coursers Continuous alghal activitation
Koley?	K. Kolev, M. Klodi, T. Brox, and D. Cremers. Continuous global optimization in multiview 3D reconstruction. HCV 2009
1101012	K Koley T Pock and D Cremers Anisotronic minimal surfaces integrating
Kolev3	nhotoconsistency and normal information for multiview stereo ECCV 2010
	V Kolmogorov and R Zabih Multi-camera scene reconstruction via graph
Kolmogorov	cuts. ECCV 2002, vol. III, pp. 82-96.
U	I. Kostrikov, E. Horbert, and B. Leibe. Probabilistic labeling cost for high-
Kostrikov	acuracy multi-view reconstruction. CVPR 2014.
	A. Kuhn, H. Mayer, H. Hirschmüller, and D. Scharstein. A TV prior for high-
Kuhn-3DV-2014	quality local multi-view stereo reconstruction. 3DV 2014.
Kuhn-GCPR-	A. Kuhn, H. Hirschmueller and Helmut Mayer. Multi-resolution range data
2013	tusion for multi-view stereo reconstruction. GCPR 2013.
	K. L1, Q. Da1, and W. Xu. Markerless shape and motion capture from multi-
V.m I	view video sequences. Submitted to IEEE Transactions on Circuits and Systems
Kun Li	for video fechnology, 2009.

	A. Kuhn, H. Hirschmueller, D. Scharstein, and H. Mayer. A TV prior for high-
	quality scalable multi-view stereo reconstruction. International Journal of
LTVRE_ROB	Computer Vision, 124(1):2–17, August 2017.
T 1'1	A. Ladikos, S. Benhimane, and N. Navab. Multi-view reconstruction using
Ladikos	narrow-band graph-cuts and surface normal optimization. BMVC 2008.
T 1 4	Philippe Lambert and Patrick Hebert. Robust multi-view stereo without
Lambert	matching. 3DIM 2009.
T 1 (2	P. Lambert, P. Hebert, and J.D. Deschenes. Robust RBF: Application to multi-
Lambert3	view stereo surface reconstruction. Submitted to CVIU 2010.
Langguth-SMVS	view stereo. ECCV 2016. Code available.
	J. Li, E. Li, Y. Chen, L. Xu, and Y. Zhang. Bundled depth-map merging for
Li	multi-view stereo. CVPR 2010.
	Y. Liu. A point cloud based multi-view stereo algorithm for free viewpoint
	video. To appear in IEEE Transactions on Visualization and Computer
Liu	Graphics 2009.
	Y. Liu, X. Cao, Q. Dai, and W. Xu. Continuous depth estimation for multi-view
Liu2	stereo. CVPR 2009.
	A Saouli, M. Babahenini, and S. Medjram. Accurate, dense and shading-aware
	multi-view stereo reconstruction using metaheuristic optimization. Submitted to
MVSPSO	Multimedia tools and applications, 2018.
	P. Merrell, A. Akbarzadeh, L. Wang, P. Mordohai, JM. Frahm, R. Yang, D.
Merrell	Nister, and M. Pollefeys. Real-time visibility-based fusion of depth maps.
Confidence	ICCV 2007.
	P. Merrell, A. Akbarzadeh, L. Wang, P. Mordohai, JM. Frahm, R. Yang, D.
	Nister, and M. Pollefeys. Real-time visibility-based fusion of depth maps.
Merrell Stability	ICCV 2007.
	C. Mostegel, R. Prettenthaler, F. Fraundorfer, and H. Bischof. Scalable surface
Mostegel	reconstruction from point clouds with extreme scale and density
CVPR17	diversity. CVPR 2017.
NG 11'1	E. Mouaddib and G. Caron. Photometric approach for accurate triangulation
Mouaddib	and 3D reconstruction. ICPR 2012 submission 1995.
Musalia	P. Muecke, R. Klowsky, and M. Goesele. Surface reconstruction from multi-
Nuecke	
OpenMVS_ROB	OpenMVS. ROB 2018 submission.
D	JP. Pons, R. Keriven, and O. Faugeras. Modelling dynamic scenes by
Pons	registering multi-view image sequences. CVPR 2005, vol. II, pp. 822-827.
	N. Savinov, C. Haene, L. Ladicky, and M. Polleteys. Semantic 3D
Savinav	reconstruction with continuous regularization and ray potentials using a
Savinov	C. Schroors, H. Zimmer, L. Velgeerte, A. Druhn, O. Demetz, and L.
Sabraara	U. Schloels, H. Zhinner, L. Valgaetts, A. Brunn, O. Demetz, and J. Weiskert, Anisotropic range image integration, DACM 2012
Schloers	P. Somerijan A new variational framework for multiview surface
Somarijan	B. Semerjian. A new variational framework for multiview surface
Semerjian	S Li S V Sin T Fang and I Quan Efficient multiview surface refinement
Shiwei Li	with adaptive resolution control ECCV 2016
	S Sinha P Mordohai and M Pollefeys Multi-view stereo via granh cuts on
Sinha	the dual of an adaptive tetrahedral mesh ICCV 2007
Siina	P Song X Wu and M Wang Volumetric stereo and silhouette fusion for
Song	image-based modeling Visual Computer Journal 2010
50115	M Sormann C Zach I Bauer K Karner and H Rischof Watertight multi-
Sormann	view reconstruction based on volumetric granh-cuts SCIA 2007
Somulin	I Starck and A Hilton Surface canture for performance-based animation
Starck	CG&A 27(3):21-31 2007

	C Strache B Francing and L Van Gool Combined donth and outlier
Strecha	estimation in multi-view stereo. CVPR 2006.
	Y. Xi and Y. Duan. An iterative surface evolution algorithm for multiview
SurfEvolution	stereo. EURASIP Journal on Image and Video Processing, 2010.
	S. Aroudj, P. Seemann, F. Langguth, S. Guthe, and M. Goesele. Visibility-
	consistent thin surface reconstruction using multi-scale kernels. SIGGRAPH
TSR	Asia 2017.
	S. Tran and L. Davis. 3D surface reconstruction using graph cuts with surface
Tran	constraints. ECCV 2006, vol. II, pp. 219-231.
	Z. Xue, X. Cao, Y. Liu, Q. Dai, and N. Zhang. Continuous depth-map
	estimation with explicit occlusions for multi-view stereo. Submitted to CVIU
Tsinghua BBNC	2011.
	B. Ummenhofer and T. Brox. Global, dense multiscale reconstruction for a
Ummenhofer	billion points. ICCV 2015.
	G Vogiatzis P Torr and R Cipolla Multi-view stereo via volumetric graph-
Vogiatzis	cuts. CVPR 2005. pp. 391-398.
	G Vogiatzis C Hernandez P Torr and R Cipolla Multi-view stereo via
Vogiatzis2	volumetric graph-cuts and occlusion robust photo-consistency. PAMI 2007.
	H H Vu R Keriven P Labatut and L-P Pons Towards high-resolution large-
Vu	scale multi-view stereo CVPR 2009
	D Lu W Zhu C Diao I Xiang and D Xu Continuous disparity chain
	estimation for multi-view stereo. Submitted to Journal of Zheijang University
WOZhu	Science C 2012
Wei-BMVC-	I Wei B Resch H Lensch Multi-view denth man estimation with cross-view
2014	consistency BMVC 2014
2011	W Huang K Sun and W Tao Multi-view stereo combined with space
Wenije	propagation and pixel-level refinement. Submitted to ACPR 2017
,, onjie	Y Li and S Fang Rejected based multi-view stereo using window-based
Yichao Li	matching method Submitted to PAMI 2013
	C Zach T Pock and H Bischof A globally ontimal algorithm for robust TV-
Zach	L1 range image integration ICCV 2007
Zach?	C. Zach East and high quality fusion of donth mans. 2DBVT 2008
Zaciiz	C. Zach. Fast and high quality fusion of depth maps. 5DF v 1 2008.
Zaharescu	mesh-based approach to surface evolution. ACCV 2007.
	A. Zaharescu, E. Boyer, and R. Horaud. Topology-adaptive mesh deformation
	for surface evolution, morphing, and multi-view reconstruction, TPAMI 33(4):
	823-837. 2011.
	A. Zaharescu, C. Cagniart, S. Ilic, E. Boyer, and R. Horaud, Camera clustering
	for multi-resolution 3-D surface reconstruction. ECCV 2008 M2SFA2
Zaharescu2	Workshop.
	Z. Li, K. Wang, W. Jia, H. Chen, W. Zuo, D. Meng, and M. Sun, Multiview
	stereo and silhouette fusion via minimizing generalized reprojection error
ZhaoxinLi	Image and Vision Computing 33(1):1-14 2015
	Z Li K Wang D Meng X Feng C Xu and W Zuo Multi-view stereo via
	depth map fusion: a coordinated decent optimization method. Submitted to
	Neurocomputing special issue on "Smart Computing for Large Scale Visual
ZhaoxinLi2	Data Sensing and Processing" 2015
	Z Zhu C Stamatopoulos and C Fraser Accurate and occlusion-robust multi-
	view stereo Submitted to the ISPRS Journal of Photogrammetry and Remote
Zhu	Sensing 2015

# 4 PRAKTICKÉ APLIKÁCIE SFM V OBLASTI KULTÚRNEHO DEDIČSTVA

Oblasť počítačového videnia zaznamenala v poslednom čase nemalý posun smerom k bežnému užívateľovi – zdarma dostupné softvérové riešenia pre 3D modelovanie z amatérskych snímok už od neho nevyžadujú ani náročné hardvérové vybavenie, pretože výpočty môžu prebiehať na vzdialenom serveri a výsledok si potom možno stiahnuť do svojho počítača alebo mobilného telefónu prostredníctvom internetu. Komerčne využiteľné softvéry pravdaže zadarmo nie sú, avšak ich cena je mnohonásobne nižšia než napr. cena špecializovaných softvérov a vybavenia na terestrické laserové skenovanie, pričom kvalita výsledkov je na porovnateľnej úrovni, ba dokonca v určitých aplikáciách aj vyššia. Celkovo teda možno povedať, že nástup digitálnych technológií umožnil aj opätovné oživenie fotogrametrie ako jednej z hlavných metód pre zber priestorových údajov o objektoch kultúrneho dedičstva (MARČIŠ & FRAŠTIA, 2012).

Pre demonštráciu širokej využiteľnosti softvérov pracujúcich na princípoch SfM je v nasledujúcich podkapitolách uvedených niekoľko špecifických príkladov, s ktorými sa možno stretnúť pri digitalizácii kultúrneho dedičstva. Rôznorodosť príkladov sa týka jednak veľkosti a typu meraných objektov a zároveň účelu ich digitalizácie, ako aj použitia fotogrametrie v tomto procese. Nie vždy totiž fotogrametrické meranie slúži na tvorbu finálneho produktu, často ide iba o užitočný medzikrok, ktorý zefektívni ďalšie spracovanie.

# 4.1 Miniatúrne objekty

Ako prvý príklad slúžia objekty, ktoré sú zároveň z hľadiska svojich rozmerov najmenšie. Artefakty o rádovo centimetrových rozmeroch sa v súčasnosti zvyknú dokumentovať iba fotograficky, spolu s približným mierkovým zakreslením jedného alebo viacerých charakteristických pohľadov, prípadne rezov – to všetko ručne, v praxi nejde o presné ortopohľady z dôvodu časovej náročnosti spracovania v porovnaní s ručným zákresom skúseného pracovníka. Digitálne textúrované 3D modely tak nachádzajú uplatnenie predovšetkým v oblasti virtuálnych prezentácií pre verejnosť, možnosti trojrozmernej tlače replík, suvenírov, vo výnimočných prípadoch pri reštaurovaní a tvorbe presných rezov a ortosnímok pre výkresovú dokumentáciu.

Všetky uvedené artefakty boli modelované v softvéri Agisoft PhotoScan Professional. Archeologické nálezy pochádzajú z výskumov Pamiatkového úradu Slovenskej republiky (PÚSR) a boli jeho oddeleniu grafickej dokumentácie (OGD) zapožičané na skenovanie triangulačným skenerom Comet LED. 3D modely vybraných predmetov tak mohli byť porovnané s veľmi presnou technológiou (0,05 mm) skenovania na báze štruktúrovaného svetla. Snímkovanie jednotlivých artefaktov bolo vykonané v difúznom stane 70 x 70 x 70 cm na bielom pozadí – v tomto prípade teda bola kamera stabilná a natáčal sa iba objekt. Keďže pozadie bolo prakticky tvorené plochou jednofarebnou textúrou, softvér na ňom nenašiel žiadne významné body, ktoré by mohli ovplyvniť orientáciu snímok, a tak boli snímky zorientované iba na základe zmien v natočení objektu. Modely z PhotoScanu s referenčnými modelmi z Cometu boli porovnané v softvéri Geomagic Studio. V tomto softvéri bola pre modely z PhotoScanu zadefinovaná aj mierka meraním korešpondujúcich charakteristických bodov na modeloch zo skenera Comet.

# 4.1.1 Hlinená nádoba

Prvý objekt je hlinená nádoba s výškou približne 18 cm pochádzajúca z neznámeho náleziska, datovaná približne do 15. storočia n. l. Rozmiestnenie snímok a nádobu v difúznom stane možno vidieť na Obr. 4.1.



Obr. 4.1. Polohy kamier voči objektu a nádoba v difúznom stane

Vzájomné polohy nádoby a kamery boli volené tak, aby bolo dodržané vejárovité rozloženie snímok okolo objektu a aby jednotlivé vejáre mohli byť prepojené dostatočným množstvom významných bodov – pre vonkajší obvod, spodok nádoby, aj vnútro. Spolu bolo vyhotovených 53 snímok digitálnou zrkadlovkou Nikon D5100 s objektívom Tamron 18-270 mm (nastaveným na 35 mm ohniskovú vzdialenosť). Výpočet 3D modelu bol spustený s nastavením generovania *meshu* na kvalite *high*. Spracovanie od orientácie snímok až po vytvorenie textúrovaného 3D modelu trvalo 6,7 hodiny. Na spresnenie výsledkov generovania

3D modelu a minimalizáciu šumu (odľahlých zhlukov trojuholníkov) bola pre každú snímku aplikovaná automatická maska, ktorá z generovania 3D modelu vylúčila jednofarebné biele pozadie difúzneho stanu. Na Obr. 4.2 možno vidieť tieňovaný 3D model z Cometu (vľavo) a z PhotoScanu (vpravo).



Obr. 4.2. 3D model nádoby z Cometu (vľavo) a z PhotoScanu (vpravo)

V červenom poli je zvýraznený detail obsahujúci prasklinu vnútorného okraja hrdla nádoby. Triangulačný skener Comet prasklinu vymodeloval, no pri spracovaní snímok z Nikonu D5100 vo PhotoScane prasklina zanikla, nakoľko softvér ju vyhodnotil iba ako povrchový znak textúry. Model z PhotoScanu síce na pohľad pôsobí podrobnejšie, ide však iba o známky šumu a vo všeobecnosti sú detaily ostrých hrán jemne zahladené (do úrovne 0,2 mm). Rozloženie deformácií je viditeľné na rozdielovom modeli (Obr. 4.3). Porovnanie bolo vykonané v softvéri Geomagic Studio, pričom 3D odchýlky sú počítané ako najkratšia vzdialenosť od testovaného bodu po ktorýkoľvek bod na referenčnom modeli.



**Obr. 4.3.** Rozdielový model Comet – PhotoScan (stupnica v mm)

Z rozdielového modelu je viditeľné, že najväčšie odchýlky (do +0,2 mm) vznikli po vonkajšom obvode nádoby – ich pôvod môže mať dve príčiny. Nakoľko sa odchýlky nachádzajú na prekryte dvoch snímkových pásov, môžu byť spôsobené výraznou konvergenciou snímok medzi pásmi. Druhou príčinou môže byť nepresnosť už samotného referenčného modelu, nakoľko aj ten je vyskladaný z viacerých čiastkových skenov.

# 4.1.2 Kamenné pečatidlo

Okrem uvedenej nádoby bol vytvorený aj 3D model kamenného pečatidla z mastenca, vysokého približne 67 mm (lokalita Ivanovce). Snímkovanie prebehlo opäť v difúznom stane, tentokrát však s kompaktnou digitálnou kamerou Nikon Coolpix P510 (16 megapixelový CMOS senzor) v macro-režime. Spolu bolo vyhotovených 44 snímok.



**Obr. 4.4.** Pečatidlo z mastenca (vľavo), 3D model z PhotoScanu (v strede) a rozdielový model voči modelu zo skenera Comet v mm (vpravo)

Spracovanie pečatidla do podoby textúrovaného 3D modelu trvalo približne 1,8 hod.

Z rozdielového modelu voči modelu zo skenera Comet na Obr. 4.4 vpravo je viditeľné, že PhotoScan opäť mierne zahladzoval ostré hrany artefaktu, maximálne však do úrovne 0,1 mm. Problematické boli aj oblasti v zákrytoch so zlou viditeľnosťou, čo je však samozrejme možné vyriešiť vhodnejším rozmiestnením kamier počas snímkovania.

# 4.2 Archeológické náleziská

Digitálna fotogrametria nachádza uplatnenie aj v oblasti záchranných archeologických výskumov, kde je značný dôraz kladený nielen na širokú použiteľnosť a presnosť

fotogrametrických výstupov, ale aj na nízku časovú náročnosť prác v teréne (MARČIŠ, CHLEPKOVÁ & HALIČKOVÁ, 2010).

# 4.2.1 Sondy

V priebehu investičnej výstavby sa veľmi často stáva, že počas výkopových prác dôjde k odkrytiu archeologických nálezov a výstavba je pozdržaná do ukončenia výskumu. To pre investora samozrejme znamená nárast finančných nákladov s každým dňom odkladu výstavby a použitie rýchlych dokumentačných metód sa stáva prirodzenou voľbou. Oproti bežným meračským metódam má zároveň fotogrametria výhodu nie len v nízkej časovej náročnosti terénnych prác a dosiahnuteľnej presnosti, ale najmä v texturálnych informáciách, ktoré sú pre archeológov dôležitým aspektom pri analýze odkrytej lokality.



Obr. 4.5. 3D model náleziska s polohami kamier (vľavo) a ortofotomozaika (vpravo)

Na Obr. 4.5 vpravo je viditeľná odlišná farebnosť pôdy v jednotlivých sondách, pričom zmena farby pôdy signalizuje zásah ľudskej činnosti a môže byť dôvodom pre hlbšie skúmanie oblasti. Pre tvorbu obdobného fotoplánu postačuje vyhotoviť dostatok snímok (závisí od veľkosti a tvaru lokality) s vhodným prekrytom a zamerať geodeticky niekoľko vhodne rozložených vlícovacích bodov (aj kontrolných). Nie je potrebné merať prácne geodeticky každý lomový bod objektu. Umiestnenie vytvoreného modelu v referenčnom súradnicovom systéme (napr. S-JTSK) možno docieliť zapojením GNSS-meraní na minimálne 2 bodoch vyhodnotených aj fotogrametricky (za predpokladu definície mierky modelu a jeho orientácie v smere zvislice z terestrického zamerania pomocou univerzálnej meracej stanice UMS).

Model vyobrazený na Obr. 4.5 vľavo bol vytvorený technológiou konvergentného snímkovania v softvéri PhotoModeler Scanner – zvolenej metóde zodpovedala aj poloha kamery počas snímkovania, ktoré bolo pritom vykonávané z rebríka, pre dosiahnutie väčšieho prekrytu medzi susednými snímkami a súčasne zníženie počtu snímok. Jednotlivé

charakteristické body boli na snímkach merané manuálne, čo značne predĺžilo kancelárske práce, no v dobe zamerania tohto objektu (máj 2010) ešte nebol k dispozícii softvér PhotoScan. Skúsenému vyhodnocovateľovi by spracovanie približne 30 vybraných snímok vo PhotoModeleri nemalo zabrať viac než 1 až 2 dni, v závislosti od veľkosti prekrytov a členitosti objektu. Stále pritom hovoríme o blízkej pozemnej fotogrametrii – použitie UAV (*Unmanned Aerial Vehicle*), pre malé lokality najlepšie vo forme systémov s rotačným krídlom (*quadrocopter, hexacopter, octocopter* a pod.) z dôvodu lepšej ovládateľnosti, by výrazne znížilo počet snímok a potrebu modelovania jednotlivých lomových hrán každej sondy – stačilo by celú lokalitu považovať za jednu plochu a pri dodržaní vhodnej výšky (napr. pre výšku 50 m je s kamerou Nikon D5100 a objektívom 55 mm dosiahnuteľné GSD (Ground Sample Distance – veľkosť pixela v predmetovej vzdialenosti) približne 4 mm, pričom snímka na zemi pokryje plochu približne 21 x 14 m) a s tým súvisiacim menším radiálnym skreslením iba prekresliť snímky do požadovanej roviny.

Vďaka softvérom umožňujúcim úplnú automatizáciu spracovania od orientácie snímok až po generovanie textúrovaného 3D modelu, náročnosť spracovania výrazne klesá, počet snímok nie je tak dôležitý, čiže možno spracovávať aj dokumentačné snímky vyhotovené priamo archeológmi, ktorí nemusia mať podrobné znalosti o vhodnosti rozloženia stanovísk kamery pre tú ktorú metódu fotogrametrického spracovania – jedinou požiadavkou je, aby snímkovali s vysokou hustotou, aspoň s 3-násobným prekrytom a rovnomerne okolo celého objektu. PhotoScan umožňuje spracovanie aj pomerne konvergentných snímok, čo síce na výslednom 3D modeli spôsobuje nepresnosti v podobe zvlnenia a zašumenia, no na tvorbu fotoplánu a archeológmi vyžadovanú presnosť 1 cm bohato postačuje.



**Obr. 4.6.** Ortosnímka z PhotoScanu (vľavo) a archeologický náčrt z Budmeríc v mierke 1 : 20 (vpravo)

Porovnaním ortosnímky vyprodukovanej z PhotoScanu a manuálneho archeologického náčrtu, ktorý sa bežne vytvára v teréne na milimetrovom papieri v mierke 1 : 10 až 1 : 20,

možno dospieť k odchýlkam 2 až 3 cm v polohe ručne zakreslených objektov (Obr. 4.6), čo je spôsobené odhadom pracovníka tvoriaceho náčrt, ale aj hrúbkou samotnej ceruzky.

Pre ilustráciu je na Obr. 4.7 znázornený 3D model náleziska pri Svätom Jure vytvorený v softvéri PhotoScan. Snímkovanie bolo pre absenciu vyvýšenej plochy vykonané iba zo zeme, z maximálnej možnej výšky (na výšku človeka s natiahnutými rukami) a pre zabezpečenie čo najväčšieho prekrytu bol na digitálnej zrkadlovke Nikon D5100 použitý objektív s veľmi krátkym ohniskom (10 mm).



**Obr. 4.7.** 3D model náleziska pri Svätom Jure so znázornením polôh kamery v súlade s podmienkami pre obrazové skenovanie (86 snímok)

Objektívy, ktoré dĺžkou ohniska hraničia s kategóriou *fisheye* (rybie oko) sú charakteristické výraznou mierou radiálnej distorzie po okrajoch snímky. Vďaka dostatočnému prekrytu však softvér PhotoScan dokáže vyprodukovať veľmi kvalitné výsledky aj v extrémnych prípadoch. Chyby v obvodových kontrolných dĺžkach sa pri tomto 12 metrovom objekte pohybovali do 4 mm, čo je opäť postačujúca presnosť pre obdobný druh archeologickej aplikácie a bežné mierky 1 : 10 až 1 : 20.

#### 4.2.2 Hroby, kostry

Špecifickým prípadom archeologických vykopávok sú hroby, pri ktorých je potrebné podrobne zamerať rozloženie všetkých kostí pozostalého, aj predmetov, ktoré sa pri ňom nachádzajú (Obr. 4.8).



**Obr. 4.8.** Vektorový plán manuálneho zakreslenia objektov v hrobe ("Natalka" – Rusovce)

Fotogrametricky možno vyprodukovať nielen ortosnímku, ktorú možno ďalej spracovať do vektorového plánu s vyznačením dôležitých objektov, ale získať prehľad aj o priestorovom členení dna hrobu, ktoré hovorí o spôsobe uloženia pozostalého (Obr. 4.9).



Obr. 4.9. Vertikálny pozdĺžny rez hrobovou jamou – produkt obrazového skenovania

Podrobnosť, presnosť aj rýchlosť zamerania hrobových jám fotogrametrickými metódami je pritom výrazne vyššia než u štandardných archeologických metód merania pásmom a prevažovania bodov pomocou olovnice.



Obr. 4.10. Tieňovaný 3D model hrobu "Natalky" v Rusovciach


Obr. 4.11. Textúrovaná verzia 3D modelu hrobu

Tvorba textúrovaného 3D modelu na Obr. 4.11 vo PhotoScane trvala 40 minút v *medium*-kvalite na notebooku Asus G53S (26 snímok z Nikon D200 – 10 Mpx). Snímky boli pôvodne vyhotovené na spracovanie v softvéri PhotoModeler Scanner dvoma rôznymi metódami spracovania (konvergentne, aj cez DSM – preto až 26 snímok). Do spracovania vo PhotoScane však vstúpili všetky snímky, aby sa vylúčila možnosť akýchkoľvek zakrytých oblastí na modeli.

### 4.3 Fasády historických budov

Azda najčastejšou aplikáciou fotogrametrie v oblasti dokumentácie pamiatok sú fotoplány fasád nehnuteľných stavebných objektov. Ešte v časoch analógových snímok sa nato najčastejšie využívali metódy jednosnímkovej fotogrametrie a stereofotogrametrie. Obe tieto metódy sú pravdaže aplikovateľné aj pri digitálnych snímkach pre svoju jednoduchosť spracovania, avšak s členitosťou fasády buď narastá prácnosť manuálneho vyhodnotenia lomových bodov, alebo na druhej strane klesá presnosť vplyvom radiálnych odchýlok, ak je celá fasáda aproximovaná jednoduchou rovinou. Na digitálne manuálne vyhodnocovanie charakteristických bodov objektu sa v súčasnosti najčastejšie využíva metóda konvergentného snímkovania.

Výsledkom takéhoto spracovania napr. vo PhotoModeleri je 3D model, ktorý možno otextúrovať a vyexportovať z neho ortosnímku v požadovanom rozlíšení. Vektorizácia už potom môže prebehnúť v ľubovoľnom CAD-softvéri (Obr. 4.12).



**Obr. 4.12.** Vektorový model fasády kaštieľa v Bučanoch (hore), časť ortosnímky (dole vľavo) a vektorový plán (dole vpravo)

Na tvorbu ortosnímky fasády je v prípade architektonicky bežne vyžadovanej presnosti 1 cm pravdaže opäť možné použiť aj technológiu "skenovania obrazom" (Obr 4.13). Tu je však potrebné brať do úvahy prístupnosť objektu a viditeľnosť jednotlivých ostrých hrán a rohov, aj nastavenie kvality generovania 3D modelu.



**Obr. 4.13.** Orientačné mračno bodov fasády vo PhotoScane (vľavo), výrez ortosnímky v kvalite *ultra high* (v strede) a *lowest* (vpravo) s viditeľnou deformáciou texturálnych informácií spôsobenou vyššou úrovňou zahladenia ostrých hrán a detailov

## 4.4 Geodetická dokumentácia historickej budovy

Súčasťou meračskej dokumentácie pamiatkových stavebných objektov samozrejme nemôže byť iba vektorový plán a fotoplán fasády – obsah dokumentácie sa síce mení prípad od prípadu, no kompletná dokumentácia stavby by v zásade mala obsahovať aj horizontálne a vertikálne rezopohľady rôznymi úrovňami, vrátane znázornenia stropných konštrukcií a krovov.

Príkladom takejto dokumentácie je napr. zameranie Husitskej bašty v Krupine (Obr. 5.14), ktorej vznik sa datuje približne do 15. storočia a patrí medzi národné kultúrne pamiatky (NKP). K objektu bola pristavaná farnosť a po plánovanej rekonštrukcii by sa tu malo

nachádzať cirkevné múzeum. Použitie fotogrametrických metód pri jej dokumentácii malo veľmi špecifické uplatnenie, keďže výstupy z fotogrametrie slúžili iba ako efektívny medziprodukt – 3D model exteriérových aj interiérových častí objektu, ktorým bolo možno viesť rezy požadovanými úrovňami.



Obr. 4.14. Husitská bašta v Krupine (vľavo) a náhľad na 3D model (vpravo)

Vlícovacie body boli merané v bezhranolovom móde Leicou TC(R) 407 s presnosťou merania dĺžok 3 mm + 2 ppm a strednou chybou meraného smeru 7", pričom na uľahčenie ich identifikácie na snímkach bola vždy dokumentačne odfotená aj na stene viditeľná laserová stopa. Spolu bolo vyhotovených približne 300 snímok dvoma rôznymi kamerami – digitálnou zrkadlovkou Nikon D5100 (16 Mpx) a strednoformátovou kamerou Phase One 645D s digitálnou stenou Leaf Aptus II-7 (33 Mpx).



**Obr. 4.15.** Znázornenie jednotlivých úrovní interiérových priestorov (vľavo) a výsledný rezopohľad (vpravo)

O efektivite použitia fotogrametrie a automatizácie spracovania na báze obrazovej korelácie hovorí aj fakt, že terénne práce trvali dvom pracovníkom iba približne 6 hodín.

Spracovanie do výkresovej podoby bolo pravdaže časovo náročnejšou časťou celého procesu (2 týždne), avšak veľká informačná hodnota snímok doňho opäť priniesla jednoduchosť a efektivitu za dosiahnutia požadovanej presnosti. Zároveň väčšina fotogrametrickej časti spracovania prebiehala automatizovane, takže spracovávateľ sa mohol venovať iným činnostiam až do bodu, keď musel pozornosť venovať tvorbe samotných rezov a výkresov (MARČIŠ & FRAŠTIA, 2012). Prioritne sa na spracovanie používal softvér PhotoScan, avšak v nových miestnostiach s čistými bielymi stenami bolo z dôvodu absencie kvalitnej textúry potrebné použiť konvergentné snímkovanie na spracovanie v softvéri PhotoModeler (Obr. 4.16). Tento príklad teda súčasne poukazuje na možnosť výhodnej kombinácie rozličných metód merania počas meračskej dokumentácie jedného objektu.



**Obr. 4.16.** Izba mníšok (vľavo) a schodisko do podzemného karnera (vpravo) vyhodnotené vo PhotoModeleri

Po navlicovaní fotogrametricky vytvorených modelov do lokálneho referenčného súradnicového systému boli dosiahnuté maximálne reziduálne odchýlky na bodoch do 5 mm, čo je pre príslušný objekt postačujúca presnosť. Potom bolo možno modely rezať, editovať a upravovať pre potreby výkresov. Exportované ortosnímky slúžili ako veľmi efektívny podklad pre vektorizáciu.



Obr. 4.17. 3D model a ortosnímka strešného krovu

Výsledkom celej dokumentácie bolo napokon 9 výkresov s horizontálnymi a vertikálnymi rezopohľadmi, súčasťou ktorých bolo aj znázornenie stropných konštrukcií v dvoch podlažiach. Práve tu sa ukázala veľká výhoda vysokého rozlíšenia strednoformátovej kamery s digitálnou stenou Leaf Aptus (Obr. 4.17).

Vektorizáciou ortosnímky s vysokým rozlíšením bolo možné znázorniť pomerne komplikovaný priebeh jednotlivých trámov, krokiev a krokvíc.

# 4.5 Využitie RPAS pre dokumentáciu hradov a pamiatok veľkých rozmerov

Nehnuteľné stavebné pamiatky často dosahujú veľké rozmery (100 m a viac) a bývajú ťažko prístupné v teréne – tým nie je myslený iba nekontrolovaný rast vegetácie, ale aj umiestnenie stavby napr. pri skalných zrázoch a pod. V týchto prípadoch nachádzajú uplatnenie tzv. RPAS (*Remotely Piloted Aircraft Systems*) – diaľkovo ovládané letecké systémy – malé vrtuľníky, hexacoptery alebo lietadlá, na ktoré možno upevniť digitálnu kameru.



Obr. 4.18. UAV Microdrone md4-1000 (www.flightsafetyaustralia.com, 2018)

Využiteľnosť týchto zariadení je veľmi široká a v súčasnosti sa používa aj ako veľmi efektívny nástroj na lokálne fotogrametrické mapovanie, nakoľko letové hodiny s použitím veľkého pilotovaného lietadla nie sú práve lacná záležitosť. Takto vyhotovené snímky potom opäť možno spracovať napr. v softvéri PhotoScan, ktorý disponuje funkciami určenými špeciálne na spracovanie leteckých snímok do podoby DMR a ortosnímok. To sa však týka najmä bežných nadirových leteckých snímok, zatiaľ čo pri leteckom snímkovaní hradov ide o kombináciu nadirových a šikmých záberov v podobe vejára okolo objektu. Transformácia 3D modelu do referenčného súradnicového systému sa môže vykonať pomocou na zemi signalizovaných cieľových značiek (s dostatočnou veľkosťou s ohľadom na GSD – Obr. 4.19 vpravo), ktorých poloha je určená napr. pomocou GNSS systémov. Na Obr. 4.19 vľavo sa nachádza príklad obrazového skenovania zrúcaniny Plaveckého hradu, ktorý sa nachádza na západnom úpätí Malých Karpát a vznikol medzi rokmi 1256 až 1273 n. l.



**Obr. 4.19.** Textúrovaný 3D model Plaveckého hradu z PhotoScanu (vľavo) a signalizovaný vlícovací bod na snímke (vpravo)

Do spracovania vstúpilo 54 snímok z kamery OLYMPUS E-P2 (12 Mpx), ktorá bola upevnená na UAV typu md4-1000 (Obr. 4.18). Reziduálne odchýlky vlícovacích bodov sa po transformácii do referenčného súradnicového systému pohybovali okolo 16 mm, čo je postačujúca presnosť na zameranie zrúcaniny. Terénne práce trvali v tomto prípade jeden deň, spracovanie potom v závislosti od nastavení kvality výpočtov zabralo 1 až 3 hodiny.

### 5 TESTOVANIE SYSTÉMU AGISOFT PHOTOSCAN

Sotvér PhotoScan je produktom ruskej firmy Agisoft a v súčasnosti patrí k najpoužívanejším fotogrametrickým softvérom na automatizovanú tvorbu 3D modelov v nespočetnom množstve odvetví hospodárstva. Okrem podpory generovania samotnej geometrie objektov umožňuje aj meranie vlícovacích bodov, a tak sa stáva vhodným nástrojom aj pre aplikácie, ktoré vyžadujú nielen transformáciu do referenčného súradnicového systému, ale aj vyššiu kontrolu nad finálnym fotogrametrickým riešením. Výstupom zo spracovania v tomto softvéri môžu byť mračná bodov, 3D modely, DMP (DEM), ortofotomozaiky, vrstevnice a pod.

Programátori pri tvorbe PhotoScanu použili už existujúce práce týkajúce sa spracovania obrazu (Bundler, SfM), použité algoritmy však prepísali nanovo, doplnili ich o mnohé vlastné vylepšenia, a tak dosiahli jednak zrýchlenie výpočtového procesu, ako aj zvýšenie výslednej presnosti (SEMYONOV, 2011). Je teda schopný spracovať akékoľvek snímky aj pri absencii EXIF-dát a môže byť použitý napr. aj pri spracovaní skenovaných originálov analógových snímok alebo snímok extrahovaných z videozáznamu. Z mnohých štúdií (VERHOEVEN, 2011, DONEUS, 2011, MARČIŠ, 2012 a iné) vyplýva, že tento softvér je, čo sa týka ovládania, síce z pohľadu odborníkov v oblasti fotogrametrie veľmi jednoduchý a umožňuje tak používať fotogrametriu na tvorbu 3D modelov aj užívateľom bez fotogrametrického vzdelania, nemožno mu však uprieť veľmi kvalitné výsledky v porovnaní s inými profesionálnymi softvérmi.

Prácu v softvéri možno rozdeliť do niekoľkých základných etáp s rôznymi úrovňami nastavení:

- 1. Načítanie snímok.
- 2. Orientácia snímok, vrátane kalibrácie kamery.
- 3. Generovanie podrobného mračna bodov.
- 4. Generovanie 3D modelu (mesh) alebo DEM.
- 5. Generovanie textúry.
- Transformácia do referenčného súradnicového systému prostredníctvom vlícovacích bodov, resp. je tu možnosť aj definície mierky cez iba 2 vlícovacie body.
- 7. Export výstupov.

Snímky s ohľadom na ich vzájomný prekryt možno rozdeliť do viacerých dávok (tzv. *chunkov*), pričom snímky v jednotlivých dávkach sú zorientované osobitne a potom je možné dávky zorientovať aj voči sebe a zlúčiť ich do jednej dávky. Táto funkcia nachádza uplatnenie napr. pri snímkovaní uzavretých objektov (sošiek, váz), ktoré je počas rôznych etáp snímkovania potrebné otáčať na podložke, aby bolo možno vymodelovať aj zákrytové oblasti (spodok podstavca...), čím sa ale menia aj parametre vonkajšej orientácie medzi jednotlivými sadami dát.

Vlícovacie body možno umiestňovať buď priamo na hotový model, alebo ich vytvárať na snímkach. Na základe kontrolných bodov možno upraviť orientáciu snímok aj kalibračné parametre, čo je veľká výhoda najmä v prípade rozľahlých objektov s dlhými snímkovými pásmi, kde postupne narastá chyba v napojení jednotlivých susedných snímok s ohľadom na ich prekryt. Optimalizácia orientácie snímok prispôsobením na vlícovacie body zabezpečuje vyššiu celkovú geometrickú presnosť modelu. Po každej takejto optimalizácii však musí byť celý 3D model (*mesh*) vygenerovaný nanovo, keďže PhotoScan nie je schopný zdeformovať trojuholníkovú sieť modelu na základe pevných kontrolných bodov.

*Mesh* je generovaný trianguláciou mračna bodov získaného na základe výpočtu hĺbkových máp z dvojíc snímok, pričom PhotoScan berie do úvahy všetky dostupné prekrývajúce sa snímky, z ktorých sú vo fáze fúzie hĺbkovej mapy a generovania plochy použité tie s najlepším odhadom a v prípade chýbajúcich oblastí aj s menej presným hĺbkovým odhadom.

Práve vzhľadom na rozšírenosť tohto softvéru bude v nasledovných kapitolách PhotoScan využitý na prezentovanie základných komplikácií a obmedzení, s ktorými sa môže užívateľ stretnúť počas digitalizácie kultúrneho dedičstva automatizovanými fotogrametrickými metódami využívajúcimi podobnosť obrazov.

### 5.1 Základnicový pomer

Softvéry fungujúce na princípoch obrazovej korelácie v zásade vychádzajú z hľadania zhôd medzi dvojicou snímok, teda možno hovoriť o stereofotogrametrii. Pri tejto metóde výsledná presnosť určeného bodu závisí od pomeru medzi fotogrametrickou základnicou *b* (vzdialenosť medzi dvoma polohami kamery) a vzdialenosťou od snímkovaného objektu *y*. Osi záberov môžu pritom mierne konvergovať, vzhľadom na potrebu dosiahnuť medzi susednými snímkami čo najväčší prekryt. Vychádzajúc z literatúry (GÁL, 1967) základnicový pomer (*b*/*y*) pre stereofotogrametriu sa bežne pohybuje v rozmedzí 1 : 4 až 1 : 20 (0,25 až

0,05). Tvorcovia napr. softvéru PhotoModeler Scanner však odporúčajú dodržiavať pri snímkovaní základnicový pomer v rozmedzí 1 : 2 až 1 : 10 (0,5 až 0,1). Pri aplikáciách s využitím obrazovej korelácie je potrebné brať ohľad na zachovanie dostatočnej podobnosti obrazov, aby vôbec bolo možno nájsť zhody medzi susednými snímkami, čo znamená skrátenie základnice. Zároveň by však základnica nemala byť príliš krátka, pre dosiahnutie vyššej presnosti v smere osi záberu (presnosť v hĺbke). Túto presnosť možno vychádzajúc z digitálnej stereofotogrametrie vypočítať podľa vzťahu (2.5).

S cieľom otestovať schopnosti softvéru PhotoScan v extrémnych situáciách a nájsť vhodný základnicový pomer, bol vytvorený test s nasledujúcimi polohami kamery Nikon D5100 (objektív s ohniskovou vzdialenosťou 35 mm) voči testovaciemu objektu (Obr. 5.1).



Obr. 5.1. Polohy kamery počas testovania základnicového pomeru

24 snímok okolo objektu vytváralo polkruh s priemernou objektovou vzdialenosťou 1,37 m, pričom susedné polohy kamery boli voči sebe posunuté o približne 12 cm.

Všetky snímky boli spolu zorientované v jednom projekte a pre generovanie 3D modelu už boli vždy vybrané iba konkrétne dvojice snímok (16 variant) s rôznym pomerom b/y, ktorý sa pohyboval v rozmedzí 0,08 až 1,78. Kvalita generovania 3D modelu bola nastavená na *high*.

Testovací objekt pozostával z dvoch textúrou potlačených papierov formátu A4 nalepených na sklenenej tabuli s pridanými 12-bitovými kódovými cieľovými značkami pre jednoduchšiu transformáciu všetkých modelov do spoločného súradnicového systému. Jedna vzorka bola čisto plošná, druhá vzorka obsahovala aj priestorový útvar – vystupujúce ostré hrany (Obr. 5.2).



Obr. 5.2. Testovací objekt s kamennou textúrou a kódovými cieľovými značkami

Jednotlivé 3D modely boli potom v softvéri Geomagic Qualify Lite porovnávané s referenčným modelom vygenerovaným z 5 snímok zo vzdialenosti približne 0,7 m (viac než dvojnásobne menšie GSD). Výsledné smerodajné odchýlky z plošného porovnania v Geomagicu (vzorka 1) aj z porovnania v oblasti vystupujúceho detailu (vzorka 2) v závislosti od základnicového pomeru možno vidieť na Obr. 5.3. Hodnoty odchýlok vychádzajú priamo z číselných výstupov porovnania v softvéri Geomagic Qualify Lite a boli počítané iba v smere kolmom na plochu testovacieho objektu.



Obr. 5.3. Smerodajná odchýlka v pixeloch a jej závislosť od základnicového pomeru

Z grafu vidieť, že softvér PhotoScan nemá pri modelovaní rovinných útvarov problém spracovať výrazne konvergentné snímky (v uvedenom prípade bol maximálny konvergenčný uhol medzi osami záberu až 125°) a veľkým pomerom základnice ku objektovej vzdialenosti (až 1,78). Akonáhle je však povrch objektu členitý, dochádza ku strate detailov, ktoré vzhľadom na veľmi nízku podobnosť medzi snímkami z tak výrazných uhlov záberu jednoducho nie sú detekovateľné. Zmenšovanie základnicového pomeru teda prináša spresnenie vymodelovaných detailov, resp. ich úplnosť, nakoľko členitosť objektu spôsobuje

na snímkach oblasti so zákrytmi. K zlepšeniu však dochádza iba do základnicového pomeru približne 1 : 5 (0,2), nakoľko pri kratších základniciach už mračno bodov disponuje výrazným šumom. Do praxe teda možno odporučiť používať základnicový pomer 1 : 2 (0,5) až 1 : 5 (0,2) ako kompromis medzi snahou o dostatočnú hĺbkovú presnosť a zachytenie prípadnej členitosti modelovaného povrchu.

Vo výnimočných prípadoch samozrejme nie je možné zabezpečiť optimálny základnicový pomer kvôli prekážkam v teréne. Zvýšenie počtu snímok pod rôznymi uhlami záberu pritom môže byť vždy nápomocné. V zásade by sa vždy mali používať kombinácie paralelných a konvergentných snímok – algoritmy v softvéri PhotoScan sú už navrhnuté tak, aby pre modelovanie konkrétnych plôch vybrali najvhodnejšie dvojice snímok. Výsledná generovaná plocha potom vzniká z kombinácie viacerých prekrývajúcich sa mračien bodov.

### 5.2 Uhol osi záberu voči snímkovanej ploche

Kvalita vyprodukovaného 3D modelu závisí nielen od vhodnosti základnicového pomeru, ale aj od uhla, ktorý zvierajú osi záberov kamier s modelovanou plochou. V praxi je vždy snaha o snímkovanie kolmo voči ploche objektu, čím ostrejší uhol s ňou osi záberu zvierajú, tým viac deformovaná (zvlnená, zašumená) je výsledná modelovaná plocha (Obr. 5.4).



**Obr. 5.4.** Plocha vymodelovaná z dvojice snímok pod uhlom 34° (vľavo) a 89° (vpravo)

Na zistenie vplyvu tohto uhla na výslednú modelovanú plochu bol vytvorený nový test s odlišnou konfiguráciou stanovísk kamery než v predchádzajúcom prípade. Opäť bola použitá kamera Nikon D5100, snímkovanie bolo vykonané z objektovej vzdialenosti 1,2 m. Aby bol pre každú dvojicu snímok zabezpečený rovnaký uhol voči testovacej ploche, kamera bola na statíve zvislo posúvaná na každom stanovisku do dvoch polôh (vzdialených o základnicu, b / y = 0,25). Testovacia plocha bola pokrytá pieskovou textúrou (opäť farebná laserová tlač, tentokrát na A3). Do výpočtu 3D modelu tak vstupovali vždy iba dvojice nachádzajúce sa nad sebou.



Obr. 5.5. Konfigurácia stanovísk kamery voči testovacej ploche

Výsledných 12 3D modelov bolo postupne porovnávaných s referenčným modelom vytvoreným strednoformátovou kamerou Phase One 645D s digitálnou stenou Leaf Aptus II-7. Z rozdielových modelov v softvéri Geomagic Qualify Lite vychádza nasledujúci graf na Obr. 5.6. Smerodajné odchýlky pochádzajú opäť z číselných výstupov porovnania v softvéri Geomagic v smere kolmom na plochu testovacieho objektu.



Obr. 5.6. Závislosť smerodajnej odchýlky v pixeloch a uhla osi záberu voči ploche

Z grafu možné vidieť, že relatívne dobré výsledky možno dosiahnuť pri snímkovaní plochy pod uhlom v rozmedzí 35° až 90°. To pravdaže opäť platí iba pre približne rovinné alebo ploché útvary, nakoľko pod ostrými uhlami by pri vystupujúcich alebo vnorených ostrých detailoch dochádzalo k zákrytom. Zároveň treba povedať, že modely vytvorené zo snímok pod uhlom 30° vykazovali pri generovaní 3D modelu v kvalite *high* veľké množstvo

dier. Model prislúchajúci uhlu 22° pozostával prakticky iba zo 166 000 trojuholníkov, čo je 5 % oproti modelu prislúchajúcemu uhlu 89° a plocha bola výrazne neúplná a zašumená. Uhly blízke 20° možno považovať už za kritickú hodnotu, pri ktorej je softvér PhotoScan ešte schopný vygenerovať akúkoľvek plochu.



**Obr. 5.7.** Použiteľný rozsah uhlov snímkovania voči ploche (35° až 90°) a kritická oblasť so zanikajúcim modelom (0° až 20°)

Model zaniká tým viac, čím vzdialenejšia je konkrétna časť plochy od snímkovacej základnice – vplyv základnicového pomeru teda hrá opäť dôležitú rolu aj v tomto prípade (Obr. 5.8).



Nikon D5100 (35 mm)

**Obr. 5.8.** Zmena základnicového pomeru pod vplyvom ostrého uhla voči snímkovanej ploche

### 5.3 Spracovanie ostrých hrán

Pri riešení predchádzajúcich experimentov aj praktických aplikácií sa vo PhotoScane opakovane prejavovalo zahladzovanie ostrých hrán vystupujúcich a vnorených detailov.

V literatúre možno nájsť mnoho rôznych príkladov, pri ktorých bola preukázaná vysoká presnosť modelovania na báze obrazovej korelácie (BELIŠ, 2009, JUNGHAUS, 2010) a síce boli vykonávané aj s ohľadom na rozličný typ textúry, vždy išlo prevažne o rovinné útvary. Z tohto dôvodu bol v rámci dizertačnej práce (MARČIŠ, 2013) vytvorený test, ktorý bol zameraný na zistenie závislosti zmeny GSD (zväčšujúca sa vzdialenosť), typu textúry a narastajúceho zahladenia ostrých hrán. Okrem toho bola zisťovaná aj zmena presnosti pod vplyvom premenlivého ohniska objektívu v rozsahu 18 až 270 mm (s približne rovnakým GSD). Počas oboch testov boli pritom zohľadnené všetky predchádzajúce zistenia o vhodnej polohe kamery voči objektu.

Testovací objekt pozostával zo sklenenej platne 820 x 820 mm, na ktorej boli nalepené papierové vzorky šiestich rôznych typov prirodzenej textúry (Obr. 5.9). 1 – tehlová stena, 2 – kamenný múr, 3 – fasádna omietka s hrubou zrnitosťou, 4 – fasádna omietka s jemnou zrnitosťou, 5 – drevo a 6 – bežná interiérová omietka. Uvedené typy textúr sú typické pre pamiatkové objekty.



Obr. 5.9. Testovací objekt so 6-timi typmi prirodzenej textúry

Každý typ textúry pozostával z dvoch základných druhov detailu – vystupujúceho a vnoreného – pričom uhol ostrej hrany každého detailu predstavoval 90°. Okrem týchto dvoch základných vzoriek pre každú textúru bol vytvorený aj tzv. zanikajúci detail – 90° ostrá hrana, ktorej základňa sa plynule zmenšovala od 25 mm až k nule. Na základe tohto detailu bolo možné neskôr určiť kritickú hodnotu, pri ktorej už detail zanikne a nie je na 3D modeli vizuálne identifikovateľný.

Testovací objekt bol priložený k stene disponujúcej nepravidelnou náhodnou textúrou (drevený obklad), aby nevznikli komplikácie pri orientácii vzdialených snímok.



**Obr. 5.10.** Testovací objekt umiestnený v telocvični SvF STU a body zvolené na definíciu mierky

Polohy jednotlivých stanovísk kamery boli určené meraním pásmom s dodržaním pomeru b/v = 0.25. Pre každú objektovú vzdialenosť v bolo vyhotovených 5 snímok kamerou Nikon D5100 s podporou fotografického statívu. Na testovací objekt aj stenu za ním boli nalepené kódové cieľové značky – pre spracovanie v softvéri PhotoModeler Scanner 2012 boli na stenu aplikované aj RAD-terče. Na samotný objekt boli aplikované 12-bitové kódové cieľové značky pre PhotoScan. Mierka bola určená odmeraním dĺžok medzi RAD-terčmi – v rôznych smeroch, vertikálne, aj horizontálne – z ktorých bola následne pre definíciu mierky vybraná vertikálna dvojica bodov čo najbližšie k objektu (na zamedzenie vplyvu z previsu pásma). PhotoModeler Scanner 2012 bol napokon použitý iba na definíciu súradnicového systému (mierka, rotácia, translácia) – spracovaním konvergentných snímok z kamery PhaseOne 645D s digitálnou stenou Leaf Aptus II-7 bola dosiahnutá celková stredná chyba na bodoch testovacieho objektu do 0,05 mm. Týchto 12 bodov potom slúžilo ako vlícovacie body pre transformáciu modelov z PhotoScanu do spoločného súradnicového systému. Jednotlivé modely vo PhotoScane boli generované v kvalite ultra high, aby boli dosiahnuté podľa možnosti čo najpodrobnejšie výsledky, nakoľko ultra high nastavenie zahrňuje do výpočtu každý jeden pixel snímky.

Ako referenčný model bol použitý výstup z triangulačného skenera Comet, ktorého deklarovaná presnosť je 0,05 mm. Porovnanie bolo vykonané pomocou softvéru Geomagic Studio, a to vytvorením rezov s pravidelnými rozostupmi cez jednotlivé vzorky (Obr. 5.11).



Obr. 5.11. Rozloženie rezov testovacím objektom a označenie detailov A, B, C

V každom reze bola pre jednotlivé vzorky textúry meraná výška vrcholu ostrej hrany – minimálna hodnota pre vnorený detail ("A") a maximálna pre vystupujúci ("B"). Takto bolo pre každý druh detailu (A a B) získaných 10 hodnôt, z ktorých bola vypočítaná smerodajná odchýlka od referenčného modelu na základe vzťahu:

$$\sigma = \sqrt{\frac{\Sigma \varepsilon \varepsilon}{n}},\tag{5.1}$$

kde  $\varepsilon$  predstavuje rozdiel medzi *y*-súradnicou bodu ostrej hrany na testovanom modeli a na referenčnom modeli, n = 10. Zvlášť teda bola vždy vypočítaná smerodajná odchýlka pre detail A aj B. Os *y* smeruje kolmo na plochu testovacieho objektu.

Pri detaile C nebola počítaná smerodajná odchýlka z rezov, ale bola meraná dĺžka detailu, od jeho širokej základnice v zužujúcom sa smere po miesto, v ktorom už detail nebolo možné vizuálne identifikovať na modeli (Obr. 5.12 vľavo). Pre každý typ textúry boli získané 3 takéto dĺžky.



**Obr. 5.12.** Zanikajúci detail a určenie kritickej výšky detailu z podobnosti trojuholníkov

Výška detailu *dh*, ktorý už nebol vymodelovaný bola potom vypočítaná z podobnosti trojuholníkov (Obr. 5.12 vpravo). Výsledná hodnota zaniknutého detailu vychádza z jednoduchého aritmetického priemeru troch hodnôt.

### 5.3.1 Prípad s rovnakou ohniskovou vzdialenosťou a premenlivým GSD

Snímkovanie bolo vykonané digitálnou zrkadlovkou Nikon D5100 s ohniskom objektívu nastaveným na 35 mm, nemenným počas celého merania prvej časti experimentu. Objektová vzdialenosť *y* bola postupne predlžovaná s pravidelnými rozostupmi (2, 4, 6, 8, 10, 12 a 14 m), čo viedlo k zmene GSD (0,27 - 1,92 mm).

Z výsledkov možno vypozorovať nielen vplyv GSD na veľkosť odchýlok, ale aj kvality a druhu textúry, ktorá sa menila s pribúdajúcou vzdialenosťou. Ploché textúry (4 a 6) vykazovali najväčšiu úroveň šumu, čomu potom zodpovedala aj najväčšia nepravidelnosť v priebehu zmeny smerodajnej odchýlky v závislosti od GSD. Ostatné typy textúr (1, 2, 3 a 5) vykazovali v smerodajných odchýlkach takmer lineárny priebeh s veľkosťou GSD, avšak výsledky sa postupne zhoršovali nelineárne vplyvom zhoršujúcej sa kvality textúry (Obr. 5.13).

Pri objektovej vzdialenosti 14 m boli najhoršie výsledky dosiahnuté pre textúru č. 6 a tehlovú textúru č. 1. Dôvody nekvalitných výsledkov pri tehlovej textúre treba hľadať najmä v jej nehomogenite spôsobenej tmavými špárami medzi jednotlivými tehlami – zatienené oblasti sú zväčša nekvalitne rekonštruované. Naopak najlepšie výsledky boli dosiahnuté pri zrnitých textúrach č. 2 a 3, ktoré disponovali nielen jemnou, ale aj hrubou zrnitosťou zreteľnou aj z väčších objektových vzdialeností.



**Obr. 5.13.** Zmena smerodajnej odchýlky pre rôzne typy textúr v závislosti od GSD (priemer medzi detailom A a B)

Testovanie kritickej hodnoty zanikajúceho detailu C prinieslo výsledky viditeľné na Obr. 5.15. Na grafe je v tomto prípade znázornená veľkosť detailu, ktorý už nebol vymodelovaný.



Obr. 5.14. Zmena zaniknutého detailu v závislosti od GSD pre rôzne typy textúry

Z grafov na Obr. 5.13 a 5.14 možno vypozorovať, že k zaniknutiu detailu dôjde skôr, než sa odhadnutá smerodajná odchýlka ostrej hrany priblíži k veľkosti hrany. Ostrá hrana je totiž v určitej úrovni taká malá, že softvér ju už nepovažuje za deformáciu plochy, ale iba za texturálny znak plochého povrchu. Do praxe je teda potrebné počítať s tým, že akonáhle smerodajná odchýlka ostrej hrany dosiahne približne 60 % jeho celkovej veľkosti, detail nebude v softvéri PhotoScan ani pri nastavení najvyššej kvality vymodelovaný.

#### 5.3.1.1 Analýza rovinných oblastí

Nakoľko testovacie vzorky obsahovali aj rovinné časti, boli jednotlivé textúry analyzované nielen v oblasti ostrých hrán. Smerodajné odchýlky plošného porovnania s referenčným modelom zo skenera Comet boli získané v softvéri Geomagic Studio. Z grafu na Obr. 5.15 možno vidieť aj pomer medzi odchýlkami v ostrých hranách a v rovinných oblastiach objektu – rozdiel je prakticky 5-násobný.



**Obr. 5.15.** Smerodajné odchýlky pri ostrých hranách a pri rovinných oblastiach v závislosti od GSD

Presnosť vyhodnotenia v softvéri PhotoScan teda dosahuje kvalitné výsledky najmä pri prevažne makroskopicky plochých, resp. spojitých oblastiach – priemerná hĺbková presnosť sa pri vhodných typoch textúry (1, 2, 3 a 5) pohybuje okolo tretiny GSD (čiže iba 0,3 pixela). Pri textúre č. 6, pri ktorej boli vždy dosiahnuté najhoršie výsledky sa smerodajná odchýlka v rovinných oblastiach pohybovala do 1,9-násobku GSD (teda maximálne 2 pixely v hĺbke).

### 5.3.1.2 Presnosť generovania 3D modelu pri rozličných nastaveniach

Pre ilustráciu vplyvu zmeny nastavenia kvality generovania *meshu*, boli snímky pre objektovú vzdialenosť 2 m spracované nie len s nastavením *ultra high*, ale aj s nastaveniami *lowest, low, medium* a *high*.



Priemerné smerodajné odchýlky zo všetkých typov textúr možno vidieť na Obr. 5.16.

**Obr. 5.16.** Zmena smerodajnej odchýlky v ostrej hrane vzhľadom na nastavenie kvality generovania 3D modelu

Z priemerných hodnôt pomeru medzi susednými nastaveniami kvality vyplýva, že nastavenie *ultra high* dosahuje približne 1,5-násobne lepšie výsledky než *high* a pri ostatných nastaveniach ide o postupný približne 2,5-násobný nárast presnosti. V pomere voči *medium* je teda *ultra high* približne 4-násobne presnejšie, voči *low* približne 10-násobne a voči *lowest* dokonca 25-násobne presnejšie. Je teda iba na užívateľovi akú presnosť spracovania vyžaduje, nakoľko je potrebné zvážiť aj časovú náročnosť jednotlivých výpočtov.

Rozdielna presnosť aj rýchlosť spracovania súvisí s faktom, že pri *ultra high* nastavení softvér berie do úvahy každý pixel (vychádza z originálnych dát), zatiaľ čo pri *high* je už znížené rozlíšenie snímky prevzorkovaním o faktor 2 (obraz je v oboch smeroch o polovicu menší), pri *medium* o faktor 4 atď.

### 5.3.1.3 Časová náročnosť generovania 3D modelu

Vplyv zmeny nastavenia kvality generovania 3D modelu na časovú náročnosť spracovania možno vidieť na Obr. 5.17. Z grafu možno vyčítať značný nepomer medzi časovou náročnosťou a nárastom presnosti – najmä čo sa týka použitia *high* a *ultra high* kvality. Nárast presnosti v tomto prípade bol iba približne 1,5-násobný, no časová náročnosť je až 6-násobná. Pri ostatných nastaveniach išlo o 3- až 4-násobný časový nárast oproti susednej nižšej kvalite.



Obr. 5.17. Časová náročnosť generovania 3D modelu pri rôznych nastaveniach kvality

Z uvedených výsledkov vyplýva, že pre väčšinu praktických aplikácií postačuje používať nastavenia *medium* a *high* pokiaľ do spracovania vstupujú snímky s dostatočne vysokým rozlíšením. 1,5-násobný nárast presnosti nie je opodstatnením 6-násobne dlhšieho času potrebného na spracovanie a nastavenie *ultra high* tak má zmysel uplatňovať iba v špeciálnych prípadoch s veľmi kvalitnými obrazovoými dátami, ktoré obsahujú minimum šumu (napr. kvôli zvýšenej hodnote ISO).



**Obr. 5.18.** Nárast času a presnosti s postupným zvyšovaním kvality generovania 3D modelu

### 5.3.2 Prípad s premenlivou ohniskovou vzdialenosťou – rovnaké GSD

V digitálnej fotogrametrii sa najčastejšie používajú ohniskové vzdialenosti s dĺžkou približne 30 až 50 mm, keďže pri veľmi krátkych ohniskových vzdialenostiach dosahujú skreslenia objektívu veľmi vysoké hodnoty a naopak pri veľmi dlhých ohniskových vzdialenostiach sa zväzok určujúcich lúčov stáva nestabilným. V teréne však môže nastať situácia, keď kvôli komplikovanej dostupnosti objektu alebo stiesneným priestorom je nutné používať väčší rozsah ohniskových vzdialeností, od tzv. rybích očiek (*fisheye*) až po teleobjektívy. V nasledujúcom teste bol použitý plný rozsah objetívu Tamron 18-270 mm, pričom vzdialenosť od testovacieho objektu sa menila v súlade so zachovaním približne rovnakého GSD (aby objekt zaberal vždy približne rovnakú plochu v zornom poli) digitálnej zrkadlovky Nikon D5100.

Počas snímkovania bol vždy dodržiavaný základnicový pomer 1 : 4 (0,25) a podpora fotografického statívu. S postupne predlžovanou ohniskovou vzdialenosťou sa vždy znižuje aj svetelnosť objektívu a klesá kvalita texturálnych informácií (kontrast, intenzita). Kvalitu obrazu možno vyjadriť aj prostredníctvom modulačnej prenosovej funkcie (Modulation Transfer Function – MTF), ktorá je definovaná ako podiel kontrastu obrazu v obrazovej rovine vzhľadom ku kontrastu predmetu v predmetovej rovine pre sinusový testovací obrazec. Zároveň si treba uvedomiť, že napriek použitiu statívu, môže pri snímkovaní s veľmi dlhými ohniskovými vzdialenosťami a nedostatku svetla v optickej sústave dôjsť k pohybovému rozostreniu obrazu, keď že celý systém je viac citlivý na jemné otrasy, ktoré môžu vzniknúť už aj z obyčajného sklopenia zrkadla v prípade digitálnej zrkadlovky. Tento vplyv bol badateľný aj pri snímkovaní s objektívom Tamron 18-270 mm, najmä pri ohniskových vzdialenostiach blížiacich sa k 200 mm a dlhších. Spolu bolo vytvorených 8 sád dát pre ohniskové vzdialenosti: 18, 35, 55, 70, 100, 170, 250 a 270 mm. Keďže zabezpečenie rovnakého GSD pre všetky sety bolo vykonávané iba približne priamo počas merania (testovací objekt zaberal v zornom poli približne rovnaký priestor), na Obr. 5.19 sú znázornené smerodajné odchýlky v pixeloch (teda vzhľadom na aktuálne GSD). Hodnoty GSD pritom variovali v rozsahu 0,275 až 0,322 mm (14 % rozdiel). Vyhodnotenie je opäť znázornené pre rovinné oblasti aj ostré hrany, pričom sa jedná o priemerné hodnoty zo všetkých typov textúr. Ohniskové vzdialenosti sú uvádzané pre konkrétnu kameru Nikon D5100, ktorá disponuje CMOS snímačom APS-C s rozmermi 23,6 x 15,6 mm.



**Obr. 5.19.** Smerodajná odchýlka na ostrých hranách a v rovinných oblastiach v závislosti od zmeny ohniskovej vzdialenosti objektívu

Z grafu možno vyčítať mnohonásobný rozdiel v presnosti modelovania ostrých hrán voči prevažne rovinným oblastiam. Zároveň sa jasne ukazuje, že s predlžovaním ohniskovej vzdialenosti sa zvyšuje aj miera nepresnosti generovania 3D modelu, najmä čo sa týka ostrých hrán a detailov. Pozitívom ostáva, že napriek odporúčaniu výrobcov softvéru PhotoScan používať bežné širokouhlé objektívy a nezachádzať do extrémov ako sú teleobjektívy, možno dosiahnuť vcelku kvalitné výsledky aj v takýchto výnimočných prípadoch, keďže smerodajné odchýlky sa aj pri veľmi dlhých ohniskových vzdialenostaich nad 200 mm pohybovali v hodnotách do 4,5 násobku GSD.

Testovaný rozsah ohniskových vzdialeností síce nepokrýva oblasť fisheye-objektívov, no obdobný objektív (Tamron 10-24 mm) bol so svojou najkratšou ohniskovou vzdialenosťou používaný pri zameraní interiérových častí Husitskej bašty v Krupine a celková geometria 3D modelu nebola deformovaná – kontrola bola vykonávaná na vlícovacích bodoch, pričom reziduálne odchýlky na 6 bodoch nepresiahli 5 mm, čo je na stavbu obdobného charakteru postačujúci výsledok.

### 5.4 Zhrnutie poznatkov z jednotlivých testov

Na základe poznatkov získaných počas podrobného testovania a riešenia praktických aplikácií možno vyvodiť nasledovné odporúčania a závery pre terénne práce a spracovanie v softvéri Agisoft PhotoScan Professional:

Základnicový pomer b:y by sa mal pohybovať v rozmedzí 1 : 2 až 1 : 5 (0,5 až
 0,2) s ohľadom na členitosť snímkovaného povrchu. Menší základnicový pomer

produkuje vyššiu neistotu v hĺbke (šum), naopak väčší základnicový pomer spôsobuje stratu vystupujúcich a vnorených detailov. Za vhodný kompromis možno považovať pomer 1 : 4 (0,25).

- Os záberu by mala byť voči snímkovanej ploche podľa možnosti vždy čo najkolmejšia. PhotoScan je schopný produkovať pomerne kvalitné výsledky v rozmedzí 35° až 90°. To však platí iba pre prevažne rovinné povrchy, akonáhle by išlo o členitý povrch, dochádza k strate ostrých detailov kvôli zákrytom. Od približne 20° už PhotoScan prakticky negeneruje žiadny 3D model.
- PhotoScan dosahuje kvalitné výsledky spravidla pri modelovaní rovinných povrchov (presnosť v hĺbke 0,5 až 1 pixel). Úroveň zahladenia ostrých hrán závisí jednak od GSD a zároveň od nastavenia kvality generovania 3D modelu. V prípade zreteľnej textúry (teda pre blízke vzdialenosti) možno apriórnu hĺbkovú presnosť vypočítať na základe vzťahu vychádzajúceho zo stereofotogrametrie (2.5). S pribúdajúcou vzdialenosťou sa znižuje aj kvalita textúry a narastá odchýlka od ostrej hrany.
- Počas snímkovania je vhodné používať ohniskovú vzdialenosť približne 30 až 50 mm (pre snímač 23,6 x 15,6 mm). Jej skrátenie alebo predĺženie produkuje zvýšený šum na 3D modeli. V extrémnych prípadoch však môžu byť bez problémov použiteľné, nakoľko aj s veľmi dlhými ohniskovými vzdialenosť ami okolo 200 a viac mm možno dosiahnuť presnosť v hĺbke 4,5 pixela na ostrých hranách a 0,5 pixela v rovinných oblastiach (v prípade dodržania základnicového pomeru 1 : 4).
- Nastavenie kvality orientácie snímok je vhodné ponechať na najvyššom nastavení (*high*), nakoľko sa celkovo jedná o časovo najmenej náročný proces. Čas výpočtu však závisí najmä od predvoleného počtu bodov, ktorý má byť vyhľadaný na snímkach. V prípade veľkého počtu snímok pokrývajúcich plochy značných rozmerov je vhodné spresniť výsledky orientácie a kalibrácie kamier cez optimalizáciu na základe vlícovacích bodov.
- Na generovanie 3D modelu postačuje vo väčšine aplikácií používať nastavenie high a medium, nakoľko nastavenie ultra high prináša iba 1,5-násobné zlepšenie presnosti oproti high pri až 6-násobnom predĺžení výpočtového času.
- Voliť čo najvhodnejšiu polohu kamier počas snímkovania je z hľadiska efektivity samozrejme potrebné, no snažiť sa o prehnanú minimalizáciu počtu snímok nemá

v teréne zmysel. Samotný výrobca softvéru PhotoScan odporúča: viac snímok je vždy lepšie než menej. Výpočtová technika neustále napreduje, spracovávať veľké množstvá dát je čím ďalej, tým menší problém. Výber vhodných snímok možno vykonať kedykoľvek v kancelárii a nepotrebné vylúčiť zo spracovania. Ich hustotu je pravdaže vhodné voliť s ohľadom na GSD a základnicový pomer podľa aktuálnej situácie.

## 6 NÁVRH ZBERU ÚDAJOV PRE RÔZNE TYPY OBJEKTOV

Napriek automatizácii v spracovaní obrazových dát, ktorá výrazne zefektívňuje celý proces tvorby realistických 3D modelov, je kvalita výstupov aj časová náročnosť automatizovanej rekonštrukcie scény a objektov zo snímok stále závislá od konfigurácie kamier v teréne. Optimálna konfigurácia siete kamier by mala zabezpečiť minimalizáciu počtu vyhotovených snímok za dosiahnutia požadovanej presnosti ich vyhodnotenia.

Jedna cesta ako navrhnúť optimálnu polohu kamier voči objektu je klasifikovať objekt hrubého CAD-modelu do úrovne geometrických primitív (roviny, valce atď.), vytvoriť všeobecnú sieť kamier obsahujúcu 4 kamery pre zobrazenie každej roviny a potom jednotlivé sady kamier spojiť do jednej siete (MASON, 1995, 1997). V prípade, keď nie je k dispozícii žiadny hrubý model objektu, možno použiť už existujúcu sieť kamier a kontrolných bodov a na základe *fuzzy* logiky, podmienok viditeľnosti bodov a prístupnosti kamier optimálne doplniť sieť o nové polohy kamier, ktoré zvýšia presnosť merania (SAADATSERESHT a kol., 2005). Napriek vysokej dosiahnuteľnej presnosti však pri členitých objektoch kultúrneho dedičstva nie je odporúčané používať dlhé základnice s výraznými uhlami prieseku určujúcich lúčov a je potrebné zvýšiť hustotu snímok s ohľadom na dostatočný prekryt a podobnosť susedných snímok. Pri tom si je však nutné uvedomiť, že výpočtová náročnosť narastá so štvorcom počtu snímok (BARAZZETTI a kol., 2010). Ďalší spôsob môže byť vytvorenie optimálnej siete nájdením postačujúceho počtu kamier pre každý objektový bod hrubého mračna bodov získaného z SfM-techník a následné optimalizovanie presnosti siete na základe tzv. vnútornej penalizačnej funkcie (Interior Penalty Function), ktorá penalizuje prípustné riešenia (ALSADIKA a kol., 2012).

Napriek tomu, že v blízkej budúcnosti sa určite stretneme s plne funkčnými inteligentnými automatizovanými systémami na návrh optimálnej snímkovej konfigurácie na základe prvotných obrazových dát (snímok alebo videozáznamu), objekty kultúrneho dedičstva sa vyznačujú tak komplikovanými tvarmi a dostupnosťou, že iba zriedkavo by sa podarilo použiť optimálnu konfiguráciu kamier v teréne bez ohľadu na okolité prostredie a už len samotný návrh optimálnej siete by bol časovo a napokon aj finančne značne náročný. Z tohto dôvodu je vhodné rozhodovací proces v etape voľby polohy kamier voči objektu prispôsobiť aktuálnym podmienkam priamo v teréne, avšak s ohľadom na požadovanú presnosť výstupov vo vzťahu ku GSD a zachovanie geometrie snímkovania použitej fotogrametrickej metódy.

96

Vo všeobecnosti možno z pohľadu geometrie rozdeliť základné typy objektov do troch skupín:

- ploché fasády, fresky, obrazy, podlahy, archeologické sondy,
- uzatvorené zvonka sochy, artefakty, stavebné objekty,
- a uzatvorené zvnútra interiérové priestory.

### 6.1 Ploché objekty

Pre potreby spracovania snímok na princípe SfM možno používať paralelné osi záberu kolmo na plochu objektu a opierať sa o snímkové prekryty používané aj pri leteckom snímkovaní – čiže pozdĺžny prekryt snímok v páse 60 %, priečny medzi pásmi 20 % (MATTHEWS, 2008). V tomto prípade základnicový pomer závisí od dĺžky ohniskovej vzdialenosti a veľkosti snímača (resp. od veľkosti obrazového uhla). Z hľadiska zvyšovania presnosti je teda vhodné aj v tomto prípade dodržiavať základnicový pomer b : y = 1 : 4 (Obr. 6.1).



**Obr. 6.1.** Snímkový pás s prekrytom p %

Pokiaľ zlúčime obe podmienky – percentuálny prekryt aj základnicový pomer – dopracujeme sa k záveru, že na ich splnenie je potrebné meniť obrazový uhol a teda pracovať s dĺžkou ohniskovej vzdialenosti, keďže veľkosť snímača sa zmeniť nedá. Dĺžku ohniskovej vzdialenosti *f* zodpovedajúcu obom podmienkam teda možno vypočítať na základe vzťahu:

$$f = \frac{y}{h}(1-p)w,\tag{6.1}$$

kde *y* predstavuje objektovú vzdialenosť, *b* základnicu, *p* percentuálny prekryt susedných snímok a *w* rozmer snímača použitej kamery v smere snímkového pása. Výraz *y/b* možno jednoducho nahradiť číslom charakterizujúcim základnicový pomer. Napr. pre digitálnu zrkadlovku Nikon D5100 teda možno jednoducho vypočítať, že na dodržanie základnicového pomeru 0,25 (y/b = 4) a prekrytu snímok 60 % je potrebné používať ohniskovú vzdialenosť približne 38 mm (šírka senzora w = 23,6 mm, pomer f/w = 1,6).

Z uvedeného zároveň vyplýva, že pre potreby obrazového skenovania je v prípade paralelných osí záberu pri dodržaní štvrtinového základnicového pomeru a trojnásobného prekrytu (na prepojenie nasledujúcich snímok do pása) potrebné používať ohniskové vzdialenosti kratšie než je dvojnásobok rozmeru senzora v smere snímkového pása (f/w < 2). Na Obr. 6.2 je znázornená závislosť veľkosti trojnásobného prekrytu od dĺžky ohniska pre kameru Nikon D5100. Pri ohniskovej vzdialenosti 47,2 mm, paralelných osiach záberu a základnicovom pomere 0,25 už nie je k dispozícii žiadny trojnásobný prekryt a nie je teda možné nadviazať na ďalšie snímky v páse.



**Obr. 6.2.** Závislosť veľkosti trojnásobného prekrytu od dĺžky ohniskovej vzdialenosti pri kamere Nikon D5100 pri dodržaní základnicového pomeru 1 : 4

Veľkosť trojnásobného prekrytu *s* % pritom možno vypočítať na základe dvojnásobného prekrytu z jednoduchého vzťahu:

$$s \% = 2p \% - 100 \%.$$
 (6.2)

Treba si však uvedomiť, že aj trojnásobný prekryt by mal dosahovať určitú minimálnu hodnotu, aby bol snímkový pás dostatočne presne zorientovaný, pričom táto hodnota by nemala klesnúť pod 20 %. Pre už spomenutú zrkadlovku Nikon D5100 to znamená použitie ohniskovej vzdialenosti do približne 37 mm.

Zväčšovanie prekrytu jednak zlepšuje súdržnosť susedných snímok, no na druhej strane zvyšuje aj ich počet a časovú náročnosť spracovania – znižovanie prekrytu by pritom jednoznačne malo sprevádzať zhustenie vlícovacích, resp. kontrolných bodov, na základe ktorých možno napr. v softvéri PhotoScan spustiť optimalizáciu prvkov vonkajšej aj vnútornej orientácie kamier.

### 6.1.1 Dlhé líniové objekty

Skúsenosti s prácou v softvéri PhotoScan ukazujú veľmi dobré výsledky pri spracovávaní objektov, ktoré homogénne pokrývajú celú plochu snímky a disponujú približne rovnakými rozmermi čo do výšky, hĺbky a šírky (vďaka tomu možno zabezpečiť aj vhodné prekryty medzi susednými snímkami). Ako vhodné sa však ukázalo zistiť, ako si táto technológia poradí v extrémnych prípadoch ako sú napr. dlhé hradné múry (výrazný nepomer medzi výškou a šírkou objektu) (MARČIŠ, 2012). Ako predmet testovania fotogrametrického spracovania bol preto zvolený obvodový múr bratislavského hradu, ktorý spĺňal niekoľko hlavných podmienok:

- disponuje zreteľnou nepravidelnou náhodnou textúrou (kamenný povrch je jedna z najvhodnejších textúr na výpočty obrazovej korelácie),
- k vybranému úseku severozápadného múru je dobrý prístup, je pri ňom dostatok miesta pre rozličné polohy stanovísk kamery aj pre stanovisko UMS stanice na zameranie vlícovacích a kontrolných bodov,
- pozdĺžny tvar múra umožňuje testovanie výpočtov v extrémnych podmienkach – veľké množstvo snímok v snímkovom páse so 60 % prekrytom.

Cieľom nebolo vyhotoviť 3D model celého múru – čo do výšky bola stena modelovaná iba v rámci aktuálnych možností zorného uhla použitého objektívu. Vlícovacie a kontrolné body boli na múre signalizované nalepenými kódovými cieľovými značkami približne v pravidelných rozostupoch. Spolu bolo na múr umiestnených 14 značiek, vždy v dvojiciach (jedna tesne nad zemou a jedna vo výške približne 2,3 metra), pričom celý 80 metrový úsek múra bol spomínanými značkami napokon rozdelený na 6 úsekov (Obr. 6.3).



Obr. 6.3. Rozloženie pozorovaných bodov na hradnom múre

Pri snímkovaní bola používaná digitálna zrkadlovka Nikon D5100 s dvoma rôznymi objektívmi (Tamron 10-24 mm a Nikkor 18-55 mm) a pre zameranie vlícovacích bodov bola použitá UMS stanica Leica TCR407.

Základným predpokladom spracovania bolo, že výsledný 3D model múra bude vykazovať priehyb v smere osi záberu (os *y* na Obr. 6.4), pokiaľ sa na určenie prvkov vonkajšej orientácie kamier nevyužije možnosť optimalizácie prostredníctvom vlícovacích bodov. Ako vlícovacie body boli použité iba 4 okrajové body a zvyšných 10 stredových bolo kontrolných.





Priehyb múra súvisí najmä s nepresnou orientáciou snímok spôsobenou nedostatočnou kalibráciou kamier, ktorej pôvod je potrebné hľadať v malom prekryte susedných snímok a teda v nízkom preurčení kalibračných parametrov.

Pri použití rôznych objektívov sa líšil aj počet snímok, ktoré vstúpili do spracovania (43 snímok pre Nikkor 18 mm, 26 snímok pre Tamron 10 mm pri 60 % prekryte a 5 m objektovej vzdialenosti). Krátke ohniskové vzdialenosti umožňujú výrazne znížiť počet

snímok, vďaka čomu sa zmenšuje aj hodnota priehybu modelovaného pásu, s narastajúcim počtom snímok totiž priamo úmerne narastá aj veľkosť priehybu modelu. Zväčšením prekrytu z 60 % na 80% až 90% bolo možno znížiť hodnoty súradnicových rozdielov  $\Delta z$  a  $\Delta y$  na polovicu. Rovnaké výsledky boli dosiahnuté pri pridaní doplnkových snímok z dvojnásobnej predmetovej vzdialenosti. Keďže maximálne hodnoty  $\Delta x$  a  $\Delta z$  sa v týchto prípadoch pohybujú do 2 cm, môže byť takto vyhotovený model bez ohľadu na priehyb v smere osi y (max.  $\Delta y = -13$ cm) použitý na export ortosnímky s rozlíšením 1 pixel/1 cm a tieto odchýlky ( $\Delta x$  a  $\Delta z$ ) budú pri danom rozlíšení na exportovanej snímke zanedbateľné. Akonáhle je však cieľom vytvoriť aj 3D model, je potrebné rovnomerne po celom objekte rozložiť vlícovacie body a použiť pri orientácii snímok vo PhotoScane funkciu optimalizácie (MARČIŠ, 2012).

Uvedené výsledky však boli dosiahnuté iba s jednou konkrétnou digitálnou kamerou – iné, kvalitnejšie fotografické vybavenie môže produkovať aj výrazne kvalitnejšie výsledky. Príklad teda slúži iba na ilustráciu komplikácií, s ktorými sa môžeme stretnúť pri líniových objektoch.

### 6.2 Objekty uzatvorené zvonka

Pri objektoch uzatvorených zvonka (izolovaných objektoch) je potrebné vytvoriť uzatvorený snímkový pás (príp. viac odsadených pásov s priečnym prekrytom) okolo objektu. Snímky tak vytvárajú "vejár" opisujúci objekt v objektovej vzdialenosti *y*. Pri dodržiavaní zvoleného základnicového pomeru možno na základe stredového uhla  $\beta$ , ktorý zvierajú osi záberov smerujúce do centra objektu, odhadnúť počet snímok potrebných na zachytenie celého obvodu (Obr. 6.5).



**Obr. 6.5.** Poloha kamier pri izolovanom objekte so znázornením stredového uhla  $\beta$ 

Veľkosť stredového uhla, a teda aj počet snímok je pritom závislý od polomeru objektu *r* vzhľadom k objektovej vzdialenosti *y*. Pokiaľ má objekt tak malý horizontálny polomer *r*, že ho možno vzhľadom na geometriu snímkovania zanedbať, predstavuje stredový uhol hodnotu približne 14,5° prislúchajúcu 25 snímkam okolo objektu. S narastajúcou veľkosťou polomeru *r* sa pri stanovenom základnicovom pomere zmenšuje aj stredový uhol  $\beta$  a teda narastá aj počet snímok. Počet snímok *PS* na pokrytie kompletného obvodu objektu v závislosti od pomeru medzi *r* a *y* potom možno vypočítať na základe vzťahu:

$$PS = \frac{360^{\circ}}{\cos^{-1}(1 - \frac{b^2}{2(y+r)^2})}.$$
(6.3)



Pre jednoduchšiu predstavu je možné túto závislosť vidieť na Obr. 6.6.

**Obr. 6.6.** Nárast počtu snímok s narastajúcim percentuálnym podielom polomeru objektu *r* voči objektovej vzdialenosti *y* 

Počet snímok teda opäť samozrejme závisí aj od požadovanej presnosti premietnutej do GSD. Veľkosť GSD ovplyvňuje objektovú vzdialenosť a tá napokon vzhľadom na veľkosť objektu ovplyvňuje aj stredový uhol medzi osami záberu. V prípade, že objekt je tak rozmerný, že jeho polomer dosahuje veľkosť objektovej vzdialenosti (100 % na Obr. 6.6), na pokrytie celého obvodu objektu by bolo potrebných 50 snímok, čo sa môže veľmi ľahko stať najmä v prípade stavebných objektov (napr. bašty, veže a pod.).

Keďže závislosť medzi uvedenými parametrami je lineárna, možno na výpočet počtu snímok pre zjednodušenie použiť približný vzťah vhodný pre b : y = 1 : 4, ktorý vyzerá takto:

$$PS' = 25 \cdot \left(\frac{r}{y} + 1\right). \tag{6.4}$$

Vo všeobecnosti možno odhadnúť, že pre objekty ako sú napr. sochy (výška objektu je približne 3,5-násobok jeho šírky), v prípade, že sa socha zmestí do záberu v celej svojej výške, je pri bežne používaných ohniskových vzdialenostiach okolo 30 až 50 mm a základnicovom pomere b : y = 1 : 4 potrebné vyhotoviť okolo objektu približne 30 snímok v jednom súvislom páse. A keďže sochy bývajú značne členité a nepostačuje ich snímkovať nikdy iba zboku, je potrebné pridať ďalšie vzájomne prepojiteľné snímkové pásy (napr. zhora alebo zdola), čiže s ohľadom na členitosť aktuálneho objektu sa počet snímok môže pohybovať okolo 40 až 60.

#### 6.3 Objekty uzatvorené zvnútra

V interiérových oblastiach je opäť potrebné brať do úvahy nielen základnicový pomer, ale aj prekryt medzi susednými snímkami. Nakoľko osi záberu majú v tomto prípade pri dodržaní rovnakého základnicového pomeru tendenciu konvergovať viac než pri snímkovaní izolovaných objektov (kvôli cieleniu do stredu objektu, nie do stredu steny v podstate dochádza k divergencii osí záberu od stredu objektu smerom k snímkovanej stene), je vhodné používať počas snímkovania kratšie ohniskové vzdialenosti, aby vôbec bolo možné zabezpečiť dostatočný prekryt medzi susednými snímkami. Na zjednodušenie je na odvodenie matematických vzťahov používaná kruhová miestnosť (Obr. 6.7) - rozdiel oproti miestnosti hranatej je však minimálny, nakoľko konfigurácia kamier je obdobná v oboch prípadoch.



Obr. 6.7. Snímkovanie interiéru

Od veľkosti základnicového pomeru a polomeru miestnosti opäť závisí aj stredový uhol, pod ktorým sa pretínajú osi záberu susedných kamier. Počet snímok možno vypočítať na základe vzťahu:

$$PS = \frac{360^{\circ}}{\cos^{-1}(1 - \frac{b^2}{2(y-r)^2})}.$$
(6.5)

Za predpokladu, že steny objektu by boli snímkované od protiľahlej steny a teda, že  $2r \approx y$ , je pri základnicovom pomere b : y = 1 : 4 potrebné vyhotoviť približne 13 snímok. Pri 35 mm ohniskovej vzdialenosti s kamerou Nikon D5100 by bol pritom dosiahnutý trojnásobný prekryt v úrovni 22 % (dvojnásobný prekryt susedných snímok 61 %). Veľkosť trojnásobného prekrytu *s*% je pritom možné vypočítať na základe vzťahu:

$$s \% = 100 \cdot \left\{ \frac{\beta}{\sin^{-1} \left[ (y-r) \frac{\sin \frac{\alpha}{2}}{r} \right] + \frac{\alpha}{2}} - 1 \right\},$$
 (6.6)

kde

$$\frac{\alpha}{2} = \tan^{-1} \frac{w}{2f}, \qquad \beta = \cos^{-1} \left[ 1 - \frac{b^2}{2(y-r)^2} \right]. \tag{6.7}$$

Uvedený vzťah samozrejme platí iba v prípade, že r < y. Pre spomenutú kameru je závislosť dĺžky ohniskovej vzdialenosti od percentuálneho trojnásobného prekrytu pri b : y = 1 : 4 graficky znázornená na Obr. 6.8



**Obr. 6.8.** Závislosť veľkosti trojnásobného prekrytu od dĺžky ohniskovej vzdialenosti pri kamere Nikon D5100 pri dodržaní základnicového pomeru 1 : 4

Porovnaním závislosti s grafom súvisiacim s rovinnou stenou a paralelnými osami záberu možno povedať, že je takmer identická s tým rozdielom, že vzhľadom na zakrivenie steny je v druhom prípade potrebné používať o niečo kratšie ohniskové vzdialenosti. Trojnásobný prekryt teda zanikne už pri ohniskovej vzdialenosti o dĺžke približne 45 mm.

Uvedené výpočty boli vykonávané pre ideálny prípad, keď  $2r \approx y$ . To znamená, že kamera je umiestnená cca v úrovni protiľahlej steny. V praxi logicky nemôže nastať prípad, keď by 2r < y, znamenalo by to totiž, že kamera je umiestnená za stenou. Približovaním *y* k hodnote *r* sa pri dodržaní základnicového pomeru zmenšuje počet snímok, avšak klesá aj prekryt medzi susednými snímkami. V teoretickom prípade  $r \approx y$  by sa kamera nachádzala v strede objektu a točila okolo svojej vertikálnej osi, čo pre riešenie fotogrametrického pretínania napred neprichádza do úvahy.

Kvôli členitosti vnútorných priestorov, oporným stĺpom, klenbám a múrom však môže nastať situácia, keď uvedená schéma snímkovania nemôže byť dodržaná. V takom prípade je jednoducho potrebné s ohľadom na základnicový pomer a GSD umiestňovať kameru postupne oproti všetkým dôležitým plochám interiéru a vyhýbať sa pritom, aby stanoviská kamery boli veľmi blízko seba. Je vhodné vytvárať doplňujúce snímky stropu a podlahy na vytvorenie ďalších prekrytov a väčšej súdržnosti celej siete kamier. Počet snímok tak môže pri doplnenom kompletnom snímkovaní stropov dosiahnuť opäť 40 až 60 snímok v rámci jednej miestnosti.

Všetky všeobecné vzťahy v poslednej kapitole odvodené autorom tohto učebného textu tak slúžia skôr len na predstavu o minimálnych podmienkach, ktoré je potrebné dodržať na úspešné zachytenie celej trojrozmernej štruktúry danej scény a v teréne je potrebné k jednotlivým objektom vždy pristupovať individuálne.

# 7 ZOZNAM POUŽITEJ LITERATÚRY

ALSADIKA, B. S., GERKEA, M., VOSSELMANA, G.: Optimal camera network design for 3D modeling of cultural heritage. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume I-3, 2012 XXII ISPRS Congress, 25 August – 01 September 2012, Melbourne, Australia.

BARAZZETTI, L., SCAIONI, M., REMONDINO, F.: Orientation and 3D modelling from markerless terrestrial images: combining accuracy with automation. *The Photogrammetric Record* 25, pp.356-381, 2010.

BAUMGART, B.G.: *Geometric modeling for computer vision*. Ph.D. Dissertation. Stanford University, Stanford, CA, USA, 1974.

BELIŠ, M., NEMČÍK, M.: *Analýza merania plôch fotogrametrickým skenerom*. Študentská vedecká konferencia, STU v Bratislave, Svf. 2009.

BEZDĚK, L. - FROUZ, M.: *Digitální a digitalizovaná fotografie pro vědecké účely v památkové péči*. NPÚ, generální ředitelství. Praha, 2014. 216 s. ISBN: 978-80-7480-017-7.

BEZDĚK, L., BOBEK, K., BURŠÍK, D., JEDLIČKA, K.: *Metodika pro elektronický pasport zpřístupněné památky*. NPÚ, generální ředitelství. Praha, 2011. 88 s.

BIRCHFIELD, S., TOMASI, C.: *Depth discontinuities by pixel-to-pixel stereo*. In Proceedings of the Sixth IEEE International Conference on Computer Vision, pages 1073–1080, Mumbai, India, January 1998.

BÖHLER, W.: Comparison of 3D scanning and other 3D measurment techniques. International Workshop on Recording, Modeling and Visualization of Cultural Heritage. Centro Stefano Franscini, Monte Verità, Ascona, Switzerland. 2005.

BOLLES, R. C., BAKER, H. H., HANNAH, M. J.: *The JISCT stereo evaluation*. In DARPA Image Understanding Workshop, pages 263–274, 1993.

BOYKOV, Y., VEKSLER, O., ZABIH, R.: *A variable window approach to early vision*. IEEE Trans. Pattern Analysis and Machine Intelligence 20 (1998) 1283-1294.

BOYKOV, Y., VEKSLER, O., ZABIH, R.: *Efficient approximate energy minimization via graph cuts*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 23(11):1222–1239, 2001.

BRADLEY, D., BOUBEKEUR, T., HEIDRICH, W.: *Accurate multi-view reconstruction using robust binocular stereo and surface meshing*. Proc. Int'l Conf. Computer Vision and Pattern Recognition (2008) pp. 1-8.

BROWN, D. C.:: *The bundle adjustment - progress and prospects*. International Archives of Photogrammetry, 21(3), 1976.

CAMPBELL, N.D.F., VOGIATZIS, G., HERNANDEZ, C., CIPOLLA, R.: Using multiple hypotheses to improve depth-maps for multi-view stereo. Proc. European Conf. Computer Vision (2008) pp. 766-779.

CIPOLLA, R.: *Structure from motion*. [online] 2008. [citované 10.10.2012]. Dostupné z <a href="http://mi.eng.cam.ac.uk/~cipolla/publications/contributionToEditedBook">http://mi.eng.cam.ac.uk/~cipolla/publications/contributionToEditedBook</a>

/2008-SFM-chapters.pdf>.

DONEUS, M., VERHOEVEN, G., FERA, M., BRIESE, CH., KUCERA, M., NEUBAUER, W.: From deposit to point cloud: a study of low-cost computer vision approaches for the straightforward documentation of archaeological excavations. GEOINFORMATICS (FACULTY OF CIVIL ENGINEERING, CZECH TECHNICAL UNIVERSITY IN PRAGUE). 2011, 6. p.81-88, ISBN 978-80-010-4885-6.

FAUGERAS, O. D.: Three Dimensional Computer Vision: A Geometric Viewpoint. MIT Press, Boston, 1993. [online] aktualizované 29.11.2006. [citované 20.1.2013]. Dostupné z <a href="http://www.it.lut.fi/international\_studies/study/Tuomo\_Kauranne\_files/3d\_computer\_vision.pdf">http://www.it.lut.fi/international\_studies/study/Tuomo\_Kauranne\_files/ 3d\_computer\_vision.pdf</a>>.

FISCHLER, M. A., BOLLES, R. C.: *Random Sample Consensus: A Paradigm for Model Fitting with Apphcatlons to Image Analysis and Automated Cartography*. [online]. [citované 20.01.2013]. Dostupné z <a href="http://www.ai.sri.com/pubs/files/836.pdf">http://www.ai.sri.com/pubs/files/836.pdf</a>>.

FÖRSTNER, W. & GÜLCH, E.: *A Fast Operator for Detection and Precise Location of Distinct Points, Corners and Centers of Circular Features*. In: Proceedings of the ISPRS Intercommission Workshop on Fast Processing of Photogrammetric Data. 1987, S. 281–305.
FRAŠTIA, M.: *Kalibrácia a testovanie digitálnych kamier pre aplikácie blízkej fotogrametrie: Edícia vedeckých prác. Zošit č. 52.* 2008. Bratislava: Slovenská technická univerzita v Bratislave, Vydavateľstvo STU. ISBN 978-80-227-2812-6.

FURUKAWA, Y., PONCE, J.: *Accurate, dense, and robust multi-view stereopsis.* Proceedings, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 17–22 June, Minneapolis, USA (2007), pp. 1-8.

FURUKAWA, Y. & PONCE J.: *Carved Visual Hulls for Image-Based Modeling*. Int'l J. Computer Vision vol. 81 pp. 53-67 Mar. 2009.

FURUKAWA, Y., PONCE, J.: *Patch-based Multi-view Stereo Software* (PMVS - Version 2). 2010. [online]. [citované 15.11.2013] Dostupné na <a href="http://www.di.ens.fr/pmvs/">http://www.di.ens.fr/pmvs/</a>>.

FUSIELLO, A., ROBERTO, V., TRUCCO, E.: *Efficient stereo with multiple windowing*. IEEE Conf. Computer Vision and Pattern Recognition (1997) 858-863.

GÁL, P. a kol.: *Fotogrametrická dokumentácia stavebných pamiatok*. Záverečná správa úlohy 02.12 f. Vedecké laboratórium fotogrametrie, Stavebná fakulta Slovenskej vysokej školy technickej v Bratislave. 1967.

GOESELE, M., CURLESS, B., SEITZ, S.M.: *Multi-view stereo revisited*. Proc. Int'l Conf. Computer Vision and Pattern Recognition (2006) pp. 2402-2409.

HAAVARDSHOLM, T. V.: Lecture 8.3 Multiple-view stereo. Universitetet i Oslo. 2016. (online)

<https://www.uio.no/studier/emner/matnat/its/UNIK4690/v16/forelesninger/lecture\_8\_3\_mult iple\_view\_stereo.pdf>.

HANZL, V., & SUKUP, K. (2001). Fotogrametrie I. Brno: Cerm.

HARRIS, C. & STEPHENS, M.: *A combined corner and edge detector*. In: Proceedings of the 4th Alvey Vision Conference. 1988, S. 147–151.

HARTLEY, R. I., STURM, P.: *Triangulation*. In American Image Understanding Workshop, pages 957–966, 1994. [online]. [citované 20.1.2013]. Dostupné z <http://users.cecs.anu.edu.au/~hartley/Papers/triangulation/triangulation.pdf>. HARTLEY, R. I.: *In defence of the 8-point algorithm*. [online] 1997. [citované 16.1.2013]. Dostupné z < http://www.cse.unr.edu/~bebis/CS485/Handouts/hartley.pdf >.

HIRSCHMÜLLER, H., INNOCENT, P. R, GARIBALDI, J. M.: *Real-time correlation-based stereo vision with reduced border errors*. International Journal of Computer Vision, 47(1/2/3):229–246, April-June 2002.

HIRSCHMÜLLER, H.: Accurate and Efficient Stereo Processing by Semi-Global Matching and Mutual Information. Proc. IEEE Conf. Computer Vision and Pattern Recognition, vol. 2, pp. 807-814, 2005-June.

JANCOSEK, M., PAJDLA, T.: *Multi-view reconstruction preserving weakly-supported surfaces*. In: CVPR (2011). [online]. Dostupné na: http://cmp.felk.cvut.cz/~jancom1/JancosekCVPR11.pdf

JUNGHAUS, O.: Untersuchungen zur photogrammetrischen Erfassung von Punktwolken mit dem System PhotoModeler Scanner, Bachelorarbeit, Bochum University of Applied Sciences, 2010.

KANADE, T., OKUTOMI, M.: *A stereo matching algorithm with an adaptive window: Theory and experiments.* IEEE Trans. Pattern Analysis and Machine Intelligence 16 (1994) 920-932.

KATUŠČÁK, D.: *Súčasný stav formovania stratégie digitalizácie na Slovensku*. Colloquium of Library Information Employees of the V4+ Countries. Brno. 1998.

KIM, J., KOLMOGOROV, V., AND ZABIH, R.: *Visual correspondence using energy minimization and mutual information*. In International Conference on Computer Vision, 2003.

KRAUS, K.: *Photogrammetry: Advanced Methods and Applications*. 1<sup>st</sup> english ed. Bonn: Dűmmler, 1997, 466 s.

LAZEBNIK S.: Projective visual hulls. Technical Report MS Thesis, UIUC, 2002.

LOWE, D.: Object recognition from local scale-invariant features, in: ICCV, 1999.

LUHMANN, T., ROBSON, S., KYLE, S., HARLEY, I.: *Close Range Photogrammetry: Principles, Methods and Applications.* Dunbeath: Whittless Publishing, 2006. 510p. ISBN 1-870325-50-8.

LUHMANN, T., STUART, R., KYLE, S., BOEHM, J.: *Close-range Photogrammetry and 3D Imaging*. De Gruyter, Berlin, 2013, pp. 702.

MACH, L.: SIFT: Scale Invariant Feature Transform, Automatické nalezení korespondencí mezi dvojicí obrázků. [online] 2012. [citované 15.01.2013]. Dostupné z <a href="http://cgg.mff.cuni.cz/~pepca/ref/SIFT.pdf">http://cgg.mff.cuni.cz/~pepca/ref/SIFT.pdf</a>>.

MARČIŠ, M.: *Ochrana a obnova kultúrneho dedičstva metódami digitálnej fotogrametrie*. Dizertačná práca. Bratislava: SvF STU, 2013. 140 s.

MARČIŠ, M., FRAŠTIA, M.: Automatizovaný fotogrametrický zber priestorových údajov pre potreby dokumentácie kultúrnej pamiatky Husitská bašta v Krupine. In: Telč 2012 aneb co je nového v oblasti fotogrammetrie, DPZ, laserového skenování a GIS. ČVUT Praha, 2012.

MARČIŠ, M., FRAŠTIA, M.: *Automatizovaná tvorba 3D modelov sôch s využitím obrazovej korelácie*. In: Telč 2012 aneb co je nového v oblasti fotogrammetrie, DPZ, laserového skenování a GIS. ČVUT Praha, 2012.

MARČIŠ, M., CHLEPKOVÁ, M., HALIČKOVÁ, J.: *Digitálna fotogrametria pri dokumentácii archeologických nálezov*. In GIS v archeológii 2010 : Zborník z konferencie. Nitra,SR,25.-26.11.2010. Nitra: Archeologický ústav SAV v Nitre, 2010, s. 146--154. ISBN 978-80-89315-25-3.

MARČIŠ, M.: Automatizované modelovanie hradných múrov technológiou optického skenovania, In Juniorstav 2012: 14. Odborná konference doktorského studia. Brno, VUT, 26.
1. 2012. Brno: Vysoké učení technické v Brně - Fakulta stavební, 2012, ISBN 978-80-214-4393-8.

MASON, S.: Expert system-based Design of Close-Range Photogrammetric Networks. *ISPRS Journal of Photogrammetry & Remote Sensing* 50, pp.13-24, 1995.

MASON, S.:. Heuristic Reasoning Strategy for Automated Sensor Placement. *Photogrammetric Engineering & Remote Sensing* 63, pp.1093-1102, 1997.

MATTHEWS, N.A.: Aerial and Close-Range Photogrammetric Technology: Providing Resource Documentation, Interpretation, and Preservation, *Technical notes 428 U.S. Department of the Interior*, Bureau of Land Management, Denver, Colorado p. 42, 2008.

MORAVEC, H. P.: *Towards Automatic Visual Obstacle Avoidance*. In: Proceedings of the 5th International Joint Conference on Artificial Intelligence. 1977, S. 584.

SAADATSERESHT, M., SAMADZADEGAN, F., AZIZI, A.: Automatic Camera Placement in Vision Metrology Based on a Fuzzy Inference System. *Photogrammetric Engineering & Remote Sensing* 71, pp.1375-1385, 2005.

SCHARSTEIN, D., & SZELISKI, R.: *A taxonomy and evaluation of dense two-frame stereo correspondence algorithms*. International Journal of Computer Vision, 47(1–3), 2002, 7–42.

SEMYONOV, D. *Algorithms used in Photoscan*, Agisoft PhotoScan Forum, 03.05.2011 [online]. Dostupné na <www.agisoft.ru/forum/>.

SONG, P., WU, X., & WANG, M.Y.: *Volumetric stereo and silhouette fusion for imagebased modeling*. The Visual Computer, 26, (2010), 1435-1450.

STRUTZ, T.: Data Fitting and Uncertainty (A practical introduction to weighted least squares and beyond). 2nd edition, Springer Vieweg. 2016. ISBN 978-3-658-11455-8.

SUN, J., SHUM, H. Y., ZHENG, N. N.: *Stereo matching using belief propagation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 25(7):787–800, July 2003.

TOMASI, C., KANADE, T.: Shape and motion from image streams under orthography: A factorization method. International Journal of Computer Vision, 9(2):137–154, 1992.

TORR, P. H. S., ZISSERMAN, A.: *Robust computation and parameterization of multiple view relations*. In International Conference on Computer Vision (ICCV'98), pages 727–732. 1998.

TSAI, R.: A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses. IEEE Journal of Robotics and Automation, 3(4):323–344, 1987.

ULÉN, J.: *Higher-order regularization in computer vision*, Ph.D. dissertation, Lund University, 2014.

VERHOEVEN, G.: Taking ComputerVision Aloft - Archaeological Three-dimensional Reconstructions from Aerial Photographs with PhotoScan, Archeological Prospection, Archeol. Prospect. (2011).

VEKSLER, O.: *Fast variable window for stereo correspondence using integral images*. IEEE Conf. Computer Vision and Pattern Recognition 1 (2003) 556-561

VESELÝ, J.: *Měřická dokumentace historických staveb pro průzkum v památkové péči*. NPÚ, ÚOP středních Čech. Praha, 2014. 126 s. ISBN: 978-80-86516-79-0

VIOLA, P. & WELLS, W. M.: *Alignment by maximization of mutual information*. International Journal of Computer Vision, 24(2):137–154, 1997.

YOON, K.J., KWEON, I.S.: *Adaptive support-weight approach for correspondence search*. IEEE Trans. Pattern Analysis and Machine Intelligence 28 (2006) 650-656

ZHANG, Z., DERICHE, R., FAUGERAS, O., LUONG, Q.-T.: A robust technique for matching two uncalibrated images through the recovery of the unknown epipolar geometry. Artificial Intelligence Journal, 78:87–119, 1995.

## Iné internetové zdroje:

www.agisoft.com. [online] (október 2018) Dostupné na < http://www.agisoft.com>

en.wikipedia.org. [online] (2013) Dostupné na < http://en.wikipedia.org/wiki/RANSAC>

www.flightsafetyaustralia.com [online] (2018) Dostupné na <a href="https://www.flightsafetyaustralia.com/2014/09/rpa-taking-flight/6\_-microdrones-md4-1000-press-kit-industry-inspection/">https://www.flightsafetyaustralia.com/2014/09/rpa-taking-flight/6\_-microdrones-md4-1000-press-kit-industry-inspection/</a>

www.gom.com. [online] (2012) Dostupné na <http://www.gom.com/metrology-systems/3d-scanner.html>

www.photogrammetry.ethz.ch. [online] (január 2011) Dostupné na <http://www.photogrammetry.ethz.ch/summerschool/pdf/15\_2\_Patias\_CHD.pdf> www.steinbichler.com. [online] (2012) Dostupné na <http://www.steinbichler.com> vision.middlebury.edu. [online] (2018) Dostupné na <http://vision.middlebury.edu> wikimedia.org. [online] (január 2011) Dostupné na <http://commons.wikimedia.org/wiki/ File:St\_Peter\_Salzburg\_panoramic\_view\_of\_interior\_small.jpg>

Ing. Marián Marčiš, PhD.

## AUTOMATIZOVANÉ FOTOGRAMETRICKÉ METÓDY V PROCESE DIGITALIZÁCIE KULTÚRNEHO DEDIČSTVA

Vydala Slovenská technická univerzita v Bratislave vo Vydavateľstve SPEKTRUM STU, Bratislava, Vazovova 5, v roku 2019.

Edícia skrípt

Rozsah 113 strán, 82 obrázkov, 2 tabuľky, 7,066 AH, 7,257 VH, 1. vydanie, edičné číslo 6008, vydané v elektronickej forme.

85 - 204 - 2019

ISBN 978-80-227-4895-7