

Univerzita Karlova
Přírodovědecká fakulta
Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Faraz Ahmed Bashir

Mapování skalních útvarů pomocí geoinformačních metod

Topographic mapping of rock formations using GIS methods

Diplomová práce

Vedoucí práce: Ing. Eva Štefanová, Ph.D.

Praha 2020

Vysoká škola: Univerzita Karlova

Fakulta: Přírodovědecká

Katedra: Aplikované geoinformatiky a kartografie

Akademický rok: 2020/2021

Zadání diplomové práce

pro Bc. Faraze Ahmeda Bashira

obor Kartografie a geoinformatika

Název tématu: Topografické mapování složitých terénních útvarů

Zásady pro vypracování

Diplomová práce se zabývá problematikou mapování skalních útvarů z dat laserového skenování, fotogrammetrie a bezpilotní letecké fotogrammetrie. Data budou pořízena pozemním laserovým skenerem, pozemní fotogrammetrií (digitální neměřickou kamerou), UAV a klasickým geodetickým měřením. Geodeticky budou zaměřeny kontrolní profily a kontrolní body, které budou použity ke srovnání jednotlivých modelů. Při zpracování bodového mračka bude kladen důraz na možnosti využití filtrace prostorových objektů (zejména vegetace) k lepšímu a detailnějšímu modelu. Praktické testování bude provedeno na jedné vybrané lokalitě.

Dílní cíle práce jsou následující

- a) Literární rešerše zaměřená na zpracování bodového mračka z dat laserového skenování, fotogrammetrie, UAV.
- b) Literární rešerše zaměřená na filtraci prostorových objektů (zejména vegetace) z bodového mračka.
- c) Zpracování dat do podoby prostorových modelů, jejich vzájemné srovnání včetně doporučení pro další podobné aplikace.
- d) Zhodnocení dosažené přesnosti modelů získaných různými metodami pomocí geodetického zaměření.
- e) Navržení vhodného filtračního postupu – popis, praktické testování a srovnání s již existujícími.

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: cca 80 stran

Seznam odborné literatury

Anders, N., et al. (2019): Comparing Filtering Techniques for Removing Vegetation from UAV-Based Photogrammetric Point Clouds. *Drones*, 3(3), 61, <https://doi.org/10.3390/drones3030061>.

Bemis, S.P., et al. (2014): Ground-based and UAV-based photogrammetry: A multi-scale, high-resolution mapping tool for structural geology and paleoseismology. *Journal of Structural Geology*, 69, 163-178, <https://doi.org/10.1016/j.jsg.2014.10.007>.

Kisztner, J., Jelínek, J., Daněk, T., Růžička, J. (2016): 3D documentation of outcrop by laser scanner – Filtration of vegetation, *Perspectives in Science* 7, 161-165, <https://doi.org/10.1016/j.pisc.2015.11.026>.

Kraus, K. (2007): *Photogrammetry: Geometry from Images and Laser Scans*, Walter de Gruyter, 474 s., ISBN3110892871.

Shan, J., Toth, Ch. K. (2018): *Topographic Laser Ranging and Scanning: Principles and Processing*, Second Edition, CRC Press. 638 s., ISBN 9781498772273.

Surzenegger, M., Stead, D. (2009): Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts. *Engineering Geology*, 106.3-4, 163-182.

Vedoucí diplomové práce: Ing. Eva Štefanová, Ph.D.

Datum zadání diplomové práce: 08.01.2019

Termín odevzdání diplomové práce: prosinec 2020

Platnost tohoto zadání je po dobu jednoho akademického roku.

.....

Vedoucí diplomové práce

.....

Vedoucí katedry

V Praze dne 10.12.2020

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze, dne 10. prosince 2020

Faraz Ahmed Bashir

Poděkování

Rád bych na tomto místě poděkoval své vedoucí práce Ing. Evě Štefanové, Ph.D. Dále bych rád poděkoval katedře aplikované geoinformatiky a kartografie za půjčení veškerého vybavení a poskytnutí dat. Můj vděk také patří pracovníkům katedry, kteří mi pomohli se sběrem dat. Dále bych rád poděkoval firmě G4D za poskytnutí licencí pro zpracování dat. V neposlední řadě bych rád poděkoval svým přátelům za podporu při vzniku této práce.

Mapování skalních útvarů pomocí geoinformačních metod

Abstrakt

Tato diplomová práce se zabývá problematikou mapování skalních útvarů z dat pozemního laserového skenování, pozemní fotogrammetrie či UAV fotogrammetrie a automatické filtrace vegetace z nich. Teoretická část práce se zaměřuje na popis fungování a využití těchto metod. Popsána je zde i problematika filtrování 3D bodových mračen. V praktické části práce je popsán postup sběru dat v terénu a jejich následné zpracování. Dále jsou zde použity některé filtrační funkce, které z bodových mračen odstraňují odlehlá měření a vegetaci pomocí vegetačního indexu ExG, klastrovacího algoritmu DBSCAN a Houghovy transformace. Navržený postup je otestována na vybraném skalním útvaru v národním parku České Švýcarsko. Hodnocení použitého filtračního postupu je provedeno na základě porovnání modelů filtrovaných pomocí automatické filtrace s referenčním modely, které byly filtrovány manuálně. Závěrem je vyhodnocena dosažená přesnost modelů pomocí geodetického měření.

klíčová slova

laserové skenování, fotogrammetrie, UAV, bodové mračno, filtrace dat

Topographic mapping of rock formations using GIS methods

Abstract

This thesis deals with issues of creating 3D models of rock formations with data from terrestrial laser scanning, close range photogrammetry and UAV photogrammetry. The theoretical part focuses on explaining functioning and usage of those methods. Beside that there is described issues of 3D point cloud filtering. Practical part of this work describes data collecting and processing procedure. Further there is proposed filtering process which aim to remove noise points from point clouds and remove vegetation with combination of vegetation index ExG, clustering algorithm DBSCAN and Hough Transform. The proposed method is tested on the selected rock formation in Bohemian Switzerland National Park. The evaluation of the proposed method is based on comparison of models filtered with proposed method with reference models, which are filtered manually. Finally, the achieved accuracy of the models is evaluated using geodetic measurements.

key words

laser scanning, photogrammetry, UAV, point cloud, data filtering

Obsah

Seznam obrázku	10
Seznam tabulek	13
Seznam zkratk	14
1 Úvod	15
2 Současný stav řešené problematiky	17
3 Teoretická část	27
3.1 Laserové skenování	27
3.1.1 Rozdělení laserových skenerů	27
3.1.2 Pozemní laserové skenování	30
3.2 Fotogrammetrie	34
3.2.1 Členění fotogrammetrie	35
3.2.2 Základní principy fotogrammetrie	36
3.2.3 Structure from motion	39
3.2.4 UAV	40
3.3 Filtrace bodových mračen	41
3.3.1 Filtrace vzdálených bodů	41
3.3.2 Filtrace na základě úhlu dopadu	43
3.3.3 Filtrace odlehlých a šumových bodů	44
3.3.4 Vzorkování bodových mračen	45
3.4 Segmentace bodových mračen	46
3.4.1 Klastrovací algoritmy	46
3.4.2 Model fitting algoritmy	48
3.4.3 Algoritmy na bázi růstu oblastí	51
4 Použitá metodika	52
4.1 Zkoumaný objekt	53
4.2 Sběr dat	55
4.2.1 Vlastní laserové skenování	55
4.2.2 Pozemní snímkování	58
4.2.3 UAV snímkování	60
4.2.4 Geodetické zaměření	62
4.3 Zpracování dat	64
4.3.1 Tvorba bodového mračna z laserového skenování	64
4.3.2 Tvorba bodového mračna z UAV snímků	67

4.3.3	Tvorba bodového mračna z pozemních snímků.....	72
4.4	Tvorba filtrů.....	74
4.4.1	Preprocessingové filtry.....	74
4.4.2	Filtrace vegetace	79
4.5	Tvorba polygonové sítě	85
5	Hodnocení výsledků	90
5.1	Hodnocení filtrů	90
5.2	Srovnání modelů	98
5.3	Porovnání modelů s geodetickým měřením	103
6	Diskuze	106
7	Závěr.....	109
8	Zdroje	111
9	Přílohy	119

Seznam obrázku

<i>Obr. 1: Používané metody pro různě velké objekty</i>	<i>18</i>
<i>Obr. 2: Přesnost metod v závislosti na velikosti objektu</i>	<i>18</i>
<i>Obr. 3: Tvar vlny emitované a přijaté</i>	<i>20</i>
<i>Obr. 4: Laserové systémy a jejich využití</i>	<i>28</i>
<i>Obr. 5: Princip fázového skeneru</i>	<i>29</i>
<i>Obr. 6: Parametry registrace dvou skenů</i>	<i>30</i>
<i>Obr. 7: Referenční terče pro laserové skenování</i>	<i>31</i>
<i>Obr. 8: Špatné a dobré umístění spojovacích bodů</i>	<i>32</i>
<i>Obr. 9: Princip jednofázového georeferencování</i>	<i>33</i>
<i>Obr. 10: Princip dvoufázového georeferencování</i>	<i>34</i>
<i>Obr. 11: Princip fotogrammetrického měření</i>	<i>36</i>
<i>Obr. 12: Vztah mezi snímkovými a objektovými souřadnicemi</i>	<i>37</i>
<i>Obr. 13: Nedokonalosti objektivu</i>	<i>38</i>
<i>Obr. 14: Vliv vzdálenosti na nepřesnost měření</i>	<i>42</i>
<i>Obr.15: Vzdálenost, horizontální a vertikální úhel v TLS</i>	<i>42</i>
<i>Obr. 16: Vliv úhlu dopadu na nepřesnost měření</i>	<i>43</i>
<i>Obr.17: Schematická ilustrace dopadajícího paprsku</i>	<i>44</i>
<i>Obr. 18: Princip DBSCAN algoritmu</i>	<i>48</i>
<i>Obr. 19: Princip metody RANSAC.....</i>	<i>49</i>
<i>Obr. 20: Princip Houghovy transformace pro přímku</i>	<i>50</i>
<i>Obr. 21: Pozice skenovaného objektu v NP České Švýcarsko</i>	<i>53</i>
<i>Obr. 22: Pravá strana skály</i>	<i>54</i>
<i>Obr. 23: Levá strana skály</i>	<i>54</i>
<i>Obr. 24: Laserový skener FARO Focus3D-X130.....</i>	<i>55</i>
<i>Obr. 25: Umístění sférických terčů.....</i>	<i>56</i>
<i>Obr. 26: Pozice skeneru</i>	<i>57</i>
<i>Obr. 27: Fotoaparát Nikon D750</i>	<i>58</i>
<i>Obr. 28: Režimy nastavení fotoaparátu</i>	<i>58</i>
<i>Obr. 29: Poloha pořízených snímků</i>	<i>59</i>

<i>Obr. 30: Kalibrační dialog programu Metashape</i>	60
<i>Obr. 31: UAV DJI Phantom 4 PRO</i>	60
<i>Obr. 32: Základní koncept nasazení UAV systému</i>	61
<i>Obr. 33: Poloha pořízených snímků z UAV</i>	61
<i>Obr 34: Totální stanice Trimble M3 – 5CC, GNSS Trimble R10</i>	62
<i>Obr. 35: Poloha stanovisek</i>	63
<i>Obr. 36: Podrobné body</i>	63
<i>Obr. 37: Falešná měření</i>	65
<i>Obr. 38: Nástroj visual registration</i>	65
<i>Obr. 39: Výsledky registrace</i>	65
<i>Obr. 40: Řez v bodovém mračnu</i>	66
<i>Obr. 41: vlíčovací bod</i>	66
<i>Obr. 42: Výsledky georeferencování</i>	66
<i>Obr. 43: Oříznuté bodové mračno z laserových dat</i>	67
<i>Obr. 44: Pracovní postup Agisoft Metashape</i>	68
<i>Obr. 45: Estimate image quality</i>	68
<i>Obr. 46: Dialogové okno Align photos</i>	69
<i>Obr. 47: Řídké bodové mračno</i>	70
<i>Obr. 48: Ukázka spojovacích bodů</i>	70
<i>Obr. 49: Vlíčovací bod</i>	71
<i>Obr. 50: Dialogové okno Build Dense Cloud</i>	71
<i>Obr. 51: Oříznuté bodové mračno z dat UAV</i>	72
<i>Obr. 52: Řídké mračno před a po gradual selection</i>	73
<i>Obr. 53: ukázka snímku zachycující detaily skály</i>	73
<i>Obr. 54: Husté bodové mračno z pozemní fotogrammetrie</i>	73
<i>Obr. 55: Tisk konfiguračního textového dokumentu</i>	75
<i>Obr. 56: Ukázka preprocessing skriptu</i>	76
<i>Obr. 57: Sken 4 před a po preprocessing filtraci</i>	77
<i>Obr. 58: Mračno z UAV před a po preprocessing filtraci</i>	78
<i>Obr. 59: Řez v mračnu z UAV před a po preprocessing filtraci</i>	78
<i>Obr. 60: Bodové mračno z UAV před a po aplikování ExG</i>	79
<i>Obr. 61: Sken 4 před a po DBSCAN filtraci</i>	81

<i>Obr. 62: Zobrazení bodů při velikosti 1 pixel a 4 pixely</i>	<i>82</i>
<i>Obr. 63: řez v bodovém mračnu z UAV.....</i>	<i>84</i>
<i>Obr. 64: identifikace stromu pomocí Houghovy transformace</i>	<i>84</i>
<i>Obr. 65: Dialogové okno build mesh.....</i>	<i>86</i>
<i>Obr. 66: Model z automatické filtrace.....</i>	<i>86</i>
<i>Obr. 67: Model z manuální filtrace.....</i>	<i>87</i>
<i>Obr. 68: Interpolované mezery.....</i>	<i>87</i>
<i>Obr. 69: Dialogové okno build texture.....</i>	<i>88</i>
<i>Obr. 70: Texturované modely filtrovány manuální metodou</i>	<i>89</i>
<i>Obr. 71: Sken 9.....</i>	<i>91</i>
<i>Obr. 72: Sken 3.....</i>	<i>92</i>
<i>Obr. 73: Sken 7.....</i>	<i>93</i>
<i>Obr. 74: Finální modely.....</i>	<i>94</i>
<i>Obr. 75: Finální modely bez textur</i>	<i>95</i>
<i>Obr. 76: Výsledek CSF</i>	<i>97</i>
<i>Obr. 77: Výsledek Lasground s natavením přírodní typ povrchu.....</i>	<i>97</i>
<i>Obr. 78: Výsledek Lasground s natavením městský typ povrchu</i>	<i>98</i>
<i>Obr. 79: Referenční modely</i>	<i>99</i>
<i>Obr. 80: Porovnání modelů z TLS a UAV.....</i>	<i>100</i>
<i>Obr. 81: Histogram vzdálenosti bodů mezi modely z TLS a UAV.....</i>	<i>100</i>
<i>Obr. 82: Porovnání modelů z TLS a poz. fotogrammetrie</i>	<i>101</i>
<i>Obr. 83: Histogram vzdálenosti bodů mezi modely z TLS a poz. fotogrammetrie</i>	<i>101</i>
<i>Obr. 84: Histogram vzdálenosti bodů mezi modely z UAV a poz. fotogrammetrie.....</i>	<i>102</i>
<i>Obr. 85: Porovnání modelu z UAV a poz. fotogrammetrie.....</i>	<i>102</i>
<i>Obr. 86: Porovnání modelu z poz. fotogrammetrie a UAV.....</i>	<i>103</i>
<i>Obr. 87 Měření vzdálenosti metodou nejbližšího souseda.....</i>	<i>104</i>

Seznam tabulek

<i>Tab. 1: Parametry skenování.....</i>	<i>57</i>
<i>Tab. 2: Počet bodů před a po oříznutí skenů.</i>	<i>67</i>
<i>Tab. 3: Počet bodů před a po preprocessing filtraci.....</i>	<i>77</i>
<i>Tab. 4: Počty bodů před a po aplikaci ExG indexu.....</i>	<i>80</i>
<i>Tab. 5: Nastavení a výsledky DBSCAN filtrace.....</i>	<i>81</i>
<i>Tab. 6: Porovnání automatické a manuální filtrace.....</i>	<i>91</i>
<i>Tab. 7: Odchyly pro model z TLS.....</i>	<i>105</i>
<i>Tab. 8: Odchyly pro model z UAV.....</i>	<i>105</i>
<i>Tab. 9: Odchyly pro model z poz. fotogrammetrie.....</i>	<i>105</i>

Seznam zkratek

3D – trojdimenzionální

ASCII – American Standard Code for Information Interchange

ASTM – American Society for Testing and Materials

CIVE – Index vegetační extrakce (color index of vegetation extraction)

CSF – Cloth Simulation Filter

CW – Continuous Wave

DMT – Digitální model terénu

EVI – vylepšený vegetační index (Enhanced Vegetation Index)

ExG – Index nadměrné zelenosti (Excessive Greenness Index)

GIS – Geografický Informační Systém

GPS – Globální Polohový Systém (Global Positioning System)

GNSS – Global Navigation Satellite Systém (globální družicový polohový systém)

IMU – Inertial Measurement Unit (inerciální měřící jednotky)

LLS – Letecké Laserové Skenování

NDVI – normalizovaný diferenční vegetační index (Normalized Difference Vegetation Index)

PCD – Point Cloud Data

ROR – Radius outlier removal

RTK – Real time kinematice (Kinematika v reálném čase)

RVI – jednoduchý poměrový vegetační index (Ratio Vegetation Index)

SfM – Structure from Motion

SOR – Statistical Outlier Removal

TLS – Terestriální Laserové Skenování

UAV – Unmanned Aerial Vehicle (Bezpilotní letecký prostředek)

1 Úvod

Tato práce se zabývá topografickým mapováním skalních útvarů. Tyto útvary mohou mít různé rozměry, vzhled, různý sklon, různou orientaci vůči světovým stranám a různou expozici. Obvykle se jedná se o útvary, jejichž povrch není možné měřit přímo kontaktními metodami, ať už kvůli jeho velikosti, tvaru, nedostupnosti či překážkám na jeho povrchu a okolí. Příkladem takových útvarů mohou být skalní tělesa např. v národním parku České Švýcarsko, které se často nachází v prudkých svazích a jejich povrch a okolí jsou pokryty hustou vegetací.

V současné době existuje mnoho technik pro mapování skalních útvarů. Tyto metody však často nedokážou nasnímat celý povrch skály, proto je často nutné kombinace těchto metod. Vybranými metodami v této práci jsou metody pozemního laserového skenování, pozemní fotogrammetrie a UAV fotogrammetrie. Tyto metody mají své limity a žádná z nich sama o sobě obvykle nestačí pro nasnímání celého povrchu skalních útvaru. Metoda pozemního laserového skenování je omezena svojí mobilitou. Přístroj není možné bezpečně umístit v prudkém svahu. Skalní tělesa jsou často vysoká, a proto je úhel dopadu laserových paprsků na vrchní část příliš velký. Pro nasnímání vrchní části těchto útvarů je vhodné použít metodu UAV fotogrammetrie. Ta však z důvodu hustého vegetačního pokryvu nedokáže nasnímat i nižší části objektu, pro které je vhodnější metoda pozemní fotogrammetrie, u níž je operátor schopen se s fotoaparátem dostat do těsné blízkosti snímaného objektu. Nevýhodou pozemní fotogrammetrie je stejně jako u laserových skenerů nedostatečné pokrytí vrchní části snímaného objektu. Pokud se však tyto metody kombinují, je možné nasnímat celý povrch objektu. Toto však umožňuje pouze tvorbu 3D modelu celého objektu, jehož povrch a okolí jsou stále pokryty vegetací, která se obvykle složitými postupy odstraňuje manuálně.

Většina současných přístupů pro odstranění vegetace z 3D dat je zaměřená na data z leteckého laserového skenování, která obsahují informace o vícenásobném odrazu a jež jsou základem pro filtraci vegetace. Tato data však neposkytují dostatečně podrobné informace nutné pro tvorbu velmi přesných 3D modelů, které je možné získat pouze metodami blízkého měření. Data získaná z Pozemního laserového skenování a metodami fotogrammetrie obvykle neobsahují informace o vícenásobném odrazu, a proto na ně není

možné aplikovat stejné přístupy jako na data z leteckého skenování. V současné době se tato data obvykle filtrují manuální metodou.

Tato diplomová práce se zabývá problematikou mapování skalních útvarů. Data budou pořízena pozemním laserovým skenerem, pozemní fotogrammetrií, bezpilotní leteckou fotogrammetrií (UAV) a klasickým geodetickým měřením, které bude použito ke kontrole dosažených výsledků. Při zpracování bodového mračka bude kladen důraz na možnosti využití filtrace prostorových objektů k lepšímu a detailnějšímu modelu. Testování navržené metodiky bude provedeno na vybraném skalním útvaru v národním parku České Švýcarsko.

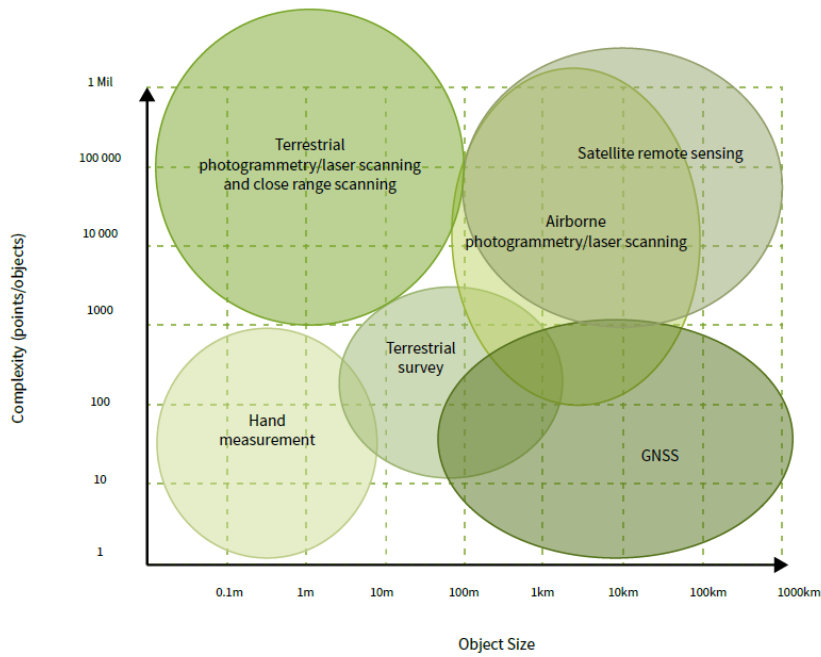
Díličními cíli práce jsou:

- a) Literární rešerše zaměřená na zpracování bodového mračka z dat laserového skenování, fotogrammetrie, UAV.
- b) Literární rešerše zaměřená na filtraci prostorových objektů (zejména vegetace) z bodového mračka.
- c) Zpracování dat do podoby prostorových modelů, jejich vzájemné srovnání a jejich vzájemné srovnání.
- d) Zhodnocení dosažené přesnosti modelů získaných různými metodami pomocí geodetického zaměření.
- e) Navržení vhodného filtračního postupu – popis, praktické testování a srovnání s již existujícími


2 Současný stav řešené problematiky

Geodézie je aplikovaná věda, která se zabývá měřením velikosti Země, tvarem Země, topografií zemského povrchu, orientací, gravitačním polem Země a změnami těchto veličin v čase. Geodézie je jednou z nejstarších přírodních věd, s historií sahající nejméně dva tisíce let nazpět. K pokroku teorií a technologií v geodézii přispěli i někteří nejznámější astronomové, fyzici a matematici historie jako jsou například Isaac Newton, Leonhard Euler, Carl Friedrich Gauss, George Airy, Albert Michelson nebo Albert Einstein, který vytvořil teoretický základ pro pozdější tvorbu laseru. Mezi nejmodernější metody geodézie patří laserové skenování a fotogrammetrie (Carter et al. 2007). Tyto metody umožňují měření nezbytná pro tvorbu přesných 3D modelů. Laserové skenování a fotogrammetrie se v přírodních vědách těší velké oblibě. V posledních dvou dekadách došlo k velkému zlepšení prostorového a časového rozlišení dat. Díky tomuto rozvoji se tyto metody staly běžnými nástroji například ve spektrální a strukturální geologii, seismologii, ve studiu přírodních ohrožení, geomorfologii či glaciologii (Telling et al. 2017). Topografické modely s velkým rozlišením se běžně používají jako jeden ze základních nástrojů v mnoha těchto oborech (Glennie et al. 2013).

Výběr vhodné metody pro mapování by se měl řídit závislostí na velikosti objektu, jeho komplexnosti a dostupnosti (obr. 1). Často však vznikají omezení, a to zejména kvůli nízkému rozpočtu a dostupnosti vybavení (Boardman a Bryan 2018). Laserové skenování a fotogrammetrie jsou příklady metod, které kromě toho, že dokážou nasbírat velké množství dat během relativně krátké doby, mají i široké spektrum využití. Hodí se i pro velice komplexní objekty různých velikostních úrovních (Boehler et al. 2002). Kromě těchto proměnných se musí také brát v potaz požadovaná přesnost (obr. 2). Přesnost je přímo závislá na použité technologii. Malé triangulační skenery dokážou nasnímat povrch s přesností mikrometrů, ale jejich dosah skenování je omezený na desítky centimetrů. Naopak letecké skenery jsou schopné nasnímat území o rozloze několika stovek kilometrů s přesností dosahující několika decimetrů (Mathys et al. 2013).




Obr. 1: Používané metody pro různě velké objekty (Boardman a Bryan 2018)



Obr. 2: Přesnost metod v závislosti na velikosti objektu (Luhmann 2006)

V současné době je letecké laserové skenování (LLS) nejpoužívanější metodou pro topografické mapování. Největší výhodou LLS je možnost naskenování velké plochy území během krátkého časového intervalu (Glennie et al. 2013). LLS lze uplatnit v mnoha oborech, jako je například měření biomasy v lesích (Boudreau et al. 2008), monitoring svahových pohybů (Ventura et al. 2011) a monitoring tektonické činnosti (Meigs 2013). Výhodou LLS

je, že data obvykle obsahují záznam o vícenásobném odrazu (obr. 3). Laserové paprsky LLS na rozdíl od fotogrammetrie dokážou často proniknout přes vegetační pokryv až na samotný terén, díky čemuž je možné vytvářet přesné digitální modely terénu (Meng et al. 2010). Georeferencované bodové mračno vyprodukované pomocí LLS obsahuje všechny zaznamenané odrazy. Nezpracované body ale nemají žádnou klasifikaci a není možné rozlišit, který odraz odpovídá skutečnému terénu. Proto se skoro ve všech LLS datech musí provést filtrace a následná klasifikace. Pro většinu oborů v přírodních vědách je nejdůležitější rozlišení odrazu od terénu od ostatních odrazů, jako jsou například budovy nebo vegetace a následné vytvoření digitálního modelu terénu (Glennie et al. 2013). Automatická filtrace a klasifikace leteckých laserových dat jsou předmětem výzkumu, přičemž již existuje mnoho přístupů (Sithole a Vosselman 2004, Meng et al. 2010). Široké využití LLS také vedlo k rozvoji analytických nástrojů, které jsou dostupné v mnoha GIS softwarech. 3D data se často převádí na rastrová data. Taková data se obvykle označují jako 2,5D data. Každý bod je určen X a Y souřadnicí a obsahuje také informace o nadmořské výšce a také například o intenzitě odrazu či jeho klasifikaci. Převedení dat na rastrový formát umožňuje zpracování dat pomocí image processing algoritmů (Telling et al. 2017). Tato zjednodušená reprezentace je pro většinu typů území vyhovující, avšak pro 3D vizualizaci skalních útvaru je nedostačující. Skály mají často převisy, prohlubně či jeskyně, a proto je v takových případech nutné tyto útvary nasnímat z více stran pomocí pozemního měření (Lysák 2016). Porovnání LLS a pozemního laserového skenování (TLS) pro identifikaci skalních útvaru bylo provedeno v práci autorů Palečka a Kubíčka (2018). Autoři práce hodnotí LLS jako velice účinnou metodu, pokud se na daném místě nenachází moc hustá vegetace nebo pokud není skála fragmentovaná a nemění se její relativní výška. Je však nutné podotknout, že v jejich případě se jednalo o relativně velké skalní útvary o rozměrech několika desítek metrů s minimální pokrytím vegetace. Nevýhodou LLS je také malá hustota bodů, která se nehodí pro podrobné 3D modely.



Obr. 3: Tvar vlny emitované a přijaté (Kashani et al. 2015)

Z hlediska velikosti zpracovaného území za jednotku času je pozemní laserové skenování v porovnání s LSS méně produktivní. Tuto nevýhodu však kompenzuje vysokou mírou detailů, se kterou dokáže skenovat (Lysák 2016). TLS se liší od LLS v principu skenování. Zatímco LLS je po celou dobu skenování v pohybu, pozemní lasery musí zůstat ve statické poloze (existují i pozemní mobilní skenery). V TLS je objekt skenován z více pozic a je nutné mít alespoň částečný překryv mezi generovanými mračny. Předtím než se finální mračno převede do globálního souřadnicového systému, je nutné sjednotit lokální systémy. Tento proces se nazývá registrace (Kraus 2007). Další výhodou pozemního skenování oproti LLS je, že není nutná integrace GNSS/IMU systémů pro georeferenční technologie. Obvykle stačí pouze malé množství bodů na scéně změřené pomocí GNSS nebo totální stanice, které se následně naskenují a během postprocesingu se jim přiřadí souřadnice metodou nepřímého georeferencování (Shan a Toth 2018). TLS je velice užitečným nástrojem v mnoha odvětvích. Uplatnění nachází ve stavebnictví, kde se často používá pro zachycení skutečného stavu objektu, což je užitečné zejména při přestavbách výrobních hal a továren (Fröhlich et al. 2004). Dále se TLS využívá například v archeologii (Lerma et al. 2010), při monitorování útesů (Lim et al. 2005), ve strukturní geologii a paleoseismologii (Bemis et al. 2014), při skalním řízení (Sturzenegger a Stead 2009) nebo při monitorování svahových pohybů (Bitelli et al. 2004). Souhrnný přehled užití TLS v přírodních vědách lze najít například v práci Tellinga et al. (2017). TLS se naopak nehodí pro malé objekty se složitou geometrií, kde je potřeba submilimetrové přesnosti, jako například v antropologii. Pro tyto účely jsou vhodnější triangulační laserové skenery pro blízké skenování nebo blízká fotogrammetrie (Bashir 2018). Aplikaci TLS pro monitoring pohybu skalních útvarů se zabývá Alba et al. (2009). Ve své práci porovnává metody pro georeferencování bodových

mračen a také porovnává metody pro filtraci vegetace, konkrétně metody octree filtrace a iterativní filtrace. Metoda octree rozděluje celé mračno bodů na malé krychle. Velikost krychle je určena operátorem. Uvnitř každé krychle je vybrán bod s hodnotou nejnižší Z souřadnice a všechny ostatní Z souřadnice bodů jsou touto hodnotou porovnány. Pokud je rozdíl mezi těmito hodnotami větší, než určí operátor, jsou vzdálenější body z bodového mračna odstraněny. Nevýhodou této metody je předpoklad, že hodnoty Z souřadnic jsou zhruba ortogonální vůči určovanému povrchu. Tato metoda se častěji používá pro LLS data (Kilian et al. 1996). Metoda iterativní filtrace generuje 2,5D model. Na začátku je určena referenční plocha P s velikostí pixelu v . Celé bodové mračno je promítnuto na tuto referenční plochu. Pokud na jeden pixel připadá více bodů, je vždy vybrán bod s nižší hodnotou Z souřadnice. Takto vzniklá plocha je přijata jako referenční plocha P' pro další krok. Do této nově vzniklé plochy je opět promítnuto celé bodové mračno a každému pixelu jsou zachovány pouze hodnoty Z , které jsou od minimální hodnoty v pixelu vzdáleny o vybranou prahovou hodnotu d . Tento proces se opakuje a v každém kroku se snižuje velikost pixelů a také se snižuje hodnota prahové hodnoty d . Závěr práce autorů Alby et al. (2009) zní, že pokud je mračno bodů správně registrováno, stačí pro kratší vzdálenosti nepřímá georeference pomocí kontrolních bodů. Co se týče filtrace vegetace, Alba et al. (2009) tvrdí, že obě zkoumané metody nedokázaly zcela úspěšně odfiltrout vegetaci z bodové mračna, a jejich aplikace byla časově velice náročná, protože bylo nutné zbývající vegetaci filtrovat manuálně. Proto autoři doporučují pro takové případy integrovat do měření infračervenou kameru, která dokáže lépe identifikovat vegetaci a vykazuje daleko přesnější výsledky.

Nejstarší metodou tvorby 3D modelů je fotogrammetrie. Tato metoda je založena na principu částečného překryvu snímků. Zkoumaný objekt je nasnímán z několika pozic a následně pomocí spojovacích bodů vznikne rekonstrukce jeho topologie. Velkou výhodou fotogrammetrie je její nízká cena a snadná mobilita. To z fotogrammetrie dělá jednu z nejvyužívanějších metod rekonstrukce povrchu. Nevýhodou fotogrammetrie je její časová náročnost. Zpracování dat může trvat i několik dní. Výsledná kvalita vytvořeného modelu je závislá na celé řadě faktorů. Kvalitu ovlivňuje počet snímků, kalibrace a rozlišení. Další nevýhodou je náročnost na světelné podmínky při snímání. Jelikož se jedná o pasivní senzor, je nutné pečlivě vybrat čas snímání (Kraus 2007). Fotogrammetrie se rozděluje podle několika kritérií. Jedno z nejdůležitějších kritérií je poloha stanoviště. Podle toho je

fotogrammetrie rozdělena na pozemní a leteckou (Pavelka 2009). Při letecké fotogrammetrii je nosič neustále v pohybu. Nejčastějším nosičem je letadlo, ale patří sem i družice a v dnešní době hojně využívané UAV přístroje. Ty se nejčastěji používají pro topografické mapování terénu, a to zejména proto, že dokážou zachytit větší plochu než pozemní snímkování (Gonçalves a Henriques 2015). Modelováním terénu z dat UAV fotogrammetrie se zabývá práce autorů Anderse et al. (2019). V práci je porovnáváno celkem pět filtračních algoritmů pro rozlišení vegetace od terénu:

1. Klasifikace terénu na základě vegetačních indexů
2. Adaptivní TIN v sadě LAStools
3. Nativní filtrovací algoritmus softwaru Agisoft metashape
4. Iterativní snižování povrchu
5. Kombinace iterativního snižování povrchu s vegetačním indexem ExG

Všechny tyto metody byly porovnány na třech typech povrchů, a to téměř holá půda, křovinaté oblasti a oblasti s vysokou vegetací. Po porovnání těchto metod autoři došli k závěru, že všechny algoritmy produkují téměř stejný výsledek na holé půdě. V křovinaté oblasti se nejvíce osvědčily algoritmy adaptivní TIN a kombinace iterativního snižování povrchu v kombinaci s vegetačním indexem. V oblasti, kde se nachází vysoká vegetace, vykazují nejlepší výsledky algoritmus adaptivní TIN.

Hlavní výhodou skenování je rychlost a přímý sběr velkého množství bodů na povrchu. Samotné měření nevyžaduje přítomnost technika, kromě fáze přenosu skeneru na další stanoviště. V porovnání s tachymetrií tedy přináší do měření velkou produktivitu. Hlavní rozdíl mezi fotogrammetrií a laserovým skenováním je, že zatímco fotogrammetrie je metodou nepřímou, tedy že snímky se musí pořídít před měřením, u skenování probíhá měření okamžitě (Boehler et al. 2002).

Laserové skenování s sebou nese určité limity, které se při skenování musí brát v potaz. Absence kalibrovaných terčů přináší do měření některé nepřesnosti. Vlastnosti plochy, například textura nebo vlhkost, od které se paprsek odráží, ovlivňují vracející se laserový paprsek. Vlastnosti paprsku jsou též ovlivněny vzdáleností od skeneru a úhlem dopadu paprsku (Lichti a Harvey 2002). Pro odstranění těchto nedostatků je nutné data filtrovat.

Většina bodových mračen z TLS obsahuje informace o X, Y, Z souřadnicích. Pozemní skenery často disponují i barevnou kamerou, která dokáže každému bodu přidělit barevnou informaci, která se ukládá ve formě červené (R) zelené (G) a modré (B) hodnoty. Body také

nesou informaci o hodnotě intenzity dopadajícího paprsku (Slob a Hack 2004). Kromě těchto informací, které jsou přiřazeny ke každému bodu zvlášť, uchovává skener i metadata každého skenu. Tato metadata mohou obsahovat informace o pozici skeneru během skenování, počtu bodů v mračnu, časovou stopu, matici rotace, informaci o teplotě atd. (Kromer et al. 2015).

Během skenování je nutné zachovat určitou hustotu bodů. Ta se obvykle uvádí jako maximální vzdálenost mezi body do deseti metrů od skeneru. Pro tento účel je velice důležitou informací pozice skeneru během měření, díky čemuž je možné filtrovat body vzdálenější, než je definovaná vzdálenost. Navíc u vzdálenějších bodů vznikají větší polohové chyby. Poloha skeneru je také důležitá při výpočtu normál, jelikož normála bodu může mít vždy dva směry. Pozice skeneru pomáhá normálu správně orientovat. Díky normálám je možné filtrovat body, které mají velký úhel dopadu. Další informace, podle které je možné body filtrovat, je intenzita odrazu. Bohužel na rozdíl od leteckých skenerů uchovává většina pozemních skenerů informaci pouze o prvním odrazu. Intenzitu z pozemního skeneru je možné použít pro filtraci bodů na hranách objektu, kde část paprsku dopadá na hranu objektu a část za objekt, a tak má vracející se paprsek malou intenzitu a jeho poloha je určena mezi tyto dva dopady (Han et al. 2017). Fotogrammetrické metody na rozdíl od TLS tyto informace většinou neobsahují. Obvykle nesou informaci pouze o poloze bodu a jeho barvě.

Často se také lze při pozemním měření setkat s tím, že množství získaných bodů překračuje množství bodů nutných pro analýzu. Množství bodů přímo ovlivňuje výkon počítače, který může zpomalit celý proces zpracování dat. Pozemní měření také vyžaduje velké množství paměti pro ukládání nasbíraných dat. U laserového skenování se tomu dá částečně zabránit omezením úhlu skenování. Toto však není vždy možné, např. když se skener nachází uvnitř skenovaného objektu nebo když není mezi skeny dostatečný překryv. Další možností je nastavení menšího prostorového rozlišení při skenování, což může způsobit, že vzdálenější body nemusí mít dostatečnou hustotu. Toto je však možné kompenzovat pomocí více skenů (Pesci et al. 2011). Dále je možné množství bodů snížit při zpracování dat například pomocí výběru bodů. Jednou z možností je uniformní samplování, během něhož dojde k odstranění každého n -tého bodu. Jak už bylo výše zmíněno, množství bodů je úměrné vzdálenosti od skeneru, a proto uniformní samplování zachová více bodů v menší vzdálenosti (Puttonen et al. 2013). Existují ovšem i pokročilejší metody, jako je

například samplování pomocí detekce hran a zachování důležitých bodů kolem nich (Song a Feng 2009). Pro snížení velikosti dat je také nutné zvolit vhodný formát dat. Existuje velké množství komerčních i open source formátů pro 3D data. Jedním z nejpopulárnějších formátů je LAS. Tento formát je primárně určen pro letecká laserová data, ale je možné ho použít i pro bodová mračna z jiných zdrojů (Mongus a Žalík 2011). Další populární formát je ASTM E57, který je navržen tak, aby data ukládal více flexibilně a je možné ho použít jak pro laserová data, tak data z optických skenerů nezávisle na zdroji dat (Huber 2011).

RGB informaci o barvě lze potencionálně využít ke klasifikaci bodů, například použitím prahové hodnoty barev nebo pomocí vegetačních indexů. Vegetační indexy vznikají kombinací hodnot spektrálních pásů vytvořených pomocí matematických rovnic a jsou navrženy tak, aby zdůrazňovaly odezvu určité vegetační vlastnosti (Anders et al. 2019). Vegetační indexy slouží k odlišení bodů či pixelů, které náleží k vegetaci, od ostatních (např. infrastruktura, voda, oblaka nebo půda). Existuje mnoho vegetačních indexů pro různé účely. Nejčastěji jsou vegetační indexy vypočítány na základě zelené a červené barvy a na základě blízkého infračerveného a infračerveného pásma. Mezi nejpoužívanější vegetační indexy patří *Normalized Difference Vegetation Index* (NDVI), *Ratio Vegetation Index* (RVI), *Enhanced Vegetation Index* (EVI). Všechny tyto indexy však pro výpočet používají blízké infračervené pásmo (Bannari et al. 1995). Existují i vegetační indexy, jejichž výpočet je založen pouze na viditelném pásmu. Podle Ponti (2012) mezi tyto indexy patří indexy *Excessive Greenness Index* (ExG), *Color Index of Vegetation Extraction* (CIVE) a *Visual Vegetation Index* (VVI). Index ExG lze vypočítat pomocí rovnice:

$$ExG = 2 * G - R - B$$

kde G, R, B jsou normalizované hodnoty pásma zeleného, červeného a modrého spektra:

$$G = G/(R + G + B), R = R/(R + G + B), B = B/(R + G + B)$$

Index CIVE lze vypočítat pomocí rovnice:

$$CIVE = 0.441R - 0.811G + 0.385B + 18.787$$

kde R, G, B jsou hodnoty barevných kanálů. Hodnota indexu VVI se určí jako:

$$VVI = \left[\left(1 - \left| \frac{R - R_0}{R + R_0} \right| \right) * \left(1 - \left| \frac{G - G_0}{G + G_0} \right| \right) * \left(1 - \left| \frac{B - B_0}{B + B_0} \right| \right) \right]^{\frac{1}{w}}$$

kde R, G, B jsou hodnoty červeného, zeleného a modrého komponentu, RGB_0 je vektor referenční zelené barvy a w je váhový exponent pro úpravu citlivosti škály.

Ponti (2012) také provádí porovnání těchto indexů a dochází k závěru, že nejlepší výsledky vykazuje index ExG. Tyto závěry potvrzuje také Anders et al. (2019) a dodává, že index VVI lépe slouží pro rozpoznávání rozdílů mezi jednotlivými typy vegetace a index ExG se více hodí pro odlišení vegetace od ostatních povrchů. Kromě vegetačních indexů můžeme vegetaci filtrovat pomocí geometrických vlastností. Pro identifikaci vysoké vegetace z dat TLS je možné použít hledání kruhových objektů v obraze. Kmeny stromu jsou často kruhovitěho tvaru nebo tvarů velice podobných. Tento způsob identifikace se obvykle používá při inventarizaci lesů. Některé metody dokážou detekovat stromy až s 93 % přesností a s polohovou chybou okolo jednoho centimetru (Pfeifer a Winterhalder 2004, Maas et al. 2008). Takových výsledků je však dosaženo v ideálně vzrostlém lese s velmi nízkou hustotou nízké vegetace a na rovinném terénu, což se vyskytuje velmi zřídka (Pirotti et al. 2013). V současnosti nejspíš neexistuje žádná práce, která by tyto metody vyzkoušela ve svažitém terénu.

Jednou z nejpoužívanějších metod pro hledání křivek v obraze je Houghova transformace. Výhodou Houghovy transformace je odolnost vůči šumu a také možnost detekovat kružnice i v situacích, kdy část kružnice chybí. Její nevýhodou je naopak velká časová a paměťová náročnost (Vlach 2011). Houghovu transformaci pro automatickou detekci stromů v TLS datech používá metoda navržená autory Aschoffem a Spieckerem (2004). Jedná se o rozšíření metody navržené v práci Simonse et al. (2003). Metoda funguje v několika krocích. Jako první jsou z bodového mračka odstraněna špatná měření a vytvoří se digitální model terénu (DMT). Následně se provede řez v bodovém mračnu o šířce deseti centimetrů ve výšce 1,3 metru nad vytvořeným DMT. Tento řez je převeden do snímků a pomocí Houghovy transformace se identifikují kruhové objekty. Tato metoda je velice často využívána a různé její variace se objevují například v publikacích autorů Van Leeuwena et al. (2010) nebo Huanga et al. (2011). Další práce, která se zabývá automatickou filtrací vegetace z mračka bodů z pozemního laserového skenování je práce autorů Kisztnera et al. (2016). Tato práce pro filtraci vegetace využívá kombinace spektrálních vlastností vegetace a shlukovou analýzu, konkrétně metodu DBSCAN. Metoda, kterou navrhuje práce (Kisztner et al. 2016) je rozdělena do dvou kroků. V prvním kroku jsou z bodového mračka odstraněny všechny body, které náležejí k listům stromů a malé větve. Toho je dosaženo tím, že do DBSCAN vstupují kromě souřadnic bodů také jejich spektrální hodnoty. Autoři tvrdí, že tímto způsobem je možné odstranit velkou část těchto větví a listů.

V druhém kroku jsou v mračnu bodů provedeny horizontální řezy s krokem 0,5 metru. Pokud je kmen stromu naskenován z více stran, je v řezu zobrazen jako elipsa a je možné ho detekovat pomocí hranových filtrů. Autoři tvrdí, že touto metodou je možné odstranit vegetaci ze skalních útvarů. Bohužel ve své práci nepředkládají konečný model pro zhodnocení.

3 Teoretická část

3.1 Laserové skenování

Laser je akronymem pro anglická slova *light amplification by stimulated emission of radiation*, což lze přeložit jako zesilování světla stimulovanou emisí záření. Laser je optický zdroj záření emitující fotony, které jsou kolimované, monochromatické a koherentní (Kraus 2007). Lasery se obvykle rozdělují podle typu materiálu, který je použitý jako zdroj záření. Nejčastěji se používají plynové, pevnolátkové nebo polovodičové lasery. Existují i méně časté lasery, jako kapalně nebo barevné. Pro potřeby laserového skenování je vyžadován vysoký výkon a usměrnění paprsku. Proto se nejčastěji používají pevné nebo polovodičové lasery, které tyto vlastnosti mají. Lasery využívané v laserovém skenování obvykle pracují v neviditelném spektru, v oblasti blízkého infračerveného záření, od 750 do 1000 nanometrů. (Shan a Toth 2018). Během posledních dekád laserové skenování revolucionizovalo jak topografické mapování velkých území, tak blízké 3D zaznamenávání objektů. Laserové skenování nebo také LIDAR (Light Detection And Ranging), je aktivní, bezkontaktní, rychlá a automatická metoda pro měření 3D souřadnic na povrchu objektu, která pro měření používá laserové světlo (Grussenmayer et al. 2018). Boehler a Marbs (2002) definují laserový skener jako jakékoliv zařízení, které automaticky a systematicky zaznamenává 3D souřadnice na povrchu objektu ve vysoké rychlosti a vytváří výsledky v reálném čase. Výsledkem laserového skenování je mračno bodů, kterých může být až miliardy (Pfeifer a Briesse 2007).

3.1.1 Rozdělení laserových skenerů

Laserové skenery lze rozdělit do několika kategorií, jako jsou například způsob měření vzdálenosti, podle nosiče, podle využití nebo podle přesnosti. První z těchto kategorií se zabývá způsobem měření vzdálenosti. V současnosti existují tři hlavní metody pro měření vzdálenosti – metoda pulzní doby letu, metoda fázového rozdílu a metoda triangulace. Triangulační skenery se obvykle používají pro velice přesné skenování malých předmětů. Obvykle měření triangulačními skenery probíhá v laboratoři, protože přístroje fungující na tomto principu mají nízkou mobilitu. Jejich dosah je omezen na několik metrů, a proto se nehodí pro topografické mapování (Mills a Andrews 2011). Využití a typy laserových skenerů shrnuje obr. 4.

Scanning System		Usage	Typical Accuracies (mm)	Typical Range (m)
Triangulation	Rotation stage	Small objects taken to scanner. Replica production	0.05	0.1 – 1
	Arm mounted	Small objects. Lab or field. Replica production	0.05	0.1 – 3
	Tripod mounted	Small objects in the field. Replica production	0.1 – 1	0.1 – 2.5
	Close range handheld	Small objects. Lab. Replica production	0.03 – 1	0.2 – 0.3
	Mobile (handheld, backpack)	Awkward locations eg building interiors, caves	0.03 – 30	0.3 – 20
Pulse (TOF)	Terrestrial	Building exteriors/interiors. Drawings, analysis, 3D models	1 – 6	0.5 – 1000
	Mobile (vehicle)	Streetscapes, highways, railways. Drawings, analysis, 3D models	10 – 50	10 – 200
	UAS	Building roofscapes, archaeological sites. Mapping and 3D models	20 – 200	10 – 125
	Aerial	Large site prospecting and mapping	50 – 300	100 – 3500
Phase	Terrestrial	Building exteriors/interiors. Drawing, analysis, 3D models	2 – 10	1 – 300

Obr. 4: Laserové systémy a jejich využití (Mills a Andrews 2011)


Metoda Pulzní doby letu pracuje na principu měření času. Laserový vysílač vyšle krátký puls laserového paprsku do prostoru. Během vysílání je uložen do paměti skeneru směr a čas vysílaného paprsku. Laserový paprsek putuje prostorem do doby, než narazí na nějaký povrch, od kterého je paprsek odražen zpět. Tento odražený paprsek je zachycen laserovým skenerem a do paměti skeneru je uložen čas přijmutí vlny a jeho intenzita. Abychom mohli určit celkový čas letu paprsku odečte se čas, kdy byl paprsek emitován skenerem (t_e) od času, kdy byl zase skenerem zachycen (t_p). Jelikož paprsek urazí vzdálenost od skeneru na povrch dvakrát, je nutné čas letu vydělit dvěma. Laserový paprsek se pohybuje rychlostí světla (v), která je 299 792 458 metrů za sekundu ve vakuu. Jelikož měření obvyklé probíhá na zemském povrchu, kde na paprsek mají vliv teplota při měření, vlhkost, tlak vzduch a další faktory, je nutné rychlost opravit o refrakční koeficient (n) (Marshall a Stutz 2011). Poté se pomocí rovnice:

$$s = \frac{v}{n} * \frac{t_p - t_e}{2}$$

vypočte vzdálenost povrchu od skeneru (Shan a Toth 2018). Energie emitovaná pulzními skenerem je větší než u skenerů, které pracují na principu fázového rozdílu. Proto je možné pomocí pulzních skenerů měřit až na vzdálenost několika kilometrů. Nejčastěji se pulzní

skenery používají při leteckém laserovém skenování (Mills a Andrews 2011). Dříve byla tato metoda považována za pomalou, jelikož skener vždy emitoval pouze jeden paprsek a nebylo možné vyslat další, dokud nebyl přijat předchozí. Díky rozvoji v technice je dnes už možné mít v jednom skeneru více emitorů a zaznamenávat několik paprsků najednou (Toth 2004).

Druhý typ skenerů pracuje na principu fázového rozdílu. Tyto druhy skenerů se občas také nazývají *Continuous Wave (CW)* skenery. CW skenery mají podobnou přesnost jako pulzní skenery, ale jejich měření probíhá dost odlišně. Skenery na principu fázového rozdílu nevyužívají čas pro měření vzdálenosti od skeneru, ale porovnávají fáze vlny emitované a přijaté (obr. 5). Díky změřenému fázovému rozdílu a známé frekvenci vlny je možné vypočítat vzdálenost povrchu od skeneru (Shan a Toth 2018). Jelikož je zde laserový paprsek vysílán kontinuálně, lze zachytit více bodů (milióny bodů za sekundu), než pomocí pulzních skenerů, ale jeho energie je menší. Proto se CW skenery obvykle nepoužívají v leteckém skenování, ale nachází větší uplatnění v pozemních skenerech, kde je měřena vzdálenost do několika set metrů (Mills a Andrews 2011).




Obr. 5: Princip fázového skeneru (Vosselman a Mass, 2010)

Dále je možné rozdělit laserové skenery podle typu nosiče na letecké a pozemní. Letecké nosiče můžeme dále dělit na letadlové, UAV nebo družicové, u kterých je vždy známa aktuální poloha nosiče pomocí GNSS/IMU (inerciální měřicí jednotka). Při pozemním skenování obvykle zůstává skener ve statické poloze. Existují však i mobilní pozemní skenery, které jsou z praktických důvodů obvykle připojené k nějakému dopravnímu prostředku. U mobilních pozemních skeneru je nutné, stejně jako u leteckých, mít neustále informaci o jejich poloze v souřadnicích (Vosselman a Mass 2010).

3.1.2 Pozemní laserové skenování

Při statickém skenování musí skener během celé doby měření zůstat na jednom místě. Obvykle se při pozemním skenování skenují objekty s velkou rozlohou a složitou strukturou. Pro naskenování celého objektu je nutné pořídít skeny z více stanovisek. Každý sken má vlastní souřadnicový systém – jedná se o polární souřadnice. Aby tyto skeny bylo možné spojit a vytvořit výsledné bodové mračno, je nutné transformovat jejich souřadnice pomocí spojovacích bodů či pomocí společných ploch. Tomuto procesu se říká registrace (Kraus 2007). Aby bylo možné dva skeny registrovat, je nutné mezi nimi mít dostatečný překryv. Obvykle se udává hodnota mezi 40 až 60 procenty jako optimální překryv v závislosti na typu skenovaného objektu. Aby bylo možné převést souřadnice jednoho skenu do souřadnicového systému druhého skenu je nutné určit transformační parametry mezi těmito souřadnicovými systémy, jedná se o tři posuny podél tří os souřadnic (ΔX , ΔY , ΔZ) a tři rotace kolem těchto os (ω , ϕ , κ) (obr. 6).




Obr. 6: Parametry registrace dvou skenů (Reshetyuk 2009)

Existuje několik způsobů, jak tyto parametry určit a provést registraci:

- **Registrace pomocí speciálních terčů**

Jedná se o nejvíce používaný způsob. Pro určení šesti transformačních parametrů je nutné znát alespoň souřadnice tří stejných bodů ve dvou souřadnicových systémech. Tyto body by měly být dobře rozložené po celé ploše překryvu dvou skenů. V praxi se pro jistotu obvykle používá nadbytečný počet spojovacích bodů (Reshetyuk 2009). Terče se používají dvojího typu, a

to ploché terče a terče trojrozměrné (obr. 7). Ploché terče jsou nejvyužívanější. Jejich výhodou je snadné použití a cena. Ploché terče je možné vytisknout i na obyčejný papír. Nevýhodou těchto terčů je, že bývají pouze jednostranné, a proto je nutné použít velké množství terčů. Další nevýhodou je, že pokud je úhel dopadu laserového paprsku na plochu terče větší než 45° nebo pokud se laserový skener nachází ve větší vzdálenosti, není možné terč automaticky detekovat. Trojrozměrné terče jsou oproti plochým terčům několikanásobně dražší. Obvykle se jedná o bílé koule, které mají přesně určený střed. Jejich velkou výhodou je, že je možné skenovat z jakéhokoli úhlu. Proto se hodí pro venkovní skenování (Ge a Wunderlich 2015).



Obr. 7: Referenční terče pro laserové skenování (vlevo: sférický terč, vpravo: plochý terč) (Hydralab+ 2019)

- **Registrace pomocí přirozených bodů**

Pokud není na scéně umístěno dostatečné množství terčů, je možné pro registraci použít přirozené body. Přirozené body nejsou definované a je možné použít libovolný bod, který je v dostatečném rozlišení vidět na obou skenech. Obvykle se však používají hrany objektů. Registrace pomocí těchto bodů probíhá stejně jako u terčů, s rozdílem, že tyto přirozené body je nutné manuálně identifikovat ve všech skenech. Stejně jako u terčů platí, že by tyto body měli být dobře rozloženy v prostoru (Reshetyuk 2009). Příklady špatného a správného rozložení bodů je vidět na obr. 8.



Obr. 8: Špatné (vlevo) a dobré (vpravo) umístění spojovacích bodů

- **Registrace pomocí společných ploch**

Tato metoda je ze všech zmiňovaných nejmladší. Na rozdíl od výše zmiňovaných postupů se nepoužívá pro určení registračních parametrů pouze několik vybraných bodů, ale celá plocha překryvu. Tato společná plocha může obsahovat až desítky milionů společných bodů a může vést k daleko lepší registraci. Aby tato metoda byla úspěšná, je nutné mít dostatečný překryv mezi skeny. Samotný dostatečný překryv však nezaručuje úspěšnost metody. Další podmínkou je množství 3D objektů s dobrou geometrií v překryvu, kde jsou objekty orientovány v různých směrech v osách X, Y a Z. Příkladem špatné geometrie jsou například silnice, kde se pouze mění X, Y souřadnice a souřadnice Z je téměř nezměněná. Aby registrace pomocí této metody byla úspěšná, je nutné skeny zhruba orientovat. Toto je možné například pomocí spojovacích bodů nebo jednoduše manuálním posunem a otočením jednoho mračna k druhému (Bornaz et al. 2003).

Registrované mračno se nachází v lokálních souřadnicích. Pro převod těchto lokálních souřadnic do referenčního souřadnicového systému je nutné provést georeferencování. Metody georeferencování se rozdělují na přímé a nepřímé (Kraus 2007).

- **Přímé georeferencování**

Během přímého georeferencování musí být známa poloha skenerů. Poloha se dá určit totální stanicí nebo GNSS přístrojem. Některé typy skenerů mají vlastní integrovaný GNSS přístroj, kterým je možné určit polohu všech nebo pouze jednoho skenu, který poté vstupuje do registrace jako referenční sken. Výhoda této metody je, že není nutné provádět další měření pro určení vlíčovacích bodů. Pokud je zaměřena poloha všech skenů, odpadá také nutnost registrace a postprocesingu. Nevýhodou je však nižší přesnost, než je u nepřímé georeference (Schuhmacher a Böhm 2005).

- **Nepřímé georeferencování**

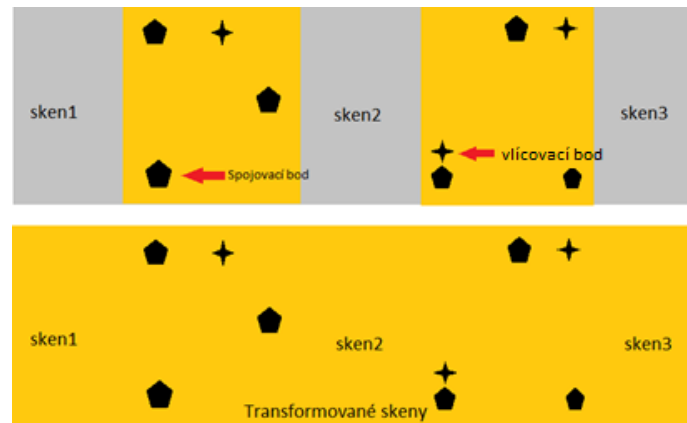
Během nepřímé georeference se neurčuje přímo pozice skeneru, ale pozice vlíčovacích bodů v požadovaném souřadnicovém systému. Tyto body jsou obvykle změřeny pomocí totální stanice nebo pomocí GNSS přístroje. Obvyklé se jedná o hrany budov, ale často se používá i umělé značení. Metoda nepřímé georeference se dělí na dva způsoby. První způsob se označuje jako jednofázové georeferencování. Při tomto způsobu není nutné provádět registraci. Každý sken je georeferencován nezávisle na ostatních skenech. Aby bylo možné použít metodu nepřímého georeferencování, je nutné označit minimálně tři vlíčovací body v každém skenu. Opět zde platí, že by body měly být rozložené v prostoru po celé ploše skenovaného území. Výhodou této metody je, že není nutný žádný překryv mezi skeny. Nevýhoda je však náročnost sběru vlíčovacích bodů pro každý sken zvlášť (Jacobs 2005). Princip jednofázového georeferencování je zobrazen na obr. 9.



Obr. 9: Princip jednofázového georeferencování
(nahore: skeny před georeferencováním, dole: skeny po georeferencování)

Druhý způsob se označuje jako dvoufázové georeferencování. První fáze začíná registrací skenů do společného souřadnicového systému. Je možné k tomu použít jakoukoliv výše zmiňovaných metod. Po úspěšné registraci, lze přistoupit k dalšímu kroku, což je samotná transformace souřadnic pomocí vlíčovacích bodů. Tyto body se mohou nacházet na libovolném skenu. Všechny body se mohou také nacházet na jednom skenu, to však není obvyklé doporučováno, jelikož by body měly být dobře rozložené v prostoru po celé skenované ploše. Tento způsob zaručuje méně přesný výsledek než jednokroková metoda, ale přináší velkou úsporu času. Jedná se o nejčastější způsob georeferencování. V praxi se však často používá kombinace těchto

dvou metod, kdy už během registrace se zároveň označují i vlíčovací. Princip dvoufázového georeferencování je zobrazen na obr. 10 (Gordon a Lichti 2004).



Obr. 10: Princip dvoufázového georeferencování
(nahore: skeny před georeferencí, dole: skeny po georeferencování)

3.2 Fotogrammetrie

Slovo fotogrammetrie vzniklo spojením třech řeckých slov – photos (světlo), gramma (záznam) a metron (měřit). Samotná historie fotogrammetrie sahá dál než objev první fotografie. Za zakladatele fotogrammetrie je považován Leonardo da Vinci, který popsal a sestrojil první dírkovou komoru. Pomocí ní obkresloval středové průměty a rekonstruoval obrazy zpět na mapový obraz (Böhm 2002). Jako první si vynález fotografie v roce 1839 patentoval francouzský vynálezce Louis-Jacques-Mandé Daguerre (Gosh 1981). Slovo fotogrammetrie jako první použil v roce 1858 Albrecht Meydenbauer a spolu s Aimé Laussedat jsou považováni za otce fotogrammetrie. V roce 1858 byla také pořízená první fotografie z balónu, což můžeme označit jako počátek letecké fotogrammetrie. V 50. letech 20. století začíná období analytické fotogrammetrie. Metoda analytické fotogrammetrie byla známa už dříve, ale nebyla používána pro svou náročnost výpočtu. Toto se změnilo s příchodem prvních počítačů. Konec 80. let znamená velký rozmach osobních počítačů a zároveň vzniká i digitální fotogrammetrie. V 90. letech se na trhu objevují první digitální fotoaparáty a vzniká plně digitální fotogrammetrie, jak ji známe dnes (Böhm 2002). Fotogrammetrie umožňuje rekonstruovat pozici, orientaci, tvar a velikost objektů z jednoho nebo více snímků. Tyto snímky mohou být buď fotochemické, nebo digitální (Kraus 2007). Primárním cílem fotogrammetrického měření je trojrozměrná rekonstrukce objektů v digitální nebo grafické podobě. V podstatě lze fotogrammetrické metody

aplikovat na jakýkoli objekt, který je možný zaznamenat na fotografické snímky (Luhmann 2006). Výsledkem fotogrammetrické analýzy můžou být:

- **Čísla** – souřadnice jednotlivých bodů v trojrozměrném prostoru
- **Výkresy** – mapy nebo plány s planimetrickými údaji a vrstevnicemi spolu s ostatními grafickými reprezentacemi objektů
- **Geometrické modely** – v geoinformačních systémech
- **Snímky** – analogové či digitální, ortorektifikované snímky a produkty z nich odvozené, trojrozměrné CAD modely s texturou (Kraus 2007)

3.2.1 Členění fotogrammetrie


Podle Luhmanna (2006) můžeme fotogrammetrii kategorizovat podle několika způsobů:

- **Podle pozice kamery a vzdálenosti objektu**
 - Satelitní fotogrammetrie – snímky jsou pořízeny ze satelitu, výška je větší než 200 km
 - Letecká fotogrammetrie – snímky jsou pořízeny z letadla nebo pomocí UAV přístroje, výška je větší než 300 m
 - Pozemní fotogrammetrie – měření probíhá z fixní polohy na zemi
 - Blízká fotogrammetrie – vzdálenost od objektu je menší než 300 m
 - Makro fotogrammetrie – mikroskopické snímky
- **Podle počtu snímku**
 - Jednosnímková fotogrammetrie – mapování v rovinném území, plány fasád, ortofotopohledy
 - Stereofotogrammetrie – ze dvou snímků, stereoskopické měření
 - Vícesnímková fotogrammetrie – počet snímků je větší než 2, metoda průsekové fotogrammetrie
- **Podle metody pořízení a zpracování**
 - Rovinná fotogrammetrie – grafické vyhodnocování (cca do 1930)
 - Analogová fotogrammetrie – analogové kamery, optické nebo mechanické nástroje vyhodnocování (cca do 1980)
 - Analytická fotogrammetrie – analogové snímky, vyhodnocení pomocí počítače
 - Digitální fotogrammetrie – digitální snímky, vyhodnocení pomocí počítače

- **Podle dostupnosti změřených výsledků**
 - Fotogrammetrie v reálném čase – snímání a vyhodnocení je dokončeno ve stanovené době od pořízení v závislosti na aplikaci
 - Off-line fotogrammetrie – sekvenčně, digitální pořízení snímků je oddělené od vyhodnocení časem a lokací
 - On-line fotogrammetrie – několik měřicích zařízení, k pořizování a zpracování záznamů dochází simultánně


3.2.2 Základní principy fotogrammetrie

Fotogrammetrie je trojrozměrná měřičská metoda, která využívá princip centrální projekce. Každý snímek objektu je jeho centrální projekcí, přičemž středem promítání je střed objektivu a obrazovou rovinu tvoří citlivá vrstva filmu nebo senzoru (Böhm 2002). Tvar a pozice objektu je určena pomocí rekonstrukce svazku paprsků. Každý bod snímaného objektu odpovídá jednomu bodu na snímku. Každý bod P' na snímku spolu s projekčním centrem O' určují směr paprsku k odpovídajícímu bodu P na objektu (obr. 11). Pokud se minimálně dva svazky paprsků z různých snímků protínají, lze určit polohu bodu ve 3D prostoru (Luhmann 2006).



Obr. 11: Princip fotogrammetrického měření (Luhmann 2006)

Vztah mezi snímkovými (x, y, z) a objektovými souřadnicemi (X, Y, Z) vyjadřuje podmínka kolinearit, jenž je základem celé fotogrammetrie. Podmínka říká, že každý bod v terénu a jeho obraz ve snímku leží s projekčním centrem v na jedné přímce. Vztah mezi snímkovými a objektovými souřadnicemi je vidět na obr. 12.



Obr. 12: Vztah mezi snímkovými a objektovými souřadnicemi (Pavelka 2009)

Vztah mezi snímkovými a objektovými souřadnicemi lze vyjádřit jako:

$$x = x_0 - f \frac{r_{11}(X - X_0) + r_{21}(Y - Y_0) + r_{31}(Z - Z_0)}{r_{13}(X - X_0) + r_{23}(Y - Y_0) + r_{33}(Z - Z_0)}$$


$$y = y_0 - f \frac{r_{11}(X - X_0) + r_{21}(Y - Y_0) + r_{31}(Z - Z_0)}{r_{13}(X - X_0) + r_{23}(Y - Y_0) + r_{33}(Z - Z_0)}$$

kde x, y jsou snímkové souřadnice bodu, x_0, y_0 a f jsou prvky vnitřní orientace, X_0, Y_0, Z_0 a r_{ij} jsou prvky vnější orientace a X, Y, Z jsou souřadnice bodu v reálném světě (Pavelka 2009).

Aby bylo možné snímky zpracovat do podoby 3D modelu, je nutné znát parametry kamery, které se označují jako prvky vnitřní orientace. Prvky vnitřní orientace určují vnitřní část fotogrammetrické kamery a patří mezi ně konstanta kamery, poloha hlavního snímkového bodu, distorze objektivu a velikost snímku v pixelech a milimetrech.

- **Konstanta kamery** – je definována jako vzdálenost mezi středem promítání a hlavním snímkovým bodem.
- **Hlavní snímkový bod** – je průsečíkem osy záběru s rovinou snímku.
- **Distorze objektivu** – je to souhrn zbytkových vad, které posunují bod v rovině snímku od jeho správné polohy. Tyto vady vznikají kvůli nedokonalostem

konstrukce objektivu. Objektiv fotoaparátu je tvořen soustavou čoček. Přední část objektivu se nazývá vstupní pupila, její střed O je středem promítání pro objektový prostor. Zadní část objektivu se nazývá výstupní pupila a je středem promítání O' pro snímkový prostor. V ideálním případě je úhel α výstupního paprsku stejný jako úhel vstupního paprsku α' . Distorze objektivu mají dvě složky, a to radiální a tangenciální distorze. Radiální distorze je posun bodu P' o vzdálenost $\Delta r'$ na snímku (obr. 13). Toto může mít vliv na výslednou kvalitu modelu a je nutné radiální distorzi, co nejvíce potlačit. Tangenciální distorze je kolmá na radiální distorzi. Tato distorze je způsobená nepřesnou centrací jednotlivých čoček v objektivu. U moderních kamer je hodnota tangenciální distorze zanedbatelná.



Obr. 13: Nedokonalosti objektivu (Pavelka 2009)

Prvky vnější orientace určují polohu a orientaci kamery v prostoru v době pořízení snímku. Tyto prvky jsou určeny pro každý pořízený snímek zvlášť. U letecké fotogrammetrie jsou tyto hodnoty určeny pomocí GNSS/IMU. Pro každý snímek se určuje šest prvků vnější orientace. Tři prostorové souřadnice X, Y, Z středu promítání v čase pořízení snímku a tři úhly rotace ω, φ, κ kolem tří os v čase pořízení snímku (Luhmann 2006).

3.2.3 Structure from motion

Metoda structure from motion (SfM) vznikla v na konci 80. let 20. století s rozvojem digitální fotogrammetrie. V současné době patří mezi nejvyužívanější metody fotogrammetrie. Cílem metody je rekonstrukce 3D objektu ze 2D překrývajících se snímků z pohybujícího se nosiče, kde nemusí být známé prvky vnější orientace. Prvky vnitřní orientace jsou získány z metadat snímků. Snímky mohou být pořízeny rovnoběžnými i konvergentními osami záběru. Podmínkou pro pořízení snímků je velký překryv a vysoká kvalita snímků. Struktura, pozice a orientace 3D objektu je získána pomocí společných bodů ve snímcích (Snavely at al. 2008).

Princip metody je rozdělen do několika kroků. V první fázi jsou v každém snímku nalezeny významné body pomocí vyhledávání lokálních extrémů ve snímcích. Každý bod musí být nalezen minimálně na dvou snímcích. Každý snímek obsahuje až tisíce takových bodů. Nalezené body se použijí pro prvotní odhad pozice kamer a jejich orientaci. Body, které se nepodaří identifikovat minimálně na dvou snímcích jsou vyloučeny z dalšího výpočtu. Obvykle se jedná o body se špatným kontrastem anebo o okrajové body snímku. Proto se tato metoda obvykle nedá aplikovat na povrchy, kde nejsou výrazné rozdíly textur např. holé zdi, zasněžené plochy, jednobarevné objekty apod. Tyto informace slouží pro rekonstrukci struktury a pohybu nosiče. Pro rekonstrukci se používá sekvenční postup, kde je vypočtena struktura a pohyb nosiče mezi dvěma snímky a postupně se rozšíří na celou sadu snímků. Mračno bodů je vygenerováno v tzv. modelových souřadnicích a je nutné ho převést do referenčního souřadnicového systému. Souřadnice jsou převedeny pomocí prostorové podobnostní transformace s využitím vlíčovacích bodů, u kterých jsou známy souřadnice v referenčním souřadnicovém systému. Tyto body musí být jednoznačně identifikovatelné jak vzniklém modelu, tak na původní snímané ploše. Obvykle se k tomuto účelu používají reflexní terče, u kterých je možné jednoznačně určit střed. Tyto terče jsou rovnoměrně rozmístěny po celém snímaném objektu a jejich souřadnice jsou obvykle zaměřeny pomocí GNSS přístroje nebo totální stanice (Westoby at al. 2012).

3.2.4 UAV

UAV je zkratkou pro anglická slova *Unmanned Aerial Vehicle*. Jedná se o bezpilotní letecký prostředek, jenž může být také označen jako UAS (Unmanned Aerial System), RPAS (Remotely Piloted Aircraft System) nebo jednoduše dron. Jak už název napovídá, jedná se o letecký prostředek bez přítomnosti pilota na palubě. Stroj je buď ovládán na dálku nebo let probíhá podle předem nastaveného letového plánu. V současnosti existují také autonomní systémy, které pomocí senzoru a umělé inteligence umí pracovat bez zásahu člověka. UAV přístroje můžeme dělit podle konstrukce na:

- Bepilotní letouny
- Bepilotní vrtulníky
- Vzducholodě/Balóny
- Multikoptéry
- Ostatní

Dále můžeme UAV přístroje dělit podle velikosti a hmotnosti na mikro, mini, blízké, střední a dlouhé vzdálenosti. Další rozdělení je podle pohonu – na UAV přístroje bez pohonu a s pohonem. Také lze UAV přístroje kategorizovat dle výkonnostních charakteristik jako jsou rychlost, výdrž, dolet, maximální výška (Remondino et al. 2011).

UAV přístroje nachází velké uplatnění v letecké fotogrammetrii, kdy jsou využívány jako nosiče snímacích zařízení (fotoaparáty, termální kamery, infračervené kamery, videokamery). Pomocí UAV přístrojů je možné dosáhnout vysokých detailů srovnatelných s pozemní fotogrammetrii a zároveň využít výhod vertikálního pohledu klasické letecké fotogrammetrie. Modernější UAV přístroje také disponují GNSS/IMU systémy, díky tomu je možné během snímkování zaznamenávat polohu kamery v době pořízení snímku. Většina moderních softwarů dokáže prvky vnitřní orientace získat během autokalibrace z metadat snímků (Uysal et al. 2015).

3.3 Filtrace bodových mračen


Každé bodové mračno obsahuje odlehlé body a šumová data, která nepatří ke snímanému povrchu. Toto je obvykle způsobeno meteorologickými podmínkami v době skenování, kvalitou skenovacího zařízení, nasvícením nebo reflektivitou snímaného objektu a překážkami na scéně. Proto je nutné provést filtraci bodového mračna, aby byla odstraněna falešná a nepřesná měření a zůstalo pouze mračno bodů vhodné ke dalšímu zpracování či analýze. V minulých desetiletích bylo představeno mnoho metod pro filtraci 3D dat, avšak většina těchto metod je zaměřena na filtraci polygonových sítí tzv. mesh. V současnosti existuje i široká řada metod zaměřená přímo na bodová mračna. Níže jsou představeny nejpoužívanější z nich. Podrobnější přehled lze najít v publikacích (Schall et al. 2008, Han et al. 2017).

3.3.1 Filtrace vzdálených bodů

Jako první filtrace, která se obvykle v datech TLS provádí je filtrace bodů vzdálených od skeneru o prahovou hodnotu. Pozemní skenery mají dosah až několik stovek metrů, skenované objekty se však obvykle nacházejí ve vzdálenosti do několika desítek metrů, a vzniká tak mnoho nepotřebných bodů. Rostoucí vzdálenosti od skeneru se taktéž zvyšuje poloměr dopadajícího laserového paprsku a snižuje se přesnost měření. Hraniční vzdálenost pro odstranění bodů nelze jednoznačně definovat, jelikož existuje velké množství skenerů s odlišnými vlastnostmi a záleží také na vlastnostech skenovaného objektu. Teoretický vliv vzdálenosti (r) na nepřesnost měření se dá vyjádřit koeficientem $c_R(r)$ definován rovnicí:

$$c_R(r) = \frac{r_{max}^2 - r^2}{r_{max}^2 - r_{min}^2}$$

Kde r_{min} a r_{max} jsou minimální a maximální vzdálenosti měřitelný laserovým skenerem. Hodnoty koeficientu se pohybují od 0 do 1. Teoretický podíl vzdálenosti na přesnost měření je zobrazen na obr. 14.




Obr. 14: Vliv vzdálenosti na nepřesnost měření (Soudarissanane et. al 2011)

TLS při měření bodů používají sférický souřadný systém. Pro každý bod se do paměti ukládají dva úhly (horizontální úhel φ , vertikální úhel θ) a vzdálenost bodu (r) od skeneru (obr. 15). Počátek souřadnicového systému je ve středu skeneru. Díky tomu, že se jedná o polární souřadnice, není při odstraňování vzdálených bodů nutný žádný přepočítání a odstraní se všechny body, kde hodnota r je větší než definovaná hodnota. Obvyklejším výstupem TLS je bodové mračno o n bodech $[x_i, y_i, z_i]_{i=1\dots n}$ v kartézské soustavě souřadnic (Soudarissanane et al. 2009). Převod ze sférického souřadného systému do kartézské soustavy probíhá podle vzorce:

$$\begin{bmatrix} x_i \\ y_i \\ z_i \end{bmatrix}_{i=1\dots n} = \begin{bmatrix} r_i \cos \varphi_i \cos \theta_i \\ r_i \cos \varphi_i \sin \theta_i \\ r_i \sin \varphi_i \end{bmatrix}_{i=1\dots n}$$

Kde x_i, y_i, z_i jsou souřadnice bodu kartézské soustavy souřadnic, r_i je vzdálenost bodu od skeneru ve sférických souřadnicích, φ_i je horizontální úhel a θ_i je vertikální úhel. Vzdálenost bodu od skeneru se pak vypočte podle vztahu:

$$r_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$$



Obr.15: Vzdálenost, horizontální a vertikální úhel v TLS (Puttonen et al. 2013)


3.3.2 Filtrace na základě úhlu dopadu

Další vlastnost, která ovlivňuje přesnost bodů zaznamenaných pomocí laserového skenování, je úhel dopadu laserového paprsku. Pokud je úhel dopadu na povrch objektu příliš velký, sníží se intenzita odraženého laserového paprsku a může dojít ke nesprávnému určení polohy bodu. V ideálním případě je měření povrch kolmý k laserovému paprsku. Toto však není obvykle možné, a proto je nutné odstranit body s velkým úhlem dopadu. Vektor $P = [x_i, y_i, z_i]_{i=1..n}$ je definován jako vektor laserového paprsku z laserového skeneru na povrch objektu ve směru emitovaného laserového paprsku (Obr. 17). Úhel dopadu α je definován jako úhel mezi vektorem laserového paprsku P a normálovým vektorem povrchu N (Soudarissanane et. al 2009). Úhel α se pak určí podle vztahu:

$$\alpha = \cos^{-1}\left(\frac{P \cdot N}{|PN|}\right)$$

Teoretický graf vlivu úhlu dopadu na přesnost měření je zobrazen na obr. 16. Vliv úhlu dopadu se vyjadřuje jako koeficient $c_I(\alpha)$ s hodnotami od 0 do 1 a vypočítá se podle vzorce:

$$c_I(\alpha) = \cos \alpha$$




Obr. 16: Vliv úhlu dopadu na nepřesnost měření (Soudarissanane et. al 2011)

Znalost normálového vektoru umožňuje vypočet nejen úhlu dopadu, ale i hodnoty odchylek (e_p) pro každý bod v bodovém mračnu od měřeného povrchu ve směru měření. Zbytkový vektor odchylek se pak vypočte jako:

$$e_d = e_p c_I(\alpha) c_r(r)$$

Vektor e_d reprezentuje kolmou vzdálenost měřeného bodu od měřené roviny (Soudarissanane et. al 2011).

Důležitá informace, je intenzita odrazu laserového paprsku. Intenzita odrazu je závislá na několika faktorech. Dva nejdůležitější faktory, které ovlivňují intenzitu jsou vzdálenost povrchu od laserového skeneru a úhel dopadajícího paprsku. Tyto faktory mají největší vliv na množství odražené energie. Mezi další faktory patří vnitřní vlastnosti laserového skeneru, vlastnosti materiálu zkoumaného objektu, citlivost aparatury, atmosférické podmínky a šířka laserového paprsku. V praxi však většina těchto informací není známa a jsou zanedbávány. Odstraní se pouze body s malou hodnotou intenzity (Soudarissanane et. al 2009).



Obr.17: Schematická ilustrace dopadajícího paprsku (Soudarissanane et al. 2009)
 (a) Úhel mezi dopadajícím paprskem a normálovým vektorem
 (b) Tvar dopadu a reflektovaný signál laserového paprsku v kolmém a šikmém směru

3.3.3 Filtrace odlehlých a šumových bodů

Jednou z nejčastějších metod pro odstranění odlehlých bodů z bodového mračka je metoda *Statistical Outlier Removal* (SOR). Tato metoda odstraní body, které jsou od svých sousedních bodů vzdálenější, než je průměrná vzdálenost bodového mračka. Metoda má celkem dva parametry. První parametr je počet sousedních bodů. Tento parametr určuje, z kolika sousedních bodů je spočítána průměrná hodnota vzdálenosti pro daný bod. Druhým parametrem je směrodatná odchylka. Tento parametr umožňuje nastavení prahové hodnoty na základě směrodatné odchylky z průměrné vzdálenosti celého bodového mračka. Čím je tato hodnota menší, tím je filtr agresivnější (Rusu at al. 2008). Druhou často používanou metodou je *Radius Outlier Removal* (ROR). Tato metoda odstraní body, které mají ve svém okolí méně bodů, než je definovaná hodnota. Tato metoda má

také dva parametry. První parametr je počet bodů, které se v okolí bodů musí nacházet, aby bod nebyl vymazán. Druhý parametr je rádius, který určuje velikost okolí bodu, ve kterém se stanoví počet bodů musí nacházet (Dung a Lee 2015). Další možností je metoda *Voxel grid filter* (VGF), která rozdělí celé bodové mračno na voxely (3D kostky ve 3D prostoru). Velikost těchto voxelů definuje uživatel. Poté jsou všechny body uvnitř každého voxelu aproximovány do jediného bodu. Obvykle se jedná buď o průměr všech bodů uvnitř voxelu, nebo o samotný střed voxelu. Nevýhoda této je, že nezachovává původní souřadnice bodů (Han et al. 2017).

3.3.4 Vzorkování bodových mračen

Hustota bodového mračna ovlivňuje míru detailu, s jakou je daný objekt zaznamenán. Množství změřených bodů je možné omezit již při skenování s nastavením vhodných parametrů skenování, případně nastavením nižší kvality při tvorbě bodového mračna ze snímků. Během postprocessingu je možné snížit hustotu bodového mračna pomocí vzorkování. Toto se používá zejména v případech, kdy hustota bodového mračna je vyšší než potřebná. Nejjednodušší metodou vzorkování je uniformní vzorkování, kde je vybrán náhodný vzorek bodů z celého bodového mračna. Počet bodů ve vzorkovaném mračnu se určí podle vztahu:

$$M_v = n * M_c$$

Kde M_v je nový počet bodů, M_c je počet bodů v původním mračnu a n je koeficient vzorkování. Další metoda vzorkování je lineární výběr bodů, kde se vybere každý n -tý bod z původního bodového mračna. Tato metody má obvykle velice podobné výsledky jako uniformní vzorkování.

Pravděpodobně nepoužívanější metoda vzorkování, která se takřka nachází ve všech programech pro práci s bodovými mračny je metoda minimální vzdálenosti mezi body. Uživatel na začátku vybere minimální vzdálenost, kterou musí body mezi sebou mít, poté je prohledáváno okolí každého bodu o definované velikosti, pokud se v tomto okolí nachází nějaké body, jsou vymazány z bodového mračna. Jedná se o velice jednoduchou a efektivní metodu vzorkování. Vychází se z předpokladu, že na celé ploše objektu se nachází dostatečný počet bodů. Pokud je však hustota bodů v nějaké části objektu nižší, nedojde k odstranění žádných bodů.

Další metoda je především zaměřena na data laserového skenování. Jedná se o metodu vyrovnání histogramu. Na začátku jsou všechny body rozdělené do tříd podle vzdálenosti od skeneru. Metoda pracuje s předpokladem, že všechny části mračna obsahují potřebné informace nezávisle na počtu bodů. Naopak předpokládá, že části, kde se nachází velké množství bodů obsahují přebytečné množství bodů a odstraněním části bodů se neztratí žádná důležitá informace. Výsledkem vzorkování je bodové mračno, které ve všech vzdálenostech má stejný počet bodů (Puttonen et al. 2013).

3.4 Segmentace bodových mračen

Segmentace bodových mračen je základem pro identifikaci objektů z bodového mračna. Pro úspěšné odstranění vegetace z bodového mračna, je nutné ji nejprve identifikovat. Současné segmentační přístupy lze rozdělit do čtyř základních skupin – na klastrovací algoritmy, model fitting algoritmy, algoritmy na bázi růstu oblastí a ostatní algoritmy. Existuje velké množství těchto algoritmů a jejich modifikací. Níže jsou popsány základní principy fungování nejpoužívanějších algoritmů.

3.4.1 Klastrovací algoritmy

Hlavním cílem klastrovacích algoritmů je rozdělení bodů do různých skupin na základě jejich atributů. Atributem bodu může být jakákoliv jeho vlastnost, například souřadnice nebo barva. Bod je poté umístěn do n -rozměrného prostoru a následně jsou měřeny vzdálenosti mezi jednotlivými body. Počet dimenzí prostoru odpovídá počtu atributů bodu. Pokud je vzdálenost body menší než prahová hodnota, kterou obvykle volí operátor, je bod zařazen do stejného klastru. V opačném případě bod patří do jiného klastru nebo se jedná o šum (Wang et al. 2019).

3.4.1.1 *K-means*

Jedním z nejpoužívanějších a hojně využívaný je algoritmus *K-means*. Princip algoritmu je velice jednoduchý. *K-means* je metoda, která přiřazuje body k nejbližšímu středu. Na začátku procesu jsou umístěny centroidy do n -rozměrného prostoru. Centroidy jsou středy jednotlivých klastrů a jejich počet volí operátor. Tyto středy jsou v první iteraci umístěny náhodně. Poté je vypočtena vzdálenost bodů od všech centroidů a bod je přiřazen k tomu centroidu, ke kterému má nejkratší vzdálenost. Všechny body náležící k jednomu centroidu tvoří společně jeden klastr. Po přiřazení všech bodů jsou vypočteny nové středy, které leží

uprostřed vytvořených klastrů. Opět se opakuje výpočet vzdáleností bodů a body jsou přerozděleny do nových klastrů. Tento proces se opakuje do doby, kdy žádný bod nemění své přiřazení ke klastru (Jain 2010). Výhodou tohoto algoritmu je v jeho jednoduchosti a rychlosti. Nevýhodou je, že musí být předem zvolit počet klastrů. Výsledek také může ovlivnit prvotní výběr centroidů.

3.4.1.2 DBSCAN


Další metodou klastrování je metoda DBSCAN. Název metody je zkratka anglického výrazu *Density-Based Spatial Clustering of Applications with noise*, což můžeme volně přeložit jako prostorové klastrování na základě hustoty s přítomností šumu. Jak už název napovídá, algoritmus seskupuje body do shluku na základě hustoty jejich výskytu. DBSCAN má dva základní parametry a to:

- Epsilon (ϵ) – rádius okolí bodu
- minPts – minimální počet bodů

Algoritmus rozděluje body do tří skupin na:

- Jádrové body – Jádrový bod je každý bod, který ve svém ϵ -okolí má stejně nebo více bodů než hodnota minPts
- Hraniční body – Hraniční bod je každý bod, který ve svém okolí nemá dostatečný počet minPts, ale je dosažitelný z alespoň jednoho jádrového bodu.
- Šumové body – Za šum je označen každý bod, který nemá ve svém ϵ -okolí minimální počet minPts a zároveň není dosažitelný z žádného jádrového bodu.

Princip DBSCAN algoritmu je ukázán na obr. 18. Všechny červené body představují jádrové body, všechny žluté body představují body hraniční a bod modrý je šum. Každý klastr musí obsahovat minimálně jeden jádrový bod. Všechny body, které jsou přímo či nepřímo dosažitelné z jádrového bodu, patří do stejného klastru. Body B a C patří do stejného klastru, ale tvoří jeho hranici, jelikož nemohou dále rozšiřovat klastr. Každý klastr musí splňovat dvě podmínky. První podmínkou je, že všechny body v klastru musí být propojitelné. Druhá podmínka předpokládá, že všechny body dosažitelné z jakéhokoliv bodu v klastru jsou součástí klastru.



Obr. 18: Princip DBSCAN algoritmu (Schubert et al. 2017)

Výhoda DBSCAN algoritmu spočívá v tom, že se na začátku nemusí definovat přesný počet klastrů. Algoritmus lze využít i pro složitější tvary. DBSCAN také umí označit body, které představují šum v datech. Nevýhoda algoritmu je, že hraniční body mohou patřit do dvou klastrů zároveň. Další nevýhodou je, že algoritmus je velice citlivý na nastavené hodnoty ϵ a minPts . Pokud jsou v datech velké rozdíly v hustotě bodů, nelze najít jejich optimální nastavení (Schubert et al. 2017).


3.4.2 Model fitting algoritmy

Algoritmy na bázi model fitting přístupu se rozdělují do dvou kategorií, na algoritmy pracujících na základě *Random Sample Consensus* (RANSAC) a kategorie využívající Houghovy transformace. U těchto metod musí uživatel předem vědět, jaké typy objektů vyhledává. Obvyklé se jedná o přímky či kruhy, ve 3D pak například válec či koule. Výhodou těchto metod je jejich robustnost pro segmentaci bodových mračen. Obě metody jsou také odolné vůči šumu. Nevýhodou může být, že metody nelze použít, pokud má hledaný objekt komplexnější geometrii (Wang et al. 2019).

3.4.2.1 RANSAC

Jméno metody RANSAC můžeme přeložit jako konsenzus náhodných vzorků. Jedná se o hojně využívanou metodu pro hledání křivek v obraze, ale metodu lze použít i ve 3D. Jedná se o iterativní metodu, která pracuje na principu náhodného vybírání minimálního počtu bodů pro vyhledání daného tvaru a vybere nejlépe vyhovující model. Princip metody je

ukázán na obr.19. V prvním kroku se náhodně vybere minimální počet bodů k určení parametrů modelu. Na obrázku se jedná o žluté body. V druhém kroku jsou vybrány parametry modelu na základě vybraných bodů. Následně se vypočtou vzdálenosti všech bodů od vytvořeného modelu. Pokud je vzdálenost bodu od modelu menší než předem definovaná hodnota ϵ , je bod označen jako *inliere*, v opačném případě je bod označen jako *outlier*. Do paměti se uloží celkový počet *inlieres* pro daný model. Celý proces se opakuje pro další náhodně vybrané body. Počet iterací je určen operátorem. Jako správný model je zvolen model s největším počtem *inlieres*. Pokud není snahou najít nejlepší řešení, ale pouze řešení, které by splnilo minimální požadavky, je možné využít prahové hodnoty. Pokud bude prahová hodnota v modelu dosažena, je výpočet ukončen a model označen jako správné řešení.



Obr. 19: Princip metody RANSAC (Collins 2020)

Důležitým aspektem pro úspěšné nalezení správného výsledku metodou RANSAC je počet iterací. Který se vypočte pomocí vzorce:

$$N = \frac{\log(1 - p)}{\log(1 - (1 - v)^m)}$$

kde p je pravděpodobnost úspěšného nalezení výsledku, v je pravděpodobnost, že jakýkoliv vybraný bod je *outlier* a m označuje minimální počet bodů pro sestavení modelu. Jelikož se jedná o náhodné vzorky, může být výsledek metody pokaždé jiný (Derpanis 2010).

3.4.2.2 Houghova Transformace


Druhý algoritmus z kategorie model fitting algoritmu je Houghova transformace. Jedná se o techniku, která slouží pro hledání struktur v obraze – obvykle se jedná o přímky či kružnice. Ačkoli se jedná o metodu, která pracuje obvykle s 2D objekty, je možné ji využít i pro 3D objekty (Borrmann et al. 2011). Algoritmus vyžaduje, aby rovnice hledaného objektu byla definována v parametrickém tvaru, proto se obvykle používá pro tvary, jejichž parametrický tvar rovnice je dobře znám. Algoritmus pracuje na principu hrubé síly, kdy v obraze prochází každý pixel, což může být časově a výpočetně velice náročné. Proto je obvykle obraz ještě před samotným spuštěním algoritmu zpracován detektorem hran. Toto zajišťuje, že algoritmus nemusí procházet všechny pixely, ale pouze ty, které jsou považovány za hrany. Tím se zvyšuje celková šance na úspěšné detekování objektu a snižuje se výpočetní náročnost. Princip Houghovy transformace lze vysvětlit na příkladu hledání přímky v obraze (obr. 20 a). Parametrické vyjádření přímky je:

$$Y = A * X + B$$

Toto vyjádření se nehodí pro případy, kdy je přímka rovnoběžná s osou Y. V takovém případě je A nekonečno. Proto se obvykle používá tvar:

$$r = x * \cos\varphi + y * \sin\varphi$$

Kde r je vzdálenost počátku souřadnic od nejbližšího bodu na přímce a φ je úhel mezi osou a přímkou spojující počátek a nejbližší bod na přímce (obr. 20 b). Pro přímku procházející body A, B a C existuje pouze jedno správné řešení parametrů φ a r .



Obr. 20: Princip Houghovy transformace pro přímku (Vlach 2011)

Houghova transformace pro určení parametrů používá takzvaný akumulátor. Rozměry akumulátoru se rovnají počtu parametrů hledaného objektu. V případě přímky jsou hledané parametry dva - φ a r . To znamená, že akumulátor bude dvojrozměrný graf, kde jednu osu tvoří r a druhou osu φ . Akumulátor je pole o velikosti $M \times N$. Obvykle se velikost

akumulátoru rovná velikosti původního snímku. Na začátku mají všechna políčka v akumulátoru hodnotu nula. Pro každý pixel v původním obraze se do rovnice $r = x * \cos \varphi + y * \sin \varphi$ dosadí jeho souřadnice x a y . Poté se postupně dosazují různé úhly φ v rozpětí nula až π s předem určeným krokem a vypočítají se hodnoty r . V akumulátoru se na pozici vypočítaného r a odpovídajícího úhlu φ přičte hodnota 1. Poté, co se tento postup provede pro všechny body, se v akumulátoru vybere políčko na souřadnicích r a φ , které má nejvyšší hodnotu. Souřadnice r a φ tvoří parametry hledané přímky.

Princip hledání kružnic v obraze je podobný jako u přímek. Parametrické vyjádření kružnice je:

$$r^2 = (x - a)^2 + (y - b)^2$$

kde a , b jsou souřadnice středu kružnice a r je její poloměr. Na rozdíl od přímky má kružnice tři parametry. Z toho vyplývá, že akumulátor pro kružnici musí být trojrozměrný. Aby se snížila časová a paměťová náročnost, omezuje se horní a dolní hranice poloměru. Pro každý pixel v obraze se do výše zmíněné rovnice dosadí jeho souřadnice x a y . Poté se do rovnice dosadí všechny možné dva parametry a lze vypočítat třetí parametr. Za předpokladu, že nejsou omezeny maximální a minimální hodnoty poloměru, v trojrozměrném akumulátoru vznikne kužel pro každý bod. Správným řešením jsou souřadnice a , b a r v trojrozměrném akumulátoru, kde hodnota políčka akumulátoru je nevyšší (Vlach 2011).

3.4.3 Algoritmy na bázi růstu oblastí

Další alternativou pro segmentaci bodových mračen jsou algoritmy na bázi růstu oblastí. Tyto metody jsou založeny na procesu růstu zevnitř-ven pro nalezení homogenních segmentů. Na začátku je náhodně vybrán jádrový bod nebo region. Obvykle jsou preferovány body nebo regiony, s nejmenším zakřivením jako jádrové. Poté jsou prozkoumávány body v okolí jádra, zdali splňují kritéria k přiřazení k jádrovému bodu. Nejčastější kritéria pro růst jsou orientace normálových vektorů a vzdálenost bodů. Pro lepší efektivitu jsou často jako základní jednotka růstu používány voxely místo bodů. Algoritmy na bázi růstu dobře zachovávají hranice oblastí. Algoritmy na bázi růstu jsou často používány pro segmentaci bodových mračen pro jejich jednoduchou implementaci. Nevýhodou je však jejich malá robustnost. Kvalita segmentace je silně závislá na výběru kritérií jádrových bodů/regionů a růstu, přičemž neexistují žádná univerzální kritéria výběru (Vo et al. 2015).

4 Použitá metodika

Praktická část je rozdělena na tři části. První část se zabývá sběrem dat. Pro sběr dat jsou použity metody pozemního laserového skenování, pozemní fotogrammetrie a UAV. Druhá část je zaměřena na vlastní zpracování dat. Pro zpracování laserových dat je použit program Leica Cyclone a pro fotogrammetrické metody je využit program Agisoft Metashape. Součástí je i vysvětlení jednotlivých použitých funkcí pro tvorbu bodového mračna. V poslední části je použita nejprve preprocessing filtrace, kde jsou z bodových mračen odstraněna nepřesná měření, a následně je provedena samotná filtrace vegetace. Bodová mračna z jednotlivých metod jsou zpracovávána zvlášť. Jako první jsou odstraněny body, které jsou vzdálenější od skeneru než určená hodnota. Následně je u všech bodových mračen snížena hustota bodů pro snížení výpočetní náročnosti. Tento krok je také důležitý pro následné klastrování, aby nevznikaly menší klastry uvnitř větších. Hustota bodů v jednotlivých částech bodového mračna může být různá, ale je tu předpoklad, že na povrchu skály existuje přebytečné množství bodů, je pro snížení hustoty použita minimální vzdálenost, kterou musí body mezi sebou mít. Tento krok zajistí, že v oblastech, kde je bodové mračno řídké, se vymaže méně bodů než v oblastech, kde je bodů více. Dále jsou z laserových dat odstraněny body, které mají malou intenzitu odrazu. Následně jsou ze všech mračen odstraněny osamocené body pomocí SOR a ROR filtrů, které jsou popsány v kapitole filtrace dat. Další speciální filtr, který lze použít pouze pro data z laserového skenování, je filtr pro odstranění bodů, které mají velký úhel dopadu.

Po preprocessing filtraci jsou mračna bodů dále filtrována. Jako první jsou odstraněny body náležící k zelené části vegetace. K tomuto úkonu byl vybrán index ExG, který rozdělí body náležící k zelené části vegetace od ostatních. Následně jsou všechna bodová mračna klastrována pomocí algoritmu DBSCAN podle hustoty výskytu bodů. Pracuje se zde s předpokladem, že samotná skála bude tvořit jeden nebo několik velkých klastrů. Po klastrování se v bodovém mračnu zachová pouze určité procento největších klastrů. Cílem je tedy odstranění menších klastrů, které jsou tvořeny například větvemi stromů. Následně je celé mračno rozděleno na grid o definované velikosti, u kterého je v každé mřížce segmentováno mračno ve výšce 1,3 až 1,4 metru od nejnižšího bodu v mřížce gridu. Vytvoří se tak řez v bodovém mračnu, který je převeden na 2D snímek a v němž jsou vyhledávány kruhové objekty (kmeny stromů) pomocí Houghovy transformace. Tento způsob

identifikace kmenů používají ve své práci například Aschoff a Spiecker (2004), kteří používají metodu v rovinném terénu s malým množstvím nízké vegetace. Účelem tohoto kroku je otestování metody i pro složitější terény.

4.1 Zkoumaný objekt

Zájmovým objektem je skalní útvar, který se nachází v národním parku České Švýcarsko (obr 20). Území NP patří do geomorfologického celku Děčínské vrchoviny. Celé území národního parku je silně zalesněné. Výška zkoumaného skalního útvaru je přibližně 25 metrů. Útvar se nachází v západní části národního parku, kde sousedí NP s chráněnou krajinou oblastí Labské pískovce. Skála také stojí na pomezí hranice národního parku a silnice I/62, která začíná v Ústí nad Labem a vede přes údolí Labe směrem na Drážďany na GPS souřadnicích 50.8771964N, 14.2374958E. Právě pro tuto silnici představuje skála potenciální nebezpečí. Sesuvy a řícení skal jsou běžnými úkazy, a proto jsou také na levé straně skály instalované záchytné kovové sítě, které v případě utržení části skály sníží riziko pádu do silnice. Dále jsou zde instalovány také kotevní lana pro zpevnění skalních bloků. Pískovcová skála se také nachází v bezprostřední blízkosti řeky Labe, kde společně s okolními skalními útvary tvoří takzvaný Labský pískovcový kaňon, který je nejmohutnějším pískovcovým kaňonem v Evropě.



Obr. 21: Pozice skenovaného objektu v NP České Švýcarsko (zdroj dat: AOPK ČR 2020)

Na obr. 22 je vidět pravá strana skály, kde se nachází velké množství vegetace. Právě tato vegetace, v kombinaci s prudkým svahem komplikují podrobné mapování této skály.



Obr. 22: Pravá strana skály

Levá část skály je více přístupna, alespoň v zimních měsících, protože zde rostou převážně opadavé stromy (obr. 21).



Obr. 23: Levá strana skály

4.2 Sběr dat

Sběr dat pomocí pozemního laserového skenování, pozemní fotogrammetrie proběhl dne 29. března 2019. tento den taktéž proběhlo geodetické zaměření. Na místě skenování celý předchozí den pršelo. V den samotného skenování byla proměnlivá oblačnost, po krátkých intervalech byla scéna přesvícena slunečním zářením. V době pořizování dat také vanul poměrně silný vítr. Jelikož bylo potřeba pořídit laserová data, detailní snímky skály a provést geodetické měření skály pomocí totální stanice, sběr dat probíhal současně všemi metodami. Sběr dat pomocí UAV bylo provedeno externí firmou dne 16. dubna 2019.

4.2.1 Vlastní laserové skenování

Laserové skenování bylo provedeno pomocí přístroje FARO focus3D-X130 laser scanner (obr. 24), který dokáže zaznamenat až 976 tisíc bodů za sekundu v závislosti na zvoleném rozlišení. Skener k měření vzdálenosti používá metodu fázového posunu. Laserový skener má velké množství možností nastavení. Nejdůležitějším nastavením je rozlišení, které udává počet zaznamenaných bodů skenerem. Při plném rozlišení 1/1 dokáže skener zaznamenat až 710,7 milionu bodů v jednom skenu. Vzdálenost mezi body v plném rozlišení je přibližně 1,5 milimetru do vzdálenosti deseti metrů. Druhé důležité nastavení je kvalita, která udává počet opakovaných měření stejného bodu. Při skenování v plném rozlišení je možné provést až čtyři měření stejného bodu, celková doba takového skenu je 115 minut. Při sníženém rozlišení je možné měření opakovat až osmkrát. Dále je také možné omezit horizontální a vertikální úhly skenování, a tím snížit výslednou velikost skenu. Skener taktéž umožňuje barevné skenování, u něhož kromě měření vzdáleností skener také pořizuje barevné snímky a každému bodu jsou přiřazeny barevné hodnoty R,G,B(Faro 2015).



Obr. 24: Laserový skener FARO Focus3D-X130 (Faro 2015)

Ještě před samotným skenováním byla vytipována místa pro umístění referenčních terčů. K dispozici bylo pouze šest terčů, jejichž správné rozmístění bylo pro celý proces velice důležité. Jako referenční terče byly použity sférické terče o průměru 200 milimetrů. Terče by měly být z místa skenování vidět celé a neměly by být částečně zakryté. Jelikož je okolí skály zejména v její horní části hustě zarostlé vegetací, bylo umístění velice obtížné. Terče byly rozdělené do dvou skupin – fixní a přenosné. Fixní terče zůstaly po celou dobu skenování na stejném místě. Do této skupiny patřily čtyři terče, které bylo možné naskenovat současně z horní i dolní strany skály. Tím bylo zajištěno, že jednotlivé skeny budou patřit do uzavřeného polygonu. Dva z těchto terčů byly umístěny do horní části skály a dva do dolní části (obr. 25). Druhá skupina terčů byla přesouvána podle potřeb. Tato skupina sloužila pro jednotlivá propojení s dalšími skeny. Jelikož takto malé množství terčů nestačí pro celou oblast skály, byly na skálu umístěny signalizované body (bílé kříže). To umožnilo při registraci kombinovat metody registrace pomocí terčů a „cloud to cloud“. Tyto kříže byly také zaměřeny pomocí totální stanice a některé z nich byly použity pro georeferencování.



Obr. 25: Umístění sférických terčů

Po umístění terčů bylo provedeno skenování. Nejprve bylo nutné nastavit správné parametry skenování. Jelikož skenování probíhalo kolem skály, nebylo nutné skenovat v plném rozsahu 360°. Proto byl, kromě u dvou skenů, vertikální úhel skenování snížen na 180°. Současně však bylo nutné skener vždy před spuštěním správně orientovat. Pro dva skeny v horní části byl nastaven rozsah na plných 360°, protože jejich plocha překryvu byla z důvodu výskytu husté vegetace velice malá. Celkem bylo provedeno dvanáct skenů a jejich rozmístění je vidět na obr. 26.



Obr. 26: Pozice skeneru

Skála se nachází v těsné blízkosti silnice, kde probíhal normální provoz, a tak nebylo možné umístit skener do ideální pozice. První tři skeny proběhly z chodníku u řeky, protože pokud by byl skener umístěn na chodníku blíže ke skále, úhel dopadajících paprsků na vrchní část skály by byl moc velký. Z důvodu větší vzdálenosti od skály bylo použito rozlišení 1/2 pro zachování dostatečné hustoty bodů. Základní nastavení skeneru při jednotlivých skenech se nachází v tab. 1. Uvedená nastavení byla vybrána tak, aby rozestupy mezi body na ploše skály nepřesáhly pěti milimetrů. Skála se nachází v prudkém svahu, a tak nebylo možné skener bezpečně umístit po jejích stranách, a proto množství skenů je menší, než se původně předpokládalo.

Číslo skenu	Rozlišení	Kvalita	Horizontální úhel [°]	Čas skenu[min]
1	1/2	3	180	14:19
2	1/2	3	180	14:19
3	1/2	3	180	14:19
4	1/4	3	180	3:35
5	1/4	2	180	1:47
6	1/4	3	180	3:35
7	1/5	3	360	2:17
8	1/5	3	360	2:17
9	1/5	3	360	2:17
10	1/2	2	180	7:09
11	1/4	2	180	1:47
12	1	2	180	28:38

Tab. 1: Parametry skenování

4.2.2 Pozemní snímkování

Pro pořízení pozemních snímků byl použit fotoaparát Nikon D750 s objektivem AF-S 24-120 f/4G (obr. 27). Jedná se o digitální zrcadlovku s obrazovým snímačem obsahujícím 24,3 milionu pixelů. Objektiv AF-S 24-120 f/4G má maximální ohniskovou vzdálenost 120 milimetrů, druhá krajní poloha objektivu je 24 milimetrů (Nikon 2014).




Obr. 27: Fotoaparát Nikon D750 (Nikon 2014)

Při fotogrammetrickém snímkování je nutné nastavení několika parametrů fotoaparátu pro dosažení optimální kvality. První parametr se nazývá expoziční čas. Jedná se o dobu, po kterou je závěrka fotoaparátu otevřena a umožňuje dopadání světla na senzory fotoaparátu. Při delších expozičních časech může dojít k rozmazání snímků kvůli pohybu. Druhý z těchto parametrů je hodnota ISO, která určuje citlivost senzorů na světlo ve fotoaparátu. Obecně platí že, se zvýšením hodnoty ISO lze zkrátit expoziční čas za stejných světelných podmínek, avšak čím vyšší hodnota ISO, tím více šumu se ve snímku objeví. Třetím parametrem je clona, která reguluje množství světla procházející objektivem fotoaparátu. Fotoaparát Nikon D750 nabízí několik režimů snímkování (obr. 28). Každá z těchto možností nabízí různé stupně kontroly nad fotoaparátem. Režim programová automatika (P) je určený pro rychlé snímkování, kdy program automaticky nastavuje čas závěrky a clonu pro optimální expozici. Při režimu clonová automatika (S) uživatel nastavuje čas závěrky a fotoaparát nastavuje clonu. Režim časová automatika (A) je opak režimu S, uživatel volí clonu a fotoaparát nastavuje čas závěrky pro dosažení optimální expozice. V manuálním režimu (M) všechna nastavení provádí uživatel (Nikon 2015).

	Clona	Čas závěrky	Citlivost ISO (□□ 322)	Korekce expozice	Měření expozice
P, S	—	—	—	✓	✓
A	✓	—	—	✓	✓
M	✓	✓	✓	—	✓
SCENE, □□	—	—	—	✓	—
Ostatní provozní režimy	—	—	—	—	—

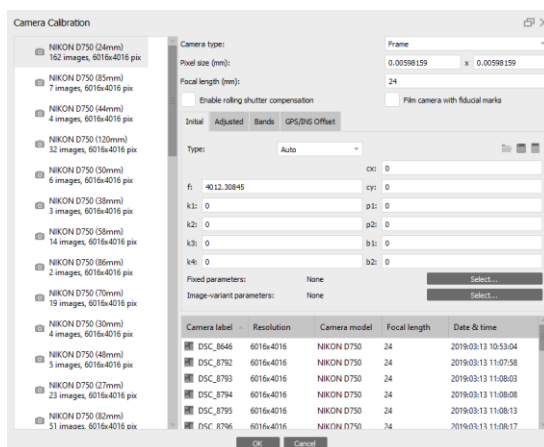
Obr. 28: Režimy nastavení fotoaparátu (Nikon 2014)

Při fotogrammetrickém snímkování je doporučováno snímkování v manuálním režimu pro maximální kontrolu výsledných snímků. Obecně se doporučuje nepřekračovat hodnotu ISO 400. Expoziční čas by měl být co možná nejkratší, aby nedocházelo k rozmazání snímků kvůli jemným pohybům. Měla by být zvolena dostatečně velké clonové číslo pro dostatečnou hloubku snímků. Dále je také doporučováno používání objektivu s ohniskovou vzdáleností mezi 20 a 80 mm. Pokud jsou použity zoom objektivy, je doporučováno snímkování v jedné z krajní pozic. Při snímkování je doporučováno vytvořit více snímků, než je potřeba. Tímto se předchází vytváření slepých míst v modelu. Polohy pořízených snímků si lze prohlédnout na obr. 29. Na obrázku je vidět, že snímkování probíhalo kolem celé skály, avšak většina snímků byla pořízena z dolní části. Toto je pochopitelné kvůli tvaru zájmové skály a husté vegetace.



Obr. 29: Poloha pořízených snímků

Snímkování probíhalo v režimu programová automatika. Při snímkování byla použita hodnota ISO 2000. Délka expozice se pohybovala mezi 1/40 až 1/1600 s. Velikost clony se pohybovala mezi f/5 až f/14. Z důvodu husté vegetace se měnila jak vzdálenost snímkování, tak i ohnisková vzdálenost. Celkem bylo pořízeno 40 různých ohniskových vzdáleností (obr. 30). Tyto faktory mohou ovlivnit nejenom výslednou kvalitu modelů, ale také kvalitu orientace snímků. Celkem bylo pořízeno 722 snímků. Při snímkování byl kladen důraz hlavně na pořízení co největšího množství snímků s předpokladem, že nevhodné snímky se později vytřídí a nevstoupí do samotné tvorby modelu.



Obr. 30: Kalibrační dialog programu Metashape

4.2.3 UAV snímkování

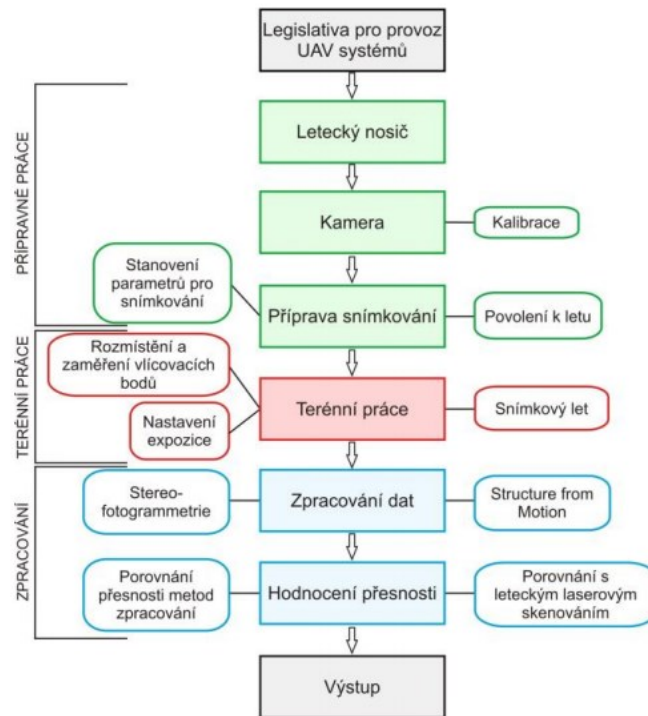
Pořízení snímků z UAV bylo provedeno kvadrokoptérou DJI Phantom 4 PRO (obr. 31). Jedná se o středně velký UAV přístroj se zabudovaným GPS/GNSS zařízením, díky kterému je možné určit polohu kamery pro každý snímek v době pořízení snímku. Phantom 4 PRO má v sobě zabudovaný 20megapixelový fotoaparát s rozměry 5472 x 3648 se zabudovaným objektivem s měnitelnou ohniskovou vzdáleností 9–24 milimetrů. Maximální výška letu je 500 metrů (DJI 2020).




Obr. 31: UAV DJI Phantom 4 PRO (DJI 2020)

Dle Miřijovského (2013) lze koncept nasazení UAV systému rozdělit do tří fází (Obr. 32). První fází jsou přípravné práce, kde se provádí kalibrace kamery, získání povolení k letu a přípravy letového plánu. V druhé fázi se provádí rozmístování vlíčovacích bodů, nastavení kamery a samotné snímkování. Poslední fáze je zaměřena na zpracování snímků a hodnocení přesnosti. V této práci byly první dvě fáze procesu provedeny externí firmou a byl požadavek, aby prostorová rozlišovací schopnost jednoho pixelu byla 1 cm. Snímkování se provádělo ohniskovou vzdáleností 24 mm. Hodnota ISO byla nastavena na 200. Délka expozice byla 1/400 s. Velikost clony se pohybovala mezi hodnotami f/4 a f/5.6. Na začátku bylo provedeno kolmé snímkování přibližně ve výšce 60 m. Celkem bylo pořízeno 150

snímků v pěti řadách. Zbývajících 406 snímků bylo pořízeno v šikmé poloze ve třech obloucích v přibližných výškách 45, 35 a 20 metrů (obr. 33). celkem bylo pořízeno 556 snímků.



Obr. 32: Základní koncept nasazení UAV systému (Miřijovský 2013)



Obr. 33: Poloha pořízených snímků z UAV

4.2.4 Geodetické zaměření

Pro měření podrobných bodů byla použita totální stanice Trimble M3 5" (Obr. 34). Měřický dosah tohoto přístroje je bez hranolu až 300 m a při měření s hranolem až 5000 m. Doba měření na hranol v přísném režimu je 1,5 s a bez hranolu 1,8 s. V normálním režimu je doba měření 0,8 s s hranolem a 1,0 s bez hranolu. Přesnost měření úhlů je 5". Přístroj obsahuje dálkoměr DR s přesností $\pm 2 \text{ mm} + 2 \text{ ppm}$. Pro zaměření bodů bodového pole byl použit GNSS přístroj Trimble R10. Přístroj umožňuje měření metodou Real-time kinematic (RTK). Přesnost měření polohy metodou RTK je $\pm 8 \text{ mm} + 1 \text{ ppm}$ a ve výšce $\pm 15 \text{ mm} + 1 \text{ ppm}$ (Geoobchod 2020).




Obr 34: Totální stanice Trimble M3 – 5CC (Vlevo), GNSS Trimble R10 (Vpravo) (Geoobchod 2020)

Nejprve byly pomocí GNSS přístroje určeny souřadnice stanovišek 4001 až 4005. Stanoviško 4006 nebylo možné zaměřit z důvodu husté vegetace. Souřadnice tohoto stanoviška byly určeny pomocí totální stanice. Rozmístění jednotlivých stanovišek je vidět na obr. 35. Bezrozměrný parametr přesnosti polohy (PDOP) pro žádné měření nepřekročil hodnotu 2,96. Protokol měření z GNSS přístroje se nachází v příloze 10. Jako první byla totální stanice zcentrována a horizontována nad bodem 4003 a bylo zaměřeno 34 podrobných a 19 signalizovaných bodů. Poté byl přístroj umístěn nad bodem 4004 a bylo určeno 56 podrobných a 2 signalizované body. Nakonec byl přístroj umístěn na bod 4006 a bylo změřeno 52 podrobných a 6 signalizovaných bodů. Rozložení bodů na ploše skály je vidět na obr. 36. Výpočet bodů probíhal v programu Groma polární metodou. Byl použit souřadnicový systém S-JTSK. Souřadnice bodů a protokol o výpočtu podrobných bodů lze najít v příloze 10.



Obr. 35: Poloha stanovisek




Obr. 36: Podrobné body

4.3 Zpracování dat

4.3.1 Tvorba bodového mračna z laserového skenování

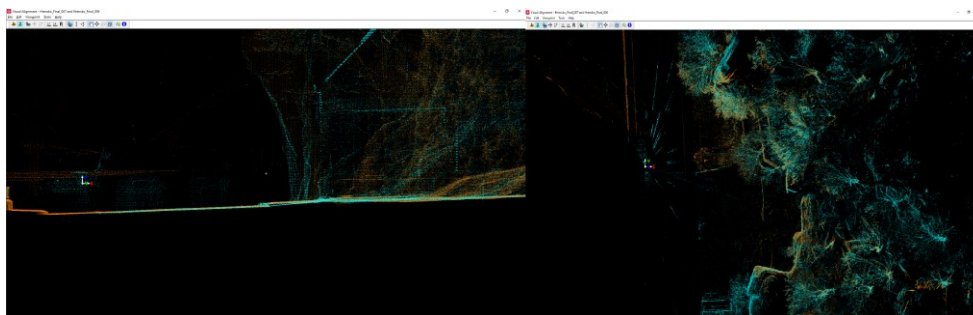
Původně byla data registrována v softwaru Autodesk ReCap. Během skenování však došlo k pohybu referenčních terčů z důvodu silného větru. Registrace následně vykazovala odchylky až několik desítek centimetrů. Z tohoto důvodu byla provedena druhá registrace, pro kterou byl zvolen program Leica Cyclone Register od firmy Leica Geosystems. Jedná se o jeden z nejpokročilejších programů pro zpracovávání pozemních laserových dat. Program nabízí širokou škálu nástrojů pro práci s daty a vyžaduje určitou zkušenost pro dosažení optimálních výsledků. Leica Geosystems nabízí kromě softwarových nástrojů i skenovací zařízení. Jejich softwary a přístroje mají velkou kompatibilitu a umožňují velice efektivně zpracovávat laserová data. Nevýhodou je, že mají uzavřený systém a jejich propojení s produkty od jiných výrobců je komplikované. Nativní formát dat ze skenerů Faro je *FLS*. Ačkoli program Cyclone nabízí možnost importu tohoto formátu, data se z neznámého důvodu nepovedlo importovat. Proto byl jako mezikrok použit program CloudCompare, který nabízí doplněk pro import *FLS* formátu. Jednotlivé skeny byly importovány do programu CloudCompare a byly přeuloženy do formátu *E57*. Tyto skeny bylo možné úspěšně importovat do Cyclonu.

Nejdříve byla založena nová databáze, do které byly importovány všechny skeny. Program vytvoří pro každý sken tzv. *controlspace* a *modelspace*. *Controlspace* je část, kde je uložené nezpracované bodové mračno, které se používá pro registraci. *Modelspace* je část, kde je možné provádět různé operace s bodovým mračnem. Pokud je mračno v *modelspaceu* jakkoli poškozeno, je možné ho vždy obnovit do původního stavu z *controlspaceu*. Na začátku byla provedena vizuální kontrola jednotlivých skenů. Z registrace byly vyloučeny skeny číslo deset a jedenáct, protože většinu jejich bodového mračna tvořila pouze vegetace a jen malé množství tvořila samotná skála, která nepřinášela do registrace žádné nové informace. Na téměř všech skenech se objevil „stín“, který je zvýrazněn na obr. 37. Jedná se o falešná měření způsobená špatnými odrazy laserových paprsků od hladiny řeky. Tyto body komplikovaly registraci, a proto byly manuálně odstraněny.



Obr. 37: Falešná měření

Následně byla vytvořena nová registrace, do které bylo importováno zbývajících deset skenů. Pro každý sken byly vytvořeny alespoň dvě vazby s ostatními skeny. Toto bylo provedeno pomocí nástroje *visual registration* (obr. 38). Tento nástroj umožňuje posun skenů v jednotlivých osách a jejich rotaci pomocí kurzoru myši. Uživatel může skeny ztotožnit podle vizuální kontroly. Tento postup umožňuje velkou kontrolu nad výsledkem registrace, ale nehodí se pro velké množství skenů, jelikož je to časově velice náročné.



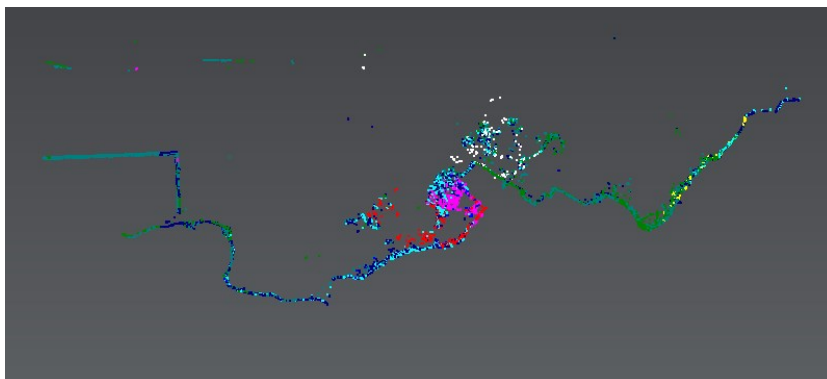
Obr. 38: Nástroj *visual registration*

Po manuálním ztotožnění všech skenů byly vypočteny hodnoty odchylek mezi jednotlivými skeny. Žádná vazba mezi skeny nepřesahovala celkovou chybu 3 mm a směrodatná odchylka pro všechny vazby byla 2 mm (obr. 39).

Constraint ID	ScanWorld	ScanWorld	Type	Status	Weight	Overlap Points	Error
Cloud/Mesh 1	Hrensko_Final_003	Hrensko_Final_005	Cloud/Cloud/Mesh-Cloud...	On	1.0000	588433	0.001 m
Cloud/Mesh 2	Hrensko_Final_003	Hrensko_Final_007	Cloud/Cloud/Mesh-Cloud...	On	1.0000	280833	0.002 m
Cloud/Mesh 13	Hrensko_Final_005	Hrensko_Final_013	Cloud/Cloud/Mesh-Cloud...	On	1.0000	112433	0.001 m
Cloud/Mesh 5	Hrensko_Final_005	Hrensko_Final_006	Cloud/Cloud/Mesh-Cloud...	On	1.0000	495700	0.002 m
Cloud/Mesh 3	Hrensko_Final_005	Hrensko_Final_007	Cloud/Cloud/Mesh-Cloud...	On	1.0000	441233	0.002 m
Cloud/Mesh 4	Hrensko_Final_007	Hrensko_Final_006	Cloud/Cloud/Mesh-Cloud...	On	1.0000	827856	0.001 m
Cloud/Mesh 6	Hrensko_Final_007	Hrensko_Final_009	Cloud/Cloud/Mesh-Cloud...	On	1.0000	220133	0.003 m
Cloud/Mesh 14	Hrensko_Final_008	Hrensko_Final_010	Cloud/Cloud/Mesh-Cloud...	On	1.0000	46233	0.002 m
Cloud/Mesh 7	Hrensko_Final_009	Hrensko_Final_008	Cloud/Cloud/Mesh-Cloud...	On	1.0000	77966	0.002 m
Cloud/Mesh 8	Hrensko_Final_009	Hrensko_Final_010	Cloud/Cloud/Mesh-Cloud...	On	1.0000	246800	0.002 m
Cloud/Mesh 11	Hrensko_Final_010	Hrensko_Final_012	Cloud/Cloud/Mesh-Cloud...	On	1.0000	701600	0.001 m
Cloud/Mesh 9	Hrensko_Final_010	Hrensko_Final_011	Cloud/Cloud/Mesh-Cloud...	On	1.0000	795500	0.001 m
Cloud/Mesh 10	Hrensko_Final_011	Hrensko_Final_012	Cloud/Cloud/Mesh-Cloud...	On	1.0000	803866	0.001 m
Cloud/Mesh 12	Hrensko_Final_011	Hrensko_Final_013	Cloud/Cloud/Mesh-Cloud...	On	1.0000	107600	0.003 m


Obr. 39: Výsledky registrace

Číselné výsledky však nemusí vždy znamenat správnou registraci, protože jsou porovnávány blízké body a nemusí se jednat o body správné. Proto byly provedeny horizontální a vertikální řezy v registrovaném bodovém mračnu. Každému skenu byla přiřazena unikátní barva a byla provedena vizuální kontrola správného ztotožnění všech skenů (obr. 40).



Obr. 40: Řez v bodovém mračnu

Dalším krokem bylo georeferencování bodového mračna. Celkem bylo pro georeferencování použito sedm bodů. Tyto body byly označeny v bodovém mračnu a byly zde vytvořeny vertexy (obr. 41), kterým byly následně určeny nové souřadnice. Celková souřadnicová chyba pro žádný bod nepřesáhla hodnoty 1,5 centimetru a směrodatná odchylka souřadnic byla 1,1 centimetru (obr. 42).




Obr. 41: vlíčovací bod

Constraint ID	ScanWorld	ScanWorld	Type	Status	Weight	Overlap Points	Error
1018	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.003686 m
1017	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.008036 m
1019	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.008581 m
2006	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.012299 m
2004	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.012977 m
1008	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.014454 m
1020	Hrensko_final...	Souradnice.bt...	Coincident: Vertex - Vertex	On	1.0000	n/a	0.014601 m

Obr. 42: Výsledky georeferencování

Jelikož množství bodů v jednotlivých skenech bylo obrovské a většina těchto bodů nepatřila ke skále ani k jejímu okolí, bylo bodové mračno oříznuto pouze na okolí skály (obr. 43). Celkový počet bodů před a po oříznutí lze najít v tab. 2. Pro další zpracování byly jednotlivé skeny exportovány ve formátu E57.



Obr. 43: Oříznuté bodové mračno z laserových dat


Číslo skenu	Původní počet bodů	Počet bodů po oříznutí
1	52 131 721	2 923 039
2	48 872 131	4 841 800
3	55 228 553	1 918 794
4	13 091 014	886848
5	19 988 064	10 956 815
6	15 023 684	1 171 616
7	24 721 035	21 160 401
8	23 203 341	17 391 649
9	22 000 025	1 907 996
10	71 353 416	1 112 796

Tab. 2: Počet bodů před a po oříznutí skenů.

4.3.2 Tvorba bodového mračna z UAV snímků

Pro tvorbu bodových mračen z pozemních snímků a ze snímků UAV byl použit software Agisoft Metashape, který se používá pro zpracovávání digitálních snímků z pozemní fotogrammetrie, letecké fotogrammetrie i satelitních snímků. Na základě těchto snímků jsou vygenerována 3D prostorová data. Software umožňuje zpracovávat RGB, termální nebo multispektrální snímky. Výsledkem může být mračno bodů, texturovaný polygonový model, georeferencované ortofoto nebo digitální model terénu. Dále nabízí i postprocessingové nástroje např. pro výpočet vegetačních indexů a klasifikaci bodového mračna (Agisoft 2020).

Rolovací nabídka *workflow* v programu Metashape obsahuje všechny nutné kroky pro tvorbu 3D modelu (obr. 44). Jako první jsou snímky importovány pomocí funkce *Add photos*.



Obr. 44: Pracovní postup Agisoft Metashape

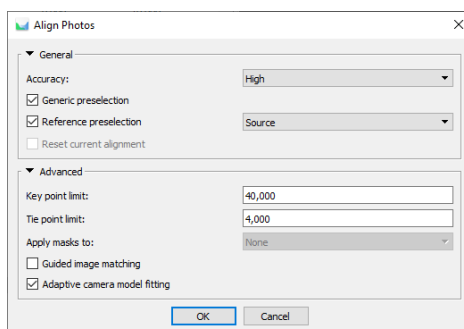
Poté co jsou všechny snímky importovány, je možné přejít k dalšímu kroku. Ještě před orientací snímků je doporučována kontrola kvality snímků, ta se obvykle provádí vizuální kontrolou jednotlivých snímků nebo je také možné použít funkci v programu Metashape *Estimate image quality*, která odhadne kvalitu každého snímku a přiřadí jej hodnotu mezi nulou a jedničkou. Hodnota parametru je vypočítána na základě ostrosti snímku v nejostřejší části snímku. Je doporučováno z výpočtu vyřadit snímky s hodnotou nižší než 0,5 (obr. 45). Žádný z 556 snímků neměl kvalitu horší než 0.83 a proto také žádný snímek nebyl vyloučen z výpočtu.

Label	Size	Aligned	Quality	Date & time	Make	Model	Focal length	F-stop	ISO	Shutter	35mm focal
DJI_0001	5472x3648	✓	0.850192	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0002	5472x3648	✓	0.859428	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0003	5472x3648	✓	0.867192	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0004	5472x3648	✓	0.86255	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0005	5472x3648	✓	0.857008	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0006	5472x3648	✓	0.84463	2019:04:16 13:50...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0007	5472x3648	✓	0.848852	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0008	5472x3648	✓	0.853262	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0009	5472x3648	✓	0.852153	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0010	5472x3648	✓	0.850963	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0011	5472x3648	✓	0.85238	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0012	5472x3648	✓	0.863824	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0013	5472x3648	✓	0.856101	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0014	5472x3648	✓	0.856499	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24
DJI_0015	5472x3648	✓	0.853835	2019:04:16 13:51...	DJI	FC6310	8.8	F/5.6	200	1/400	24

Obr. 45: Estimate image quality


Následně byla provedena orientace snímků pomocí funkce *Align Photos*. V tomto kroku probíhá autokalibrace kamery. Důležitou roli v tomto kroku hrají tzv. EXIF data. Jedná se o metadata, která obsahují informace nejen o kameře (velikost snímače, ohnisková vzdálenost atd.) s kterou byl snímek pořízen, ale mohou také obsahovat informace o poloze kamery z GNSS/IMU při pořízení snímku. Tyto údaje slouží pro autokalibraci kamery a pro

lepší orientaci snímků. Pro úspěšnou orientaci snímků je nutné zvolit nastavení v dialogovém okně (obr. 46).

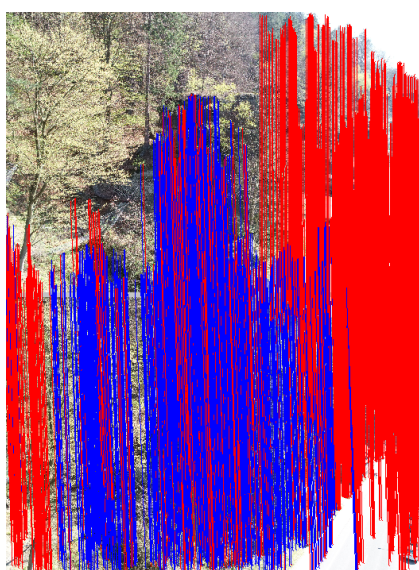


Obr. 46: Dialogové okno Align photos

První parametr nastavení je *Accuracy*, který je možné nastavit od *very low*, přes *low*, *medium*, *high* až *highest*. Možnost *high* pracuje s původní velikostí snímků. Pokud je zvolená možnost *medium* velikost snímků je čtyřikrát menší než původní velikost snímků. Další dvě nastavení, které je možné použít pro urychlení celého procesu jsou *Generic preselection* a *Reference preselection*. Proces orientace snímků porovnává každý snímek se všemi ostatními snímky pro hledání společných bodů. Pokud je však použita možnost *Generic preselection*, jsou tyto snímky nejprve porovnávány v nízkém rozlišení. Vysoké rozlišení snímků je použito pouze pro snímky, kde se podařilo identifikovat velké množství společných bodů. Možnost *Reference preselection* je možné použít pro snímky, které obsahují informaci o pozici kamery během snímkování. Pokud je tato možnost použita, snímek je porovnán pouze se snímky nacházející se v jeho okolí. Naše snímky tuto informaci obsahovaly, proto byly použity obě možnosti. V pokročilém nastavení je ještě možné nastavení limitu pro *Key point limit* a *Tie point limit*. *Key point limit* je maximální počet bodů, který se bude ve snímku vyhledávat a *Tie point limit* je maximální počet bodů použitých pro spojení. V našem případě byly použity hodnoty 40 000 pro *Key points* a 5 000 pro *Tie points*. Po orientaci snímků vznikne řídké bodové mračno, které má 357 034 bodů (obr. 47). Funkce *view matches* umožňuje si prohlédnout body na základě, kterých byly jednotlivé snímky spolu orientované (obr. 48).



Obr. 47: Řídké bodové mračno



Obr. 48: Ukázka spojovacích bodů

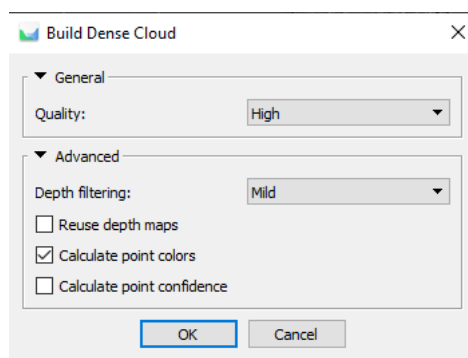
Následně byla použita funkce *Gradual selection*, která umožňuje filtrovat body na základě některých kritérií. Jako první byl použit filtr *Reprojection error*, který odstraní špatně lokalizované body. V našem případě byly odstraněny všechny body, které měly projekční error větší než 0,3 pixelu. Další filtr se jmenuje *Reconstruction uncertainty*. Tento filtr odstraní body, které byly vygenerovány z blízkých snímků s malou základnou. V našem zpracování byla vybrána mezní hodnota 200 pro odstranění bodů. Třetí filtr *Number of images* odstraní body, které se nachází na menším počtu snímků, než je zvolena hodnota. V našem mračnu byly odstraněny všechny body, které se nenacházely minimálně na třech snímcích. Následně bylo bodové mračno georeferencováno pomocí 5 bodů. Jelikož snímky obsahují vlastní souřadnice, které mohou mít odchylky až několik metrů bylo nutné je nejprve vypnout. Poté byly importovány vlastní souřadnice bodů a tyto body byly označeny

ve snímcích pomocí *markers* a byly jim přidělené souřadnice (obr. 49) a následně byla provedena optimalizace kamer. Směrodatná souřadnicová odchylka je 1,5 cm.




Obr. 49: Vlícovací bod

Další fáze procesu je tvorba hustého bodového mračna, která je z celého procesu nejnáročnější pro výpočetní výkon. Na základě orientace snímků se vypočte hloubková mapa z každého snímku a spojí je do jednoho hustého bodového mračna. Kvalitu výsledného bodového mračna lze ovlivnit několika parametry (obr. 50). Prvním parametrem je kvalita, kterou lze zvolit od *ultra high* až *ultra low*. Vyšší kvalita zajišťuje vytvoření detailnější a přesnější geometrie objektu, nicméně je časově velice náročná. Pokud je zvolena možnost *ultra high*, jsou snímky zpracovávány v plném rozlišení, každá další možnost snižuje rozlišení o jednu úroveň. Druhý parametr je *Depth filtering*, který odstraňuje odlehlé body. K dispozici jsou čtyři možnosti, *mild* pro členité povrchy, *aggressive* pokud není potřeba zachovat malé detaily, *moderate* je kompromisem přechozích dvou a *disabled* zachování všech bodů. Pro vlastní model byly použity možnosti *high* a *mild*. S tímto nastavením vzniklo bodové mračno obsahující 57 606 381 bodů.



Obr. 50: Dialogové okno Build Dense Cloud

Ještě před samotným exportem bodového mračna došlo k jeho oříznutí pouze na okolí skály (obr. 51). Tímto se snížil počet bodů na 12 964 754. Tyto body byly exportovány ve formátu *PCD*.




Obr. 51: Oříznuté bodové mračno z dat UAV

4.3.3 Tvorba bodového mračna z pozemních snímků

Postup tvorby modelů z pozemních snímků je velice podobný jako u UAV snímků. Celkem bylo k dispozici 740 snímků. Jako první byla zkontrolována kvalita snímků a bylo odstraněno 76 snímků, které měly kvalitu nižší než 0.7. Následně byly po manuální kontrole odstraněny snímky, kde větší část neobsahovala samotnou skálu. Pro zpracování bylo použito zbylých 613 snímků. Orientace snímků byla provedena s nastavením kvality *low* s použitím *Generic preselection*, a hodnotami *key* a *tie point limit* na 60 000 a 6 000. Jelikož snímkování probíhalo z velké blízkosti, nebyl dostatečný překryt mezi některými částmi skály, a proto se podařilo orientovat pouze 364 snímků. Jednalo se o snímky, které zachycovaly levou dolní část skály. Zbylých 249 snímků bylo rozděleno do 2 skupin. První skupina obsahovala 140 snímků, které převážně zachycovali zadní část skály. Druhá skupina obsahovala 109 snímků a zachycuje pravou část skály. Tyto dvě skupiny snímků byly orientovány zvlášť za použití stejného nastavení jako předtím. Po úspěšné orientaci těchto skupin, byly na snímcích, které se překrývají mezi skupinami definovány spojovací body pomocí *markers*, díky kterým mohlo dojít k spojení všech třech skupin. Na této spojené skupině snímků byla provedená optimalizace kamer. Následně byly, na nově vzniklém řídkém bodovém mračnu použity filtrační funkce z nabídky *Gradual selection* (Obr 52). Při *gradual selection* bylo použito stejných hodnot jako v případě bodového mračna z UAV a podruhé byla použita funkce *Optimize cameras*. Při tomto procesu bylo odstraněno velké množství bodů a bylo

odstraněno 14 snímků, které neměly po filtraci dostatečný počet bodů pro správnou orientaci. Převážně se jednalo o snímky, které zachycují skálu z velkého úhlu (obr. 53).



Obr. 52: Řídké mračno před a po gradual selection



Obr. 53: ukázka snímku zachycující detaily skály

Nově vzniklé řídké bodové mračno obsahovalo 73 234 bodů. Poté bylo bodové mračno georeferencováno pomocí 5 bodů. Směrodatná souřadnicová odchylka je 2,6 cm. Následně byl proveden poslední krok tvorby bodového mračna a bylo vytvořeno husté bodové mračno. Pro tvorbu mračna byla použita kvalita *High* a filtrovací mód *aggressive*. Po oříznutí bodového mračna pouze na okolí skály vzniklo bodové mračno o 30 759 230 bodů (obr. 54). Toto mračno bylo nakonec exportováno ve formátu *PCD*.



Obr. 54: Husté bodové mračno z pozemní fotogrammetrie

4.4 Tvorba filtrů

Tvorba filtrů probíhala na osobním notebooku v programovacím jazyce Python. Byly vytvořeny dva skripty. První skript *FB_3Dfilter.py* slouží preprocessingové filtry a druhý skript *FB_vegfilter.py* pro filtraci vegetace. Celý zdrojový kód použitých skriptů se nachází v příloze 10. K tvorbě bylo použito několik volně dostupných knihoven:

- **NumPy** – je knihovna, která poskytuje infrastrukturu pro práci s vektory a maticemi. Nabízí řadu užitečných funkcí pro práci s vícerozměrnými poli. Obsahuje také základní metody lineární algebry (Numpy 2020).
- **SciPy** – je knihovna pro vědecké a matematické výpočty (SciPy 2020).
- **Open3D** – knihovna pro práci s 3D daty. Nabízí mnoho nástrojů pro práci s bodovými mračky a pro polygonové sítě (Open3D 2020).
- **OpenCV** – je knihovna pro manipulaci s obrazem, jejíž hlavním zaměřením je počítačové vidění a zpracování obrazu (OpenCV 2020).

4.4.1 Preprocessingové filtry

Existuje velké množství formátů pro práci s 3D daty. Struktura těchto formátů se často liší a jejich kompatibilita je různá. Pro vlastní práci byly vybrány formáty *E57* pro import laserových dat a *PCD* pro ostatní importy a exporty. Pro import *E57* byl použit wrapper knihovny *libE57Format* *pye57*, který slouží pro čtení a zápis dat (Pye57 2020). I přesto, že by tento formát měl být standardizovaný, výstupy z různých programů mají trochu odlišnou strukturu. Proto výsledný skript je možné spustit pouze s daty z programu Leica Cyclone. Pro čtení a zápis dat ve formátu *PCD* byla použita knihovna *Open3D*. Pro zjednodušení filtračního skriptu jsou vstupní hodnoty zadávány pomocí konfiguračního textového dokumentu. Ukázka konfiguračního souboru se nachází v příloze 10. Nový konfigurační soubor je také možné vytvořit pomocí zadání příkazu *printconfig* po spuštění skriptu *FB_3Dfilter.py* (obr. 55). Tento konfigurační soubor obsahuje návod a výčet potřebných knihoven pro úspěšné spuštění skriptů.

```

243 camera_location=(position_scan_0[0, 0], position_scan_0[0, 1], position_scan_0[0, 2]))
244 xyz_down = np.asarray(pcd.points)
245 normals = np.asarray(pcd.normals)
246 vectorPtoS = np.array([position_scan_0[0, 0] - xyz_down[:, 0], position_scan_0[0, 1] - xyz_down[:, 1],
247                        position_scan_0[0, 2] - xyz_down[:, 2]]).T
248 vectorPtoS = vg.normalize(vectorPtoS)
249 normals = vg.normalize(normals)
250 angle = vg.angle(vectorPtoS, normals, units='deg')
251 angle = np.array(angle).T
252
253 rgb_down = np.asarray(pcd.colors)
254 final = np.concatenate((xyz_down, normals, rgb_down.astype(np.float) * 255.0), axis=1)
255
256 final = np.insert(final, 9, angle, axis=1)
257
intensity_filter()

```

Run: FB_3Dfilter -x
C:\Users\fbash\AppData\Local\Programs\Python\Python36\python.exe D://diplomka_data/dip_projekt/FB_3Dfilter.py
enter config file name:

Obr. 55: Tisk konfiguračního textového dokumentu

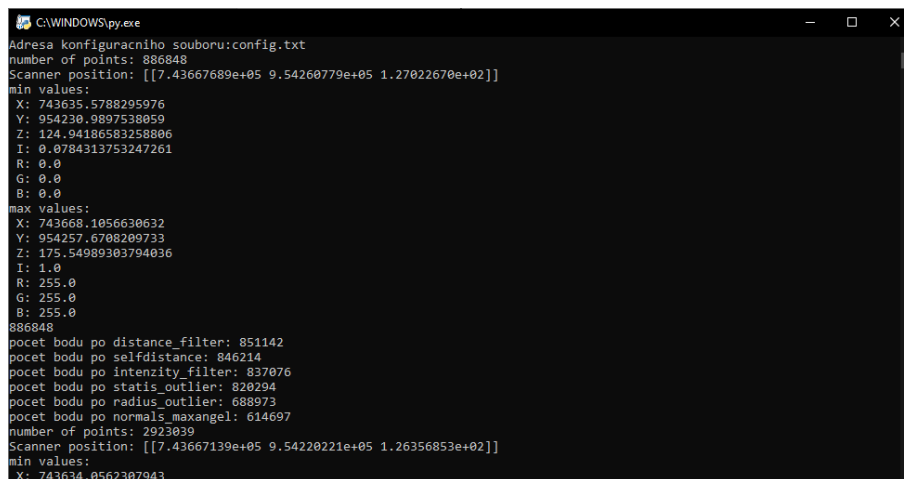
Testování vytvořených filtrů probíhalo s velkou řadou konfiguračních hodnot, z nichž byly nakonec vybrány pro každý krok hodnoty, které nejlépe zachovávaly skálu. U každé zmíněné funkce jsou uvedené konfigurační hodnoty použité pro konečný 3D model.

- **Vzdálenostní filtrace** – První filtrační funkce slouží pro odstranění vzdálenějších bodů od skeneru, než je definovaná hodnota. Tuto filtrační funkci lze použít pouze pro data z laserového skenování. Podle publikace Soudarissanane et. al (2011) při skenování na vzdálenost 50 m a skenovacím úhlu 60° vznikají odchylky měření větší než 5 mm. Proto pro vlastní data byla zvolena hodnota 40 metrů. Tato hodnota na všech skenech zachovává téměř celou skálu.
- **Snížení hustoty bodového mračka** – Každý bod prohledá své okolí o zadané vzdálenosti. Pokud najde ve svém okolí nějaký bod, je tento bod odstraněn. Funkce zajistí, že minimální vzdálenost mezi body není menší než určená hodnota. Funkce při odlišném seřazení bodů může mít u stejných dat různé výsledky. Jelikož je funkce výpočetně velice náročná, jsou body rozděleny do skupin o maximální velikosti milion bodů. Toto může způsobit, že některé body mezi sebou nemají minimální vzdálenost. Pro vlastní data byla vybrána vzdálenost pět milimetrů. Taková vzdálenost je dostatečná pro podrobné mapování skalních útvarů.
- **Filtrace podle intenzity** – Filtrační funkce je zaměřená na intenzitu odrazu laserového paprsku. Funkce odstraní body, které mají nižší intenzitu odrazu,

než je definovaná hodnota. Funkce umožňuje také omezit horní hranici intenzity odrazu. Po vizuální kontrole mračen bylo zjištěno, že téměř žádný bod na skalním povrch nemá hodnotu intenzity menší než 0,5 proto pro vlastní laserová data byly tyto hodnoty nastaveny na 0,5 až 1.

- **Statistical Outlier Removal** – Slouží pro odstranění odlehlých bodů, je popsána v kapitole 3.3 filtrace bodových mračen. Jelikož vlastní vytvořená verze této funkce byla velice pomalá a přinášela stejné výsledky jako dostupná funkce v knihovně Open3D, byla v konečném skriptu použita funkce ze zmíněné knihovny. Počet bodů použitých pro výpočet průměrné vzdálenosti bodu od okolních bodů byl nastaven na deset bodů. Hodnota směrodatné odchylky byla nastavena na dvě sigma.
- **Radius Outlier Removal** – Další funkce, která slouží pro odstranění osamocených bodů. Princip funkce je popsán v kapitole 3.3 filtrace bodových mračen. Rádus okolí, ve kterém se hledá minimální počet bodů byl nastaven na pět centimetrů. Počet minimálních potřebných bodů pro zachování bodu bylo deset.
- **Filtrace podle úhlu dopadu** – Funkce slouží k odstranění bodů z dat laserového skenování, které mají velký úhel dopadu laserových paprsků. Funkce vypočítá normálový vektor pro každý bod. Pokud je úhel mezi vektorem z bodu do skeneru a normálovým vektorem bodu větší než 80° , je bod vymazán.

Po spuštění skriptu je také možné vidět minimální a maximální hodnoty souřadnic, intenzit a barev. Dále skript vypisuje počty bodů po jednotlivých filtracích (Obr. 56).




```
C:\WINDOWS\py.exe
Adresa konfiguračního souboru: config.txt
number of points: 886848
Scanner position: [[7.43667689e+05 9.54260779e+05 1.27022670e+02]]
min values:
X: 743635.5788295976
Y: 954230.9897538059
Z: 124.94186583258806
I: 0.0784313753247261
R: 0.0
G: 0.0
B: 0.0
max values:
X: 743668.1056630632
Y: 954257.6708209733
Z: 175.54989303794036
I: 1.0
R: 255.0
G: 255.0
B: 255.0
886848
pocet bodu po distance_filter: 851142
pocet bodu po selfdistance: 846214
pocet bodu po intensity_filter: 837076
pocet bodu po statis_outlier: 820294
pocet bodu po radius_outlier: 688073
pocet bodu po normals_maxangel: 614697
number of points: 2923039
Scanner position: [[7.43667139e+05 9.54220221e+05 1.26356853e+02]]
min values:
X: 743634.0562307943
```

Obr. 56: Ukázka preprocessing skriptu

Počty bodů před a po preprocessing filtraci si jsou uvedeny v tab. 3. Velký pokles počtu bodů zaznamenaly skeny, které se nacházely v těsné blízkosti skály. Naopak nejmenší pokles bodů vykazovaly skeny, které byly pořízeny ze strany silnice. Toto lze vysvětlit tím, že skeny blíže ke skále mají na jejím povrchu větší hustotu bodů než skeny vzdálenější. Obr. 57 ukazují výsledky preprocessing filtrace na skenu číslo 4, kde bylo odstraněno 241 880 bodů. Je vidět že se odstranilo množství osamocených bodů. V červeně označené oblasti jsou také body které byly odstraněny kvůli velkému úhlu dopadu.


Označení mračna	Původní počet bodů	Počet bodů po filtraci
Sken 1	2 923 039	2 057 315
Sken 2	4 841 800	3 245 256
Sken 3	1 918 794	1 347 014
Sken 4	886 848	644 968
Sken 5	10 956 815	1 991 886
Sken 6	1 171 616	909 677
Sken 7	21 160 401	5 847 094
Sken 8	17 391 649	3 376 436
Sken 9	1 907 996	1 486 004
Sken 10	1 112 796	636 988
UAV fotogrammetrie	12 964 754	5 784 148
Poz. fotogrammetrie	30 769 230	15 944 132

Tab. 3: Počet bodů před a po preprocessing filtraci




Obr. 57: Sken 4 před a po preprocessing filtraci

U mračen z pozemní a UAV fotogrammetrie na první pohled nenastala žádná viditelná změna, ale po nahlédnutí do tabulky 3 lze vidět, že největší pokles bodů nastal u mračna pořízeného pozemní fotogrammetrií. To bylo způsobeno tím, že snímkování bylo prováděno z velké blízkosti a při vytváření mračna se použily vysoké hodnoty rozlišení pro zachování detailů, kvůli tomu vzniklo na malém prostoru velké množství bodů a tím pádem bylo při snižování hustoty vymazáno mnoho bodů z mračna. Obr. 58 zobrazuje bodové mračno z UAV a na první pohled zde není žádná patrna změna. Na obr. 59 je vidět řez v bodovém mračnu z UAV, kde červené body jsou body, které byly odstraněny. Na první pohled je vidět, že kromě bodů na samotném povrchu skále bylo odstraněno i mnoho osamocenených bodů.




Obr. 58: Mračno z UAV před a po preprocessing filtraci



Obr. 59: Řez v mračnu z UAV před a po preprocessing filtraci

4.4.2 Filtrace vegetace

Největší překážkou pro vytvoření 3D modelů skalních útvarů obvykle nejsou stromy, které kolem nich rostou, ale jejich listí, které často zakrývá velkou část skalních útvarů. Tato překážka se dá částečně eliminovat snímáním mimo vegetační období. To však není možné, pokud je skalní útvar obklopen neopadavými stromy. Vzniklý problém se dá částečně vyřešit měřením z mnoha pozic, kde každá pozice zaznamená část snímaného útvaru, a tím se vytvoří kompletní model celého objektu. I když je model objektu kompletní, velkou část mračna tvoří listí stromů. Aby se tato část mračna nemusela odstraňovat manuálně, je v této práci použit ExG index. Největším problémem bylo nalezení správné prahové hodnoty pro odstranění bodů náležící vegetaci. Po několika pokusech byla na základě vizuálního vyhodnocení zvolena hodnota 0,04. Na obr. 60 je možné vidět výsledek aplikace ExG na data z UAV, kde se podařilo odstranit velkou část bodů náležící zelené části vegetace. Na obrázku je vidět, že byl vymazán téměř celý strom na pravé straně skály. Počty bodů před a po aplikaci ExG indexu na jednotlivá mračna jsou uvedeny v tab. 4.



Obr. 60: Bodové mračno z UAV před a po aplikování ExG

Označení mračna	Původní počet bodů	Počet bodů po filtraci
Sken 1	2 057 315	2 042 178
Sken 2	3 245 256	3 167 288
Sken 3	1 347 014	1 049 500
Sken 4	644968	504 062
Sken 5	1 991 886	1 723 553
Sken 6	909 677	769 511
Sken 7	5 847 094	5 141 158
Sken 8	3 376 436	3 133 582
Sken 9	1 486 004	1 427 216
Sken 10	636 988	607 149
UAV fotogrammetrie	5 784 148	2 031 027
Poz. fotogrammetrie	15 944 132	12 276 931

Tab. 4: Počty bodů před a po aplikaci ExG indexu.

V dalším kroku byla jednotlivá bodová mračna shlukována do klastrů, a to na základě hustoty výskytu bodů pomocí algoritmu DBSCAN. Jak již bylo zmíněno, v jednotlivých mračcích se zachová pouze určité procento největších klastrů, které náleží ke skalnímu útvaru. Cílem je odstranit co největší počet větví stromů v okolí skály. Současně by zde mělo dojít k odstranění zbývajících listů, které se nepodařilo odstranit pomocí ExG indexu. Zároveň by po filtraci měla být odstraněna co nejmenší část objektu. Výběr vstupních parametrů algoritmu proběhl opět metodou „pokus – omyl“. Pro každé mračno bylo vždy testováno mnoho kombinací parametrů *eps* a *minPts*. Výběr těchto parametrů je velmi subjektivní. Často vznikaly situace, kdy se podařilo odstranit téměř veškeré větve, listy i kmeny stromů, nicméně byla odstraněna i část skály. Naopak v jiných situacích, kdy zůstala skála téměř celá, bodové mračno obsahovalo i velké množství vegetace. Proto bylo nutné najít kompromis. Při výběru správných parametrů bylo zohledněno, která část skály je v daném mračnu nejdůležitější. Pokud se tedy podařilo najít kombinaci parametrů, kdy se podařilo zachovat důležitou část skály a zároveň se podařila odstranit větší část vegetace s méně důležitou částí skály, byly tyto hodnoty preferovány před hodnotami, kdy skála zůstala celá i s větším obsahem vegetace. Například na obr. 61 je vidět, že při nastavení parametrů *eps* a *minPts* na hodnoty 0,1 a 30 pro sken 4 je odfiltrován kus střední části skály, ale zároveň je také vyfiltrována téměř všechna vegetace. Tento střední kus skály se nachází i na několika dalších mračcích, a proto není nezbytně nutné ho v tomto skenu zachovat.



Obr. 61: Sken 4 před a po DBSCAN filtraci (vlevo: před klastraci, uprostřed: po klastraci, vpravo: vytvořené klastry)

Pokud v DBSCAN není bod přiřazen k žádnému klastru, je považován za šum. Všechny tyto body jsou přiřazeny do jednoho klastru, obvykle označeného hodnotou -1. V tomto případě byl tento šumový klaster vymazán. Celá část skály v jednotlivých mračnecích zpravidla náležela k jednomu klastru, nicméně v některých případech (např. když byla část mračna rozdělena kvůli stínům stromů) byla skála rozdělena na více menších klastrů. Na obr. 61 jsou vidět vytvořené klastry v různých barvách. Lze vidět, že z původního mračna byly zachovány velké shluky bodů. Z každého mračna bylo vybráno jedno procento největších klastrů, případně půl procento. Nastavení pro jednotlivá mračna i výsledný počet bodů lze vidět v tab. 5.

Označení mračna	Zvolená hodnota eps	Zvolená hodnota minPts	Počet klastrovaných bodů	Počet vzniklých klastrů	Počet ponechaných klastrů	Počet bodů po filtraci
Sken 1	0,15	25	2 042 178	1357	14	1 578 500
Sken 2	0,1	25	3 167 288	2580	26	2 517 183
Sken 3	0,1	30	1 049 500	1434	15	730 733
Sken 4	0,1	30	504 062	1034	11	338 078
Sken 5	0,1	35	1 723 553	599	6	1 558 611
Sken 6	0,1	30	769 511	1034	11	528 647
Sken 7	0,1	30	5 141 158	4375	21	4 211 146
Sken 8	0,1	30	3 133 582	3839	38	2 398 571
Sken 9	0,15	25	1 427 216	2690	134	167 377
Sken 10	0,1	25	607 149	1635	17	265 563
UAV fotogrammetrie	0,15	30	2 031 027	2351	24	1 555 860
Poz. fotogrammetrie	0,1	30	12 276 931	1447	15	11 574 884

Tab. 5: Nastavení a výsledky DBSCAN filtrace

Posledním krokem bylo vyhledání kmenů stromů pomocí Houghovy transformace, která dokáže detekovat kružnicové tvary v obraze. Jako první byl proveden řez v bodovém mračnu. Řez byl proveden v tzv. výčetní výšce stromu, tj. 1,3 metru od paty stromu a jeho šířka byla 0,1 metru ve směru Z. Jelikož se okolí skály nenachází v rovinném terénu, muselo být mračno rozděleno na menší vertikální části. V každém mračnu byl vytvořen pravidelný grid přibližně o velikosti 0,5 metru. V každé mřížce gridu byly vybrány všechny body ve výšce 1,3 - 1,4 metru od nejnižšího bodu v mřížce.

Tímto vzniklo nové mračno bodů, které bylo možné zobrazit do grafu. Osy grafu tvoří X a Y souřadnice bodového mračna. Délka os grafu je stejná jako rozdíl maximální a minimální souřadnice původního mračna. Každý bod řezu je v grafu zobrazen jako bod o velikosti čtyř pixelů, takže dochází i k částečnému překrytí bodů, které nemají stejné X, Y souřadnice. Pokud by velikost bodů byla pouze jeden pixel, docházelo by k výskytu prázdných pixelů mezi body, a tím k nepropojenosti částí kružnic, které budou později detekovány (obr. 62). Tento graf byl uložen jako PNG snímek o velikosti 1920x1440 pixelů. Do snímků byla uložena pouze vnitřní část grafu bez okrajů. Jelikož známe délky os souřadnic a počty pixelů, lze jednoduše vypočítat velikost pixelu v souřadnicích. Velikost pixelů pro tato mračna byla vždy okolo 1,5 centimetru.




Obr. 62: Zobrazení bodů při velikosti 1 pixel a 4 pixely


Ve snímku byly vyhledávány kružnice pomocí funkce knihovny *OpenCV HoughCircles*, která používá metodu *Hough gradient*. Tato metoda nejprve využije Cannyho hranový detektor pro určení směru a velikosti gradientu každého hranového bodu. Následně se použije tzv. 2-1 Houghova transformace, která využívá informace, že střed

dané kružnice musí ležet na normále každého bodu kružnice. V místě, kde se tyto normály protínají je střed dané kružnice. Pro určení poloměru kružnice se vypočte vzdálenost každého bodu od předpokládaného středu a vytvoří se histogram poloměrů (Yuen et al. 1990). Funkce *HoughCircles* má několik parametrů. Prvním parametrem je velikost akumulátoru, kde např. hodnota 1 znamená, že akumulátor má stejnou velikost jako původní snímek a hodnota 2, že akumulátor je o polovinu menší než původní snímek. Dalším parametrem je minimální vzdálenost mezi středy detekovaných kružnic. Dále je zde parametr určující prahovou hodnotu gradientu pro Cannyho hranový detektor. Pokud je gradient bodu větší než zadaná prahová hodnota, je bod považován za hranový. Pokud je gradient menší než zadaná hodnota, ale jeho hodnota je větší než polovina prahové hodnoty a zároveň sousedí s bodem jehož hodnota je vyšší než prahová hodnota, je i tento bod považován za hranový. Následuje parametr, který určuje prahovou hodnotu pro akumulátor. Čím je hodnota parametru nižší, tím víc falešných kružnic může být detekováno. Poslední dva parametry určují minimální a maximální poloměr hledaných kružnic.

Pro vlastní bodová mračna bylo otestováno několik desítek kombinací těchto parametrů. Žádná však nepřinesla požadovaný výsledek. Na obr. 63 lze vidět řez v bodovém mračnu z dat UAV. Červenou barvou jsou zde označeny oblasti, kde jsou stromy. Na první pohled je jasné, že část obsahující kmeny stromů, zabírá velmi malou část celého snímku. Navíc se jedná pouze o část kružnice, která je obklopena šumem. Pokud bychom tuto část chtěli identifikovat na snímku, musely by být velice sníženy parametry určující prahové hodnoty. V takovém případě by však docházelo k výskytu velkého počtu falešně detekovaných kružnic. Metoda byla také otestována na snímku, na kterém se nacházela pouze část bodového mračna se stromem (obr. 64). V tomto snímku se podařilo strom identifikovat, nicméně ve snímcích plné velikosti se nepodařilo identifikovat žádný kmen stromu. Metoda byla také otestována na bodovém mračnu, které vzniklo spojením všech mračen z laserového skenování, ani v tomto případě se však nepodařilo identifikovat žádný strom. Pomocí Houghovy transformace tedy nebyly nalezeny žádné kmeny stromů a z bodových mračen nebyly odstraněny žádné body. Pro finální spojení bodových mračen byl tedy použit výstup po filtraci pomocí DBSCANu. Všechna bodová mračna byla uložena ve formátu *PCD*.



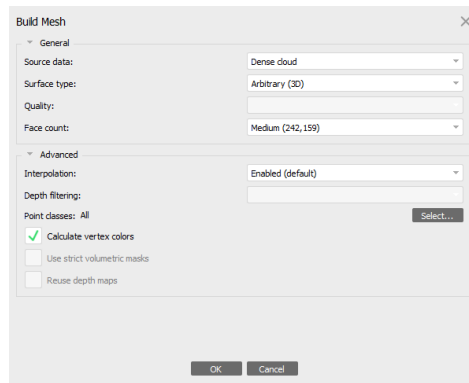
Obr. 63: řez v bodovém mračnu z UAV



Obr. 64: identifikace stromu pomocí Houghovy transformace


4.5 Tvorba polygonové sítě

Tvorba polygonové sítě (mesh) probíhala v programu Agisoft Metashape. Celkem bylo vytvořeno devět modelů. Z každé použité mapovací metody byly vytvořeny dva modely. Jeden model z mračna automatické filtrace a jeden z mračna manuální filtrace. Jeden model byl vytvořen spojením všech bodových mračen bez filtrace. Zbývající dva modely vznikly sjednocením mračen z jednotlivých filtračních metod. Postup pro tvorbu všech modelů byl téměř totožný. Jako první byla jednotlivá bodová mračna importována pomocí funkce *import points*. Tyto body jsou importovány jako husté bodové mračno, proto je pro zobrazení bodů nutné přepnout z výchozího zobrazení bodu na *dense cloud*. Nutné je také posunout region zájmu okolo importovaného mračna pomocí funkce *Reset Region*, která rozšíří region na všechny body. Veškeré výpočty probíhají vždy na bodech, které se nachází v tomto regionu. Poté byla vytvořena polygonová síť pomocí funkce *Build mesh*. Dialogové okno funkce nabízí několik možností nastavení (obr. 65). Jako první je možné vybrat zdroj dat. Je možné vybrat z možností řídké bodové mračno, hloubková mapa a husté bodové mračno. V našem případě byla vybrána možnost husté bodové mračno. Dále je možné vybrat typ povrchu z možností *arbitrary*, která je určena pro jakýkoliv 3D objekt a *height field*, která se hodí pro rovinné objekty. V našem případě byla pochopitelně vybrána možnost *arbitrary*. Možnost *Face count* umožňuje specifikovat množství polygonu ve finálním modelu. Je možné si vybrat z možností *High, Medium, Low*. Množství polygonu je vypočítáno na základě počtu bodů. Poměr polygonu a bodů je 1/5, 1/15 a 1/45. Dále je tu také možnost *Custom*, která umožňuje vybrat počet polygonu uživatel. V našem případě byla vybrána možnost *Medium*. V pokročilém nastavení je možné vybrat použití interpolaci. Pokud je tato možnost vypnuta, polygonová síť je vytvořena pouze v částech kde se nachází bodové mračno. Pokud je možnost zapnuta, program automaticky interpoluje některé oblasti okolo bodového mračna. Dále je tu také možnost extrapolace, která vytvoří vodotěsný model. V našem případě byla interpolace vždy zapnuta. Pro všechny modely byly vybrány stejné hodnoty.




Obr. 65: Dialogové okno build mesh


Na obr. 66 je vidět model vytvořený z všech spojených bodových mračen po automatické filtraci. Model postrádá pravou nižší část skály nachází se za jedlí, která je v tomto místě v přímém kontaktu se skálou. Na obr. 67 je vidět model vytvořený z manuální filtrace bodového mračna. Na tomto modelu je mezera na pravé straně menší než v modelu z automatické filtrace. Pokud se však přepne režim zobrazení na stínovaný model, je na obr. 68 vidět, že manuální model je v tomto regionu z velké části interpolován. Model z automatické filtrace postrádá i kus levé střední části skály. Tato část není na datech z UAV zaznamenaná kvůli husté vegetaci. Na datech z laserového skenování a pozemní fotogrammetrie je tato část zachycena v malém detailu, jelikož je převážně orientována nahoru. Proto při automatické filtraci byla tato část odstraněna, ale v při manuální filtraci byla zachována.



Obr. 66: Model z automatické filtrace



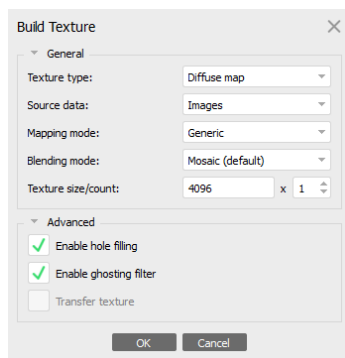
Obr. 67: Model z manuální filtrace



Obr. 68: Interpolované mezery


Vytvořené modely už jsou připraveny pro export pro další využití. Pro lepší vizuální vjem byly však vytvořeny i textury pro jednotlivé modely. Pro aplikování textury byly modely vytvořené fotogrammetrickými metodami opět importovány do původních Metashape projektu a byla na ně aplikována textura ze snímků. Bohužel toto není možné u modelů z laserového skenování a spojeních modelů, a proto na ně byla aplikována textura z UAV. Textura byla vytvořena pomocí funkce *Build texture*. Funkce nabízí několik možností nastavení textury (obr. 69). Jako první je možnost výběru typu textury, kromě běžné textury nabízí Metashape i možnost *Occlusion map*, jedná se o stínovanou texturu užívanou v počítačové grafice. V našem případě byla použita normální textura. Dále je tu možnost výběru zdroje dat pro tvorbu textury. Lze si vybrat mezi texturou ze snímků, která byla použita v našem případě, nebo z vertexů modelu. Možnost *mapping mode* určuje, jak bude

objekt zabalen do textury, kromě běžné možnosti *Generic*, která se hodí pro většinu typu objektů a byla použita i v našem zpracování, je zde možné si vybrat i možnost mapování ortofoto, sférické a z jednoho snímku. Další možnost je *Blending mode*, která určuje způsob, jak bude výsledná textura kombinována. Na výběr jsou zde možnosti *Mosaic*, *Average*, *Max intensity*, *Min intensity* a *disabled*. Možnost *Mosaic* má dvě fáze, v první fázi se provádí míchání nízkofrekvenčního komponentu pro odstranění viditelných švů. Vysoko frekvenční složka zajišťuje detaily a vybere v každé oblasti snímků, který vykazuje nejlepší kvalitu. Možnost *Average* používá vážený průměr hodnot pixelů z jednotlivých snímků. Možnosti *Min* a *Max intensity*, použijí snímek, který má nejmenší či největší intenzitu daného pixelu. Pro naše potřeby byla vybrána možnost *Mosaic*. Mezi základní nastavení ještě patří výběr rozlišení textury a počet souborů pro export. Pro všechny modely byla použita velikost 4096 v jednom souboru. V pokročilém nastavení je ještě možné zapnout možnosti vyplňování děr a *ghosting filtering*, která z textury odstraní části, které se nepodařilo zkonstruovat, například kvůli pohybujícím objektům. Obě tyto možnosti byly použity pro naše modely.



Obr. 69: Dialogové okno build texture

Na obr. 70 jsou vidět texturované modely z UAV a laserového skenování, které byly filtrovány manuální metodou. Na obou modelech lze vidět nazelenalá textura, která je způsobena vegetačním pokryvem, který se přímo dotýká skály. Na obrázku vpravo se nachází model z laserového skenování, jehož textura byla vytvořena ze snímků z UAV. V dolní části je vidět stromová textura na skalním povrchu. To je způsobeno tím, že snímky z UAV tyto části skály nezachycují, a proto této části byla přiřazena textura stromu, který se nachází před skálou. Všechny vytvořené modely jsou zobrazeny v přílohách 1-9. Modely byly vyexportovány ve formátu *OBJ* a jsou uloženy na cloud disku.



Obr. 70: Texturované modely filtrovány manuální metodou (vlevo: UAV, vpravo: Las. skener)

5 Hodnocení výsledků

Hodnocení výsledků je rozděleno na dvě části. V první části jsou porovnávána vytvořená bodová mračna filtrovaná pomocí automatické filtrace s referenčními mračny, která byla filtrována manuálně. V druhé části jsou porovnány jednotlivé modely mezi sebou včetně vzájemného srovnání přesností vytvořených modelů z jednotlivých metod pomocí geodetickým měřením. Toto srovnání bylo provedeno na referenčních modelech.

5.1 Hodnocení filtrů


Hodnocení úspěšnosti navrženého filtračního postupu je provedeno pomocí referenčních bodových mračen, ve kterých byla vegetace filtrována manuálně. Jelikož je znám původní počet bodů v mračnách a je znám také počet bodů po manuální filtraci, lze jejich odečtením zjistit počet bodů náležících k vegetaci. Během odstraňování vegetace došlo také k odstranění okolního terénu tak, aby na mračnách zůstala pouze samotná skála. Proto je během hodnocení považován za vegetaci i okolní terén. Jelikož při automatické filtraci také došlo ke snížení hustoty bodů, kdy byly odstraněny body i na ploše skalního útvaru, byla pro porovnání snížena i hustota původních mračen stejným postupem na minimální vzdálenost mezi body na pět milimetrů.

Původní počet bodů ve všech mračnách byl 69 265 119. Po manuální filtraci bylo odstraněno 67,53 % bodů, a tím pádem k vegetaci náleží 46 776 449 bodů. Navržené automatické filtrace odstranily z původního mračna 60,41 % bodů, což znamená, že počet bodů náležící k vegetaci podle automatické filtrace je 41 839 966. Pokud je tento počet bodů vydělen počtem bodů, které skutečně náleží k vegetaci (podle manuální filtrace), vyjde celková úspěšnost automatických filtrů 89,45 % (tab. 6).

Označení mračna	Původní počet bodů	Počet bodů po manuální filtraci	Procento odstraněných bodů (%)	Skutečný počet bodů náležící k vegetaci	Počet bodů po automatické filtraci	Procento odstraněných bodů po automatické filtraci (%)	Počet bodů náležící k vegetaci podle automatických filtrů	Procento úspěšnosti filtrů (%)
Sken1	2 367 214	1 526 597	35,51	840617	1578500	33,32	788714	93,83
Sken2	3 574 234	1 513 886	57,64	2060348	2517183	29,57	1057051	51,30
Sken3	1 466 862	721 767	50,80	745095	730733	50,18	736129	98,80
Sken4	686 284	284 779	58,50	401505	338078	50,74	348206	86,73
Sken5	3 849 012	1 419 057	63,13	2429955	1558611	59,51	2290401	94,26
Sken6	996 215	275 794	72,32	720421	528647	46,93	467568	64,90
Sken7	9 994 690	2 712 932	72,86	7281758	4211146	57,87	5783544	79,43
Sken8	5 747 581	662 237	88,48	5085344	2398571	58,27	3349010	65,86
Sken9	1 377 262	291 383	78,84	1085879	167377	87,85	1209885	111,42
Sken10	626 517	311 827	50,23	314690	265563	57,61	360954	114,70
UAV fotogrammetrie	7 810 018	1 058 346	86,45	6751672	1555860	80,08	6254158	92,63
Poz. fotogrammetrie	30 769 230	11 710 065	61,94	19059165	11574884	62,38	19194346	100,71
FINÁLNÍ MODEL	69 265 119	22 488 670	67,53	46776449	27425153	60,41	41839966	89,45

Tab. 6: Porovnání automatické a manuální filtrace


Na první pohled se automatická filtrace zdá jako vcelku úspěšná. Při podrobnějším pohledu na data však je vidět, že u některých mračen bylo pomocí automatické metody odstraněno více bodů, než byl skutečný počet bodů náležící k vegetaci. Extrémem je sken číslo deset, kde z celkového počtu 626 517 bodů bylo pomocí automatické filtrace odstraněno 360 954 bodů, ale manuální filtrací bylo odstraněno pouze 314 692. Při číselném hodnocení se musí brát v potaz, že automatická filtrace není zaměřena pouze na vegetaci, ale i na některá špatná měření, např. bodů s velkým úhlem dopadu. Ve skenu číslo devět bylo odstraněno více bodů pomocí automatické filtrace než pomocí manuální filtrace. V tomto skenu ale bylo odstraněno mnoho bodů filtrem pro odstranění bodů s velkým úhlem dopadu, konkrétně 315 511, což je téměř jedna čtvrtina všech odstraněných bodů. Na obr. 71 lze vidět, že automatická filtrace nezvládla odstranit mnoho bodů náležících k vegetaci, ale byly odstraněny některé části skály, což při číselném hodnocení může ovlivnit výsledek.




Obr. 71: Sken 9 (zprava: Původní bodové mračno, mračno po manuální filtraci, mračno po automatické filtraci)

Nutné je taky zdůraznit použití klastrovacího algoritmu DBSCAN. Při aplikaci tohoto algoritmu byly preferovány takové hodnoty nastavení, které dokázaly odstranit většinu vegetace i s méně důležitými částmi objektu. Pokud by byla snaha zachovat celou skálu na všech skenech, byla by účinnost algoritmu nižší.

Kombinace ExG indexu s DBSCAN algoritmem přinášela lepší výsledky na skenech, kde byly převážné neopadavé stromy. ExG dokázal odstranit většinu zelené části vegetace a zbyly pouze malé části, které se podařilo odstranit pomocí vymazání malých klastrů vytvořených algoritmem DBSCAN (obr. 72). Algoritmus však byl méně úspěšný, pokud část skály byla v přímém kontaktu s opadavým stromem. Jelikož sběr dat probíhal v brzkém jarním termínu, většině těchto stromů nezačalo růst olistění. V tomto případě ExG index nerozdělil skálu a stromy a DBSCAN vytvořil ze stromů a skály jeden klastr. Na obr. 73 lze vidět, že část stromu je v přímém kontaktu se skálou, a tudíž algoritmus DBSCAN z nich vytvořil jeden klastr. V některých případech však ani tento kontakt není nutný, aby se část stromu dostala do stejného klastru jako skála. Pokud je na terénu v okolí skály dostatečná hustota bodů, dokáže algoritmus „růst“ i po zemi, až k blízkému stromu. Takový případ nastal například u skenu číslo 9 (obr. 71).



Obr. 72: Sken 3 (zprava: Původní bodové mračno, mračno po manuální filtraci, mračno po automatické filtraci)




Obr. 73: Sken 7 (zprava: Původní bodové mračno, mračno po manuální filtraci, mračno po automatické filtraci)


Navržený postup byl neúspěšný v případě odstraňování kmenů stromů pomocí Houghovy transformace, kdy se nepodařilo odstranit ani jeden kmen. Nutné je zdůraznit, že při otestování pouze na malé části mračna, algoritmus dokázal strom identifikovat. Pokud však byl algoritmus použit na celé mračno se stejným nastavením parametrů, objevilo se mnoho falešně detekovaných kružnic. Algoritmus lze tedy použít pouze v případech, kdy je měření přímo zaměřené na kmeny stromů z velké blízkosti a je omezena část mračna pouze na okolí stromů.

Jak je výše zmíněno, číselné výsledky nemusí správně reflektovat úspěšnost metody. Pro jejich správné hodnocení by bylo nutné předem znát klasifikaci každého bodu. Toto však není možné, proto je nutné provést vizuální hodnocení. Obr. 74 zobrazuje model z původního bodového mračna, z mračna po manuální filtraci a automatické filtraci. Může se zdát, že nebyly odstraněny některé zelené části vegetace. To je způsobeno tím, že pro texturu byly použity snímky z UAV, které nezachycují celou škálu, a proto některým částem modelů jsou nesprávně přiděleny textury z vegetace. Na obr. 75 si lze prohlédnout stejné modely bez textur. Zde je patrné, že automatická filtrace byla úspěšnější na zelených částech vegetace, kdy se podařilo odstranit téměř veškeré listí a jehličí z bodového mračna. Navržená metoda fungovala i v případě, kdy byla vegetace od skály ve větší vzdálenosti. Méně úspěšná byla, pokud se jednalo o větší haluze či kmeny stromů. Tyto části měly na svém povrchu často podobné množství bodů o podobné hustotě jako samotná skála a tvořily velké klastry. Navržený postup filtrace nejméně fungoval, pokud se část stromu přímo dotýkala skály. V takovém případě došlo k odstranění velmi malého počtu bodů náležících k vegetaci. Skála taktéž postrádá kus pravé strany. Tato část však chybí i na

referenčním modelu. Jedle, která roste v blízkosti skály zakrývá značnou část pravé strany. Pomocí pozemní fotogrammetrie a laserového skenování se podařilo nasnímat část za stromem u země, ale bohužel ne horní část, kde je strom v těsném kontaktu se skálou. To je příčinou, že žádný model není kompletní.




Obr. 74: Finální modely (ze shora: model po manuální filtraci, model po manuální filtraci, model bez filtrace)




Obr. 75: Finální modely bez textur (ze shora: model po manuální filtraci, model po manuální filtraci, model bez filtrace)

Nakonec bylo také provedeno porovnání použité metody s existujícími nástroji. Jako první byl otestován nástroj Cloth Simulation Filter (CSF). Tento nástroj slouží pro extrakci bodů náležící k terénu od ostatních bodů. Metoda je založena na jednoduchém fyzikálním principu. Pokud by se snímaný povrch otočil vzhůru nohama a byl by na něj položen imaginární plášť, body dotýkající se tohoto pláště by byly body náležící k terénu (Zhang et al. 2016). Metoda je primárně určena pro data z leteckého laserového skenování. Při nastavování parametrů byl vybrán jako typ terénu prudký svah a velikost gridu 0.1 metru. Funkce odstranila téměř všechny body náležící ke skále. Výsledné mračno obsahuje pouze silnici, chodník a rovný travnatý povrch před skálou (obr. 76). Následně byla funkce otestována i většími i menšími velikostmi gridu, ale ani to nepřineslo žádnou zásadní změnu. Tuto funkci lze tedy považovat za nevhodnou pro extrakci skalních útvaru z bodového mračna.


Jako další byl otestován nástroj Lasground ze sady LAsTools. Tento nástroj je taktéž primárně zaměřen na data z leteckého laserového skenování. Jako první byl nástroj testován s nastavením terénu přírodního typu. V tomto případě nástroj rozdělil bodové mračno na dvě velké skupiny. V obou skupinách se nachází jak skalní útvar, tak i vegetace. První skupina obsahuje přední a dolní část skály. Druhá skupina obsahuje horní část skály (obr. 77). Jelikož toto nastavení nedokázalo oddělit skálu od vegetace, byl v dalším pokusu vybrán typ terénu „městský“. Tímto nastavením bylo mračno rozděleno na více skupin (obr. 78). Avšak ani toto nastavení nedokázalo oddělit skálu od vegetace. Skála je rozdělena do několika menších skupin a všechny tyto skupiny obsahují velké množství vegetace. Žádný z dostupných nástrojů nedokázal oddělit vegetaci od skály takovým způsobem, aby bylo možné provést porovnání s manuální metodou.



Obr. 76: Výsledek CSF



Obr. 77: Výsledek Lasground s natavením přírodní typ povrchu



Obr. 78: Výsledek Lasground s natavením městský typ povrchu

Navržená metoda se prokázala jako úspěšná tím, že se podařilo odstranit téměř veškerou zelenou vegetaci a malé větve stromů. Odstranění těchto částí manuální metodou bývá velice časově náročné. Méně úspěšná byla metoda při odstraňování kmenů stromů a velkých větví, kdy se je nepodařilo odstranit ani ExG indexem, jelikož tvoří zelenou část vegetace. Nedokázal je vymazat ani klastrovací algoritmus, protože tvoří velké klastry. V tomto ohledu nebyla úspěšná ani Houghova transformace, jelikož povrch kmenů obsahuje malý počet bodů a v jejich okolí se nachází velké množství šumu. Metoda byla také neúčinná, pokud stromy rostly přímo na skále nebo se jejich velká část skály dotýkala.

5.2 Srovnání modelů

Žádná z použitých metod nedokázala samostatně vytvořit model, který by obsahoval všechny části skály (obr. 79). Model z UAV fotogrammetrie postrádá téměř celou pravou nižší část skály. Model z laserového skenování lze považovat za nejvíc kompletní, však ani


tento model neobsahuje kus pravé části a také chybí vrchní strana skály. Model pozemní fotogrammetrie postrádá kus přední části skály, a navíc se nepodařilo zrekonstruovat celou část skály za stromem v pravé části skály.




Obr. 79: Referenční modely (zprava: UAV fotogrammetrie, pozemní fotogrammetrie, laserové skenování)

Pro porovnání jednotlivých modelů byl použit program CloudCompare. Původně se jednalo o open source program pro porovnání mračen bodů a trojúhelníkových sítí. V současnosti nabízí i další funkce jako např. registrace mračen, statistické porovnávání, segmentace a klasifikace (CloudCompare 2016).

K porovnání byla použita funkce *compute cloud/mesh distance*. Jako první byl porovnán model z laserového skenování s UAV modelem (obr. 80). Modrá barva zobrazuje oblasti, kde je rozdíl mezi modely nejmenší, červená zachycuje naopak největší rozdíly. Jako referenční model byl v tomto případě použit model z TLS. Jak lze na obr. 80 vidět největší rozdíly mezi modely jsou na zadní straně skály, kde v blízkosti skály roste několik stromů a bodové mračno z UAV zde není kompletní. Dále jsou velké rozdíly na vrchní straně skály, která je orientovaná nahoru a tudíž, zde chybí data z TLS. Průměrná vzdálenost mezi mračny je 0,076 metru a směrodatná odchylka je 0,105 metru. Z histogramu vzdálenosti na obr. 81 je patrné, že většina bodů se nachází ve vzdálenosti 0,1 metru.




Obr. 80: Porovnání modelů z TLS a UAV




Obr. 81: Histogram vzdálenosti bodů mezi modely z TLS a UAV

Jako další byl porovnán model TLS s modelem pozemní fotogrammetrie. Z obr. 82 je patné je, že největší rozdíly mezi modely jsou na horní pravé straně skály. Mezi mračny je v této části malá mezera. Jedná se o mračno ze skupiny snímků, které byly primárně zaměřeny na pravou část skály za vysokou jedlí a horní část byla zachycena pouze na okrajích snímků a z větší vzdálenosti a vznikají zde proto větší nepřesnosti. Snímky z pozemní fotogrammetrie se nepodařilo orientovat všechny najednou a musely být použity *markers* pro dodatečné spojení snímků, a to taktéž způsobuje větší nepřesnosti. Dále k nepřesnosti také přispívá, že body použité pro georeferencování se nacházely převážně na nižší části skály. Velké odchylky lze pozorovat také na zadní straně skály. Průměrná vzdálenost mezi body je 0,117 metru a směrodatná odchylka vzdáleností je 0,136 metru. Je překvapivé, že i při takovém rozdílu na pravé straně jsou hodnoty průměrné vzdálenosti takto nízké. Toto lze vysvětlit tím, že se jednalo o okrajovou část původního

mračna a počet bodů zde byl velice malý. Toto potvrzuje i histogram na obr. 83, kde je vidět, že jen velmi malé procento bodů má vzdálenost větší než 0,2 metru.



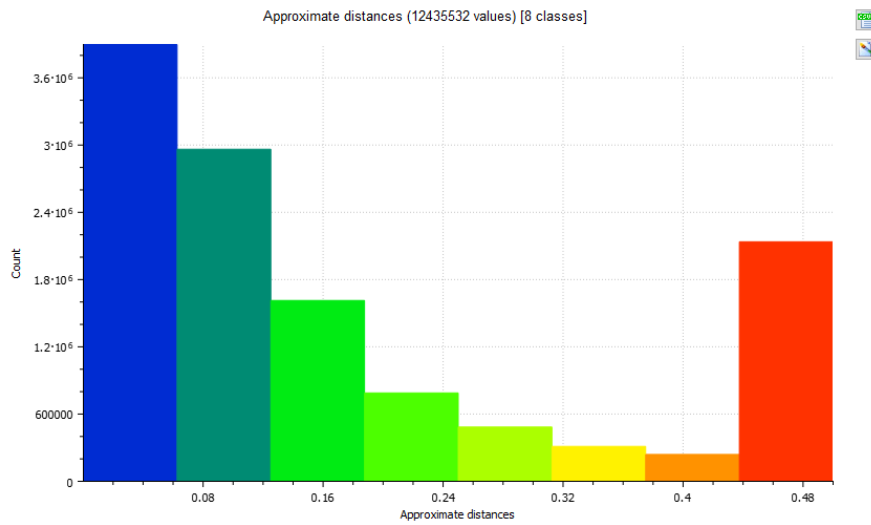
Obr. 82: Porovnání modelů z TLS a poz. fotogrammetrie




Obr. 83: Histogram vzdálenosti bodů mezi modely z TLS a poz. fotogrammetrie

Poslední porovnání bylo provedeno mezi modely z UAV a pozemní fotogrammetrie. Referenčním modelem byl zvolen model z UAV. Už na první pohled je z obr. 85 patrné, že tyto modely mají mezi sebou největší rozdíl. Toto je způsobeno tím, že model z UAV postrádá velké části spodní strany skály, a naopak část mračna z pozemní fotogrammetrie je tvořena právě touto částí skály. Jak lze vidět téměř celá spodní pravá část je zobrazena červenou barvou, protože zde chybí body, se kterými by bylo možné porovnání. Velké odchylky také vykazuje zadní a přední strana skály. Průměrná vzdálenost mezi body je 0,178

metru a směrodatná odchylka je 0,168 metru. Z histogramu na obr. 84 je patrné, že tyto vysoké hodnoty jsou způsobeny chybějícími částmi mračna.




Obr. 84: Histogram vzdálenosti bodů mezi modely z UAV a poz. fotogrammetrie



Obr. 85: Porovnání modelu z UAV a poz. fotogrammetrie

K výsledkům těchto porovnání je nutné přistupovat kriticky. Program CloudCompare porovnává pouze body, které byly nalezeny v modelu, který není označen jako referenční, proto je možné ovlivnit výsledky výběrem referenčního modelu. Pokud jsou například v posledním porovnání prohozeny modely a je vybráno mračno z pozemní fotogrammetrie jako referenční, klesne hodnota průměrné vzdálenosti 0.162 metru a hodnota směrodatné odchylky na 0,165 metru. Na obr. 86 je také vidět, že se už

nezobrazuje pravá část skály červeně, ale vrchní část, která chybí na mračnu z pozemní fotogrammetrie. Těchto chybějících bodů je však méně, a proto i o něco klesají hodnoty průměrné vzdálenosti a směrodatné odchylky.




Obr. 86: Porovnání modelu z poz. fotogrammetrie a UAV

5.3 Porovnání modelů s geodetickým měřením

Pro porovnání přesnosti modelů v programu CloudCompare bylo použito 142 podrobných bodů z geodetického měření. Tyto body byly do programu importovány jako nové mračno bodů, které bylo použito jako referenční pro všechna porovnání. Jelikož ne na všech modelech se nachází všech 142 bodů, byla omezená vzdálenost porovnání na 0,5 m. Tím bylo zajištěno, že program nebude při výpočtu brát ohled na body, kde mračno chybí. Jako první byl porovnáváno mračno z laserového skenování. V tomto případě byla směrodatná odchylka vzdáleností bodů v obou mračnech 0,075 m. Následně bylo porovnáno mračno z dat UAV, zde byla směrodatná odchylka 0,07 m. Jako poslední bylo porovnáno mračno z pozemní fotogrammetrie, které mělo směrodatnou odchylku 0,067 m.

Vzdálenost mezi mračny je vypočítána metodou nejbližšího souseda. Pro každý bod porovnávaného mračna se vyhledá nejbližší bod referenčního mračna a spočítá se jejich euklidovskou vzdálenost (Obr. 87). Toto však může být neúčinné, pokud bod, se kterým má být provedeno porovnání, je ve větší vzdálenosti než jiný bod mračna. Proto bylo nutné provést i manuální porovnání modelů s geodetickým měřením.



Obr. 87 Měření vzdálenosti metodou nejbližšího souseda

Pro manuální porovnání modelů s geodetickým zaměřením bylo vybráno šest signalizovaných bodů. Podmínky výběru těchto bodů byly, že se nachází na všech modelech a jsou identifikovatelné a zároveň nebyly použity pro georeferencování žádného modelu. Tyto body byly označeny v modelech a byly uloženy jejich souřadnice. Jako první byly vypočteny souřadnicové rozdíly (X_{err} , Y_{err} , Z_{err}) bodů mezi geodetickým měřením a souřadnicemi v modelech. Dále byla u každého bodu vypočtena prostorová souřadnicová chyba podle vzorce:

$$Error = \sqrt{X_{err}^2 + Y_{err}^2 + Z_{err}^2}$$

Následně byla pro každý model vypočtena směrodatná odchylka v souřadnici pro všechny tři souřadnice:

$$TotalErrorX = \sqrt{\frac{X_{err1}^2 + X_{err2}^2 + X_{err3}^2 + \dots + X_{errn}^2}{n}}$$

kde n je počet bodů. Vzorec je obdobný pro souřadnice Y a Z . Nakonec byla vypočtena celková směrodatná odchylka podle vzorce:

$$TotalError = \sqrt{\frac{Error_1^2 + Error_2^2 + Error_3^2 + \dots + Error_n^2}{n}}$$

Všechny vypočtené hodnoty se nachází v tab. 7, 8 a 9. Celková směrodatná odchylka vypočtená manuálně je, kromě u dat TLS, vždy vyšší než vypočtená programem CloudCompare. Výpočet probíhal na menší sadě bodů než v programu CloudCompare. Hodnoty však nejsou až tak odlišné, aby z toho mohl být vyvozen nějaký konkrétní závěr. Všechny tři metody vykazují podobné hodnoty přesnosti, a tak nelze žádnou z nich označit za lepší než jinou. Tyto metody je možné kombinovat při vytváření modelů terénních útvarů.

ID bodu	Xerr [m]	Yerr [m]	Zerr [m]	Error [m]
1	0,006	0,007	-0,017	0,019
2	0,03	-0,004	0,013	0,033
3	-0,032	-0,036	-0,001	0,048
4	-0,054	-0,033	0,032	0,071
5	-0,048	0,002	-0,039	0,062
6	-0,041	-0,049	-0,085	0,106
TotalError	0,038	0,028	0,041	0,063

Tab. 7: Odchylky pro model z TLS

ID bodu	Xerr [m]	Yerr [m]	Zerr [m]	Error [m]
1	-0,074	0,052	0,015	0,123
2	-0,052	0,009	-0,069	0,133
3	-0,036	-0,067	-0,077	0,183
4	-0,019	0,064	-0,042	0,106
5	-0,055	-0,081	-0,032	0,103
6	-0,001	0,003	-0,046	0,056
TotalError	0,046	0,054	0,051	0,088

Tab. 8: Odchylky pro model z UAV

ID bodu	Xerr [m]	Yerr [m]	Zerr [m]	Error [m]
1	-0,032	0,067	0,021	0,077
2	0,05	0,067	-0,069	0,108
3	-0,037	-0,063	0,045	0,086
4	0,025	0,031	0,062	0,074
5	-0,055	0,063	-0,06	0,103
6	-0,021	0,018	-0,042	0,050
TotalError	0,039	0,055	0,052	0,085

Tab. 9: Odchylky pro model z poz. fotogrammetrie

6 Diskuze

Podle očekávání žádná metoda nedokázala nasnímat celý povrch skály, proto je nutná kombinace metod pro tvorbu celého modelu povrchu. Přesnost těchto metod je u takových typů objektů velice podobná, a tak je možné tyto metody kombinovat. Dosažená přesnost koresponduje s přesnostmi obecně uváděnými v literatuře. Výběr metod by však měl vždy zohledňovat potřebné míry detailů a tvar daného objektů.

Nutné je také zvážit časovou náročnost jednotlivých metod. Z této práce vyplývá, že lze metody seřadit podle časové náročnosti od nejmenší po největší na UAV fotogrammetrie, laserové skenování a pozemní fotogrammetrie. Toto však neplatí obecně. Při registraci laserových dat se objevilo několik nečekaných překážek. Hlavním zpomalením procesu registrace byl pohyb referenčních terčů během sběru dat a nekompatibilita jednotlivých softwarů a datových formátů, které zpomalovaly celý proces práce. Při importu skenů do programu Leica Cyclone bylo nutné nejprve importovat skeny z přístroje Faro ve formátu *FLS* do programu CloudCompare a následně je exportovat do formátu *E57*. Toto bylo pro skeny v plné velikosti velice náročné, hlavně kvůli opakovaným pádům programu CloudCompare. Velkou výhodou UAV fotogrammetrie je dostupnost informací o pozici kamery v době pořízení snímku, čímž se snižuje celková výpočetní náročnost při orientování snímků, a tím se i zkracuje celkový čas zpracování. Vzniklé komplikace při tvorbě modelu z pozemního snímkování lze částečně připsat ne úplně ideálním snímkům.

Výsledná kvalita modelů je také ovlivněna meteorologickými podmínkami v den sběru dat. Jak už bylo zmíněno, v době měření vanul silný vítr, důsledkem čehož došlo k pohybu referenčních terčů. Kromě toho také docházelo k pohybu větví stromů a většina větví na skenech má barvu oblohy. To je způsobeno tím, že skener nejprve provádí laserové měření a pořizování snímků probíhá až nakonec. Tím dochází tomu, že větvím při pohybu není přiřazena správná barva. Sběr dat pomocí UAV probíhal téměř o tři týdny později než zbývajícími metodami. V té době už většině stromům začalo růst olistění, a proto se na těchto datech nachází více zelené vegetace než na ostatních mračcích.

Preprocessingové filtry dokázaly z bodových mračen odstranit mnoho nepotřebných dat. Velké množství bodů se podařilo odstranit ze skenů, které se nacházely v těsné blízkosti skály, a tudíž úhel dopadajících paprsků na horní část byl velký. Podařilo se také odstranit mnoho odlehlých a osamocených bodů. Důležité při tomto kroku bylo také snížení hustoty

bodového mračna. Mračno v některých částech obsahovalo přebytečné množství bodů, které u takových typu objektů není potřeba. Použité filtrační funkce nejsou přímo zaměřené na bodová mračna terénních útvarů a je možné je použít pro bodové mračno jakéhokoliv objektu. Výběr hodnot pro jednotlivé filtry byl subjektivní. Byly voleny hodnoty, které se hodily pro tuto konkrétní práci. V současnosti neexistuje žádný univerzální klíč, který by umožňoval tyto hodnoty určit. Existuje velké množství faktorů, které výběr hodnot ovlivňují. Kromě použitého skeneru, záleží taktéž na skenovacích podmínkách a vlastnostech skenovaného materiálu. Největší překážkou však představuje samotný tvar skály, každá skála je originální a pro podrobné mapování je vždy nutné vybrat hodnoty, které se nejvíce hodí pro konkrétní skálu.

ExG byl neúčinnější pro data z UAV, kdy se podařilo odstranit téměř veškerou zelenou vegetaci a počet bodů se v tomto mračnu snížil z 5 784 148 na 2 031 027. Mračno ale také obsahovalo největší množství zelené vegetace. Tímto byl potvrzena teze, která ke často zmiňovaná v literatuře (Ponti 2012, Anders et al. 2019), že ExG index dokáže spolehlivě oddělit zelenou vegetaci od ostatních typů povrchů pouze pomocí R, G, B hodnot. Pomocí algoritmu DBSCAN se nejlépe podařilo odstranit vegetaci, která se přímo nedotýkala povrchu skály. Výběrem vhodných parametrů se na některých skenech podařilo odstranit téměř veškerou vegetaci. Nevýhodou bylo, že ideální parametry pro všechna mračna nebyly stejné a musela být vždy provedena vizuální kontrola po každém klastrování. Algoritmus je velice citlivý na vstupní parametry. Díky tomu, že všechny mračna měly ve všech částech přibližně stejnou vzdálenost mezi body, a tudíž nevznikaly menší klastry uvnitř větších, byly tyto parametry pro všechny mračna velice podobné. V případě, že by nebylo nutné najít pro každé mračno tu nejvhodnější kombinaci, bylo by možné vytvořit průměr ze všech vstupních hodnot. Odstranění malých větví je poměrně jednoduché. Problém představují tlusté větve a kmeny stromů, které tvoří velké klastry a není možné je automaticky odlišit od klastrů skály na základě jejich velikosti. K tomuto závěru došli i autoři Kisztner et al. (2016). Cílem tohoto kroku nebylo odstranění veškeré vegetace, ale dosáhnout co nejlepšího možného výsledku a zachovat zároveň co největší množství bodů náležících ke skále.

Pomocí Houghovy transformace se nepodařilo identifikovat žádný kmen stromů. Na vině zde není nevhodnost Houghovy transformace pro identifikace kmenů stromů. Existuje mnoho prací, v kterých se touto metodou podařilo kmeny úspěšně identifikovat (Aschoff a

Spiecker 2004, Huang et al. 2011). Rozdíl mezi těmito pracemi a touto diplomovou prací je, že v jejich případě nebyla snaha o odstranění kmenů jakožto nadbytečné informace v mračnu, ale určení průměru těchto kmenů. To znamená, že i jejich měření bylo primárně zaměřené na kmeny stromů. Při vlastním sběru dat byla snaha minimalizovat plochu nasnímané vegetace. Dalším velkým rozdílem je, že ve většině těchto prací byla provedena měření v ideálně vzrostlém lese s malým množstvím nízké vegetace a na rovném terénu. Na základě výsledků této práce lze tvrdit, že použití této metody pro identifikaci a filtraci kmenů stromů ve svažitém terénu není vhodné. Tímto byla potvrzena teze autorů Porotti et al. (2013), že filtraci stromů pomocí Houghovy transformace není možné použít, pokud stromy rostou na svazích.

Filtrování vegetace z bodových mračen je velice náročný úkon, a to zvláště z dat pozemního laserového skenování a fotogrammetrických metod. Jakýkoliv automatický postup musí být vysoce adaptivní pro různé typy a tvary povrchů. V současnosti neexistuje žádná metoda, která by dokázala automaticky odstranit veškerou vegetaci z těchto dat. Většina autorů proto ve svých pracích doporučuje používat alternativní metody. Alba et al. (2009) doporučují integraci multispektrálních kamer do procesu skenování. Multispektrální kamery mohou značně pomoci při identifikaci vegetace a jejich následné filtraci. Pirotti et al. (2013) doporučují pro lepší extrakci terénu používat skenovací zařízení, které dokáže zaznamenávat více odrazů. Tyto nástroje však nejsou vždy k dispozici, a proto je nutné vytvořit metodu, která dokáže filtrovat vegetaci i z dat pořízených „klasickými metodami“.

7 Závěr

Tato diplomová práce se zabývá problematikou mapování skalních útvaru pomocí dat pořízených pozemním laserovým skenerem, pozemní fotogrammetrií, UAV a klasickým geodetickým měřením, které bylo následně použito ke kontrole dosažených výsledků. Při zpracování bodového mračka byl kladen důraz na využití filtrace vegetace k lepšímu a detailnějšímu modelu. Testování bylo provedeno na vybrané lokalitě, kterou byl skalní útvar v NP České Švýcarsko.

V teoretické části lze nalézt používané metody pro vytváření 3D bodových mraček a možnosti jejich filtrací. V praktické části, kde je mimo jiné popsán sběr dat, pak byly tyto metody použity pro tvorbu 3D modelů skalního útvaru. Následně bylo zhotoveno několik bodových mraček. Pro tvorbu těchto mraček byly použity programy Leica Cyclone a Agisoft metashape. V práci jsou popsány jednotlivé nástroje použité při tvorbě bodových mraček. Tato bodová mračka byla následně filtrována podle navrženého filtračního postupu. Filtrační funkce jsou rozdělené do dvou skupin – na obecné filtry bodových mraček a filtry vegetace. V práci je vždy popsán účel jednotlivých filtračních funkcí.

Vytvořené modely byly nejprve srovnány mezi sebou a následně byla provedena kontrola dosažené přesnosti s geodetickým zaměřením. Přesnost jednotlivých metod byla velice podobná, kdy směrodatná odchylka souřadnic pro laserové skenování byla 0,075 m, pro pozemní fotogrammetrii 0,067 m a pro UAV fotogrammetrii 0,07 m. U modelu z laserových dat schází hlavně vrchní část a u modelu z UAV snímků chybí téměř celá pravá dolní strana. Na modelu z pozemní fotogrammetrie schází vrchní strana a velká část pravé strany. Díky kombinaci těchto metod se však podařilo nasnímat téměř celý povrch skalního útvaru.

Vlastní použité filtrační funkce dosáhly lepšího výsledku než dostupné automatické funkce, protože v modelech byla zachována velká část skály. Na rozdíl od použitých filtračních funkcí, dostupné funkce z programu CloudCompare a Lastools nedokázaly zachovat celou plochu skály, což z nich dělá nevhodné metody. Tyto metody jsou však primárně zaměřené na data z LLS. Postprocessingové filtry odstranily 64 734 820 bodů z původních 108 005 738 bodů ze všech mraček. Jednalo se o šumové body a některá nepřesná měření, která není možné odstranit manuální filtrací. Pomocí filtrů byla také snížena hustota bodového mračka na minimální vzdálenost mezi body na 5 mm. ExG

dokázal velice spolehlivě odstranit zelenou část vegetace. Celkem bylo odstraněno 9 397 763, jejichž hodnota ExG hodnota byla nižší než 0,04. Nejúspěšnější byl index na datech z UAV, kde se nacházelo nejvíce zelené vegetace. Odstraňování menších klastrů vytvořených klastrovacím algoritmem DBSCAN se ukázalo být vhodnou metodou při odstraňování menších větví, které nebyly v přímém kontaktu s povrchem skály. Z celkového počtu 24 375 vytvořených klastrů bylo zachováno pouze 332 největších klastrů. Tyto klastry obsahují převážně body zachycující skalní útvar. Metoda Houghovy transformace nedokázala identifikovat žádné kmeny stromů v celém bodovém mračku a bylo tím potvrzeno, že se metoda nehodí pro identifikaci kmenů ve svažitém terénu. Navržený filtrační postup bez Houghovy transformace lze použít hlavně v případech, kdy se skalní útvar nenachází v hustě vegetací pokrytém terénu. Použitá filtrační metoda zaostává za manuální filtrací, pomocí které je možné odstranit téměř veškerou vegetaci. Manuální filtrace je však časově velice náročná.

Kombinace ExG indexu a algoritmu DBSCAN přináší úspěch, přestože jen částečný. V této práci jsou tyto metody používány sekvenčně. Prostor pro další výzkum nabízí možnost zařazení ExG indexu přímo do procesu klastrování algoritmu DBSCAN, kde by byl každý bod shlukován nejen na základě jeho prostorových souřadnic, ale také podle jeho hodnoty indexu.

8 Zdroje

- AOPK ČR (2020): Zonace velkoplošných zvláště chráněných území. Agentura ochrany přírody a krajiny ČR. Dostupné z: <http://gis-aopkcr.opendata.arcgis.com/> (cit. 2020.07.20).
- AGISOFT LLC (2020): Agisoft Metashape User Manual: Professional Edition, Version 1.6. Dostupné z: http://www.agisoft.com/pdf/photoscan-pro_1_2_en.pdf (cit. 2020.07.02).
- ALBA, M., et al. (2009): Application of TLS for change detection in rock faces. Proceedings of the International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Paris, France, 38, 3, s. 99-104.
- ANDERS, Niels, et al. (2019): Comparing Filtering Techniques for Removing Vegetation from UAV-Based Photogrammetric Point Clouds. Drones, 3, 3, s. 61-75.
- ASCHOFF, T., SPIECKER, H. (2004): Algorithms for the automatic detection of trees in laser scanner data. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 36, 8, s. 71-75.
- BANNARI, A., et al. (1995): A review of vegetation indices. Remote sensing reviews, 13, 1-2, s. 95-120.
- BASHIR, F. A. (2018): Aplikace geoinformatiky v antropologii. Bakalářská práce. Katedra aplikované geoinformatiky a kartografie PŘF UK, Praha, 68 s.
- BEMIS, S. P., et al. (2014): Ground-based and UAV-based photogrammetry: A multi-scale, high-resolution mapping tool for structural geology and paleoseismology. Journal of Structural Geology, 69, s. 163-178.
- BITELLI, G., et al. (2004): Terrestrial laser scanning and digital photogrammetry techniques to monitor landslide bodies. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 35, 5, s. 246-251.
- BOARDMAN, C., BRYAN, P. (2018): 3D laser scanning for heritage: Advice and guidance on the use of laser scanning in archaeology and architecture. Historic England. 113 s.
- BOEHLER, W., et al. (2002): The potential of non-contact close range laser scanners for cultural heritage recording. International archives of photogrammetry remote sensing and spatial information sciences, 34, 5, s. 430-436.
- BORNAZ, L., et al. (2003): Multiple scan registration in lidar close-range applications. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 34, 5, s. 72-77.

BORRMANN, D., et al. (2011): The 3d hough transform for plane detection in point clouds: A review and a new accumulator design. 3D Research, 2, 2, s. 1-12.

BÖHM, J. (2002): Fotogrammetrie. vydavatelství VŠB – TUO, Ostrava, 16 s.

BOUDREAU, J., et al. (2008): Regional aboveground forest biomass using airborne and spaceborne LiDAR in Québec. Remote Sensing of Environment, 112, 10, s. 3876-3890.

CARTER, W. E., et al. (2007): Geodetic laser scanning. Physics Today, 60, č. 12, s. 41-47.

CloudCompare (2016): User's Manual. Dostupné z: <http://www.danielgm.net/cc/> (cit. 2020.07.28)

COLLINS, R. (2020): Robust Estimation: RANSAC. Dostupné z: <http://www.cse.psu.edu/~rtc12/CSE486/lecture15.pdf> (cit. 2020.07.21)

DERPANIS, K. G. (2010): Overview of the RANSAC Algorithm. Image Rochester NY, 4, 1, s. 2-3.

DJI (2020): Phantom 4 PRO. Dostupné z: <https://www.dji.com/cz/phantom-4-pro/info> (cit. 2020-07-20).

Dung, H. T., Lee, S. (2015): Outlier removal based on boundary order and shade information in structured light 3D camera. In 2015 IEEE 7th international conference on cybernetics and intelligent systems (CIS) and IEEE conference on robotics, automation and mechatronics (RAM), s. 124-129.

FARO TECHNOLOGIES (2015): FARO Laser Scanner Focus3D X 130 Manual. Dostupné z: https://knowledge.faro.com/Hardware/Laser_Scanner/Focus/User_Manuals_for_the_Focus3D_X_130_or_130_HDR (cit. 2020.07.21).

FRÖHLICH, C., et al. (2004): Terrestrial laser scanning—new perspectives in 3D surveying. International archives of photogrammetry, remote sensing and spatial information sciences, 36, 8, s. 7-13.

GE, X., WUNDERLICH, T. (2015): Target identification in terrestrial laser scanning. Survey Review, 47, 341, s. 129-140.

GEOOBCHOD (2020): TOTÁLNÍ STANICE TRIMBLE M3. Dostupné z: <https://www.geoobchod.cz/cs/totalni-stanice-trimble-m3-5cc/product> (cit. 2020.10.29).

GLENNIE, C. L., et al. (2013): Geodetic imaging with airborne LiDAR: the Earth's surface revealed. Reports on Progress in Physics, 76, 8, 25 s.

GONÇALVES, J. A., HENRIQUES, R. (2015): UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS journal of Photogrammetry and Remote Sensing*, 104, s. 101-111.

GORDON, S. J., LICHTI, D. D. (2004): Terrestrial laser scanners with a narrow field of view: the effect on 3D resection solutions. *Survey Review*, 37, 292, s. 448-468.

GOSH, S. (1981). History of photogrammetry. Laval University, Canada. s. 311-327.

HAN, X.-F., et al. (2017): A review of algorithms for filtering the 3D point cloud. *Signal Processing: Image Communication*, 57, s. 103-112.

GRUSSENMEYER, P., et al. (2018): Basics of range-based modelling techniques in Cultural Heritage. *3D Recording, Documentation and Management in Cultural Heritage*, s. 305-368.

HUANG, H., et al. (2011): Automated methods for measuring DBH and tree heights with a commercial scanning lidar. *Photogrammetric Engineering & Remote Sensing*, 77, 3, s. 219-227.

HUBER, D. (2011): The ASTM E57 file format for 3D imaging data exchange. In: *Three-Dimensional Imaging, Interaction, and Measurement*. International Society for Optics and Photonics. 7864.

HYDRALAB+ (2019): Terrestrial Laser Scanning. Dostupné z: http://wiki.hydralab.eu/index.php?title=Terrestrial_Laser_Scanning (cit. 2020.07.05).

JACOBS, G. (2005): Registration and Geo-referencing. *Professional Surveyor Magazine*, s. 30-37.

JAIN, A. K., (2010): Data clustering: 50 years beyond K-means. *Pattern recognition letters*. 31, 8, s. 651-666.

KASHANI, A. G., et al. (2015): A review of LiDAR radiometric processing: From ad hoc intensity correction to rigorous radiometric calibration. *Sensors*, 15, 11, s. 28099-28128.

KAZHDAN, M., et al. (2006): Poisson surface reconstruction. *Proceedings of the fourth Eurographics symposium on Geometry processing*. Eurographics Association, s. 61-70.

KILIAN, J., et al. (1996): Capture and evaluation of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing*, 31, s. 383-388.

KISZTNER, J., et al. (2016): 3D documentation of outcrop by laser scanner—Filtration of vegetation. *Perspectives in Science*, 7, s. 161-165.

KRAUS, K. (2007): *Photogrammetry: geometry from images and laser scans*. Walter de Gruyter, Berlin, 459 s.

- KROMER, R. A., et al. (2015): A 4D filtering and calibration technique for small-scale point cloud change detection with a terrestrial laser scanner. *Remote Sensing*, 7, 10, s. 13029-13052.
- LERMA, J. L., et al. (2010): Terrestrial laser scanning and close range photogrammetry for 3D archaeological documentation: the Upper Palaeolithic Cave of Parpalló as a case study. *Journal of Archaeological Science*, 37, 3, s. 499-507.
- LICHTI, D. D., HARVEY, B. R. (2002): "The effects of reflecting surface material properties on time-of-flight laser scanner measurements." n *Proceedings of ISPRS Commission IV Symposium 2002 on Geospatial Theory, Processing and Applications*, Ottawa, Canada, 9–12 July 2002, 34, 9 s.
- LIM, M., et al. (2005): Combined digital photogrammetry and time-of-flight laser scanning for monitoring cliff evolution. *The Photogrammetric Record*, 20, 110, s. 109-129.
- LIN, Y.-J., et al. (2016): Planar-based adaptive down-sampling of point clouds. *Photogrammetric Engineering & Remote Sensing*, 82, 12, s. 955-966.
- LUHMANN, T. et al. (2006): *Close range photogrammetry: principles, techniques and applications*. Whittles Publishing, Dunbeath, 510 s.
- LYSÁK, Jakub. (2016): *Topografické mapování skalních útvarů s využitím dat leteckého laserového skenování*. Dizertační práce. Katedra aplikované geoinformatiky a kartografie PŘF UK, Praha, 248 s.
- MAAS, H.-G., et al. (2008): Automatic forest inventory parameter determination from terrestrial laser scanner data. *International journal of remote sensing*, 29, 5, s. 1579-1593.
- MARSHALL, G. F., STUTZ, G. E. (2011): *Handbook of optical and laser scanning*. CRC Press, Boca Raton, 788 s.
- MATHYS, A., et al. (2013): Comparing 3D digitizing technologies: what are the differences?. *Digital Heritage International Congress IEEE*, s. 201-204.
- MEIGS, A. (2013): Active tectonics and the LiDAR revolution. *Lithosphere*, 5, č. 2, s. 226-229.
- MENG, X., et al. (2010): Ground filtering algorithms for airborne LiDAR data: A review of critical issues. *Remote Sensing*, 2, 3, s. 833-860.
- MIŘIJOVSKÝ, J. (2013): *Fotogrammetrický přístup při sběru geodat pomocí bezpilotních leteckých zařízení*. Disertační práce. Katedra geoinformatiky přírodovědecké fakulty. Univerzita palackého v Olomouci, Olomouc, 35 s.

MILLS, J., ANDREWS, D. (2011): 3D Laser Scanning for Heritage: Advice and guidance to users on laser scanning in archaeology and architecture. Dostupné z: <https://historicengland.org.uk/images-books/publications/3d-laser-scanning-heritage/> (cit. 2018.04.08).

MONGUS, D., ŽALIK, B. (2011): Efficient method for lossless LIDAR data compression. *International journal of remote sensing*, 32, 9, s. 2507-2518.

NIKON CORPORATION (2014): Návod k obsluze Nikon D750. Dostupné z: <http://www.nikonclub.cz/files/clanky/manualy/D750.pdf> (cit. 2020.07.21).

NUMPY (2020): NumPy: The fundamental package for scientific computing with Python. Dostupné z: <https://numpy.org/> (cit. 2020.07.21).

OPEN3D (2020): Open3D: A Modern Library for 3D Data Processing. Dostupné z: <http://www.open3d.org/docs/release/index.html> (cit. 2020.07.21).

OPENCV (2020): Open Source Computer Vision Library. Dostupné z: <https://opencv.org/about/> (cit. 2020.07.21).

PALEČEK, V., KUBÍČEK, P. (2018): Assessment of accuracy in the identification of rock formations from aerial and terrestrial laser-scanning data. *ISPRS International Journal of Geo-Information*, 7, 4, s. 142-161.

PAVELKA, K. (2009): *Fotogrammetrie 1*. 1. Nakladatelství ČVUT, Praha, 200 s.

PESCI, A., et al. (2011): Terrestrial laser scanner resolution: Numerical simulations and experiments on spatial sampling optimization. *Remote Sensing*, 3, 1, s. 167-184.

PFEIFER, N., WINTERHALDER, D. (2004): Modelling of tree cross sections from terrestrial laser scanning data with free-form curves. *International Archives of Photogrammetry, remote sensing and spatial information sciences*, 36, 8, s. 76-81.

PFEIFER, N., BRIESE, C. (2007): *Laser scanning—principles and applications*. GeoSiberia 2007 International Exhibition and Scientific Congress.

PIROTTI, F., et al. (2013): Ground filtering and vegetation mapping using multi-return terrestrial laser scanning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 76, s. 56-63.

PONTI, M. P. (2012): Segmentation of low-cost remote sensing images combining vegetation indices and mean shift. *IEEE Geoscience and Remote Sensing Letters*, 10, 1, s. 67-70.

PUTTONEN, E., et al. (2013): Improved sampling for terrestrial and mobile laser scanner point cloud data. *Remote Sensing*, 5, 4, s. 1754-1773.

PYE57 (2020): Python wrapper of LibE57Format to read and write .e57 point cloud files. Dostupné z: <https://pypi.org/project/pye57/> (cit. 2020.07.21).

REMONDINO, F., et al. (2011): UAV photogrammetry for mapping and 3d modeling—current status and future perspectives. *International archives of the photogrammetry, remote sensing and spatial information sciences*, 38, 1, s. 25-31.

RESHETYUK, Y. (2009): Self-calibration and direct georeferencing in terrestrial laser scanning. PhD dissertation. KTH, Stockholm. 162 s.

RUSU, R. B., et al. (2008): Towards 3D point cloud based object maps for household environments. *Robotics and Autonomous Systems*, 56, 11, s. 927-941.

SCHALL, O., et al. (2008): Adaptive feature-preserving non-local denoising of static and time-varying range data. *Computer-Aided Design*, 40, 6, s. 701-707.

SCHUBERT, E., et al. (2017): DBSCAN revisited, revisited: why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems (TODS)*, 42, 3, s. 1-21.

SCHUHMACHER, S., BÖHM, J. (2005): Georeferencing of terrestrial laserscanner data for applications in architectural modeling.

SCIPY (2020): SciPy: Scientific computing tools for Python. Dostupné z: <https://www.scipy.org/about.html> (cit. 2020.07.21).

SHAN, J., TOTH, C. K. (2018): Topographic laser ranging and scanning: principles and processing. CRC press, Boca raton. 590 s.

SIMONSE, M., et al. (2003): Automatic determination of forest inventory parameters using terrestrial laser scanning. In: *Proceedings of the scandlaser scientific workshop on airborne laser scanning of forests*. Umeå: Sveriges Lantbruksuniversitet, s. 252-258.

SITHOLE, G., VOSSelman, G. (2004) Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds. *ISPRS journal of photogrammetry and remote sensing*, 59, 1-2, s. 85-101.

SLOB, S., HACK, R. (2004): 3D terrestrial laser scanning as a new field measurement and monitoring technique. In: *Engineering geology for infrastructure planning in Europe*. Springer, Berlin, Heidelberg, s. 179-189.

SNAVELY, N., et al. (2008): Modeling the world from internet photo collections. *International journal of computer vision*, 80, 2, s. 189-210.

- SONG, H., FENG, H.-Y. (2009): A progressive point cloud simplification algorithm with preserved sharp edge data. *The International Journal of Advanced Manufacturing Technology*, 45, 5-6, s. 583-592.
- SLOUDARISSANANE, S., et al. (2009): Incidence angle influence on the quality of terrestrial laser scanning points. In: *Proceedings ISPRS Workshop Laserscanning*. Paris, France.
- SLOUDARISSANANE, S., et al. (2011): Scanning geometry: Influencing factor on the quality of terrestrial laser scanning points. *ISPRS journal of photogrammetry and remote sensing*, 66, 4, s. 389-399.
- STURZENEGGER, M., STEAD, D. (2009): Close-range terrestrial digital photogrammetry and terrestrial laser scanning for discontinuity characterization on rock cuts. *Engineering Geology*, 106, 3-4, s. 163-182.
- TELLING, J., et al. (2017): Review of Earth science research using terrestrial laser scanning. *Earth-Science Reviews*, 169, s. 35-68.
- TOTH, C. (2004): Future trends in lidar. In: *Proc. ASPRS 2004 Annual Conference*, Denver, CO, May, s. 23-28.
- UYSAL, M. (2015): DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill. *Measurement*, 73, s. 539-543.
- VAN LEEUWEN, M. et al. (2010): Canopy surface reconstruction from a LiDAR point cloud using Hough transform. *Remote Sensing Letters*, 1, 3, s. 125-132.
- VENTURA, G., et al. (2011): Tracking and evolution of complex active landslides by multi-temporal airborne LiDAR data: The Montaguto landslide Southern Italy. *Remote Sensing of Environment*, 115, 12, s. 3237-3248.
- VLACH, J. (2011): Hledání úseček a kružnic s využitím Houghovy transformace při zpracování obrazu v LabView. *Automa*, Únor, s. 42-44.
- VO, A.-V., et al. (2015): Octree-based region growing for point cloud segmentation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 104, s. 88-100.
- VOSELMAN, G., MAAS, H.-G. (2010): *Airborne and terrestrial laser scanning*. CRC press, Boca Raton, 318 s.
- WANG, C., et al. (2019): An improved DBSCAN method for LiDAR data segmentation with automatic Eps estimation. *Sensors*, 19, 1, s. 172.
- WESTOBY, M. J., et al. (2012): 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, s. 300-314.

YUEN, H. K., et al. (1990): Comparative study of Hough transform methods for circle finding. *Image and vision computing*, 8, 1, s. 71-77.

ZHANG, W., et al. (2016): An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing*, 8, 6, s. 501-523.

9 Přílohy

Příloha 1: Model vytvořený ze všech mračen bez filtrace

Příloha 2: Model vytvořený z dat laserového skenování a filtrován navrženou metodou

Příloha 3: Model vytvořený z dat laserového skenování a filtrován manuální metodou

Příloha 4: Model vytvořený z dat pozemní fotogrammetrie a filtrován navrženou metodou

Příloha 5: Model vytvořený z dat pozemní fotogrammetrie a filtrován manuální metodou

Příloha 6: Model vytvořený z dat UAV fotogrammetrie a filtrován navrženou metodou

Příloha 7: Model vytvořený z dat UAV fotogrammetrie a filtrován manuální metodou


Příloha 8: Model vytvořený ze všech mračen filtrovaných navrženou metodou

Příloha 9: Model vytvořený ze všech mračen filtrovaných manuální metodou

Příloha 10: Cloud disk:

- Webová adresa: <https://mega.nz/>
- Email: DPbashir.skala@gmail.com
- Heslo: *DP_Priloha9_skala*
- struktura – Data z laserového skenování, Snímky z pozemní fotogrammetrie, Snímky z UAV fotogrammetrie, Protokol z GNSS měření, Podrobné body, Projekty, Skripty, Vytvořené modely

Příloha 1: Model vytvořený ze všech mračen bez filtrace




Příloha 2: Model vytvořený z dat laserového skenování a filtrován automatickou metodou



Příloha 3: Model vytvořený z dat laserového skenování a filtrován manuální metodou



Příloha 4: Model vytvořený z dat pozemní fotogrammetrie a filtrován navrženou metodou



Příloha 5: Model vytvořený z dat pozemní fotogrammetrie a filtrován manuální metodou



Příloha 6: Model vytvořený z dat UAV fotogrammetrie a filtrován navrženou metodou



Příloha 7: Model vytvořený z dat UAV fotogrammetrie a filtrován manuální metodou



Příloha 8: Model vytvořený ze všech mračen filtrovaných navrženou metodou



Příloha 9: Model vytvořený ze všech mračen filtrovaných manuální metodou

