

**UNIVERZITA PARDUBICE  
FAKULTA ELEKTROTECHNIKY A INFORMATIKY**

**Disertační práce**

**Systém automatického mapování 3D prostoru**

**Autor: Ing. Pavel Chmelař  
Školitel: Ing. Martin Dobrovolný, Ph.D.**

**Pardubice, 2018**

Prohlášení autora:

Prohlašuji, že jsem tuto práci vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Souhlasím s prezenčním zpřístupněním své práce v Univerzitní knihovně.

V Pardubicích dne 19. 11. 2018

podpis autora

Ing. Pavel Chmelař

## **Poděkování**

Tímto bych rád poděkoval vedoucímu práce Ing. Martinovi Dobrovolnému, Ph.D. za odborné vedení práce, náměty, připomínky a pomoc zejména v počáteční fázi práce, která určila směr zkoumané problematiky.

Velký dík patří Dr. Absamadu Benkridovi z Univerzity Portsmouth v Anglii za jeho odborné vedení během dvou pracovních stáží, příkladnou ukázkou řízení projektu, konzultace při řešení problémů, spolupráci a odbornou pomoc při vývoji algoritmů, které jsou součástí dizertační práce.

Děkuji rovněž všem ostatním, kteří mně jakkoliv pomáhali a podporovali, aby práci bylo možné dokončit a publikovat.

Děkuji své rodině za podporu a trpělivost poskytnutou při jejím zpracování a kompletaci. Velké díky patří i mým rodičům za jejich veškerou pomoc a podporu při studiu, nejen finanční, bez kterých by tato práce vůbec nevznikla.

## **Anotace**

Práce je tematicky orientována do oblasti systémů automatizovaného skenování a mapování třírozměrných prostorů s využitím fúze obrazových a dálkoměrných senzorů. Obsahuje tři hlavní části zahrnující popis vlastního navrženého optického skeneru prostředí, registraci mračen bodů a jejich zpracování pro základní detekci objektů se stanovením prostorových parametrů, vizualizaci a redukci popisných bodů. První část je zaměřena na popis vlastního optického skeneru prostředí a tvorbu výstupního barevného mračna bodů z měřicích snímků. Segmentace laserové čáry pomocí Gaussian mixture modelu, výběr nejlepšího laserového elementu a určení jeho středu je detailně vysvětlena. Druhá část se zabývá předzpracováním mračen bodů, registrací individuálních skenů z různých míst v prostředí. Dvě hlavní metody ICP a NDT jsou porovnány na sestavení uceleného mračna bodů z rozsáhlého patra budovy. V poslední části jsou představeny navržené metody pro zpracování mračen bodů zahrnující tvorbu hloubkového obrazu z libovolné pozice v mračnu bodů se zvolenou orientací virtuální kamery. Rovněž popisuje nový navržený koncept zpracování mračen bodů pomocí úrovněového obrazu a prostorové analýzy dat pro detekci rovin, jejich zpracování, vektorizaci a barevnou vizualizaci. Dosažené výsledky jsou ověřeny a porovnány na skutečném prostředí.

## **Klíčová slova**

laserové měření vzdálenosti, skenování prostoru, mračno bodů, registrace, úrovněový obraz, zpracování obrazu, vektorizace, vizualizace, prostorový popis

## **Title**

The System of Automatic 3D Space Mapping

## **Annotation**

This thesis is oriented into the automatic 3D space scanning and mapping area using rangefinders and an image data fusion. It contains three main parts including description of own developed optical rangefinder, point cloud registration and its processing for basic object detection with space features estimation, visualization and their point's amount reduction. The first part focusses on own developed optical rangefinder and its color point cloud construction from the measurement frames. A laser line color segmentation by the Gaussian Mixture Model, a best laser element selection on a measurement position and its center estimation is explained in details. The second part deals with a point cloud preprocessing and a registration of individual scans from different positions in a space. The two main approaches ICP and NDT are compared on a large building floor. In the last part are introduced developed methods for a point cloud processing including the method for the depth map construction from any position with arbitrary orientation of a virtual camera in a point cloud. It describes also a new point cloud processing concept by using the level image and the 3D space analysis for the plane detection, processing, vectorization and visualization. All results are verified and compared against a real space.

## **Key words**

laser distance measurement, space scanning, point cloud, registration, level image, image processing, vectorization, visualization, space description



# Obsah

Seznam zkratk.....	8
<b>1 Úvod a cíle práce.....</b>	<b>9</b>
<b>2 Mapování prostoru.....</b>	<b>11</b>
<b>2.1 Zpracování naměřených dat a detekce objektů.....</b>	<b>11</b>
<b>2.2 Vizualizace prostředí a objektů.....</b>	<b>13</b>
<b>2.3 Registrace naměřených dat .....</b>	<b>14</b>
2.3.1 ICP (Iterative Closest Points) .....	15
2.3.2 NDT (Normal Distribution Transform).....	15
2.3.3 Další algoritmy registrace bodů.....	17
<b>3 Bezdotykové systémy měření vzdálenosti.....</b>	<b>19</b>
<b>3.1 Mobilní platforma mapování prostoru.....</b>	<b>21</b>
3.1.1 Základní popis platformy .....	21
3.1.2 Kalibrace a zkreslení přesnosti vlivem vzdálenosti.....	24
<b>3.2 Barelové zkreslení.....</b>	<b>26</b>
3.2.1 Korekce barelového zkreslení .....	26
3.2.2 Optimální parametr korekce barelového zkreslení.....	28
3.2.3 Korekční matice.....	30
<b>3.3 Zkreslení chromatické aberace .....</b>	<b>31</b>
<b>3.4 Detekční algoritmus laserové čáry .....</b>	<b>32</b>
3.4.1 Vstupní úprava měřicího snímku.....	33
3.4.2 Barevné modely pro detekci laserové čáry.....	34
<b>3.5 Gaussian Mixture Model .....</b>	<b>35</b>
3.5.1 Trénování modelu GMM - Expectation Maximization.....	37
3.5.2 Určení nejlepšího počtu rozdělení .....	39
<b>3.6 Skládání detekčních masek laseru .....</b>	<b>40</b>
<b>3.7 Určení měřicí pozice laserové čáry.....</b>	<b>50</b>
3.7.1 Statistická analýza tvaru a obsahu laserového elementu.....	52
<b>3.8 Tvorba prostorové mapy .....</b>	<b>55</b>
3.8.1 Využití barevné informace .....	57
<b>3.9 Korekce měření při chybné kalibraci .....</b>	<b>60</b>
<b>3.10 Praktické výsledky optického měřiče vzdálenosti .....</b>	<b>63</b>
3.10.1 Přesnost měřicího systému .....	63
3.10.2 Praktické porovnání detekčních modelů .....	66
<b>4 Transformace mračen bodů .....</b>	<b>69</b>
<b>4.1 Vícero souřadnicových prostorů .....</b>	<b>69</b>
4.1.1 Globální souřadnicový prostor (World Space).....	70
4.1.2 Souřadnicový prostor objektu (Object Space).....	70
4.1.3 Vertikální souřadnicový prostor (Upright Space) .....	70
<b>4.2 Lineární transformace prostřednictvím matice.....</b>	<b>71</b>
4.2.1 Afinní transformace .....	71

4.2.2	Inverzní transformace .....	71
4.2.3	Ortogonální transformace .....	72
<b>4.3</b>	<b>Základní lineární transformace pomocí matice.....</b>	<b>72</b>
4.3.1	Rotace 2D .....	72
4.3.2	Rotace 3D .....	72
4.3.3	Zkosení 3D .....	73
4.3.4	Kombinace transformačních matic .....	73
<b>4.4</b>	<b>Transformace souřadnicového prostoru .....</b>	<b>73</b>
<b>4.5</b>	<b>Matice 4 x 4 .....</b>	<b>75</b>
4.5.1	4D homogenní prostor .....	75
4.5.2	Afinní transformace pomocí matice 4 x 4 .....	76
4.5.3	Obecná afinní transformace .....	78
4.5.4	Matice 4 x 4 a perspektivní projekce .....	79
<b>5</b>	<b>Systém automatického skenování a mapování prostoru.....</b>	<b>82</b>
<b>5.1</b>	<b>Úpravy mračen bodů.....</b>	<b>82</b>
5.1.1	Eliminace odlehlých bodů .....	83
5.1.2	Korekce orientace mračna bodů .....	84
<b>5.2</b>	<b>Hledání sousedních bodů .....</b>	<b>87</b>
5.2.1	kD tree .....	88
<b>5.3</b>	<b>Porovnání praktických výsledků registrace.....</b>	<b>89</b>
<b>6</b>	<b>Metody zpracování mračen bodů.....</b>	<b>94</b>
<b>6.1</b>	<b>Hlubkový obraz mračna bodů.....</b>	<b>94</b>
6.1.1	Příprava vstupního mračna bodů .....	95
6.1.2	Konstrukce zorného pole pohledu kamery .....	96
6.1.3	Segmentace bodů mračna v zorném poli .....	96
6.1.4	Transformace bodu na rovinu hloubky.....	97
6.1.5	Výsledný hlubkový obraz.....	99
<b>6.2</b>	<b>Modifikované algoritmy hledání spojených komponent.....</b>	<b>99</b>
6.2.1	Hledání spojených komponent s výskytem mezer .....	100
6.2.2	Hledání pozic hrany elementu .....	101
<b>6.3</b>	<b>Detekce ploch úrovnovým skenováním prostoru .....</b>	<b>102</b>
6.3.1	Zpřesnění odhadu plochy.....	105
<b>6.4</b>	<b>Úrovnový obraz .....</b>	<b>107</b>
6.4.1	Tvorba úrovnového obrazu.....	107
6.4.2	Význam úrovnového obrazu.....	109
<b>6.5</b>	<b>Určení prostorových vlastností mračna bodů .....</b>	<b>111</b>
6.5.1	Určení obsahu a obvodu plochy .....	111
<b>6.6</b>	<b>Vektorizace popisných bodů prostředí.....</b>	<b>113</b>
<b>6.7</b>	<b>Úprava prostorových dat pro zjištění dalších parametrů .....</b>	<b>114</b>
<b>6.8</b>	<b>Vizualizace ploch .....</b>	<b>115</b>
6.8.1	Barevná vizualizace .....	117
<b>6.9</b>	<b>Praktické výsledky.....</b>	<b>117</b>
6.9.1	Testovací model mračna bodů.....	118

6.9.2	Reálná mračna bodů .....	119
6.9.3	Přesnost určení parametrů .....	124
6.9.4	Zjednodušení popisných bodů .....	125
6.9.5	Hlubkové obrazy .....	126
6.9.6	Úpravy hloubkového obrazu a zpětná rekonstrukce mračna bodů.....	127
<b>7</b>	<b>Závěr .....</b>	<b>128</b>
<b>8</b>	<b>Reference .....</b>	<b>130</b>
	<b>Seznam obrázků.....</b>	<b>138</b>
	<b>Seznam tabulek.....</b>	<b>143</b>
	<b>Příloha A – Popis barevných modelů použitých pro detekci laserové čáry .....</b>	<b>144</b>
	<b>Příloha B – Vývojové diagramy navržených funkcí.....</b>	<b>146</b>
	<b>Příloha C – Ukázky mobilní platformy .....</b>	<b>152</b>
	<b>Příloha D – Softwarové vybavení mobilní platformy a optického měřiče.....</b>	<b>153</b>

## Seznam zkratek

AR	(Augmented reality) Rozšířená realita
CCD	(Charge-Coupled Device) Typ snímacího senzoru vyčítající informaci pomocí vázaného náboje
CIE	(Commission internationale de l'éclairage) Mezinárodní organizace věnující se světlu, osvětlování, barvě a kolorimetrickým soustavám.
CMOS	(Complementary Metal–Oxide–Semiconductor) Typ snímacího senzoru založený na struktuře unipolárních tranzistorů
EM	(Expectation Maximization) Algoritmus pro trénování Gaussian mixture modelu
GMM	(Gaussian Mixture Model) Model Gaussovských rozdělení
ICP	(Iterative Closed Points) Algoritmus registrace mračen bodů minimalizující vzdálenost mezi nimi
IDC	(Iterative Dual Correspondence) Modifikace algoritmu ICP pro dosažení rychlejší konvergence
LCCL	(Level Connected Component Labeling) Algoritmus označování spojených komponent upravený pro 3D prostor
LI	(Level Image) Úrovňový obraz, obraz nesoucí informaci o přítomnosti bodů v analyzované hladině mračna bodů
LiDAR	(Light Detection And Ranging) Systém měření vzdálenosti pomocí doby výpočtu šíření odraženého paprsku od měřeného objektu pulzně ovládaného laseru
NDT	(Normal Distribution Transform) Algoritmus registrace mračen bodů využívající statistický popis prostoru
PC	(Point Cloud) Mračno bodů
PCL	(Point Cloud Library) Knihovna funkcí pro zpracování mračen bodů
QE	(Quantum Efficiency) Efektivita přeměny energie dopadajících fotonů na elektrický signal
RANSAC	(RANDOM SAMple Consensus) Algoritmus pro hledání modelu ve vstupních datech používaný například pro detekci ploch
RGSS	(Rotated Grid Super-Sampling) Metoda vyhlazování hran v obraze
RMS	(Root Mean Squares) Odmocnina průměrné hodnoty sumy čtverců
SAD	(Sum of Absolute Differences) Algoritmus sumy absolutních rozdílů používaný například v template matching
SLAM	(Simultaneous Localization And Mapping) Souběžná navigace s obnovou a přidáváním nové informace do aktuální mapy prostoru
SODAR	(SONic Detection And Ranging) Meteorologický přístroj pro měření rozptylu zvukových vln na atmosférických turbulencích.

# 1 Úvod a cíle práce

Lidé mají ze svojí přirozenosti potřebu se neustále přemísťovat. Pro navigaci v prostoru využívají svoje smysly, zejména zrak a sluch. Celý navigační a orientační proces je ale mnohem komplikovanější a řídí ho lidský mozek. V doposud neznámém prostoru jsou lidé schopní rychlé orientace a ve známém prostředí k navigaci využívají rovněž informaci uloženou v nervových propojeních, kde utvářejí komplexní vizuální i prostorovou „mapu“. Každý člověk má schopnosti orientace individuální a mohou se lišit i v určitých situacích. Přehledná mapa umožňuje lidem se rychle zorientovat i v neznámém prostředí. Stejně tak automatizované systémy navigace potřebují znát svojí polohu v prostoru a strukturu okolního prostředí pro její efektivní provedení.

Rozvoj moderní elektrotechniky a robotiky nabízí pokročilé možnosti orientace a navigace v prostoru. Mapa je k dispozici přímo v zařízení v elektronické podobě a pro navigaci v otevřeném prostoru je využíván signál GPS a v uzavřených prostorách se nabízí inerciální navigace. Prvním automobilem navigovaným GPS byla Mazda Cosmo v roce 1990 (Evans, 2013) a úplně první automobilová navigace vznikla v roce 1981, 14 let před plným nasazením GPS (Berger, 2017). Pozice na mapě byla určovaná pomocí najetých kilometrů a gyroskopu. První pokusy s inerciální navigací pomocí akcelerometru a gyroskopu sahají již do 20. let 20. století a k prvnímu ostrému nasazení došlo během II. sv. války při vypuštění rakety V2 v roce 1940 (Ripka, 2003).

Pro podrobnou navigaci robota je samotná 2D mapa nedostačující z důvodu překonávání různých překážek a v případě vnitřních prostor je zapotřebí uvažovat rovněž více poschodí. K orientaci v prostoru využívá zejména inerciální navigaci a 3D mapu. S navigací a orientací robota a automatizovaných systémů v prostoru se pojí pojem SLAM. Jedná se o soubor algoritmů, metod a technik umožňující 3D navigaci v prostoru s aktualizací a rozšiřováním mapových dat. První zmínky o ní pochází z přelomu tohoto století (Nüchter, 2009). Její rozvoj umožnil zejména zvyšování výkonu mikroprocesorů a jejich minimalizace. Výhoda 3D mapy oproti klasické 2D verzi je poskytování velkého množství informací o celém zkoumaném prostoru. Lze z ní zjistit skutečné rozměry, obsahy, obvody a hloubky a má široké použití v různých odvětvích. Kromě navigace může sloužit i jako celkový přehled rozsahu analyzovaného prostředí nebo slouží k vizualizaci různých budoucích změn a úprav. Body prostorové mapy lze získat pomocí 3D skenerů prostředí využívající různé principy měření. Výsledkem je vektorová mapa s vysokou redundancí popisných bodů, často s velkými paměťovými nároky a mezi jednotlivými body není bez dalších úprav žádná souvislost kromě společného počátku. Získané mračno bodů je zapotřebí dále zpracovávat. Stejně jako je člověk schopen orientace v prostoru a utváření virtuální mapy v hlavě, tak cílem automatického mapování a skenování prostoru je napodobení jeho činnosti. Výslednou prostorovou mapu lze využít pro navigaci a orientaci v prostředí nebo k získání mnoha důležitých informací o analyzovaném prostoru.

Cílem práce bylo tedy vytvořit ucelený automatizovaný systém skenování a mapování neznámých prostor. V jejím průběhu byl navržen model automatizovaného vytváření vektorových třírozměrných map prostorů bez zásahu lidského činitele včetně metod jejich vizualizace a prezentace reálné scény zkoumaného prostředí. Byly vyvinuty metody analýzy mračen bodů za účelem detekce přítomných ploch, získání dalších popisných parametrů a potlačení redundance popisných bodů prostředí. Navržené algoritmy fungují obecně a lze je aplikovat i na dostupná řešení skenování prostoru. Primární využití skenovacího systému je zejména uvnitř budov. Omezení na vnitřní prostory umožňuje

použití dostupnějších měřicích zařízení s nižšími nároky na kvalitu a jejich provedení. K zvládnutí dané problematiky přispěla analýza současného stavu systémů automatického mapování vícerozměrných prostorů s využitím fúze obrazových, radarových, případně dalších senzorů a rozbor metod pro práci s mračny bodů včetně jejich zpracování (kapitola 2, 3 a 4). Pro pořízení semiprostorových dat jsme na odborném pracovišti Katedry elektrotechniky vybudovali mobilní platformu umožňující nasazení různých typů senzorů měření vzdálenosti podporující využití jejich fúze. Její popis včetně principu určení vzdálenosti, tvorby detekčních modelů barevné laserové čáry a její analýzy pro eliminaci nežádoucích situací doprovázející měření popisuje kapitola 3. Jedno skenování z určitého místa nemůže pokrýt celý zkoumaný prostor z důvodu jeho členitosti, navíc dochází k překrývání nebo i celému zakrytí objektů na scéně druhými objekty. Ucelenou prostorovou mapu je zapotřebí sestavit z dílčích částí procesem registrace mračen bodů uvedeným v kapitole 5. Výsledná mapa obsahuje velké množství redundantních bodů, které je zapotřebí snížit z důvodu velkých paměťových nároků pro její uchování. Kapitola 6 se zabývá metodami zjednodušení popisných bodů prostředí, statistickou a prostorovou analýzou mračen bodů včetně jejich vizualizace. Jsou v ní rozpracovány rovněž metody základní detekce ploch i tvorba hloubkové mapy z libovolného mračna bodů a další navržené metody jejich zpracování. Na konci každé dílčí kapitoly jsou shrnuty dosažené výsledky a možnosti navrženého systému automatického mapování a skenování prostoru.

## 2 Mapování prostoru

Podrobný přehled dostupných metod mapování a skenování prostoru je uveden v (Chmelař, 2013). Tato oblast výzkumu je dále aktivně rozšiřována a stává se stále více součástí všedního života. Cílem mapování prostoru je jeho digitalizace, která má široké možnosti použití. Ze získaného mračna prostorových bodů lze pomocí dalšího zpracování automatizovaně zjišťovat významné parametry prostředí a přítomných objektů včetně zjednodušení počtu jejich popisných bodů. Vhodná vizualizace navíc nabízí zdůraznění analyzovaných výsledků s důležitými detaily vytvořené mapy. Automatizované systémy skenování prostoru jsou nápomocné i s ohledem na bezpečnost osob, kdy nebezpečné prostory jako opuštěné doly a jiné mohou být nejdříve prozkoumány za použití technických prostředků (Chmelař, 2013).

### 2.1 Zpracování naměřených dat a detekce objektů

Dnešní systémy skenování prostoru poskytují přesné a detailní mračno bodů, například skener v (Tess, 2018), ale jsou s tím spojeny i úměrné paměťové nároky. Pro popis základních tvarů prostředí, jako například plochy, je mnoho změřených bodů redundantních. Například mobilní robot je běžně sestaven z malých embedded zařízení a 3D mapa použitá k jeho navigaci musí být patřičně zjednodušená, aby vyhověla jeho paměťovým požadavkům. Obecně při detekci objektů individuální body ztrácí význam, více nás zajímají struktury jimi tvořené. Po získání parametrů a matematického modelu popisující objekt lze tyto body utvářející jeho strukturu vynechat.

Pro účely zpracování mračen bodů bylo vytvořeno mnoho metod a algoritmů implementovaných ve specializovaných knihovnách. Jednou z neaktuálnějších knihoven je v současné době PCL (Rusu, 2011), která je neustále vyvíjena mnoha specialisty v oboru a rozšiřována o novou funkcionalitu. Začátkem listopadu byla aktuálně vydána verze 1.9.0 (PointCloudLibrary, 2018). Knihovna zahrnuje state-of-the-art algoritmy pro filtraci, rozpoznávání rysů prostředí, rekonstrukce povrchu, registrace mračen bodů, vizualizace, přizpůsobování modelu a segmentace. I v této dizertační práci jsou používány algoritmy registrace a vizualizace mračen bodů obsažené v této knihovně z důvodu jejich přirozené rychlosti a interaktivnějším možnostem používání v porovnání s výpočetním systémem Matlab.

Například pro detekci ploch existuje několik metod přístupů. Mezi výzkumníky je známý state-of-the-art algoritmus RANSAC založený na hledání požadovaného modelu. V (Kurban, 2015) autor ukázal úspěšnou detekci rovin s použitím senzoru Kinect a funkcí z knihovny PCL. Jiný výzkum prezentovaný autory (Hulik, 2014) ukazuje porovnání detekce rovin pomocí RANSAC oproti detekci použitím Houghovy transformace (HT). Obě implementace jsou porovnány na výsledcích v reálném čase získané mobilním robotem. Algoritmus HT překonal implementaci RANSAC ve svojí robustnosti a počtu chybných detekcí. V systému AR představený autory (Kim, 2017) je implementován modifikovaný algoritmus RANSAC schopný detekovat plochy v reálném čase. Autoři navrhují vlastní strategii vyhledávání rovin. V případě detekce více ploch jsou zkoumány i jejich parametry, ze kterých je pomocí hodnotící funkce vybrána rovina s nejlepšími parametry. Modifikace algoritmu výrazně zkracuje i dobu zpracování.

Další přístup využívá pro detekci rovin algoritmus Depth-driven Plane Detection založený na principu růstu regionu (Jin, 2017). Blízko k tomuto směru má nedávný výzkum

(Czerniawski, 2018) představující komplexní systém pro detekci rovin a jejich klasifikaci. Roviny jsou segmentovány pomocí metody DBSCAN, která uvažuje i zakřivení pro poskytnutí kvalitní segmentace. Autoři v (Skulimowski, 2017) popisují algoritmus pro pozemní detekci rovin z hloubkových obrazů zachycených stereokamerou. Kamera je pohyblivá a systém určuje její rotaci v ose  $X$  pro zajištění spolehlivé segmentace. Další výzkum v (Zeineldin, 2016) se rovněž zabývá detekcí zemské roviny umožňující detekci objektů přítomných na pozorované scéně.

Zpracování mračen bodů je důležité i z pohledu detekce základních objektů a rysů skenovaného prostředí. Například v (Chmelar, 2014c) jsem prezentoval algoritmus na rozbalení obdélníkové místnosti do jedné roviny. Navržený algoritmus nakonec pro zpracování mračen bodů použit nebyl, protože prostorová data rozbalením do roviny ztrácí svoji konzistentnost a tento koncept nebylo již kam dále rozšiřovat. V (Ochmann, 2016) je prezentován systém mapování vnitřních prostor budov s dostupnou vizuální informací. Nedávný výzkum se zabývá sofistikovaným zpracováním skenovaných dat, modelováním a jejich interaktivní vizualizací. Zkoumá rovněž objemový i parametrický popis zahrnující navíc kontextové informace jako je například spojení jednotlivých stěn.

Prostorové skenování objektů získalo rovněž na oblibě v případě digitalizace a vizualizace historických památek. Založená organizace v roce 2003 CyArk (CyArk, 2018) zabývající se projektem Open Heritage si klade za cíl pomocí nejmodernějších dostupných 3D skenerů, dronů a fotogrammetrie mapovat světové monumenty, a vytvořit tak největší archiv 3D dat. Online archiv za 15 let existence obsahuje okolo 200 skenovaných monumentů lidské historie ze všech 7 kontinentů světa. Mezi nejvýznamnější mapovaná místa patří například syrský palác Al Azem z válkou zmítaného Damašku, starobylé Mayské metropole Chichen Itza v Mexiku, Brandenburská brána v Berlíně nebo Waitangi na Novém Zélandě. Archiv vzniká zejména z důvodu zachování významných historických památek ohrožených přírodními katastrofami, rozšiřováním městských aglomerací, turistickým ruchem či válkami. Moderní skenery prostoru například v (Tess, 2018) umožňují pořízení přesných a detailních dat. Využitím létajících dronů nečiní problém se dostat i do míst hůře přístupných člověku. Získaná prostorová data jsou volně přístupná pro vědecké, vzdělávací a umělecké účely. Google je navíc použil pro vytvoření dvanácti zpracovaných 3D modelů, které je možné prozkoumat z každého úhlu pomocí nástroje Poly a vytisknout je na 3D tiskárně (CyArk, 2018).

V poslední době získávají na oblibě systémy rozšířené reality. Google v roce 2014 odstartoval projekt Tango (Bohn, 2015). Jeho cílem byla konstrukce mobilního zařízení schopného pomocí zpracování obrazu a nadstandardních senzorů zařízení určit pozici v okolním prostoru bez využití GPS a jiných externích signálů. Podporované zařízení mělo k dispozici klasický fotoaparát a navíc kameru s objektivem „rybího oka“, hloubkový senzor a projekci strukturovaného světla. Prostorové snímání funguje na podobném principu jako hloubkový snímač Microsoft Kinect. Projekt si kladl za cíl tvorbu mobilního zařízení schopného navigace ve vnitřních prostorech, 3D mapování okolního prostoru, měření fyzických rozměrů, rozpoznávání rysů prostředí a zábavu v podobě rozšířené reality a virtuálního světa. V roce 2015 první tablet demonstroval možnosti technologie (Hern, 2015). V roce 2016 vyšel další smartphone od značky Lenovo (Deepak, 2016). Budoucí plány na další rozšiřování platformy byly, ale tlakem ze strany konkurence od firmy Apple vyvíjející sofistikovanější systém (O'Hara, 2018) byl v prosinci roku 2017 oznámen konec podpory projektu Tango a transformace na novou platformu se jménem ARCore (Palladino, 2018). Výhodou konkurenčního řešení je využití standardních dostupných



senzorů mobilních zařízení umožňující široké rozšíření aplikace. Zvyšující se výkon mobilních zařízení navíc umožňuje aplikaci nejmodernějších metod zpracování obrazu, jako jsou deskriptory prostředí prezentované například v (Beran, 2015). ARCore si klade stejné cíle a obě řešení v současné době umožňují podobné věci, virtuální návrh umístění nábytku, umísťování objektů do prostoru včetně zpracování informace světla, virtuální měření vzdálenosti a další.

V této dizertační práci popisují systém automatického skenování a mapování prostoru určený primárně pro použití ve vnitřních prostorách. Oblast zpracování a vizualizace mračen bodů má ve skutečnosti širší rozsah a není omezena pouze na prostor kolem nás. Důležitý význam má i v nanosvětě. Moderní elektronové mikroskopy umožňují analyzovaný vzorek účelově nasvítit a z jeho jednotlivých vrstev lze následně vytvořit prostorové mračno bodů a různě ho vizualizovat (Long, 2012). Vytvořený 3D model poté výzkumníkům umožní nahlížet na analyzovanou strukturu zkoumané látky jiným pohledem, který umožní získání podrobnějších informací. Například nedávný výzkum se zabývá efektivním zpracováním biologických vzorků z mikroskopu v reálném čase pomocí mobilního telefonu (Shanmugam, 2018). Jednotlivé získané vrstvy představují 2D obrazy, které jsou dále transformovány do prostorového mračna. Nově navržené metody a algoritmy v této dizertační práci rovněž umožňují pracovat s analyzovaným mračnem bodů jako s 2D obrazem, který dále nabízí určení důležitých prostorových informací, zjednodušení popisných bodů nebo jeho vizualizaci.

## 2.2 Vizualizace prostředí a objektů

Nedílnou součástí skenování a mapování prostoru je právě jeho vizualizace při následném zpracování. Monotónní zobrazení jednou barvou nabízí pohled na celkový rozsah skenovaného prostoru, ale výsledné mračno je nepřehledné a složitě se identifikují jeho jednotlivé části. Vizualizaci mračen bodů zahrnuje i knihovna PCL (Rusu, 2011). Moderní grafické karty urychlují vizualizační proces (Lo, 2015). OpenGL API podporované mnoha platformami od PC až mobilní zařízení umožňuje vizualizaci objemných a rozsáhlých mračen bodů, kde výkon grafického čipu umožňuje zachovat normální odezvu uživateli analyzující data.

Názorným příkladem vizualizace mračen bodů je systém využívající dron pro mapování prostoru pomocí Ladar senzoru (Berge, 2016). Použitá vizualizace slouží k zvýraznění cílů. Okolí je prezentováno bílou barvou a potencionální cíl je zvýrazněn barevně. Podobným způsobem vizualizace se zabývá výzkum zaměřený na uhelné doly (Kot, 2016). Důležité rysy skenovaného prostředí jsou rozlišeny různými barvami. Ve spojení s ostatními senzory je systém schopen zvýraznit a označit části prostoru s rozdílnou teplotou nebo indikovat přítomnost větší koncentrace plynu. Hloubka prostoru je rovněž z vizualizace patrná.

Další zajímavý výzkum se zabývá spojením mračen bodů s reálnými texturami pro webovou navigaci street-view (Devaux, 2016). Autoři nabízejí real-time projekci textur při nalezení odpovídajících částí mračen bodů. Cílem výzkumu je odvrácení případných srážek při navigaci a navíc výsledná prostorová prezentace je působivá oproti současným používaným systémům. Obdobně se autor v (Arikan, 2014) zabývá vizualizací rozsáhlých mračen bodů obecně. Zaměřuje se na jejich vizuální reprezentaci a proces skenování je doplněn o pořízení fotografií s vysokým rozlišením. Výsledkem je mračno bodů vypadající jako reálná skenovaná scéna. Další výzkum (Han, 2017) se zaměřuje na skenování

a mapování celého procesu výstavby budovy včetně interaktivní prezentace a vizualizace na PC. Časový sběr dat umožňuje kontrolovat kvalitu konstrukce a dodržování stavebního plánu a může v budoucnu sloužit jako cenný zdroj informací. Prováděný výzkum je doplněn o zajímavé praktické výsledky.

Vizualizace mračen bodů je v dnešní době obecně oblíbená mezi výzkumníky zejména při možnosti použití cenově dostupného senzoru Microsoft Kinect. Společnost Microsoft v říjnu minulého roku oznámila zrušení výroby oblíbeného senzoru, ale nakonec začátkem května letošního roku oznámila vydání nové verze (Cranz, 2018). Například autoři (Chen, 2016) se zabývají fúzí dálkoměrných dat Kinectu s kombinací ToF kamery a LiDAR senzoru. Výsledné mračno bodů je barevné a systém je schopen vyhovět požadavkům mapování uvnitř budov, modelování, robotické lokalizaci a navigaci. Další robotický systém navržený primárně pro uklízení výzkumníků (Li, 2016b) vybavil fotovoltaickým panelem a Kinect senzorem umožňující mapování rozsáhlých prostor včetně jeho vizualizace. Podobný předchozím výzkumům je mobilní robot vybavený rovněž Kinect senzorem (Li, 2016a). Navržený systém je schopen navigace v neznámých prostorech a navíc robot používá okto mapu pro uložení 3D mapy prostředí. Pomocí reprezentace struktury získané mapy prostřednictvím októlového stromu nabízí její zjednodušení a efektivní navigaci. Kinect je často využíván i ve zdravotnictví například na sledování pohybu pacienta (Dao, 2015). Navržený systém je schopen vytvořit 3D model pacienta. Prostorová vizualizace je rovněž důležitá pro vytvoření modelu srdce z mračna bodů prezentovaná v (Li, 2012).

Důležitou část zpracování prostorových dat tvoří také hloubkové obrazy vyjadřující skutečnou prostorovou vzdálenost od snímacího zařízení ve formě 2D obrazu. Jsou často využívány v robotické navigaci a mapovacích systémech například (Yousif, 2013) nebo (Skulimowski, 2017), ale také v lékařství pro sledování pohybu a monitoring dýchání (Dao, 2015). Využití nachází i v dalších oblastech při sledování pohybu a detekci objektů na scéně (Li, 2016a).

Z výše uvedeného vyplývá, že skenování a mapování prostoru včetně jeho vhodné vizualizace je používáno v různých odvětvích lidské činnosti a s expanzí technologie rozšířené reality bude stále více zasahovat do všedního života.

## **2.3 Registrace naměřených dat**

Každý prostorový skener má svojí konstrukcí definovaný maximální měřicí dosah a rozsah měřených úhlů. Jedním prostorovým skenováním nelze pokrýt celé zkoumané prostředí, ať už z důvodu dosahu skeneru nebo členitosti prostoru a přítomných objektů na scéně stínící určité jeho části. Získaná mračna bodů procesem skenování z různých míst prostoru je zapotřebí spojit do uceleného celku procesem zvaným „registrace“. S touto problematikou je úzce spojena souběžná lokalizace a mapování prostoru SLAM, detailně rozpracovaná například autorem (Nüchter, 2009). Algoritmy SLAM se dostaly do popředí zájmu mnoha výzkumníků na přelomu tohoto století se zvyšováním výkonu embedded systémů.

Tato část je věnována přehledu nejpoužívanějších algoritmů určených pro registraci mračen bodů. V případech, kdy by byla zajištěna přesná uživatelská nebo robotická lokalizace pro určení pozice individuálních měření v průběhu mapování prostoru, tak lze vytvořit výsledné mračno přímo z naměřených dat. Nicméně vlivem nepřesnosti měřících senzorů a chybové vlastní lokalizaci není možné sestavit kvalitní prostorovou mapu bez

použití algoritmů registrace mračen bodů. Algoritmy registrace získávají na významu zejména při použití online SLAM, kdy mobilní robot vytváří výslednou mapu inkrementálně, například v (Nüchter, 2009), a do aktuální mapy je zapotřebí zanést nová sensorická měření se správnou orientací a pozicí v prostoru.

### 2.3.1 ICP (Iterative Closest Points)

Často používaným přístupem pro registraci naměřených bodů je ICP založený na práci s individuálními body jednotlivých mračen. Algoritmus byl nezávisle představen třemi výzkumnými skupinami autorů okolo roku 1991 (Nüchter, 2009) z nichž nejznámější jsou autoři Besl and McKay.

Vstupními parametry jsou dvě nezávislá mračna bodů o libovolné délce,  $\hat{M}$  (model set) o délce  $N_m$  a  $\hat{D}$  (data set) s délkou  $N_d$ . Obě mračna popisují určitý tvar. Cílem metody je mezi nimi nalézt transformaci definovanou jako  $(R, \mathbf{t})$ , kde  $R$  je rotační matice a  $\mathbf{t}$  je vektor posunu, která minimalizuje hodnotící funkci  $E(R, \mathbf{t})$  (Nüchter, 2009) definovanou následujícím vztahem

$$E(R, \mathbf{t}) = \sum_{i=1}^{N_m} \sum_{j=1}^{N_d} w_{i,j} \|\hat{m}_i - (R\hat{d}_j + \mathbf{t})\|^2, \quad (\text{Nüchter, 2009}) \quad (2.1)$$

kde  $w(i, j)$  označují nalezené společné body. Jestliže  $i$ -tý bod výchozího mračen bodů  $\hat{M}$  se shoduje s  $j$ -tým bodem transformovaného mračen  $\hat{D}$  nabývá hodnoty 1, v opačném případě má hodnotu 0. Během jednotlivých iteračních kroků jsou počítány dva parametry, souhlasné body  $w(i, j)$  a transformace  $(R, \mathbf{t})$  minimalizující hodnotící funkci. Cílem je najít co nejvíce souhlasných bodů. V každém kroku algoritmus zvolí nejbližší body v rozsahu  $d_{max}$  a určí k nim transformační parametry  $(R, \mathbf{t})$  pro minimalizaci hodnotící funkce (2.1). Parametry je možné vyjádřit pomocí matice  $4 \times 4$  (4.27) usnadňující provedení operace transformace. Konec algoritmu určuje zvolený počet iteračních kroků  $I_{max}$  nebo dosažení požadované hranice rozdílu změny hodnoty hodnotící funkce mezi jednotlivými iteračními kroky určené parametrem  $\epsilon$ .

Existuje mnoho variant a modifikací ICP algoritmu pro zefektivnění rychlosti výpočtu, snížení počtu iteračních kroků nebo úpravy vstupních dat pro zaručení dosažení požadovaného výsledku. Podrobný přehled je uveden v (Nüchter, 2009).

Algoritmus ICP má hlavní dva nedostatky. Při zpracování jsou uvažovány pouze individuální body a algoritmus nerespektuje žádné povrchy a tvary v blízkém okolí bodu. U rozsáhlých mračen bodů i v případě využití efektivních datových struktur pro vyhledání nejbližšího sousedního bodu je algoritmus zpracováván dlouhou dobu a u méně přesných vstupních dat může docházet k chybám.

### 2.3.2 NDT (Normal Distribution Transform)

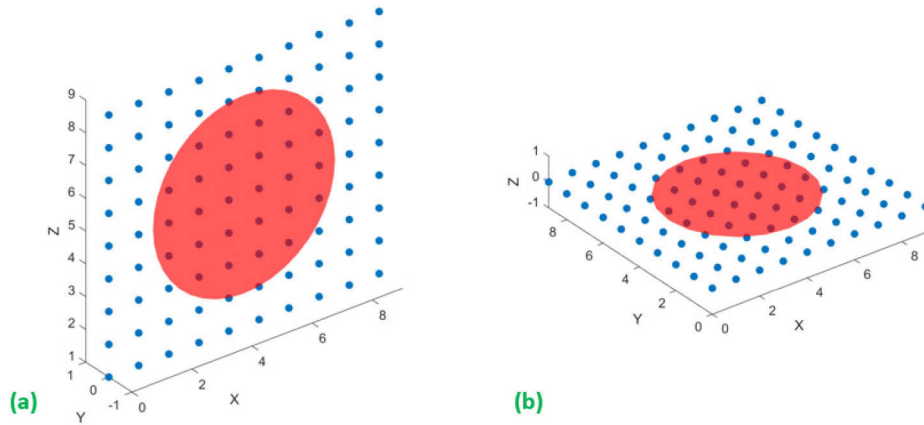
Metoda registrace Normal Distribution Transform je novější sofistikovaný algoritmus registrace prostorových mračen bodů rozpracovaná autorem (Magnusson, 2013). Klíčovým elementem zpracování dat je jejich reprezentace modelem normálního rozdělení. Místo použití individuálních naměřených bodů je využita jejich reprezentace modelem tvořeným kombinací normálních rozdělení a pravděpodobností shody bodu s povrchem tvořeným shlukem bodů na určité pozici. Normální rozdělení poskytuje reálnou a hladkou reprezentaci bodů se spojitými derivacemi prvního a druhého řádu prostřednictvím Jacobiho

a Hessovy matice umožňující aplikaci standardních optimalizačních metod, jako například Newtonova, pro účel dosažení nejlepšího výsledku registrace mračen bodů. Metoda nevyžaduje časově náročný výpočet hledání blízkých bodů.

Algoritmus NDT se skládá z několika kroků. V inicializační fázi je mračno bodů rozděleno na malé části tzv. buňky a pro každou buňku určit její statistické charakteristiky průměru a kovarianční matice. Za předpokladu, že jsou body povrchu referenčního skenu popsány pomocí D-dimenzionálního normálního náhodného procesu, je pravděpodobnost jeho bodu  $\mathbf{x}$  definovaná jako

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{D}{2}} \sqrt{|\Sigma|}} \exp\left(-\frac{(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})}{2}\right), \quad (2.2)$$

kde  $\boldsymbol{\mu}$  je střední hodnota a  $\Sigma$  kovarianční matice bodů tvořící povrch buňky referenčního skenu. Hodnoty vlastních čísel získané z kovarianční matice  $\Sigma$  popisují zastoupený tvar normálním rozdělením. Na Obr. 2.1 je zobrazená simulace povrchů buněk a červený kruh vyjadřuje poměr složek vlastních čísel v souřadných osách. V případě Obr. 2.1 (a) je složka vlastního čísla v ose Y nulová, na Obr. 2.1 (b) je naopak složka Z nulová a například stejné poměry všech složek vlastních čísel naznačují kouli formovanou body buňky. Výpočet statistických parametrů buněk je proveden pouze jednou v inicializační fázi.



Obr. 2.1 – Reprezentace povrchu buňky v NDT vlastními čísly, (a) kolmá stěna, (b) rovina

Cílem registrační fáze algoritmu NDT je nalezení transformace  $T(\mathbf{p}, \mathbf{x})$  aktuálního skenu maximalizující pravděpodobnosti jeho pozic bodů s pozicí na ploše v referenčním mračnu bodů. Transformační funkce posouvá bod  $\mathbf{x}$  pomocí pose  $\mathbf{p}$  vyjadřující jeho pozici a orientaci vůči referenčnímu mračnu. Je zapotřebí maximalizovat pravděpodobnostní funkci definovanou jako

$$\Psi = \prod_{k=1}^n p(T(\mathbf{p}, \mathbf{x}_k)) , \quad (\text{Magnusson, 2013}) \quad (2.3)$$

kde  $k$  označuje aktuální bod  $\mathbf{x}$  registrovaného mračna bodů o celkovém počtu  $n$  bodů. V případě 3D registrace jsou pro vyjádření orientace využívány Eulerovy úhly z důvodu snadnějšího zápisu a jejich pozitivních vlastností. Vektor  $\mathbf{p}$  je šestiřozměrný a má podobu  $\mathbf{p}_6 = [t_x, t_y, t_z, \Phi_x, \Phi_y, \Phi_z]^T$ , kde  $t$  značí posun v příslušných osách a  $\Phi$  rotační úhel. Transformační funkce v Eulerově zápisu má tvar

$$T_E(\mathbf{p}_6, \mathbf{x}) = R_x R_y R_z \mathbf{x} + \mathbf{t} . \quad (\text{Magnusson, 2013}) \quad (2.4)$$

V každém iteračním kroku algoritmu je určena velikost hodnotící funkce na základě aktuálního  $\mathbf{p}$ , jsou aktualizovány hodnoty Jakobioho a Hessovy matice a pomocí optimalizační metody určen nový odhad  $\mathbf{p}$ . Algoritmus končí, pokud dojde k překročení maximálního počtu iteračních kroků  $I_{max}$  nebo při dosažení hladiny maximální změny výstupu určenou parametrem  $\epsilon$ .

### 2.3.3 Další algoritmy registrace bodů

Další algoritmy registrace mračen bodů většinou vychází z výše popsáných algoritmů a liší se zejména způsobem popisu společných prvků vstupních mračen bodů nebo způsobu jejich matematického popisu případně vylepšených, urychlených nebo robustnějších metod hledání jejich společných rysů.

Pro sjednocení mračen bodů lze využít princip založený na analýze popisovačů vzorů a hledání podobností společných rysů v obou mračenech. Většina zařízení skenujících prostor využívá data získaná kamerou pro následnou analýzu a detekci společných rysů vstupních mračen bodů. Jsou využívány zejména tyto detektory: SURF, SIFT, GLOH, Shape Context, PCA, Momenty, křížová korelace a Steerable filtry viz (Nüchter, 2010). Důležitými kritérii popisovačů prostředí je jejich nezávislost na měřítku, rotaci, transformaci nebo změnách jasů. Podrobný přehled deskriptorů je uveden v (Beran, 2015).

Modifikace algoritmu ICP zaměřující se na rychlost zpracování je IDC představená autory (Lu, 1997). Jejich implementace hledá v každé iteraci jiným způsobem skupinu společných bodů pomocí polárních souřadnic v definovaném intervalu. V porovnání dosažených výsledků se IDC algoritmus se jeví více robustní než ICP při velkém počátečním rozdílu orientace a posunu obou mračen, ale méně přesný než ICP s malou počáteční chybou.

Jiný přístup k registraci mračen bodů zvolili autoři v (Montesano, 2005), kteří představili algoritmus pIC. Tato metoda si klade důraz na vyjádření šumu obou vstupních mračen bodů a počátečního odhadu transformace. Vstupní body a transformace jsou uvažovány jako náhodný Gaussovský proces s nulovým středním šumem. Kovarianční matice obsahují informaci konfigurace senzorů měření a přesnosti použité odometrie robota pro co nejlepší výsledek registrace. Algoritmus byl testován v porovnání s IDC i ICP s využitím jeho pravděpodobnostních odhadů. Dosažené výsledky dokazují o 25% rychlejší konvergenci pIC oproti porovnávaným algoritmům.

Podobný přístup k registraci mračen bodů jako NDT používá metoda Gaussovských polí (Boughorbel, 2004) K modelování vstupních mračen používá GMM a sledují se dva parametry. Prvním je prostorová vzdálenost mezi body a druhý sleduje shodu povrchu v okolí bodů. Body jsou porovnávány ve vícedimenzionálním prostoru obsahující nejen prostorové dimenze, ale další dimenzionální parametry umožňující snadnější identifikaci částí prostředí. Pomocí prostorových momentů je popisována jejich vizuální podobnost.

Myšlenka stojící za vznikem dalšího algoritmu využívající kvadratické cesty (Mitra, 2004) je modelování povrchu referenčního skenu pomocí kvadratických aproximací vůči funkci čtvercové vzdálenosti od povrchu, ve srovnání s NDT které využívá normálního rozdělení nebo přímo jednotlivé body v podobě ICP algoritmu. Registrace mračen bodů spočívá v minimalizaci sumy vzdálenosti určených pro aktuální sken.

Přístup pravděpodobnostního párování podobný NDT (Burguera, 2008). Tvůrci algoritmu se zaměřili na data získaná sonarovým měřením. Malé úhlové rozlišení sonaru

způsobuje problémy při použití algoritmů registrace zaměřené na párování bodů. Z tohoto důvodu je navíc využito robotické odometrie pro vyplnění mezer dalšími body. Toto rozšíření lze aplikovat i na ostatní registrační algoritmy a přineslo rozšíření stávajících např. sNDT, sICP (Burguera, 2012).

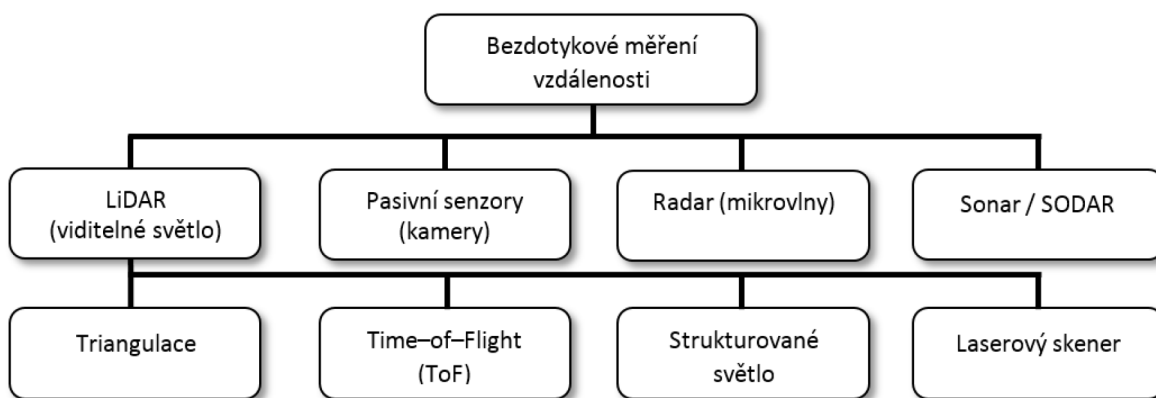
Metoda podmíněných náhodných polí představuje obecně pravděpodobnostní síť pro tvorbu pravděpodobnostních modelů vztahových informací. V porovnání se skrytým Markovovým modelem nebo Markovovými náhodnými poli, které jsou generativní modely, podmíněná náhodná pole nepotřebují nezávislé pozorování a vychází z počítačového zpracování řeči, kde je využit na přidělení vět k mluvenému slovu. Autoři výzkumu (Bataineh, 2016) ověřili jeho použitelnost na offline spojování map. Vytvořené nepřesné mapy byly úspěšně zkorigovány podle navrženého algoritmu.

Další přístup k řešení problému registrace rozsáhlé 3D skeny nabízí algoritmus PointReg (Olsen, 2011). Jeho autoři se zaměřili na registraci pobřežních skenů. Použité skenovací zařízení transformuje počátek skenování do globálního souřadnicového systému  $X$ ,  $Y$  a  $Z$  pomocí RTK GPS přijímače umožňující přesné zaměření polohy počátku skenování, jež je důležité pro proces registrace. PointReg algoritmus vyhodnocuje kombinaci rotace kolem osy  $Z$  obou vstupních mračen bodů za cílem nalezení nejmenší hodnoty RMS chyby. Vybrané body z prvního skenu jsou porovnány s trojúhelníky tvořenými nejbližšími třemi body v druhém skenu. V inicializační části je zapotřebí interakce uživatele pro zajištění, aby registrace byla prováděna na vhodných objektech vyskytujících se v obou mračcích. V případě výskytu pohybujících se bodů je zapotřebí takové body odstranit, aby byla splněna podmínka eliminaci rozdílných částí obou mračen bodů. Autory prezentované výsledky dokazují, že k registraci mračen bodů je zapotřebí jen několik iterací a pro použití na rozsáhlé 3D skeny překonal standardní ICP algoritmus.

### 3 Bezdotykové systémy měření vzdálenosti

Podrobný rozbor systémů bezdotykového měření vzdálenosti uvedených na Obr. 3.1 je zpracován v (Chmelař, 2013). Bezdotykové měření vzdálenosti se dělí do čtyř základních skupin podle rozsahů frekvencí a zpracování výstupu. Zařízení typu LiDAR využívají odrazu signálu světla ve spektrální oblasti ultrafialového, viditelného nebo infračerveného záření. Oproti tomu pasivní senzory v podobě kamer vyžadují následné zpracování pořízených snímků nebo detekci objektů v obraze pro určení vzdálenosti využitím metod stereoskopie nebo triangulace. Radary pracují s odrazem radiového signálu a sonary využívají odrazů zvukových vln od nízkých frekvencí až po ultrazvuk. Speciálním typem sonaru je SODAR využívaný meteorology pro analýzu a vytváření modelů vrstev atmosféry.

Pro skenování a mapování prostoru se zejména využívá LiDARů a kamerových systémů z důvodu jejich vysoké přesnosti, rychlosti a možnosti získání detailního popisu okolního prostředí. V této oblasti optických měřicích systémů se od rozboru uvedeného v (Chmelař, 2013) událo několik zajímavých změn.



Obr. 3.1 – Systémy bezdotykového měření

Došlo k rozšíření ToF kamer blíže běžným zákazníkům. Díky pokroku v technologii a zlepšování parametrů firma Basler, jeden z předních výrobců kamer, v roce 2015 rozšířil svoje produktové portfolio o ToF kamery (Gramatke, 2015). Jejich výstupem je hloubkový obraz. Současné kamery Basler dosahují rozlišení 640 x 480 pixelů a umožňují rychlost až 20 snímků za sekundu, které odpovídá 6,1 milionu měření za 1 s, jež řadí ToF kamery mezi nejrychlejší měřicí zařízení celkově. Kamera vyžaduje precizní kalibraci světelného zdroje a uzávěrky. Světelný zdroj, poskytnutý laserovými a LED diodami pro dostatečné osvětlení povrchů v dálce s nízkou odrazivostí, osvětluje pozorovanou scénu tisíckrát za sekundu. Každý pulz trvá pouze několik nanosekund. Například odchylka o pouhou jednu nanosekundu může znamenat chybu měření 30 cm. Jeho spektrum se blíží infračervenému světlu. Za optikou se nachází filtr pásmové propusti pro světelný zdroj kamery, aby se co nejvíce předešlo přesycení obrazu jinými zdroji světla. Pro dostatečnou rychlost synchronizace je řídicí jednotka vybavena FPGA čipem. Kamera využívá CCD snímač od firmy Philips, speciálně vyvinutý pro účely ToF kamer. Kromě výstupu hloubkové mapy poskytuje rovněž i mračno bodů.

Jako parametr kamery se uvádí přesnost aktuální, označující střední hodnotu rozdílu mezi skutečnou a měřenou vzdáleností a opakovaná přesnost je určena její standardní odchylkou. Existuje několik faktorů ovlivňující přesnost měření ToF kamer, mezi hlavní

patří vícenásobné odrazy světelného zdroje, přítomnost jiných zdrojů světla na měřené scéně i za použití speciálního filtru, rozptyl světla od okolních objektů a změny okolní teploty způsobující nežádoucí šum. Na jejich přesnost měření má zejména vliv i nastavení řídicí jednotky kamery, světelného zdroje a správnost jejího použití. Kameru včetně optiky je zapotřebí kalibrovat jako měřicí zařízení. Při dodržení všech doporučení předepsané výrobcem uživatel získá velmi rychlé měřicí zařízení s přesností měření do jednoho centimetru.

Systemy automatizovaného mapování prostoru pronikly i do mobilní sféry. Prvním pokusem měl být již ukončený projekt Google Tango (Palladino, 2018), ale nakonec kvůli potřebě specializovaného hardware byl projekt zrušen vlivem konkurence firmy Apple vyvíjející sofistikovanější systém kompatibilnější s širším rozsahem podporovaných zařízení (O'Hara, 2018). V současnosti Google aktivně vyvíjí systém rozšířené reality ARCore (ARCore Developers, 2018) využívající inerciální jednotku telefonu a pokročilé metody zpracování obrazu stejně jako konkurence.

Zajímavý bude i další vývoj skenovacích zařízení od firmy David Vision Systems zahrnující detailní skenování objektů využívající rozšířenou technologii strukturovaného světla nebo dvojice kamer. Původní společnost v roce 2016 odkoupila firma Hewlett Packard (Alec, 2016), která si od akvizice slibuje zvládnutí celého procesu 3D tisku od samého vytvoření modelu až po jeho vytisknutí. Navržený způsob skenování totiž umožňuje tvorbu digitalizovaného modelu okolních objektů v rozsahu 360° s rozlišením až 0,05 mm. Jeho výhodou je vysoká rychlost skenování a tvorba mračna bodů z aktuálního pohledu v řádu několika sekund a dále široká podpora 3D CAD software umožňující například okamžitý tisk modelu na 3D tiskárně.

Dále společnost Microsoft oznámila v říjnu minulého roku konec výroby oblíbeného senzoru Kinect. Určitou dobu to vypadalo, že projekt zcela zanikne, ale nakonec Microsoft začátkem května letošního roku oznámil vydání nové verze (Cranz, 2018). Nový modul má vylepšené rozlišení RGB kamery 1024 x 1024 a používá nový ToF senzor, který zajišťuje získání detailního mračna bodů. Senzor je rozdělen na snímání objektů v blízkém i vzdáleném rozsahu a umožňuje široký záběr pozorované scény.

Na poli kamerových čipů se také udály nemalé změny. V počátku roku 2015 firma Sony oznámila konec výroby CCD čipů (Fintel, 2015). Důvodem rušení výroby CCD čipů je rostoucí kvalita parametrů technologie CMOS a požadavek na vyšší rozlišení obrazu. V posledních letech došlo v případě technologie CMOS k výraznému zlepšení parametrů v porovnání s technologií CCD. Některé parametry jí i překročily díky využívání principů pro zvýšení efektivity. Rovněž i velikost snímacího bodu je menší než dříve a výrobní cena je znatelně nižší. Požadavkem moderní doby jsou aplikace využívající velké rozlišení a vysokou snímkovou frekvenci. Pro technologii CMOS požadavek vyššího rozlišení nečiní žádný problém a rychlost vyčítání zůstává stejná. Problém nastává právě u CCD čipů. Při použití velkého rozlišení nelze zajistit dostatečnou rychlost vyčítání použitím jednoho čipu z důvodu dlouhé doby posunu náboje. Pro tyto případy je využita technologie Multi-Tap CCD, kde výsledná plocha snímacího senzoru je rozdělena na několik menších částí s vlastními posuvnými registry a elektronikou. Z toho vyplývá, že jednotlivé části musí být precizně nastaveny a sladěny, aby na výsledném obrazu nebylo nic poznat. Snímková rychlost je dostačující díky kratším vzdálenostem posunu akumulovaných nábojů, ale senzor se stává příliš komplexní a výroba takového čipu je velmi nákladná. Navíc spotřeba takového čipu roste a s ní souvisí i jeho zahřívání mající negativní vliv na generaci šumu obrazu. Technologie CMOS nenahradí CCD zcela, která se například používá v současných ToF



kamerách (Gramatke, 2015), ale do budoucna s rostoucím rozlišením a požadavkem na rychlost bude technologie CMOS stále častěji nahrazovat stávající CCD.

Na poli laserových skenerů vznikají stále nové dokonalejší a přesnější zařízení. Například nejnovější produkt s názvem Artec Ray 3D scanner umožňuje změřit 208 000 bodů za sekundu v rozsah 110 metrů se zaručenou sub-milimetrovou přesností (Tess, 2018).

Další část této kapitoly je věnována vlastnímu navrženému optickému skeneru pro automatizované mapování prostoru. Tvorbou vlastního skeneru prostředí jsem se zabýval zejména z důvodu nedostatečné vybavenosti Katedry elektrotechniky v počátcích zkoumání problematiky automatizovaného mapování prostoru, jelikož podobnou oblastí se předtím nikdo na výzkumném pracovišti katedry nezabýval. Projekce vertikální laserové čáry ve skenovaném prostoru v kombinaci s otáčecí se měřicí hlavou a snímací kamerou nabízí poměrně jednoduchý způsob získání prostorových bodů při zvládnutí náročné segmentace vlastní čáry na statickém snímku, jejíž části mohou mít různou intenzitu jasu vlivem rozdílné odrazivosti laserového světla od přítomných objektů na scéně.

### **3.1 Mobilní platforma mapování prostoru**

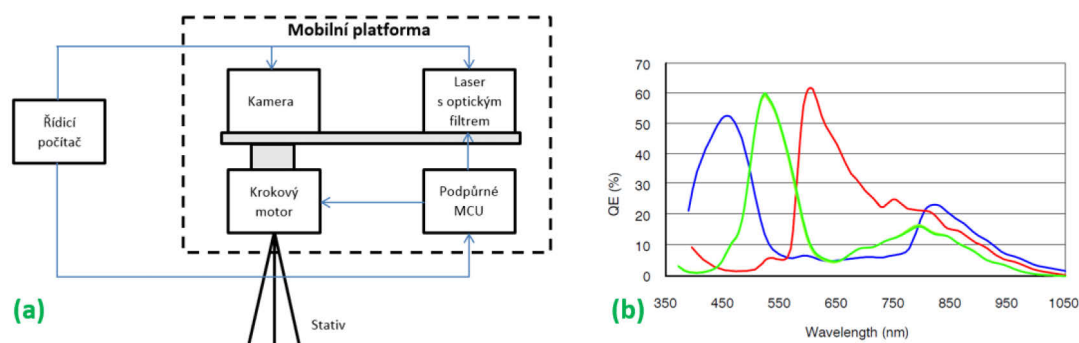
Pro potřeby automatizovaného mapování a skenování prostoru bylo zvoleno vlastní řešení a na výzkumném pracovišti Katedry elektrotechniky jsme zkonstruovali mobilní platformu skládající se ze stativu, nosné konstrukce, podpůrných obvodů a výkonného krokového motoru. Celý systém je modulární a na platformu lze umístit různá skenovací zařízení pro dosažení požadovaného rozsahu skenování prostoru. Následující část textu obsahuje její popis a rozbor vlastního optického měřiče vzdálenosti složeného z kamery a laseru s paprskem rozptylující filtr do vertikální čáry.

Navržený optický měřič vzdálenosti vychází z práce autora (Surýnek, 2008), který vytvořil bodový laserový dálkoměr. Rozšířil jsem použitý princip měření vzdálenosti na 3D skener zkoumaného prostředí, který lze využít i v neznámých prostorách. Měřicí systém umožňuje určit vzdálenost v libovolném bodě detekované vertikální laserové čáry a v součinnosti s krokovým motorem vytvořit prostorovou mapu analyzovaného místa. Měřicí systém byl prezentován v (Chmelař, 2012). Výhoda navrženého optického skeneru spočívá v možnosti určení pozice libovolného bodu prostoru na detekované vertikální laserové čáře bez nutnosti vychylování aktivních částí optického měřiče kromě rotace kolem své osy umožňující vytvoření prostorového mračna bodů. Oproti tomu systémy vyžadující vychylování jsou nákladné, jako například 3D lidary určené pro robotiku Hokuyo URG-04LX-UG01 a SICK-LMS200 nebo profesionální skenovací systémy FARO Focus. Oproti zmíněným lidarům není prezentovaný systém skenování schopen měření v reálném čase a nelze ho tak použít pro potřeby SLAM. Navíc ale umožňuje využít obrazovou informaci pro barevnou vizualizaci skenovaného prostředí.

#### **3.1.1 Základní popis platformy**

Mobilní platforma, jejíž blokové schéma je uvedeno na Obr. 3.2 (a) disponuje laserovým optickým měřičem složeným z jakostní kamery Basler Ace ac2500-14gc s rozlišením 2590 x 1942 pixelů připojená přes rozhraní USB3 umožňující dostatečný datový tok pro přenos obrazu s vysokým rozlišením. Kamera využívá moderní snímací CMOS čip MT9P031 firmy ON Semiconductor. Na Obr. 3.2 (b) je uvedena jeho QE charakteristika z technické specifikace (ON Semiconductor, 2017). Druhou hlavní část

optického měřiče tvoří laser. Na zelené spektrum světla má kamera vysokou citlivost. Tento parametr je i jedním z důvodů volby zelené laserové diody pro proces skenování.




Obr. 3.2 – Mobilní platforma, (a) blokové schéma, (b) QE charakteristika kamerového čipu MT9P031 (ON Semiconductor, 2017)

Použitá laserová dioda disponuje výkonem 200 mW pro dobrou rozlišitelnost laserového paprsku, který je rozptýlen optickým filtrem do vertikální čáry v úhlu  $90^\circ$ , od pozadí skenovaného prostředí. Otáčení měřicí hlavy kolem své osy zajišťuje krokový motor. Na stativu je umístěna mobilní platforma s optickým měřičem vzdálenosti. Kamera je vůči mobilní platformě ve fixní poloze a je možné měnit vzájemný odstup mezi ní a laserovým zářičem. Celý proces skenování je ovládaný řídicím počítačem ovládající činnost laseru a otáčení měřicí hlavy krokovým motorem přes podpůrný mikroprocesor. Mobilní platformu při procesu skenování ukazuje Obr. 3.3 (a). Měřicí snímek zachycený kamerou je zobrazen na Obr. 3.3 (b). Více ukázek navrženého skenovacího systému v různých fázích vývoje obsahuje Příloha C.



Obr. 3.3 – Mobilní platforma, (a) měření vzdálenosti, (b) snímek měření

Optický měřič vzdálenosti využívá principu triangulační metody založené na poměru parametrů dvou trojúhelníků. Horizontální řez kamerou znázorňující dva trojúhelníky a popis jednotlivých parametrů pro určení neznámé vzdálenosti navrženého měřiče je uveden na Obr. 3.4. První trojúhelník tvoří měřená vzdálenost  $D$  a konstantní odstup mezi středem objektivu kamery a laserovým paprskem definovaná jako  $h$ . Druhý trojúhelník se nachází za optikou kamery tvořený její ohniskovou vzdáleností  $f$  a odstupem pixelů  $ppx$  detekované laserové čáry na snímacím čipu od středu obrazu. Počet pixelů nemá žádný fyzikální rozměr, a proto musí být násoben navíc horizontálním rozměrem pixelu snímacího čipu označený jako  $Hr$ .



Obr. 3.4 – Princip triangulační metody, (a) horizontální řez kamerou s označenými parametry, (b) ilustrace vodorovného řezu na reálné scéně

Mezi oběma trojúhelníky platí vztah

$$\frac{h}{D} = \frac{ppx \cdot Hr}{f} \quad (3.1)$$

Při znalosti tří parametrů uvedené rovnice (3.1) získáme čtvrtý parametr, neznámou vzdálenost  $D$  v metrech, jeho úpravou

$$D = \frac{h \cdot f}{Hr \cdot ppx} \quad (3.2)$$

Použitá kamera má velikost pixelu  $Hr = 2,2 \mu\text{m}$ , ohnisková vzdálenost objektivu je  $f = 4 \text{ mm}$  a konstantní vzdálenost mezi kamerou a laserem  $h = 15 \text{ cm}$ . Rozlišení kamery a parametr  $h$  udávají přesnost systému viz graf na Obr. 3.7. uvedený v následující kapitole 3.1.2. Pro co nejširší záběr skenovaného prostoru je zapotřebí použít objektiv kamery s malou ohniskovou vzdáleností. Získá se tak široký záběr, ale mohou se projevit negativní zkreslení snímaného obrazu popsané v kapitole 3.2 a 3.3 včetně jejich eliminace. Hlavními parametry optického měřiče vzdálenosti jsou:

- Kamera Basler Ace ac2500-14gc, 2590 x 1942 px
- Zelený laser s výkonem 200 mW
- Optický filtr pro rozptýlení laserového paprsku do vertikální čáry v úhlu  $90^\circ$
- Měřicí rozsah 0,25 m až 15 m
- Chyba měření do 5 m < 2,5 %, do 10 m < 4 % a do 15 m < 6 %

Obr. 3.5 popisuje blokové schéma procesu automatického skenování prostoru.




Obr. 3.5 – Blokové schéma skenování prostoru

Pro konkrétní použité komponenty optického měřiče vzdálenosti je zapotřebí provést pečlivou kalibraci celého měřicího systému pouze jednou. Proto je ohraničení prvního bloku na Obr. 3.5 vyznačeno čárkovanou čarou. Pro zajištění stálé přesnosti, například po jeho transportu, doporučuji kalibraci ověřit. Navržený optický měřič vzdálenosti lze využít pro přímé měření vzdálenosti při konkrétním natočení měřicí hlavy nebo v omezeném rozsahu stupňů. Standardně je systém navržen pro skenování prostoru v celém úhlovém rozsahu 360°. Pro určení vzdálenosti všech detekovatelných bodů měřících snímků je využit algoritmus blokově znázorněný v kapitole 3.4 na Obr. 3.16.

### 3.1.2 Kalibrace a zkreslení přesnosti vlivem vzdálenosti


Pro přesné měření a skenování je důležitá počáteční kalibrace celého systému. Prvním krokem kalibrace je volba vzájemné vzdálenosti  $h$  kamery a laseru. Parametry systému z rovnice (3.2)  $f$  a  $Hr$  jsou neměnné, záleží na volbě použité kamery a jejího objektivu. Použitý objektiv má volitelnou ohniskovou vzdálenost, ale mým požadavkem je co největší záběr skenované scény a ohnisko musí být tedy nastaveno na nejmenší hodnotu 4 mm. Jediný parametr, který lze změnit bez ovlivnění obrazové kvality a záběru kamery je právě vzdálenost mezi středem kamery a laserovým paprskem  $h$ . Z rovnice (3.2) vyplývá, že rozsah měřené vzdálenosti lze zvýšit pomocí parametru  $h$  a naopak.

Při změně pozice laseru je zapotřebí dbát na přesné určení parametru  $h$ . Vzdálenost mezi čočkou objektivu kamery a laserovým paprskem musí být stejná jako vzdálenost promítané laserové čáry a středem snímku (červený kříž) zachyceným kamerou na Obr. 3.6. Toto nastavení má zásadní vliv na přesné určení vzdálenosti.



Obr. 3.6 – Kalibrace optického měřiče vzdálenosti


Rovnice (3.2) také zanáší do systému nelinearitu, která se projeví nejvíce při měření větších vzdáleností. Snižování parametru  $h$  navíc způsobuje velkou změnu v určené vzdálenosti při změně hodnoty  $ppx$  o 1 pixel viz graf závislosti pixelové odchylky laserové čáry od středu obrazu Obr. 3.7. Z jeho průběhu je nepřímou odvozena i přesnost optického měřiče vzdálenosti. V kapitole 3.7.1 je stanovena přesnost určení segmentované laserové čáry pod 1 pixel a chyba měření tedy odpovídá maximální skokové změně určení vzdálenosti  $D$  při změně hodnoty  $ppx$  o 1 pixel v grafu na Obr. 3.7 v určitém měřicím rozsahu. Nejvyšší nelinearita funkce vzdálenosti (3.2) se projeví při malém odstupu středu kamery a laseru  $h$ . Jeho zvyšováním se naopak nelinearita snižuje. Výhodou systému při malém  $h$  je velice přesné měření malých vzdáleností v okolí do dvou metrů viz Obr. 3.7. Při velké hodnotě  $h$



**Obr. 3.7 – Nelinearita optického měřiče vlivem změny parametru  $h$**

Lze naopak měřit delší vzdálenosti. Při kalibraci systému je zapotřebí tento fakt uvážit a zvolit nejlepší kombinaci vzhledem k požadovanému rozsahu měření.

Proces kalibrace souvisí i s nastavením clony objektivu kamery. Clonu je zapotřebí nastavit tak, aby laserová čára dopadající na blízké objekty před kamerou nebyla příliš saturovaná. Pro lepší ilustraci slouží Obr. 3.8 s profily intenzity jasu zeleného kanálu obrazu.



**Obr. 3.8 – Příklady vhodně nastavené saturace laserové čáry v procesu kalibrace**

Nastavení saturace laserové čáry je důležité s ohledem na její segmentaci pomocí detekčních masek. Průběhy jasu zeleného kanálu zachyceného obrazu na Obr. 3.8 jsou průměrem jeho intenzity přes všechny řádky. Je důležité, aby kolem saturované laserové čáry zůstala část spektra detekovaného laseru. Spodní část Obr. 3.8 je ukázka maxima přítomné saturace. Při dalším snižování clonového čísla objektivu kamery by segmentovaná laserová čára přešla v bílé světlo a její postranní části by měly příliš nízkou intenzitu, aby bylo možné čáru vůbec detekovat. Bližší popis detekce saturovaných částí laserové čáry je uveden v kapitole 3.6 popisující algoritmus skládání segmentačních masek.

## 3.2 Barelové zkreslení

Při použití navrženého skenovacího systému je hlavním požadavkem kladeným na použitou kameru její široký záběr snímané scény. Toho lze dosáhnout použitím objektivu s nízkou ohniskovou vzdáleností. Zvoleným objektivem je Computar C-Mount s proměnnou ohniskovou vzdáleností od 4 mm do 8 mm a manuálním ovládním clony. Jelikož má objektiv proměnnou ohniskovou vzdálenost nebylo u něho možné zajistit stálost všech parametrů při libovolném nastavení ohnisku kamery. Negativní parametry se projevují nejvíce při nastavení nejmenšího ohniska. Získaný měřicí snímek v průběhu skenování prostoru při aktuální kompozici optického měřiče vzdálenosti je tak zatížen barelovým zkreslením projevující se efektem „rybího oka“, které je popsáno v této kapitole včetně jeho eliminace a použití super-sampling filtru pro vyhlazení poškozených přímých linií obrazu vlivem jeho korekce. Korekce zkreslení je prezentována v (Chmelar, 2015a). Získaný obraz je dále zatížen zkreslením chromatické aberace blíže popsáním v další kapitole 3.3.

Přítomnost barelového zkreslení optiky kamery použité k měření vzdálenosti pro systém automatického mapování prostoru má negativní vliv na přesnost měření způsobené nesprávným vyhodnocením pozice laserové čáry v obraze. Zkreslení je zejména přítomno při použití vybraného objektivu s nastavenou ohniskovou vzdáleností na 4 mm umožňující širší záběr pozorované scény. V systémech detekujících přímo laserový paprsek ze snímaného obrazu má zkreslení nepříznivý vliv na přesnost celého systému. Z tohoto důvodu je zapotřebí přítomné zkreslení eliminovat. Existuje několik přístupů jejich eliminace.

Podrobnější přehled druhů optického zkreslení je uveden v literatuře (Bismpigiannis, 2007). Některé jednodušší typy je možné eliminovat matematicky použitím inverzní funkce v případech, kdy je možné popsat funkcí jejich příčiny. Složitější deformace obrazu mohou být kombinacemi několika zkreslení a jejich odstranění vyžaduje sofistikované matematické řešení. V této kapitole je popsána jednoduchá efektivní metoda pro eliminaci zkreslení kruhového typu – barelového zkreslení.

Nízké ohniskové číslo  $f = 4 \text{ mm}$  zaručuje širší rozsah záběru kamery zejména v ose  $Z$ . Triangulační metoda (3.2) v kombinaci s parametry konfigurace optického měřiče vzdálenosti umožňuje měření rozsahu 4,3 m v ose  $Z$  ve vzdálenosti 4 m od kamery, ale dochází ke vzniku nežádoucího efektu barelového zkreslení Obr. 3.9. Velikost chyby měření způsobené optickým zkreslením objektivu závisí nepřímo úměrně na měřené vzdálenosti, viz graf na Obr. 3.7 výše. Například při měřené vzdálenosti 5,6 m chyba určení pozice laseru o jeden pixel znamená chybu měření 12 cm, procentuálně vyjádřeno 2,1 %. Efekt zkreslení je zejména zesílen na okrajích obrazu.

### 3.2.1 Korekce barelového zkreslení

Výhodou prezentovaného algoritmu je minimum vstupních parametrů a jeho aplikovatelnost v systémech s neznámými parametry objektivu. Pro konkrétní konfiguraci kamery a objektivu lze rovněž vytvořit korekční matici prezentovanou v kapitole 3.2.3 urychlující dobu zpracování jednoho měřicího snímku.

Pro potlačení zkreslení je využita základní rovnice (3.4). V případě neznámých parametrů je zapotřebí nastavit parametr síly korekce  $sDist$  experimentálně pro dosažení nejlepšího výsledku potlačení zkreslení.



Algoritmus vyžaduje dva základní parametry: výšku obrazu  $H$  a jeho šířku  $W$ . Vzdálenost od středu obrazu k jeho okrajům je definovaná jako  $H/2$  respektive  $W/2$ . S pomocí těchto parametrů lze určit maximální poloměr obrazu

$$r_{maxl} = 2 \cdot \sqrt{(H/2)^2 + (W/2)^2} . \quad (3.3)$$

Rovnice (3.3) slouží k určení korekčního poloměru  $r_u$  definovaného jako

$$r_u = \frac{r_{maxl}}{sDist} . \quad (\text{Helland, 2013}) \quad (3.4)$$

Parametr  $sDist$  v (3.4) je korekční síla definovaná uživatelem a při neznalosti parametrů optické části kamery je nastavena experimentálně pro dosažení nejlepšího výsledku korekce – rovných přímých čar. Pro nalezení optimální hodnoty parametru jsem navrhl algoritmus popsáný níže v kapitole 3.2.2. Zvýšením parametru  $sDist$  bude korekční poloměr menší a naopak. Algoritmus zpracovává každý pixel vstupního obrazu zvlášť jako

$$x_{new} = x - H/2 , \quad y_{new} = y - W/2 \quad (3.5)$$

Použitím rovnic (3.4) a (3.5) je korekční vzdálenost  $d_u$  (3.6) vyjádřena

$$d_u = \frac{\sqrt{x_{new}^2 + y_{new}^2}}{r_u} \quad (3.6)$$

Hodnoty  $x_{new}$  a  $y_{new}$  jsou souřadnice pixelů vztažené ke středu obrazu. Rovnice (3.7) popisuje korekci pozice pixelu na souřadnicích  $(x, y)$  ve výstupním obrazu

$$I_u(x, y) = I_c(x, y) + I(x_{new}, y_{new}) \cdot \frac{\arctg(d_u)}{d_u} \cdot z_u , \quad (3.7)$$

kde  $I_u(x, y)$  je výstupní obraz po korekci,  $I_c(x, y)$  je střed obrazu a poměr  $\arctg(d_u)/d_u$  vyjadřuje korekci vzdálenosti pixelu, kterou je násobena původní pozice pixelu  $I(x_{new}, y_{new})$  vztažená ke středu obrazu. Hodnota  $z_u$  označuje přiblížení obrazu. Ukázka aplikace korekce barelového zkreslení je na Obr. 3.9 (b). Bližším prozkoumáním vstupního obrazu Obr. 3.9 (a) je zkreslení patrné zejména v levé části na zárubni dveří a v pravé části na zakřiveném sloupu.



Obr. 3.9 – Ukázka barelového zkreslení, (a) zkreslený obraz, (b) korigovaný obraz

Při hodnotě  $z_u = 1$  se přiblížení neaplikuje na výstupní obraz. Postupem popsáným v další kapitole byl nalezen parametr síly korekce barelové zkreslení  $sDist = 1,8$ .

### 3.2.2 Optimální parametr korekce barelového zkreslení

Uvedené parametry  $sDist$  v předchozí kapitole lze hledat experimentálně. Obraz zachycený kamerou pro nalezení nejlepších parametrů korekce popisovaného zkreslení musí být z prostředí s výskytem rovných linií, jako jsou okna, dveře, stoly, rohy místností a podobně, viz Obr. 3.6. Výsledkem aplikace korekce pomocí nalezeného nejlepšího parametru je obraz bez zakřivených linií.

Experimentální hledání může trvat neúměrně dlouhou dobu a není zaručené nalezení nejlepší hodnoty. Proto jsem navrhl automatizovaný algoritmus pro jejich odhad. Vhodným nástrojem na vyjádření přítomnosti linií v obraze a porovnání jejich kvality v podobě zakřivení je Houghova transformace (Gonzalez, 2009). Její akumulátor sumarizuje přítomnost přímek ve vstupním obraze pro definovaný rozsah stupňů prostřednictvím intenzit bodů na určitých pozicích vyjadřující celkový počet bodů tvořící přímku, která může být i nespojitá. Čím více bodů obsahuje přímka ve vstupním obraze, tím je bod v akumulátoru intenzivnější. Z této vlastnosti vychází i navržený algoritmus hledání optimálních parametrů korekce barelového zkreslení. Před aplikací transformace je provedena hranová detekce vstupního obrazu pomocí operátoru Canny s parametry hodnoty prahu  $T = 0,1$  intenzity hrany a hodnotou směrodatné odchylky Gaussova filtru  $\sigma = 10$ . Aplikace hranových operátorů je nutná pro získání hran v obraze popisující právě zakřivené čáry vlivem zkreslení.




Obr. 3.10 – Ukázka hranové detekce Canny na vstupním obraze, (a)  $sDist = 1$ , (b)  $sDist = 1,8$

Obr. 3.10 ukazuje hranovou detekci vstupního obrazu z Obr. 3.9 s hodnotou  $sDist$  1 na Obr. 3.10 (a) a 1,8 na Obr. 3.10 (b). Vstupní obraz je příliš veliký a detektor Canny produkuje hrany s šířkou 1 px, proto pro lepší názornost je na získané hrany aplikována navíc morfologická dilatace elementem disk o velikosti 3 pro dostatečné zvýraznění získaných hran. Při posuzování kvality korekce zkreslení nelze pouze vycházet z maximální hodnoty akumulátoru Houghovy transformace  $H_a$ , neboť není možné zajistit stálost počtu bodů přímky a pozice maxima v akumulátoru při změnách korekčních parametrů. Základní princip odhadu parametrů naznačuje Obr. 3.11 srovnávající akumulátory transformace a průběhy jeho intenzit rovné a zakřivené čáry.

Z Obr. 3.11 (a) je patrné, že maximum akumulátoru přímé čáry je vyšší a postranní hodnoty maxima se rychleji snižují. Této vlastnosti využívá navrhovaný algoritmus, který vyhodnocuje sumu gradientů v definovaném rozsahu stupňů, konkrétně 10 stupňů na Obr. 3.11, od nalezených hodnot maxim analyzovaného akumulátoru v jednotlivých iteračních krocích. Akumulátor  $H_a$  je dvojrozměrný, na ose  $x$  jsou vyneseny jednotlivé stupně hledaného rozsahu sklonu přímek v obraze označený jako  $A_r$ . Osa  $y$  určuje délku kolmice na přímku pod úhlem definovaným pozicí osy  $x$ , vyjádřenou jako pixelová odchylka od horizontálního středu akumulátoru.






Obr. 3.11 – Porovnání akumulátorů Houghovy transformace, (a) rovná čára, (b) čára zakřivená

Před hledáním lokálních maxim je výhodné odstranit nadbytečné body akumulátoru s malou hodnotou podle vztahu (3.8). Parametru  $k$  jsem experimentálně zvolil hodnotu 0,4.

$$H_a(H_a < kH_{a_{max}}) = 0, \quad (3.8)$$

kde  $k$  je práh z maximální hodnoty akumulátoru  $H_{a_{max}}$ . Hodnoty menší než uvedený práh jsou po aplikaci rovnice (3.8) rovny nule. Pro vyhodnocení míry zakřivení detekovaných přímků není důležitá jejich pozice ve vstupním obrazu, ale zejména intenzita bodů ve sledovaném akumulátoru. Uvedené zjednodušení umožňuje transformovat dvourozměrný akumulátor nalezením maximálních hodnot všech jeho sloupců do vektoru  $\mathbf{h}_{a_{max}}$  o počtu prvků úhlového rozsahu  $A_r$ . Nový vektor obsahuje vlivem prahování rovnicí (3.8) několik nenulových oblastí s lokálními maximy. Obr. 3.12 (a) znázorňuje vektor akumulátoru  $\mathbf{h}_{a_{max}}$  pro hodnotu  $sDist = 1$  a Obr. 3.12 (b) pro  $sDist = 1,8$ . V pravé části je zejména patrné vyšší lokální maximum středu akumulátoru  $\mathbf{h}_{a_{max}}$  a celkově je šířka ostatních lokálních maxim užší v porovnání s levou částí.




Obr. 3.12 – Maximum  $H_a$  přes všechny sloupce po aplikaci (3.8), (a)  $sDist = 1$ , (b)  $sDist = 1,8$

Pro jejich nalezení používám klasický algoritmus označení spojených komponent nebo jeho modifikaci prezentovanou v kapitole 6.2. V každé nalezené oblasti z celkového

počtu  $N$  je určena pozice lokálního maxima uložená do vektoru  $\mathbf{m}_{H_a}$ . Počet gradientů určovaný k jednomu lokálnímu maximu je označen jako  $A_g$ . Jinými slovy hodnota  $A_g$  znamená počet stupňů, pro které se určují gradienty od pozice lokálního maxima uvedené ve vektoru  $\mathbf{m}_{H_a}$ . Vzorec pro výpočet sumy gradientů  $\nabla_{S_i}$   $i$ -tého kroku navrženého algoritmu je definován jako

$$\nabla_{S_i} = \sum_{n=1}^N \sum_{a=1}^{A_g} \frac{h_{a_{max}}[\mathbf{m}_{H_a}[n]] - h_{a_{max}}[\mathbf{m}_{H_a}[n] + a]}{a}. \quad (3.9)$$

Přičítaný index úhlu  $a$  ve vztahu (3.9) označuje hledání gradientu pravé strany lokálního maxima. Pravá strana je zvolena z důvodu hledání úhlů všech přímek v obraze pro rozsah  $A_r = [0, 180]$  a hodnota  $0^\circ$  představuje právě v akumulátoru první levý sloupec.



Obr. 3.13 – Graf sumy gradientů pro parametr  $sDist = [1, 3]$

Na Obr. 3.13 je znázorněn průběh sumy gradientů  $\nabla_{S_i}$  pro parametr  $sDist$  pohybující se v rozmezí od 1 do 3 s vyznačeným maximem odpovídající  $sDist = 1,8$ . Navržený algoritmus umožnil najít nejlepší hodnotu parametru  $sDist$  analyticky. Algoritmus je navíc univerzální ve smyslu hledání přímých čar v akumulátorech Houghovy nebo Radonovy transformace při změnách vstupního obrazu, neslouží jen pro potřeby nalezení optimálních parametrů korekce barelového zkreslení objektu.

Pro vylepšení kvality obrazu po odstranění barelového zkreslení je možné využít metodu aplikace super-sampling filtru prezentovaný v (Chmelar, 2015a). Metoda je založená na principu Rotated Grid Super-Sampling (RGSS) a má zejména význam při používání malého rozlišení kamery.

### 3.2.3 Korekční matice

Pro urychlení aplikace korekce lze stanovit parametr  $sDist$  pro jeden snímek získaný kamerou na základě metody naznačené na Obr. 3.13 a následně určit všechny pozice pixelů po aplikované korekci. Nově určené pozice je možné uložit do korekční matice  $M_{pixU}(x, y)$ . V momentě stanovení pozic pixelů pro určitý typ kamery a její optiky lze aplikovat korekci na všechny snímky kamery se stejným rozlišením. Další rovnice (3.10) ukazuje použití korekční matice pro urychlení celého procesu eliminace barelového zkreslení.

$$I_u(x, y) = I_d[M_{pixU}(x), M_{pixU}(y)] \quad (3.10)$$

Obraz označen jako  $I_D$  je obraz zatížený zkreslením. Rovnice (3.10) je platná pouze pro aplikaci korekce bez filtrace. Při použití super-samplingu je nezbytné uložit všechny


pozice korigovaných pixelů včetně pozic okolních pixelů a provést průměrování. Může nastat situace, kde jsou pozice filtru některých vzorků stejné. V tomto případě si stačí zapamatovat počet výskytu pixelu se stejnou intenzitou a zahrnout tento násobek do průměrování. Tato operace rovněž urychlí proces korekce obrázku při vyšších úrovních filtrace.

V této kapitole jsem představil jednoduchý algoritmus k odstranění barelového zkreslení včetně algoritmu pro automatické nalezení korekčních parametrů. Vstupními parametry jsou pouze rozměry snímku a síla efektu korekce. Popsaný algoritmus má několik výhod: jednoduchost, širokou aplikovatelnost a možnost aplikace i bez znalosti parametrů optiky. Použití korekční matice umožňuje urychlit proces zpracování měřicích dat zejména při použití vysokého stupně filtrace. Praktické výsledky časového zpracování jsou uvedeny v kapitole 3.10. Prezentovaný algoritmus má široké použití, nejen pro skenování prostoru. U korigovaných snímků je zapotřebí ještě odstranit efekt chromatické aberace popsany v následující kapitole.

### 3.3 Zkreslení chromatické aberace

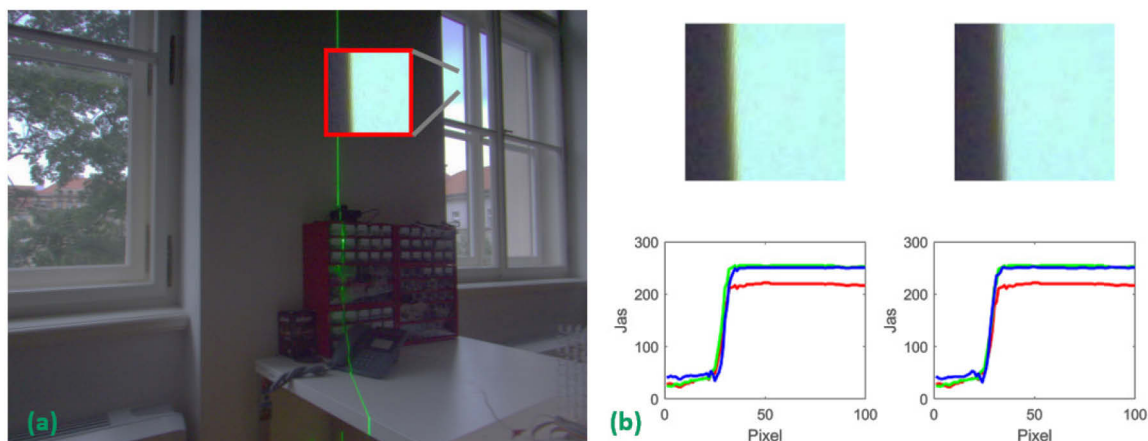
Dopadající světelné paprsky musí být směřovány spojovací čočkou objektivu pod velkým úhlem. Kromě přítomnosti barelového zkreslení, popsaného v předchozí kapitole 3.2 se u objektivu projevuje rovněž zkreslení chromatické aberace.

Zkreslení způsobuje velký úhel ohybu světelných paprsků, který se projevuje různým úhlem dopadu jednotlivých spektrálních složek bílého světla na snímací čip kamery. Efekt se projevuje nejvíce na kontrastních hranách v obraze, kde se bílé světlo mění v temné pozadí. Obr. 3.14 znázorňuje projev zkreslení chromatické aberace.



Obr. 3.14 – Ilustrace zkreslení chromatické aberace

Následující Obr. 3.15 znázorňuje praktický příklad projevu popsané vady včetně průběhu intenzity řádku ve všech spektrálních složkách obrazu. Obr. 3.15 (a) je typický měřicí snímek s vyznačeným detailem projevu efektu aberace u okna, kde bílé denní světlo v okně přechází do tmavé stěny. Na Obr. 3.15 (b) v jeho levé části jsou průběhy intenzity jasových složek RGB včetně grafického detailu. Z průběhu je patrný posun zeleného kanálu o 3 pixely vlevo. Při detekci zeleného laseru může toto zkreslení za určitých podmínek zapříčinit nesprávné určení pozice jeho čáry představující chyby měření. Pro korekci zkreslení chromatické aberace využívám algoritmus navržený autory (Johnson, 2006). Algoritmus hledá maxima mezi jednotlivými hodnotami jasových barevných kanálů a pomocí korelace dopočítává posun. Uvažuje rovněž silící efekt zkreslení od středu obrazu k jeho okrajům. Obr. 3.15 (b) vpravo zobrazuje korigované zkreslení chromatické aberace včetně průběhu jasových složek, kde na hraně přechodu jsou všechny barevné kanály zarovnané.



**Obr. 3.15 – Chromatická aberace použitého objektivu, (a) snímek měření s detailem, (b) výstup korekce**

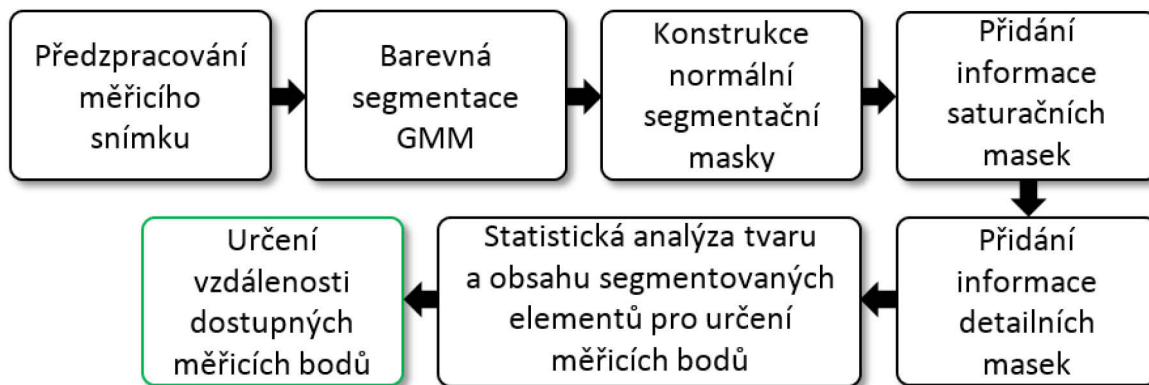
Efekt zkreslení lze eliminovat také snížením rozlišení obrazu, ale tím by došlo k nežádoucí ztrátě jeho detailu. V procesu předzpracování snímku před jeho segmentací je také použit Gaussovský filtr pro potlačení jeho šumu způsobený citlivostí snímacího čipu kamery při nastavení její clony pro potřeby snímání laseru. Použitá filtrace rovněž napomáhá potlačení zkreslení aberace. Při skládání segmentačních masek uvedené v kapitole 3.6 je rovněž využita informace saturačních masek pro eliminaci tohoto zkreslení a zamezení výskytu falešných měřicích bodů. Efekt zkreslení chromatické aberace se projevuje nejen na přechodech ze saturovaných částí obrazu, ale obecně i na přechodech s vyšší změnou intenzity jasové složky, a proto je nutná jeho eliminace více způsoby. Po odstranění všech nežádoucích efektů vstupního obrazu jednotlivé snímky vstupují dále do procesu tvorby segmentační masky laserové čáry.

### 3.4 Detekční algoritmus laserové čáry

Segmentace vertikálně promítané laserové čáry na statickém snímku měření patří mezi složitější typy segmentace. Pixely laseru mohou nabývat různých intenzit jasu. Volba jednoho nebo několika jejích prahů není dostatečující a univerzální pro všechny případy. Zachycená intenzita laseru na měřicím snímku je závislá na odrazivosti jednotlivých materiálů a povrchů skenovaného prostředí. Některé spektrum světla použitého laseru odrážejí a jiné naopak pohlcují. Výskyt různých intenzit jasu není ale jediná detekční komplikace. Laserová čára zachycená na blízkých objektech může být saturovaná, jejíž spektrum se blíží spektru bílého světla a v extrémních případech mají pixely detekovaného laseru přímo jeho spektrum. Saturované části nelze z procesu měření eliminovat, neboť nesou důležitou informaci o měřené pozici. Při detekci laserové čáry je rovněž nutné eliminovat přítomné denní světlo, které je zapotřebí odlišit od saturovaných částí laseru. Ve skenovaném prostředí se mohou také vyskytovat objekty barevného spektra blízké spektru detekovaného laseru a při určování přesné pozice měření je nutné tyto objekty rozpoznat. Pro spolehlivou detekci laserové čáry nestačí tedy pouze vhodné barevné modelování jeho intenzit jasu, ale je rovněž vyžadována podrobná statistická analýza jeho obsahu, plochy a tvaru. Zbývající část této kapitoly popisuje celý proces modelování a segmentace laserové čáry, až po sestavení finální segmentační masky, vypořádání se s různými situacemi a vlivy provázející proces měření a výběr nejlepšího segmentovaného elementu pro určení přesné pozice měření v jednotlivých bodech. Po určení všech měřicích bodů následuje popis tvorby

prostorové mapy včetně přidání barevné informace. Závěr kapitoly obsahuje zhodnocení použitých barevných modelů, přesnosti měření a řešení neočekávaných situací, které mohou vzniknout v průběhu skenování prostoru.

Blokové schéma algoritmu detekce promítané laserové čáry a určení měřené vzdálenosti v jejím libovolném bodě popisuje Obr. 3.16.

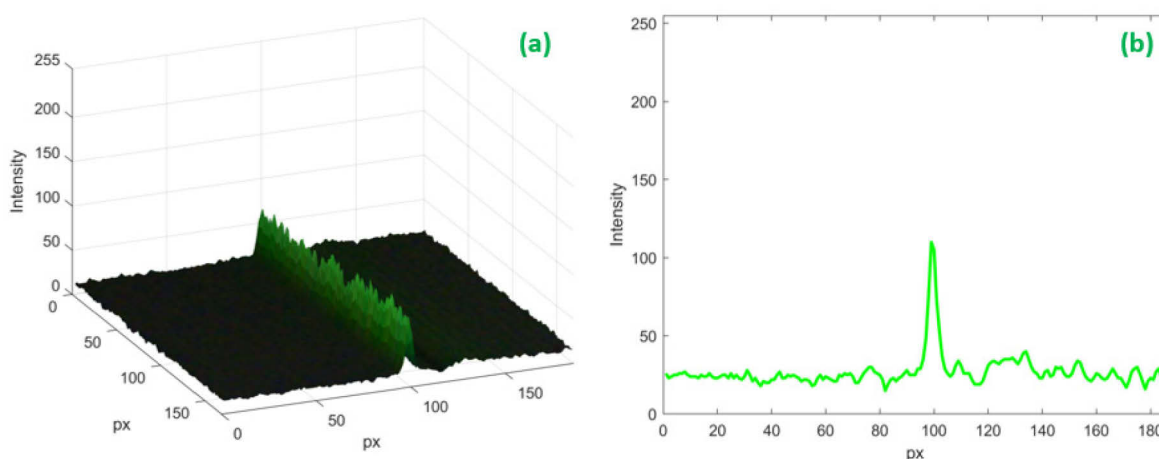


Obr. 3.16 – Blokové schéma algoritmu určení vzdálenosti na pozicích segmentovaného laseru

Prvním krokem algoritmu segmentace laseru a určení měřicích bodů je předzpracování vstupního snímku popsané v další kapitole 3.4.1.

### 3.4.1 Vstupní úprava měřicího snímku

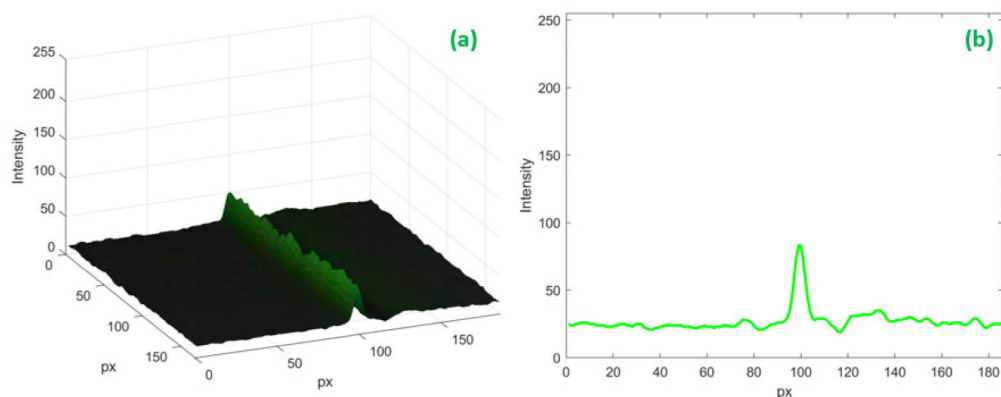
U snímku pořízeného kamerou během procesu skenování je nejprve eliminováno barelové zkreslení popsané v kapitole 3.2 a následně je odstraněn efekt chromatické aberace uvedené v kapitole 3.3. U takto opraveného snímku je zajištěna přesnost měření ovlivňující přítomnost obou druhů zkreslení. Detail zeleného kanálu měřicího snímku je zobrazen na Obr. 3.17 (a). Průběh 100řádku je ilustrován na Obr. 3.17 (b).



Obr. 3.17 – Zobrazení zeleného kanálu laseru před filtrací, (a) prostorové, (b) plošné - řádek 100

Analýzou zelené jasové složky  $G_{Int.}$  zjistíme její střední hodnotu  $\mu = 27,34$  a  $\sigma = 1,55$ . Z pohledu určování pozice laserové čáry je vstupní snímek v místech slabší intenzity poměrně zašuměn a je zapotřebí jeho filtrace. Jako vstupní filtr jsem zvolil konvoluční Gaussovský filtr s velikostí 5 a standardní odchylkou  $\sigma = 2$ . Výsledný obraz po aplikaci filtru je zobrazen na Obr. 3.18 (a) včetně průběhu 100řádku Obr. 3.18 (b).





**Obr. 3.18 – Zobrazení zeleného kanálu laseru po filtraci, (a) prostorové, (b) plošné - řádek 100**

Filtrace obrazu vylepšuje nejen jeho šumové vlastnosti, ale zároveň zlepšuje i detekční vlastnosti laseru. Tvoří-li segmentovaný laser širší přechod vyšší intenzity jasu, aplikovaný filtr způsobí jeho vyhlazení umožňující lépe určit místo hlavní koncentrace intenzity segmentovaného paprsku. Po aplikaci filtru má zelený kanál střední hodnotu intenzity  $\mu = 27,34$ , zůstala zachována. Hodnota směrodatné odchylky po aplikaci filtru je  $\sigma = 1,2$ , mírně klesla. Šum obrazu je částečně způsoben vlastním šumem snímacího čipu kamery, ale jeho hlavní příčinou je nastavení vyššího clonového čísla jejího objektivu z procesu kalibrace měření popsaného v kapitole 3.1.2. Clona je nastavena tak, aby laserová čára dopadající na blízké objekty nebyla příliš satureovaná. Vyfiltrovaný snímek poté vstupuje do procesu barevné segmentace laserové čáry.

### 3.4.2 Barevné modely pro detekci laserové čáry

Využití barevné informace ve zpracování obrazu je významné zejména ze dvou faktorů. Objekty jsou reprezentovány barvami a v mnoha případech je umožněno objekt jednoznačně identifikovat a vyseparovat pomocí jeho barvy. Druhým faktorem je schopnost člověka rozeznat tisíce barev, odstínů a intenzit jasu, umožňující manuální analýzu obrazu při vývoji a testování detekčního algoritmu. Barevný model je obecně tvořen minimálně třemi složkami. Důvodem existence mnoha barevných modelů je jejich použití pro specifické účely. Základní dvě skupiny barevných modelů tvoří modely závislé na provozovaném zařízení a modely na něm nezávislé.

U první skupiny záleží na systému, kde se používají. Příkladem takového modelu může být základní model RGB navržený pro zobrazení barvy na obrazovce. Jeho tři složky například [12, 187, 6] jsou transformovány zobrazovacím systémem jako jas a kontrast. Při změně zobrazovací charakteristiky jedné ze složek červené, zelené nebo modré se změní rovněž zobrazení výsledné barvy. Tato vlastnost řadí RGB model do skupiny závislých modelů na určitém zařízení. Všechny tři složky jsou na sebe závislé.

Druhou skupinu tvoří barevné modely nezávislé na zařízení. To znamená, že ve všech systémech, kde jsou používány, mají stejnou interpretaci. Příkladem takového modelu je CIE  $L^*a^*b^*$  barevný model. Tento systém spadá do skupiny HVS modelů. Jejich hlavním cílem je přiblížit vyjádření barvy způsobu lidského vnímání barev.

CIE systém je definován pro vyjádření barvy ve vlastním souřadnicovém systému XYZ. Pracuje s váhovaním rozdělení výkonového spektra tří barev pomocí váhových funkcí. Funkce jsou definovány s ohledem na citlivost vnímání světla „standardním pozorovatelem“ v různých vlnových délkách. Váhování probíhá přes viditelné spektrum od 360 nm do

830 nm v definovaných intervalech. Světelný zdroj, nasvětlení a geometrie pohledu jsou pečlivě definovány, jelikož ovlivňují výsledný vzhled konkrétní barvy. Výstupem váhování je trojice CIE hodnot XYZ, které jsou základem mnoha barevných modelů. Hodnoty XYZ fyzicky neexistují, pouze vyjadřují hodnotu v určitém modelu (Colantoni, 2004).

Pro barevné modelování detekované laserové čáry jsem vybral typické modely často využívané ve zpracování obrazu pro vyjádření barvy. K základnímu aditivnímu modelu RGB jsem vybral modely s oddělenou barevnou informací jako je YCbCr a modely uzpůsobené k lidskému vnímání barev, konkrétně HSV a  $L^*a^*b^*$ . Detailnější popis všech použitých barevných modelů je uveden v Příloha A.

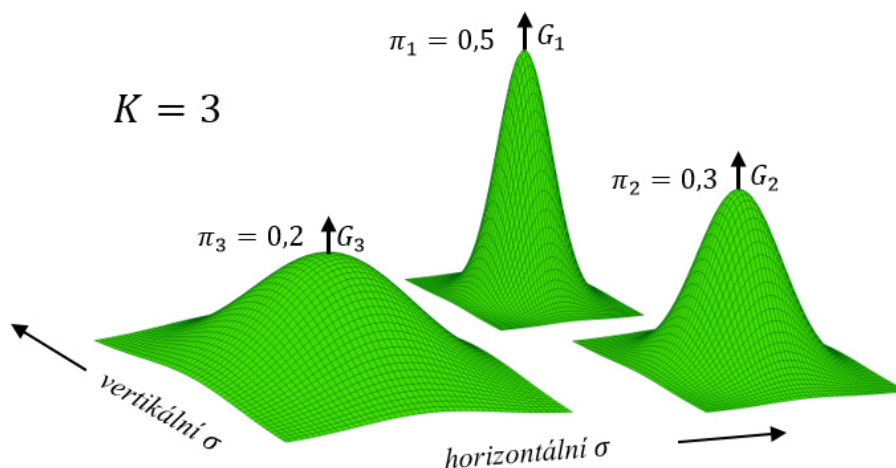
### 3.5 Gaussian Mixture Model

Tato kapitola popisuje barevné modelování intenzit odraženého světla laseru od objektů ve skenovaném prostoru, snímaného kamerou, pomocí Gaussian mixture modelu představující parametrickou pravděpodobnostní funkci reprezentovanou váhovanými sumami Gaussovských rozdělení. Základní princip modelování jsem prezentoval v (Chmelar, 2015b) a je inspirován prací Vision Based Fire and Smoke Detection prezentovaný v (Töreyn, 2006). Autor využívá RGB barevný model trénovaný na spektrum pixelů ohně. Systémem detekce ohně jsem se zabýval v rámci pracovní stáže a na tuto problematiku jsme vypracovali analýzu porovnání dvou barevných GMM v RGB a HSV barevném modelu (Chmelar, 2014a). Při detekování ohně kamerovým monitorování scény jsou k dispozici další důležité informace. Zejména lze sledovat vývoj celého procesu v časovém úseku, to umožní kombinaci historie vývoje regionu obrazu s aktuálním snímkem. Pro detekci laseru se využívá pouze statického snímku a k odlišení pixelu laseru od pozadí je zapotřebí kromě barevné detekce použít i statistické vlastnosti a tvar segmentovaných částí popsané v kapitole 3.7.1. Původní metoda detekce prahováním tří skupin intenzit laseru prezentovaná v (Chmelar, 2014b) se ukázala nedostatečná.

Úkolem barevného modelování laseru, jehož spektrum je soustředěno do úzké části prostoru barevného modelu, je vytvořit model optimálně pokrývající vstupní data, tak aby bylo dosaženo nejlepší segmentace pixelů laseru s co nejmenší mírou výskytu okolních pixelů, blízkých barevnému spektru detekovaného laseru. Gaussian mixture model splňuje tyto požadavky a umožňuje vhodné statistické modelování pixelů laseru. Je definován rovnicí


$$p(X) = \sum_{k=1}^K \pi_k \mathcal{N}(X | \mu_k, \Sigma_k), \quad (3.11)$$

kde  $X$  je  $n$ -rozměrná matice vstupních dat, pro případ barevného modelu je dimenze rovna 3,  $K$  je počet hledaných Gaussovských rozdělení, které je možné volit,  $\pi_k$  je váha (mixing coefficient)  $k$ -tého rozdělení. Součet všech vah celého modelu je rovna 1. Každé rozdělení z uceleného modelu je definováno svojí střední hodnotou  $\mu_k$ , kovariancí  $\Sigma_k$  vyjadřující jeho charakteristický rozsah pokrytého prostoru a vahou určující podíl trénovacích vzorků z celého modelu. Ilustrační zobrazení Gaussian mixture modelu pro  $K = 3$  je uvedeno na dalším Obr. 3.19.



Obr. 3.19 – Ukázka Gaussian mixture modelu pro  $K = 3$

Pro vytvoření GMM laseru je zapotřebí sestavit soubor jeho trénovacích pixelů zobrazených na Obr. 3.20. V souboru jsou zahrnuty pečlivě vybrané pixely detekovaného laseru z měřicích snímků.



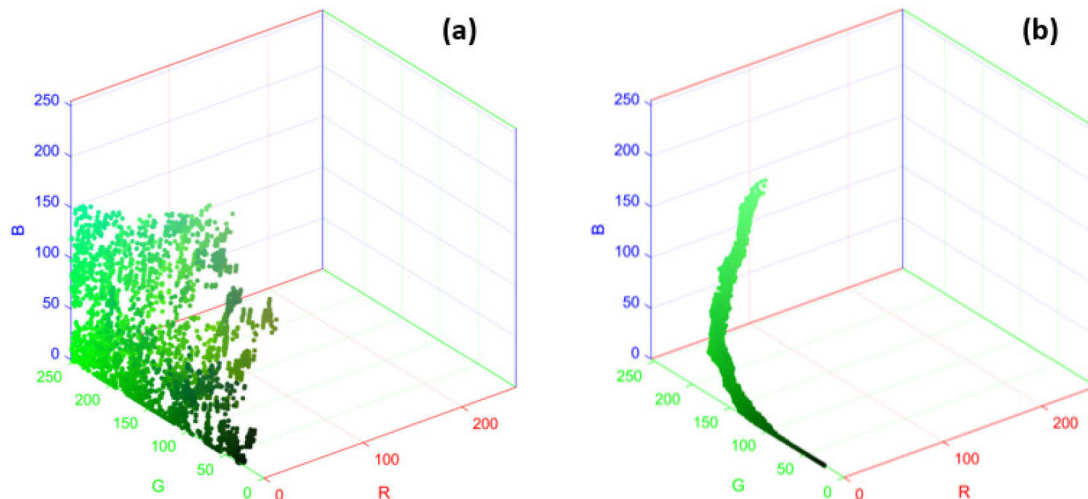
Obr. 3.20 – Trénovací pixely GMM použitého laseru, (a) původní pixely, (b) seřazené podle jasu

Na Obr. 3.20 jsou uvedeny dvě skupiny pixelů, původní uspořádání Obr. 3.20 (a) bylo vytvořeno postupným přidáváním nových pixelů z jednotlivých snímků a seřazené uspořádání intenzit pixelů vzestupně Obr. 3.20 (b) vzniklo řazením pixelů v každém barevném kanálu zvlášť. Seřazením je ztracena informace o jednotlivých trénovacích pixelech, ale data pro získání modelu zůstávají stejná. Z analýzy histogramu je patrné, že střední hodnota jasu a ostatní statistické parametry zůstávají stejné pro obě trénovací skupiny pixelů. Uspořádaná skupina pixelů může zúžit rozptyl a počet nutných rozdělení  $K$  pro pokrytí požadovaného prostoru ve zvoleném barevném modelu, ale dosažené výsledky prezentované v (Chmelar, 2015b) dokazují lepší segmentační potenciál pro původní množinu pixelů na Obr. 3.20 (a) z důvodu původního rozmístění pixelů v prostoru barevného modelu. Jejich pozice lépe reprezentuje jeho požadovanou segmentační část. Vstupní množinou dat  $X$  jsou jednotlivé pixely barevného spektra detekovaného laseru, označené jako  $x$ .

$$X = [x_{c1_n}, x_{c2_n}, x_{c3_n}] \quad (3.12)$$

Barevný kanál pixelu  $x$  je označen indexem  $c$  1, 2 a 3. Další index  $n \in [1, 2, \dots, N]$ , kde hodnota  $N$  označuje počet trénovacích pixelů. Jednotlivé pixely umístěné v barevném prostoru ilustruje Obr. 3.21. Princip trénování barevného GMM laseru pomocí implementovaného algoritmu Expectation Maximization je popsán v následující kapitole 3.5.1. Správné trénování modelu nemá vliv na přesnost měření, ta závisí až na dalším zpracování segmentovaných částí, ale přispěje k celistvosti segmentované oblasti laseru a vhodně sestavené segmentační masky napomáhají řešit problematické jevy přítomnosti okolního světla na skenované scéně nebo detekci barevných objektů blízkých spektru detekovaného laseru.





Obr. 3.21 – Pixely laseru z Obr. 3.20 zobrazené v barevném prostoru RGB, (a) původní, (b) seřazené

Sestavený model musí pokrývat celou množinu trénovacích pixelů. Pro potřeby detekce laseru byly vytvořeny GMM všech barevných modelů popsanych výše v kapitole 3.4.2 a v Příloha A.

### 3.5.1 Trénování modelu GMM - Expectation Maximization

Trénování GMM ilustruji na barevném modelu RGB. Pro tvorbu modelu a nalezení jeho optimálních parametrů  $\pi_k$ ,  $\mu_k$  a  $\Sigma_k$  jsem využil vlastní implementace algoritmu očekávání maxima (Expectation-Maximization) ve výpočetním systému Matlab. Jako trénovací množiny jsou využity skupiny pixelů z Obr. 3.21. Trénovací algoritmus EM vyžaduje základní odhad středů shluků  $\mu_k$ . Ze vstupní množiny dat lze vybrat středy náhodně, ale pro zajištění nejlepší konvergence trénovacího procesu je vhodné nastavit vstupní hodnoty středů jednotlivých rozdělení  $\mu_k$  pomocí některého z algoritmů shlukování.

Ve vlastní implementaci trénovacího algoritmu EM využívám klasifikátor k-means (Chmelar, 2014a), který podle zvoleného počtu shluků  $K$ , jejichž určení optimálního počtu popisuje kapitola 3.5.2, algoritmus na začátku stanoví  $K$  průměrů  $\mu_k$ , náhodně nebo na základě jiné informace o vstupní množině dat. Prvky vstupního souboru s nejmenší vzdáleností od k-tého středu  $\mu_k$  jsou označeny jako součást k-tého shluku. Pro každý shluk se vypočítá nový střed z přidružených dat. Proces se opakuje a v jednotlivých krocích se takto aktualizují středy shluků. Algoritmus končí docílením požadované úrovně velikosti změny středů shluků nebo dosažením celkového počtu iterací. Jeho výstupem jsou nalezené středy shluků. Klasifikátor k-means třídí data do skupin. Jeho výstupem jsou středy nově utvořených shluků a pole indexů označující přidruženost dat k odpovídajícímu shluku. Jeden prvek vstupní množiny dat může náležet jednomu shluku. K-means je schopen spolehlivě najít středy jednotlivých shluků, které jsou základem pro požadovanou detekci barevného laseru, ale neposkytuje žádnou informaci o variabilitě dat určitého shluku, důležité zejména z pohledu citlivosti laseru na jednotlivé složky barevného modelu. Oproti tomu GMM je pravděpodobnostní model složený ze skupiny Gaussovských rozdělení. Prvek vstupních dat může být zároveň zastoupen i ve více blízkých shlucích.

Funkce algoritmu EM je obdobná jako u k-means. Hlavní odlišností je pravděpodobnostní modelování vstupních dat. Proces tvorby Gaussovských mixtur se dělí do 4 základních kroků:

- 1) **Počáteční odhad Gaussovských parametrů** – Z klasifikátoru k-means jsou přímo využity zjištěné středy shluků  $\mu_k$ . Kovariance k-tého shluku je stanovena jako  $\Sigma_k = cov(C_k)$ , kde  $C_k$  je shluk  $k$  a váhový koeficient  $\pi_k = N_{C_k}/N$ . Počet prvků shluku je značen  $N_{C_k}$  a  $N$  je celkový počet prvků.
- 2) **E – krok** – Přiřazení skóre  $\gamma(z_{nk})$  každému bodu  $n$  ze vstupní množiny dat  $X$  pro každý shluk  $k$ .

$$\gamma(z_{nk}) = \frac{\pi_k \mathcal{N}(x_n | \mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(x_n | \mu_j, \Sigma_j)} \quad (3.13)$$

Koeficient  $\gamma(z_{nk})$  je označován jako „odpovědnost“ vyjádřená, jak je Gaussovské rozdělení  $k$  odpovědné za bod  $x_n$ . Jeho hodnota je důležitá pro další krok, kde se podle něho přepočítávají charakteristiky všech Gaussovských rozdělení.

- 3) **M – krok** – Pro všechny Gaussovské rozdělení  $k$  jsou obnoveny jeho parametry použitím zjištěného skóre  $\gamma(z_{nk})$ . Střed  $\mu_k$  je přepočten podle vztahu

$$\mu_k^{new} = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) x_n, \quad N_k = \sum_{n=1}^N \gamma(z_{nk}), \quad (3.14)$$

kovariance je přepočítána s využitím nově stanovených průměrů rovnicí (3.14) jako

$$\Sigma_k^{new} = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) (x_n - \mu_k^{new})(x_n - \mu_k^{new})^T \quad (3.15)$$

a nový váhový koeficient je určen rovnicí

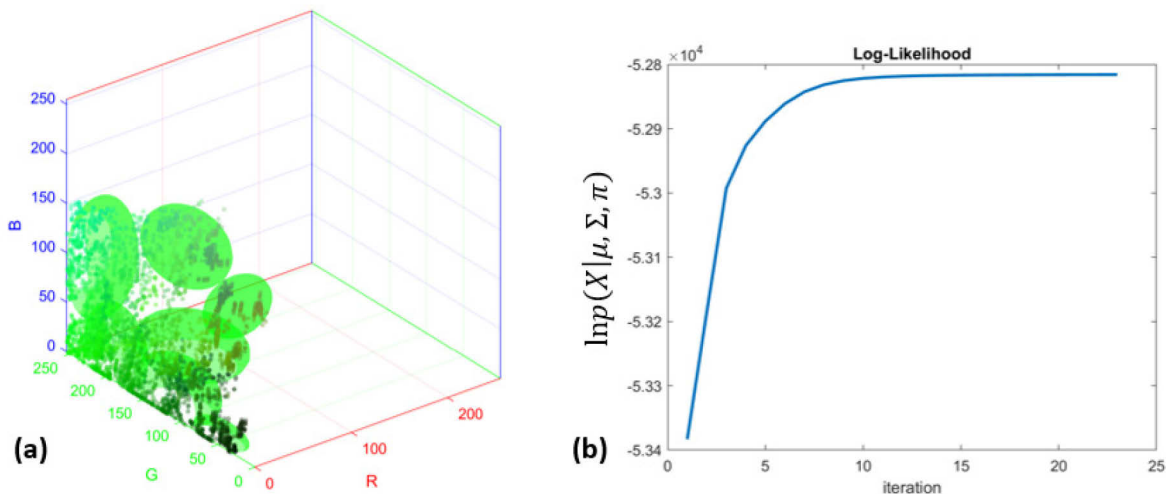
$$\pi_k^{new} = \frac{N_k}{N}. \quad (3.16)$$

Všechny nově stanovené parametry Gaussovských rozdělení (3.14), (3.15) a (3.16) jsou uzpůsobeny ve smyslu nejlepšího pokrytí určeného skóre  $\gamma(z_{nk})$  z předchozího kroku.

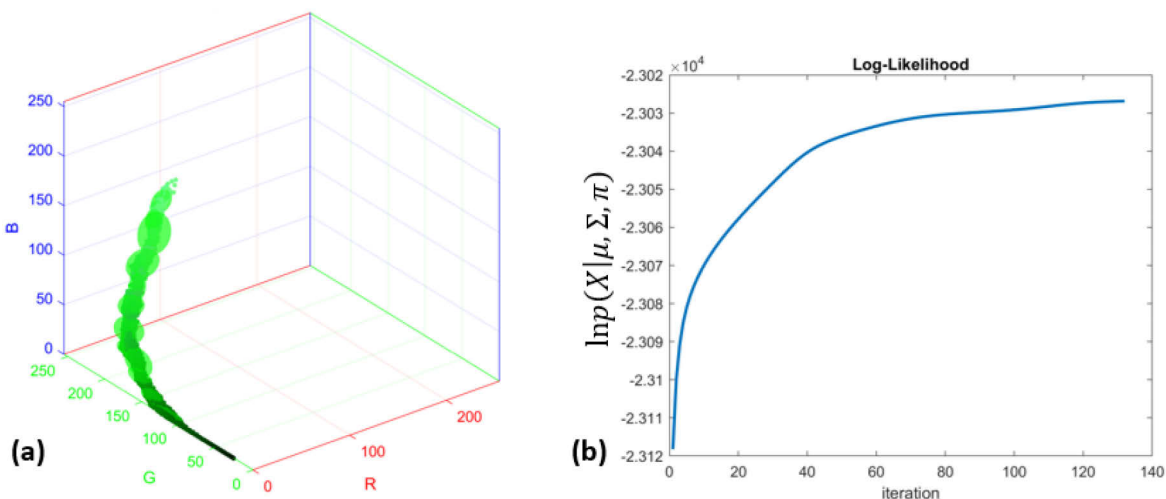
- 4) **Vyhodnocení pravděpodobnostní funkce** – V každé iteraci EM algoritmu, určená kroky 2) a 3), je vyhodnocena pravděpodobnostní (likelihood) funkce definovaná rovnicí (3.17) hodnotící kvalitu konvergence algoritmu. Vykonávání algoritmu EM končí dosažením konvergence zvolené úrovně maximální změny (3.17) mezi jednotlivými iteracemi algoritmu označené jako *eps* nebo dosažením maximálního definovaného počtu kroků *iter<sub>m</sub>*.

$$\ln p(X | \mu, \Sigma, \pi) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(x_n | \mu_k, \Sigma_k) \right\} \quad (3.17)$$

Ukázka procesu trénování modelu vstupních dat z Obr. 3.21 (a) i (b) včetně průběhu pravděpodobnostní funkce je zobrazena na Obr. 3.22 a Obr. 3.23 respektive.



Obr. 3.22 – Výsledek EM algoritmu pro vstupní data z Obr. 3.21 (a), (a) GMM  $K = 8$ , (b)  $\ln p$



Obr. 3.23 – Výsledek EM algoritmu pro vstupní data z Obr. 3.21 (b), (a) GMM  $K = 14$ , (b)  $\ln p$

Z analýzy obou výsledků trénování na Obr. 3.22 a Obr. 3.23 je patrné, že v případě neseřazené množiny vstupních pixelů pokrývají nalezené shluky vyznačené zelenou elipsou větší část barevného prostoru než v případě seřazené množiny. Pixely laseru lépe reprezentuje model z neseřazené množiny dat, viz výsledky v (Chmelar, 2015b). Nalezený model GMM vyjadřuje jejich skutečný rozptyl v barevném modelu. Výsledný počet rozdělení  $K$  není pro porovnání směrodatný, neboť seřazený model může mít i menší počet nalezených rozdělení, viz (Chmelar, 2015b). Oba modely byly trénovány s nastaveným parametrem  $iter_m = 500$  a  $eps = 1e^{-6}$ . Neseřazené vstupní množině dat s  $K = 8$  stačilo k dosažení nastavené úrovně konvergence  $eps$  23 iterací v čase 0,34 s. Seřazená množina dat s  $K = 14$  potřebovala k dosažení stanoveného  $eps$  132 iterací v čase 2,45 s. Způsob použití kovariance jednotlivých shluků pro segmentaci pixelů laseru a skládání segmentačních masek je popsán v kapitole 3.6.

### 3.5.2 Určení nejlepšího počtu rozdělení


Počet Gaussovských rozdělení tvořící GMM lze po několika pokusech stanovit rovněž ručně na základě požadavků pokrytí vstupních dat. V určitých případech, kdy se

počáteční odhady parametrů EM algoritmu volí podle uživatelského kritéria, může vhodná volba  $K$  přispět k rychlejší konvergenci tvořeného modelu a lepšímu pokrytí trénovací množiny dat. V případě, kdy k odhadu vstupních parametrů používáme klasifikátor k-means, je vhodnější určit optimální počet Gaussovských rozdělání automatizovaně. K jeho stanovení využívám metodu „kolene“ prezentovanou autorem (Sugar, 2003). Je založená na principu sledování sumy reziduí vzdálenosti jednotlivých prvků vstupních dat  $x_n$  od středů příslušných shluků  $\mu_k$ , získaných algoritmem k-means a postupným zvyšováním hodnoty  $K$ . Suma reziduí je definovaná vztahem

$$RSS_K(n) = \sum_{k=1}^{K_n} x_{nk} - \mu_k, \quad (3.18)$$

kde index  $n$  odpovídá jedné hodnotě  $K$  shluků z testovaného rozsahu  $K = [K_1, K_2, \dots, K_N]$ . Hodnota  $K_N$  značí maximální velikost testovaného  $K$ . Pro získání stabilního průběhu hodnoty popsané rovnicí (3.18) je pro každé  $K$  použit průměr 1000 běhů algoritmu k-means.

V kapitole 3.6 je popsán princip skládání segmentačních masek a význam jednotlivých GMM. Pro požadovanou detekci pixelů laseru bylo zapotřebí sestavit celkem tři typy segmentačních modelů. Na Obr. 3.24, jsou uvedeny průběhy funkce (3.18) pro nejlepší barevný model HSV na základě praktických výsledků v kapitole 3.10. Grafy ukazují



Obr. 3.24 – Určení optimálního  $K$  pro HSV GMM, (a) normální model, (b) detailní model

průběhy určení optimálního  $K$  pro modely normálního a detailního GMM. Cílem jeho analýzy je sledování změn mezi kroky při zvyšování  $K$ . V případě, kdy hodnota průběhu získá ustálený charakter, je nalezena optimální hodnota  $K$ , na obrázku vyznačena červeným bodem. Tab. 3.1 ukazuje přehled všech stanovených  $K$  pro jednotlivé barevné modely.

Tab. 3.1 – Tabulka určení optimálních  $K$  pro všechny barevné modely

$K$	Normální GMM	Detailní GMM
RGB	8	15
YCbCr	8	12
HSV	8	13
L*a*b*	8	5

Detailní popis a použití detekčních modelů prezentuje následující kapitola.

### 3.6 Skládání detekčních masek laseru

Prvním krokem algoritmu kompozice segmentačních masek  $M_L$  je vytvoření všech individuálních masek určitého barevného modelu. Pixel ze statického obrázku  $I$  na pozici

$x, y$  náleží modelu Gaussovských rozdělání barevného spektra laseru, pokud leží v oblasti tvořené centrem  $k$ -tého rozdělání a jeho směrodatnou odchylkou tvořící poloměr detekční oblasti

$$M_{L_{c,k}}(x, y) = \left( I(x, y)_c < (\mu_{c,k} + \sigma_{c,k}) \right) \wedge \left( I(x, y)_c > (\mu_{c,k} - \sigma_{c,k}) \right), \quad (3.19)$$

kde  $c$  je komponenta barevného modelu a  $k$  je analyzované rozdělání GMM. Standardní odchylka  $k$ -tého rozdělání je definovaná jako


$$\sigma_{c,k} = r_{sc} \cdot \sqrt{\text{diag}(\Sigma_k)_c}, \quad (3.20)$$

kde hodnota  $r_{sc}$  je citlivost detekce volená uživatelem určující rozsah rozdělání pro každou barevnou komponentu zvlášť. Tato volba umožňuje lépe vyjádřit citlivost složek barevného modelu na detekované spektrum laseru. Rozsah složky barevného modelu je získán z příslušné hodnoty diagonály kovarianční matice  $\Sigma_k$  GMM určené indexem  $c$ . Z procesu trénování modelu jsou hodnoty předem odhadnuty, aby pokrývaly všechny vstupní pixely pro tvorbu modelu. Výsledná segmentační maska pro  $k$ -té rozdělání je logickým součinem masek všech barevných kanálů

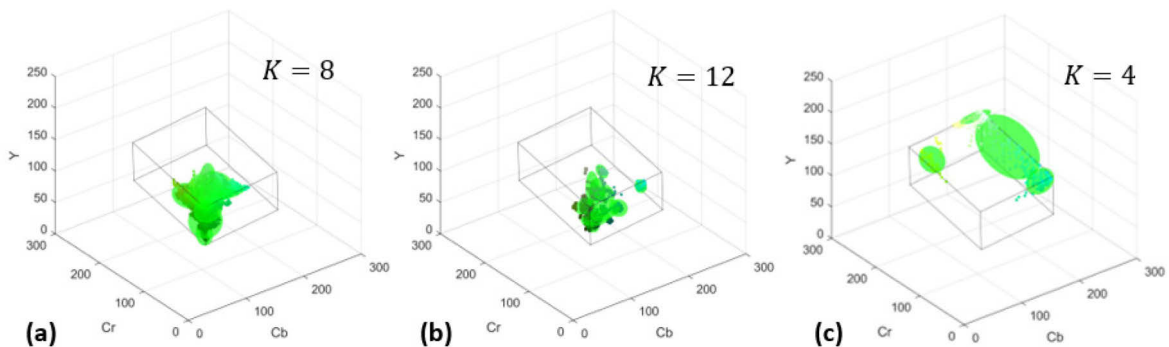
$$M_{L_k} = M_{L_{c_1,k}} \wedge M_{L_{c_2,k}} \wedge M_{L_{c_3,k}}. \quad (3.21)$$

Rovnice (3.19) popisuje kvádrový tvar rozdělání segmentující části barevného prostoru. Na ilustračních obrázcích GMM, například Obr. 3.22, jsou jednotlivá rozdělání vyjádřena tvarem elipsy. Použití zjednodušující aproximace tvaru umožňuje zrychlení segmentačního procesu a na kvalitě segmentace se projevuje pouze nepatrně.


Z fáze podrobného testování GMM a tvorby finální segmentační masky jednotlivých barevných modelů vyplynulo, že nakonec bylo zapotřebí vytvořit tři GMM modely zvlášť a jejich informace vzájemně kombinovat během procesu segmentace. Obrázky Obr. 3.25, Obr. 3.26 a Obr. 3.27 a Obr. 3.28 a tabulka Tab. 3.2 na následujících stránkách definují



Obr. 3.25 – GMM pro RGB prostor, (a) normální, (b) detailní, (c) saturační



Obr. 3.26 – GMM pro YCbCr prostor, (a) normální, (b) detailní, (c) saturační

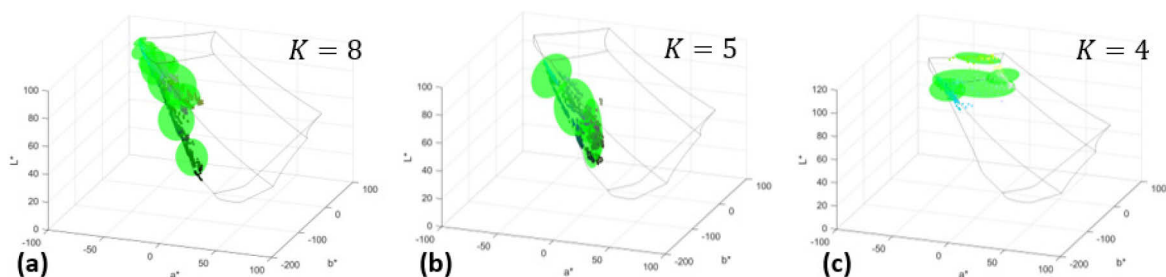


Obr. 3.27 – GMM pro HSV prostor, (a) normální, (b) detailní, (c) saturační

natrénované GMM pro použité barevné modely. Tab. 3.2 ukazuje hodnoty natrénovaného modelu pro nejlepší model HSV na základě výsledků v experimentální části kapitoly 3.10.

Tab. 3.2 – Tabulka hodnot rozdělení GMM pro barevný model HSV

$K$	Normální model				Detailní model				Saturační model			
	$H$	$S$	$V$	$\sigma [H, S, V]$	$H$	$S$	$V$	$\sigma [H, S, V]$	$H$	$S$	$V$	$\sigma [H, S, V]$
1	98.0	242.1	245.8	16.4, 16.5, 13.7	79.0	197.0	91.3	18.7, 34.2, 31.9	108.6	68.6	255.0	68.2, 152.4, 0.0
2	64.0	221.5	157.0	4.7, 23.1, 33.2	86.4	148.3	55.4	16.3, 37.6, 13.1	103.7	42.2	246.7	45.9, 59.5, 13.7
3	90.9	124.4	176.8	8.9, 19.3, 50.5	95.6	126.8	144.7	4.2, 91.0, 46.4	52.3	242.0	247.9	4.5, 22.7, 10.1
4	83.2	238.1	197.9	16.8, 23.6, 61.1	75.0	154.3	97.7	12.9, 32.4, 9.2	46.3	20.6	253.4	15.1, 25.9, 1.0
5	64.3	166.7	152.5	16.6, 34.7, 15.1	68.7	113.6	90.4	9.7, 33.8, 22.5	121.7	160.3	239.1	7.9, 69.6, 21.7
6	86.1	211.1	94.9	15.8, 59.2, 57.1	99.7	252.4	176.6	7.2, 12.6, 31.5	124.8	242.8	238.4	5.1, 25.7, 23.0
7	82.8	235.7	52.1	11.1, 22.1, 23.6	80.5	81.9	83.2	12.8, 29.9, 14.6				
8	91.8	188.4	224.7	15.3, 55.3, 36.5	81.2	64.3	137.3	15.9, 24.9, 19.7				
9					107.1	117.3	182.4	2.0, 36.7, 27.7				
10					119.2	204.6	99.8	5.9, 77.7, 29.8				
11					121.2	247.6	217.7	2.3, 13.9, 20.7				
12					120.1	152.6	142.4	2.8, 79.0, 27.9				
13					118.0	244.4	138.6	4.8, 17.4, 23.9				




Obr. 3.28 – GMM pro  $L^*a^*b^*$  prostor, (a) normální, (b) detailní, (c) saturační

Hodnoty v tabulce Tab. 3.2 popisují jednotlivá rozdělení  $K$  natrénovaných GMM pro segmentaci laseru. Pro určitý model je v tabulkách uvedena pozice středu rozdělení a hodnoty standartní odchylky  $\sigma$  pro vyjádření jeho rozsahu. Její hodnoty reflektují skutečný parametr  $r_{sc}$  z rovnice (3.20). Hodnoty rozsahu jsou nastaveny tak, aby u detailního modelu byl užší rozsah pro kanály  $c$  vyjadřující barevnou informaci spektra laseru. Pro barevný model RGB je hodnota  $r_s = [2, 2, 2]$  u normálního a saturačního modelu. Pro detailní model využívá  $r_s = [1, 2, 1]$ . Barevné modely  $L^*a^*b^*$  a YCbCr využívají  $r_s = [2, 2, 2]$  pro normální a saturační model a  $r_s = [2, 1, 1]$  pro detailní model. U HSV normálního a saturačního modelu je obdobně  $r_s = [2, 2, 2]$  a pro detailní model  $r_s = [1, 2, 2]$ .



Model pokrývající hlavní část spektra intenzity laseru bez příměsí pixelů okolí je nejdůležitější pro proces segmentace a značí se jako normální. Při testování detekce laserových pixelů pomocí normálního modelu bylo zjištěno, že část jeho masek, označené jako  $M_{LN}$ , obsahuje čistě spektrum modelovaného laseru a ostatní mohou při segmentaci obsahovat malé množství pixelů okolí. Tyto masky se označují jako  $M_{LNs}$ . Pozorovaná vlastnost se týká zejména pixelů s vyšší a nižší intenzitou jasu. Segmentační masky  $M_{LN}$  odpovídající přímo spektru laseru bez příměsí pixelů pozadí jsou v tabulce Tab. 3.2 vyznačeny tučnou barvou.

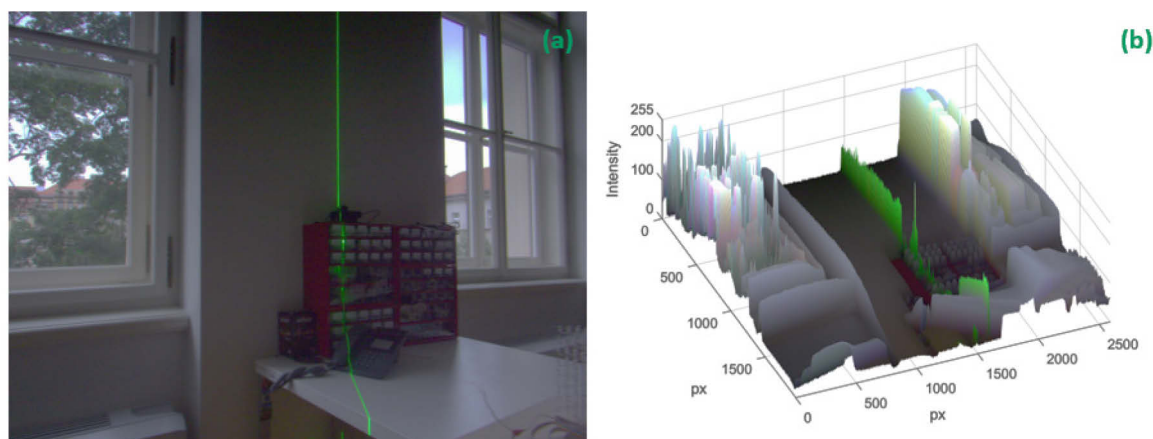
Střed zachyceného laseru kamerou, zejména při měření kratších vzdáleností, bývá často saturován a jeho spektrum se blíží spektru bílého světla. Saturovaný střed laseru nelze zanedbat a pro jeho detekci vznikl model označovaný jako saturační. Na snímcích měření jsou zastoupeny také nižší intenzity jasu laserového paprsku. Například na objektech, které pohlcují spektrum použitého laseru nebo při měření delších vzdáleností, je laserová čára zachycena kamerou slabá. Pro její detekci je sestaven detailní model laseru. Jeho nežádoucí vlastností je detekce pixelů pozadí měřicího snímku, se kterými se musí vypořádat algoritmus určení měřené vzdálenosti. Následující Obr. 3.29 ukazuje použité trénovací množiny pixelů detekovaného laseru všech GMM modelů včetně jejich histogramu vyjadřující jejich složení. Porovnáním normální Obr. 3.29 (a) a detailní Obr. 3.29 (b) skupiny pixelů je patrná převaha zeleného kanálu, oproti tomu detailní pixely obsahují i různé příměsi ostatních barevných kanálů, často větší intenzity než jejich samotná zelená složka.



Obr. 3.29 – Skupina trénovacích pixelů GMM, (a) normální, (b) detailní, (c) saturační

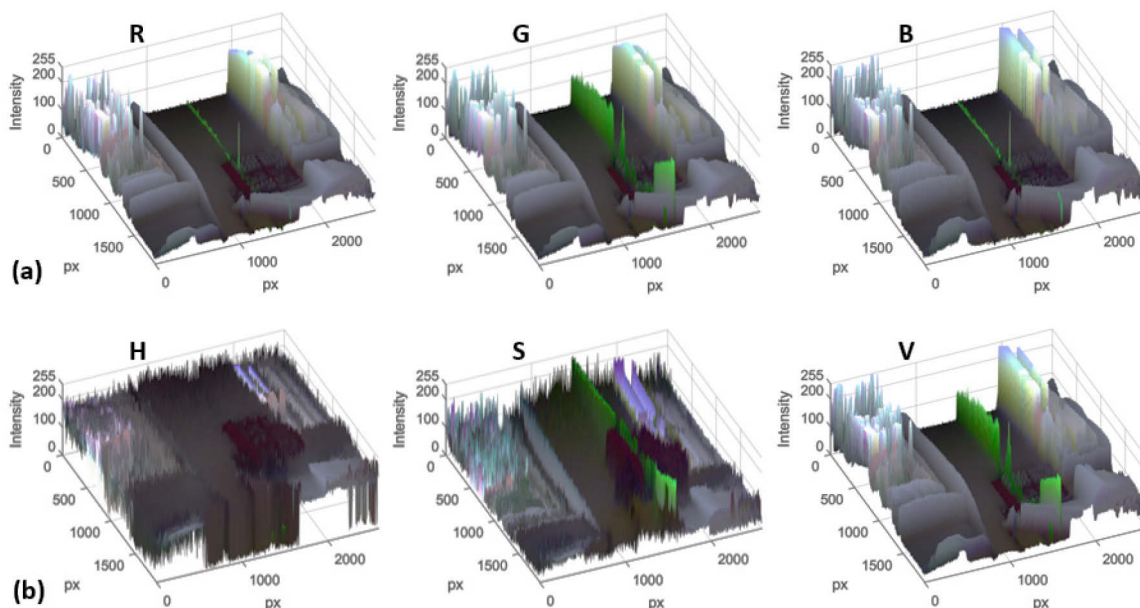
Další část této kapitoly popisuje kombinaci detekčních masek popsaných modelů a jejich využití při procesu segmentace vertikální laserové čáry.

Cílem segmentace laserové čáry je ze statického snímku pořízeným kamerou získat segmentační masku vstupující do procesu určování vzdálenosti, po bloku „Přidání informace



Obr. 3.30 – Vstupní obraz z procesu měření pro ilustraci algoritmu skládání masek detekčních modelů laseru, (a) obraz, (b) jasová složka v prostorovém zobrazení


detailních masek“ uvedeném na schématu Obr. 3.16. Pro detailní popis segmentace laserové čáry je vybrán Obr. 3.30 na předchozí straně pořízený kamerou během procesu skenování. Snímek zahrnuje většinu jevů vyskytujících se při skládání konečné masky. Měřicí pozice označují indexem  $i \in [0, 1, \dots, N - 1]$ , kde  $N$  je celkový počet měřicích bodů. Jednotlivé měřicí pozice jsou vertikálně rovnoměrně rozdělené. Jako detekční model pro popis principu segmentace barevného spektra laseru byl zvolen model HSV. Pro lepší názornost algoritmu detekce Obr. 3.31 ukazuje intenzitu pixelů v jednotlivých složkách pro RGB model Obr. 3.31 (a) a pro HSV model Obr. 3.31 (b). Každý obraz je označen příslušnou barevnou složkou a pokryt texturou původního obrazu pro lepší identifikaci jeho částí.



Obr. 3.31 – Jednotlivé kanály vstupního obrazu z Obr. 3.30, (a) RGB, (b) HSV

Z průběhu intenzity pixelů jednotlivých složek barevných modelů je zřejmé, že jednou určitou volbou rozsahu prahování intenzit pixelu není možné dosáhnout požadované segmentace laserové čáry, stejně jako v (Chmelar, 2014b).


Výstupem celého procesu kombinace popsaných GMM je tvorba finální segmentační masky  $M_{LF}$ , která je v průběhu celého procesu aktualizována. Pomocí masek normálního modelu barevného prostoru HSV citlivých pouze na spektrum laseru  $M_{LN}$  1, 2 a 4, viz tučně označené řádky v Tab. 3.2, je sestavena segmentační maska podle (3.22) obsahující pouze spektrum detekovaného laserového světla, bez pixelů pozadí Obr. 3.32.



Obr. 3.32 – Sestavení normální masky podle (3.22), (a) maska, (b) prostorová vizualizace aplikované masky na vstupní obraz Obr. 3.30 (a), (c) segmentované pixely normální maskou



$$M_{LF} = \bigcup_{k_n=1}^{K_N} M_{LNk_n} \quad (3.22)$$



Obr. 3.33 – Rozdíly normální masky  $M_{LN}$  a normální citlivostní masky  $M_{LNs}$ , (a) 4. maska, (b) 6. maska


Obr. 3.33 ukazuje rozdíly při segmentaci 4. normální maskou  $M_{LN}$  a 6. normální citlivostní maskou  $M_{LNs}$  včetně zobrazení segmentovaných pixelů v HSV barevném modelu. Masky 6 postihuje nižší hodnoty intenzity laseru a je mnohem širší, postihuje okraje laserové čáry. V její spodní části si lze všimnout i segmentace části obrazu odražené rozptýlené čáry, kterou nelze při konstrukci finální masky zanedbat. Musí být analyzována podle postupu popsaného níže v této kapitole.

Výsledná maska složená z masek  $M_{LN}$  normálního GMM se označí jako finální  $M_{LF}$  (3.22) a na měřicích pozicích je detekována její přítomnost pomocí analýzy spojených komponent  $LM_{LF}$ . Z šířky komponenty ve vymezené horizontální výšce detekované pozice  $i$  a pozice  $i + 1$  získám informaci o výskytu normální masky  $PM_{LF}$  následovně

$$PM_{LF}(i) \begin{cases} 1 \text{ pro } W \rightarrow LM_{LF}(i \leq x < i + 1, \forall) > 0 \\ 0 \text{ pro } W \rightarrow LM_{LF}(i \leq x < i + 1, \forall) = 0 \end{cases} \quad (3.23)$$

kde  $W$  označuje šířku spojené komponenty. U informace o přítomnosti segmentovaného laseru je rovněž zaznamenána pozice začátku levé a pravé části laseru, označené jako  $PM_{LF}(i)_L$  a  $PM_{LF}(i)_R$  respektive, a celková šířka laserové čáry  $PM_{LF}(i)_W$ .


Dalším krokem je kombinace informace saturační masky, sestavené obdobně jako normální maska podle (3.22) pro saturační GMM, s normální maskou. Saturační maska je citlivá na vysokou intenzitu světla a její spektrum se blíží k spektru bílé barvy. Analýzou výsledné saturační masky  $M_{Lsat}$  na Obr. 3.34 zjistíme, že převážná část detekovaných pixelů tvoří přítomné nežádoucí denní světlo.



Obr. 3.34 – Zkomponovaná saturační maska, (a) maska, (b) prostorová vizualizace s vyznačenými komponentami laserové čáry – červené šipky, (c) segmentované pixely saturační maskou

Několik pixelů laserové čáry na Obr. 3.34 je rovněž součástí saturační masky. Saturevané pixely laseru tvoří hlavní intenzitu pixelů detekované čáry a nelze je tedy

z procesu segmentace vyloučit. Tato vlastnost je hlavním důvodem použití saturační masky. Detailní pohled měřicího bodu z Obr. 3.34 (b), na který míří prostřední červená šipka, ukazuje její důležitost.




**Obr. 3.35 – Detailní pohled na měřicí bod laseru s přítomností saturačních pixelů, (a) normální maska s prostorovou vizualizací, (b) logický součet normální a saturační masky včetně vizualizace**

Porovnáním obou částí Obr. 3.35 je patrný vliv saturevané části na celkovou přesnost měřeného bodu s přítomností satureovaných pixelů. Jev saturace pixelů laseru souvisí s nastavením clony kamery ve fázi kalibrace měření uvedené v kapitole 3.1.2. Z Obr. 3.35 je patrná vzájemná souvislost normální a saturační masky. Saturační pixely laseru se vyskytují v místech normální masky. Pixely normální masky tvoří jejich okolí. Saturační maska  $M_{L_{sat}}$  je analyzována pomocí algoritmu spojených komponent  $LM_{L_{sat}}$  a na každé analyzované pozici laseru  $i$  v masce  $M_{L_F}$  je kontrolována přítomnost saturačního elementu označeného indexem  $n$  definovaného jako  $E_{sat}(n) = LM_{L_{sat}} = n$ . Element saturační masky je přidán pomocí logického součtu k finální masce podle následujícího kritéria

$$(PM_{L_F}(i)_L - l_w \leq E_{sat}(n)_L) \wedge (PM_{L_F}(i)_R + l_w \leq E_{sat}(n)_R) \wedge (PM_{L_F}(i)_W \neq 0), \quad (3.24)$$

kde  $l_w$  je definovaná maximální šířka laseru vyjadřující rozsah okolí hledání pixelů normální masky. V případě splnění podmínky (3.24) jsou detekovány pixely normální masky v okolí saturačních pixelů.



**Obr. 3.36 – Využití saturační masky pro kompozici finální, (a) využití elementů zobrazené zelenou barvou, (b) maska pro odstranění nežádoucích elementů finální masky**

Obr. 3.36 (a) ukazuje použité části saturační masky označené zelenou barvou. Červenou barvou vyznačené části Obr. 3.36 (b) jsou rovněž využity pro odstranění potenciálně nežádoucích pixelů z pozadí. Z celé šířky nežádoucích elementů  $E_{sat}(n)$  je vytvořena maska  $M_{L_{satE}}$ , která je logicky odečtena od výsledné segmentační masky  $M_{L_F}$  na konci procesu jejího sestavování po přidání všech akceptovatelných částí detailních masek.

$$M_{L_F}(M_{L_{satE}}) = 0 \quad (3.25)$$

Posledním krokem konstrukce segmentační masky laseru je přidání informace citlivých normálních masek  $M_{L_{Ns}}$  a detailních masek  $M_{L_D}$ . Detailní masky jsou využity zejména pro detekci laserového světla nízkých intenzit jasu nebo spektra laseru s příměsí ostatních barevných složek vlivem povrchu a materiálu, na které slabší laserové světlo dopadá. Detailní masky jsou rovněž citlivé na barevné spektrum objektů blízkých nižší intenzitě laserového světla. Pro přidání jejich informace k finální segmentační masce je zapotřebí analyzovat jejich užitnou hodnotu v každém bodě měření. Pro zjednodušení popisu jsou dále zkombinované zbývající citlivé masky normálního GMM  $M_{L_{Ns}}$  a detailní masky  $M_{L_D}$  do jedné skupiny s celkovým počtem  $K_{NsD}$ .

Přidání detailní informace do finální segmentační masky  $M_{L_F}$  je implementováno jako cyklus přes všechny  $K_{NsD}$ , jehož pseudokód je uveden na Obr. 9.2. Pozice finální masky  $PM_{L_F}$  je v každém kroku aktualizována podle vztahu (3.23). Před začátkem analýzy  $k_{nd}$ -té detailní masky  $M_{D_A}$  je proveden logický součet s finální maskou pro její vytvoření

$$\begin{aligned} M_{D_A} &= M_{L_F} \vee M_{L_{Ns}}(k_{nd}) \text{ pro } k_{nd} < k_s \\ M_{D_A} &= M_{L_F} \vee M_{L_D}(k_{nd}) \text{ pro } k_{nd} \geq k_s \end{aligned} \quad (3.26)$$

kde  $k_s$  je index označující začátek detailního GMM modelu.

Následně jsou čtvercovým elementem  $m_E$  o velikosti  $Sm_E = 7$  aplikovány morfologické operace otevření, pro potlačení detailů segmentace tvořené osamostatněnými pixely laserového spektra a operace uzavření, pro zacelení mezer menších než element v segmentační masce.

Velikost elementu  $Sm_E$  je nutno přizpůsobit použitému rozlišení vstupního obrazu. Upravená analyzovaná maska  $M_{D_A}$  je zkoumána ve všech bodech měření  $i$  na celkovou šířku  $WM_{D_A}$  segmentované části. Část masky  $M_{D_A}$  na pozici měření  $i$  je přidána k aktuální finální masce  $M_{L_F}$  v celé svojí šíři pokud splňuje alespoň jednu ze čtyř níže uvedených podmínek.

Základní podmínkou přidání analyzovaného elementu  $L_W(i)$  je splnění jeho maximální šířky  $WM_{D_A}(i)$  na pozici měření

$$L_W(i) = WM_{D_A}(i) \leq l_W \quad (3.27)$$

Šířka  $WM_{D_A}(i)$  nesmí být větší než definovaná šířka laseru  $l_W$ , stanovená experimentálně na 15 px. Obr. 3.37 znázorňuje výsledek pravidla  $L_W$  pro normální masku 6 z Obr. 3.33 (b). Žluté číslo určuje měřicí pozici segmentační masky  $i$ , text na pravé straně označuje šířku segmentovaného laseru vyznačenou obdélníky a zelená a červená barva označují splnění podmínky  $L_W(i)$  a její zamítnutí naopak.



Obr. 3.37 – Ukázka vyhodnocení kritéria (3.27), (a) akceptovaná šířka, (b) příliš široká laserová čára

Podmínka  $L_W(i)$  neplatí pro diagonální segmentovanou čáru, tu postihuje následující kritérium  $L_D(i)$  (3.28). Laserová čára na zachyceném obrazu kamerou mění svůj úhel jejím promítáním na různé předměty, jako je podlaha nebo stůl na vstupním Obr. 3.30. Šířka

laserového paprsku zachyceného pod úhlem se nijak zásadně neliší od šířky paprsku vertikálního, kromě velkého horizontálního rozsahu nespĺňující podmínku  $L_W(i)$ . Z tohoto důvodu je zapotřebí zohlednit úhlopříčku označenou  $DM_{DA}(i)$  v horizontálním rozsahu oblasti laseru následujícím výrazem  $L_D(i)$  zahrnující diagonálu

$$DM_{DA}(i) = \sqrt{WM_{DA}^2(i) + (H/N)^2}, \quad (3.28)$$

$$L_D(i) = \left( M_{DA(1)}(i) \geq 1,2 \cdot DM_{DA}(i) \right) \wedge \left( M_{DA(1)}(i) \leq 0,7l_W \cdot DM_{DA}(i) \right)$$

kde  $H$  je výška obrazu,  $N$  zvolený počet měřicích bodů,  $M_{DA(1)}(i)$  vyjadřuje počet nenulových pixelů (plochu) segmentovaného laseru v celé šířce  $WM_{DA}(i)$ . Vztah jinými slovy popisuje akceptování šířky plné čáry v rozsahu  $[1,2; 0,7l_W]$ . Rozsah byl stanoven ve fázi testování sestavování laserové segmentační masky. Zvolené parametry postihují jeho typickou šířku vertikálního paprsku při použitém rozlišení kamery. Obr. 3.38 ukazuje dva příklady použití kritéria  $L_D(i)$ .



Obr. 3.38 – Ukázka vyhodnocení kritéria (3.28), (a) vertikální čára, (b) diagonální čára


Na Obr. 3.38 (a) je měřicí pozice 40 vyznačena zelenou barvou, splnila kritérium  $L_D(i)$ . Segmentovaná část má tvar „horizontální čáry“, která by mohla potenciálně značit barevný objekt blízký svým spektrem detekované laserové čáře. Z Obr. 3.30 je známé, že analyzovaný element je součástí laserové čáry. Segmentování elementů podobného tvaru neznačí chybu měření. Finální rozhodnutí, zda je segmentovaná část součástí detekovaného laseru, závisí na algoritmu určení měřicího bodu prezentovaném v další kapitole zobrazeném na Obr. 9.3.

Při zpracovávání citlivé masky normálního GMM  $M_{L_{NS}}$  a nenulové šířce finální masky  $M_{L_F}$  na měřicí pozici  $i$  se pro zhodnocení přidání analyzované části k finální masce využijí ještě další dvě kritéria. Omezení na masky menší než index  $k_s$  je z důvodu předejití chybně vyhodnocených měřicích bodů. Obě podmínky by mohly znamenat přidání nežádoucích částí blízké spektrem segmentovanému laseru, jelikož nevyhodnocují vhodnost tvaru ale pouze obsah a velikost analyzovaného elementu.

Podmínka  $L_{AC}(i)$  (3.29) definovaná jako poměr nenulových pixelů laseru  $AM_{DA}(i)$  k celkovému počtu pixelů vymezených šířkou  $WM_{DA}(i)$  v hladině měřeného bodu  $i$  je definovaná jako

$$L_{AC}(i) = \frac{AM_{DA}(i) \cdot N}{WM_{DA}(i) \cdot H} \geq A_r, \quad (3.29)$$

kde  $A_r$  je koeficient uživatelsky určený poměr nenulových pixelů k šířce vymezené nenulovými pixely. Výraz  $L_{AC}(i)$  postihuje výskyt pixelů laseru vyšší intenzity, které často tvoří okolí laserových pixelů s nižší intenzitou. V průběhu testování jsem stanovil hodnotu  $A_r = 0,6$ . Následující Obr. 3.39 (a) ukazuje výsledek výrazu  $L_{AC}(i)$  pro stejné měřicí body jako na Obr. 3.37 (b). Jeho pravá část Obr. 3.39 (b) je prostorová vizualizace segmentované části laseru zvyrazněná bílou hranicí.




Obr. 3.39 – Ukázka vyhodnocení kritéria (3.29), (a) výsledky pro tři měřicí body, (b) prostorová vizualizace segmentované části

Poslední podmínka  $L_A(i)$  (3.30) postihuje počet nenulových pixelů (plochu) citlivostní masky normálního GMM  $M_{L_{Ns(1)}}(i)$  v celé šířce segmentované části  $WM_{D_A}(i)$  vůči stanovené minimální velikosti elementu  $minA_{px}$ , u které je určována měřená vzdálenost, je definovaná jako

$$L_A(i) = (M_{L_{Ns(1)}}(i) - 3 \cdot minA_{px}) > 0 . \quad (3.30)$$

Tento koeficient velikosti  $minA_{px}$  se zejména využívá při rozhodování určení měřené vzdálenosti pro analyzovaný element popsany v další kapitole 3.7. Uvedený výraz  $L_A(i)$  slouží zejména pro detekci laserových pixelů nízké intenzity jasu, které by nebylo možné detekovat jiným způsobem vlivem tvaru jimi utvořeného elementu. Příkladem jeho použití je segmentování rozptýlené odražené laserové čáry nižší intenzity jasu na Obr. 3.40 níže s finální segmentační maskou pro vstupní obraz z Obr. 3.30. Analyzovaná část je tvořena dvěma osamocenými elementy tvořící šířku zkoumané oblasti  $WM_{D_A}(i)$ , která nemůže být akceptovaná žádnou z předchozích diskutovaných podmínek. Podmínka  $L_A(i)$  se vyhodnocuje pouze pro případ přítomnosti nenulové šířky finální masky  $M_{L_F}$  na měřicí pozici  $i$ . Parametr  $minA_{px}$  jsem v testovací fázi algoritmu stanovil na 7 pixelů.

V pseudokódu uvedeném na Obr. 9.2 následuje vyhodnocení všech popsanych podmínek (3.27), (3.28), (3.29) a (3.30). Při splnění alespoň jedné z nich je analyzovaná část detailní masky na měřicí pozici  $i$  přidána do finální segmentační masky laseru  $M_{L_F}$ . Finální maska pro vstupní Obr. 3.30 je zobrazena na Obr. 3.40.



Obr. 3.40 – Finální segmentační maska pro obraz Obr. 3.30, (a) maska, (b) prostorová vizualizace

Na výstupní masku Obr. 3.40 (a) jsou rovněž aplikované morfologické operace otevření a uzavření čtvercovým elementem o velikosti  $Sm_E = 7$  pro odstranění částí menší než element  $m_E$  a celkové ucelení výstupní masky. Zejména vlivem výrazu (3.30) umožňující přidání libovolného elementu na pozici finální masky s počtem nenulových



pixelů větší než stanovený práh obsahuje výstupní maska i nežádoucí pixely pozadí obou oken blízké spektru detekovaného laseru.

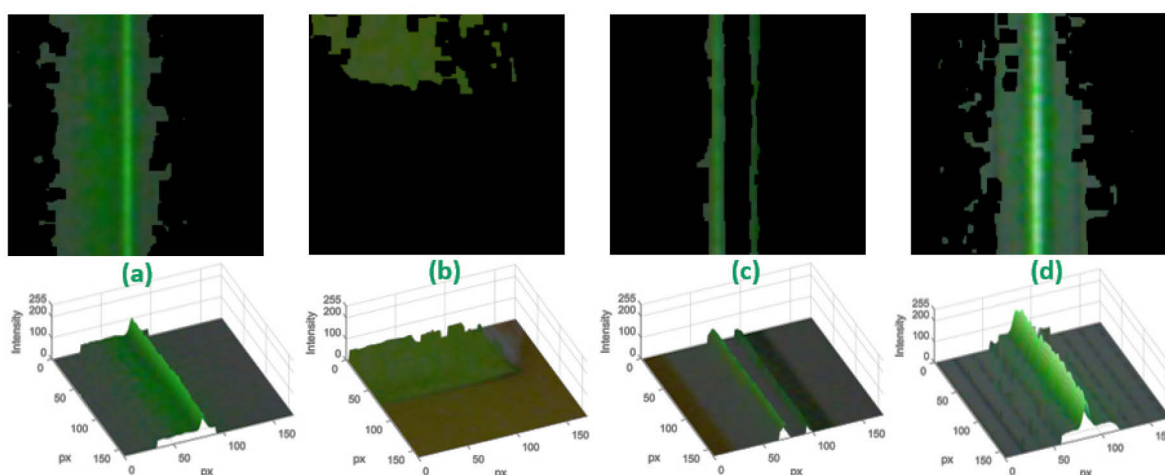
V následující kapitole popisují algoritmus detekce středu měřicího laseru se subpixelovou přesností a řešení nestandardních situací jako je saturovaný laserový paprsek, detekce odražené nebo rozdělené laserové čáry a odlišení objektů blízkého spektra detekovanému laseru.

### 3.7 Určení měřicí pozice laserové čáry

Z předchozího kroku je k dispozici finální segmentační maska laseru  $M_{L_F}$  získaná pomocí účelového skládání detekčních masek GMM pro zachování maxima detekovaných částí laserové čáry. Sestavená maska vstupuje do poslední fáze algoritmu určení měřené vzdálenosti v definovaných bodech detekované laserové čáry. Tato kapitola popisuje poslední dva bloky „Statistická analýza tvaru a obsahu segmentovaných elementů pro určení měřicích bodů“ a „Určení vzdálenosti dostupných měřicích bodů“ schématu na Obr. 3.16.


Přesnost měřicích systémů využívajících přímou detekci laserového paprsku často závisí na přesnosti jeho detekce. V průběhu měření se mohou vyskytovat nežádoucí jevy jako odrazy laserového paprsku Obr. 3.41 (a), výskyt barevných objektů blízkých spektrem detekovanému laseru Obr. 3.41 (b), paprsku rozděleného na více částí Obr. 3.41 (c) nebo jeho příliš široké segmentované části vlivem saturace Obr. 3.41 (d). Uvedené jevy ovlivňují přesnost měření a lze je eliminovat kontrolováním šířky oblasti detekovaných částí laserové čáry, ale v mnoha případech se jedná o nenávratně ztracené měřicí body, které mohou být ve většině případů správně detekovány. Obr. 3.41 ilustruje zmíněné jevy. V jeho horní části jsou zobrazeny pixely vysegmentované finální maskou a ve spodní části je prostorově ilustrován jas těchto pixelů na původních obrazech.

V této kapitole popisují detailní analýzu komponent segmentovaných částí laseru za účelem určení jeho středu se subpixelovou přesností pro správné vyhodnocení dostupných měřicích bodů a eliminaci zmíněných nepříznivých jevů doprovázející měření. Cílem procesu analýzy je maximalizace počtu měřicích bodů.



**Obr. 3.41 – Nežádoucí jevy segmentace, (a) odražený paprsek v rohu místnosti, (b) přítomný objekt ve spektru detekovaného laseru, (c) rozdělená přímka na noze stolu, (d) saturovaná čára s okolím**

Segmentační maska je při analyzování rozložena na stejně velké oblasti podle počtu měřicích bodů, jako je naznačeno na Obr. 3.42.



Obr. 3.42 – Rozdělení měřicích bodů za účelem analýzy, (a) vizualizace s měřicími body, (b) prostorová vizualizace rozdělení

V prvních fázích testování systému (Chmelar, 2014b) a (Chmelar, 2015b) byla pro určení středu laserové čáry splňující uživatelsky definovanou maximální šířku  $l_W$  využita metoda centroidu. Z rovnice (3.23) je známý horizontální rozsah finální masky  $M_{LF}$  v bodech měření  $i$  značený jako  $PM_{LF}(i)_W$  a pozice její levé  $PM_{LF}(i)_L$  a pravé  $PM_{LF}(i)_R$  hrany. Ze známé šířky segmentovaného laseru, splňuje-li podmínku její maximální velikosti  $l_W$ , je určen centroid pozice laseru  $L_C(i)$  podle rovnice

$$L_C(i) = PM_{LF}(i)_L + \frac{PM_{LF}(i)_R - PM_{LF}(i)_L}{2}, \quad (3.31)$$

Sestrojená segmentační maska mohla obsahovat pouze hlavní spektrální složky laserové čáry a nemohla být tak podrobná například jako výstupní maska na Obr. 3.40 (a). Navíc při výskytu některého z jevů popsaných výše byl měřicí bod  $i$  vynechán kritériem šířky laseru  $l_W$  z důvodu zanesení velké měřicí chyby určovaného bodu. Tato koncepce umožňuje vyhodnotit při vhodném nastavení parametrů naměřenou vzdálenost správně, ale její přesnost určení středu laseru se pohybuje okolo 1 px (Chmelarova, 2016) a jsou zbytečně vynechány bezpečně detekovatelné měřicí body ovlivněné popsanými jevy.

Pro potřeby přesné detekce laserové čáry a řešení situací při výskytu těchto jevů jsem navrhl algoritmus analýzy laserové čáry, jehož pseudokód funkce „LaserLineAnalysis“ je uvedený na Obr. 9.4. Algoritmus zkoumá elementy finální masky  $M_{LF}$  a jejich obsah v jednotlivých řádcích pozic měřicích bodů ve smyslu Obr. 3.42 uvedeného výše.

Pro každý měřicí bod je vytvořena maska jeho řádku  $M_{line}$  a ta je dále zkoumána algoritmem spojených komponent pro detekci všech elementů tvořící laser. Nejjednodušší situace je, když je nalezen pouze jeden element, ten je přímo předán jako parametr funkci „GetPpxOffset“ viz pseudokód na Obr. 9.3, kde je dále zkoumán jeho obsah a tvar před definitivním určením středu potenciální laserové čáry. Při více nalezených elementech jsou určeny jejich parametry  $EP$  a jsou rozděleny do skupin podle jejich vzájemné pozice. Dva elementy od sebe vzdálené na menší vzdálenost než uživatelsky volený parametr  $l_W$  jsou přiřazeny do jedné skupiny  $EG$ . U sestavených skupin jsou zjištěny maximální a minimální hodnoty intenzity jasu a velikosti oblastí tvořící nenulové pixely. Podle následujících kritérií jsou vybrány nejlepší elementy pro určení potenciálních měřicích bodů. První kritérium definované jako

$$eMinA / eMaxA > hR, \quad (3.32)$$

kde hodnoty  $eMinA$  a  $eMaxA$  je minimální a maximální počet nenulových pixelů tvořící element ze všech nalezených skupin a  $hR$  je poměrový koeficient výšky, určuje poměr velikosti elementů.

U velikostí vyhovující kritériu (3.32) následuje důležitá podmínka porovnání intenzit jasu elementu s nejnižší intenzitou  $eMinI$  a nejvyšší intenzitou  $eMaxI$

$$eMinI / eMaxI < vR . \quad (3.33)$$

Při podobnosti intenzit větší jak jejich poměrový koeficient  $vR$  není v měřicím bodě určována vzdálenost z důvodu jejich shody a hodnota zkoumané odchylky středu laseru  $ppx(i)$  v měřicím bodě  $i$  je stanovena na 0 indikující neurčovat vzdálenost v tomto bodě. Při shodných intenzitách jasu nejsme schopni určit hlavní intenzitu laseru a mohli bychom vnášet do výsledků nežádoucí chyby. Stejnou intenzitu jasu může mít například čára odražená od blízkého zrcadla. Při splnění podmínky (3.33) je předán funkci „GetPpxOffset“ jako parametr element s maximální intenzitou.

Naopak při nesplnění podmínky (3.32) je kontrolován index elementu maximální intenzity jasu  $eMaxIidx$  s indexem maximální velikosti elementu  $eMaxAidx$ . V případě jejich shody je funkci „GetPpxOffset“ rovněž předán element s maximální intenzitou jasu. V opačném případě je kritérii (3.34) a (3.35) zhodnocen tvar poměrem ploch  $E_A$  a výšek  $E_H$  elementů s maximální intenzitou a plohou.

$$E_A = \frac{EP_A(eMaxIidx)}{EP_A(eMaxAidx)} > \frac{hR}{2} \quad (3.34)$$

$$E_H = \frac{EP_H(eMaxIidx)}{EP_H(eMaxAidx)} > hR \quad (3.35)$$

Při splnění obou podmínek  $E_A$  a  $E_H$  je funkci „GetPpxOffset“ předán element s maximální intenzitou  $eMaxIidx$  a naopak s maximální velikostí  $eMaxAidx$ . Z fáze testování jsem stanovil parametry poměru výšky  $hR = 0,55$  použitý ve výrazech (3.32), (3.34) a (3.35) a parametr poměru rozdílu intenzit laseru  $vR = 0,76$ . V následující kapitole uvádím podrobný popis funkce „GetPpxOffset“, viz Obr. 9.3, statisticky analyzující tvar a obsah vybraného elementu pro finální určení středu laserové čáry nebo stanovení objektu blízkého spektru detekovaného laseru.

### 3.7.1 Statistická analýza tvaru a obsahu laserového elementu

Po výběru nejvhodnějšího elementu laseru pomocí funkce „LaserLineAnalysis“, viz Obr. 9.4, ze skupiny všech segmentovaných elementů nebo v případě výskytu pouze jednoho elementu v aktuálně zkoumané horizontální části bodu měření  $i$  na vstupním snímku je zvolený element detailně analyzován, zda je skutečně součástí detekovaného laseru nebo nepředstavuje objekt blízký jeho barevnému spektru. Nejprve je prověřena podmínka minimální velikosti elementu a jeho tvaru podle následující rovnice

$$E_{Ash} = (E_{A(1)} < minA_{px}) \vee \left( \left( \frac{E_W}{E_H} \geq whR \right) \wedge \left( \frac{E_H N}{H} < whR \right) \wedge \left( \frac{E_{A(1)}}{E_W E_H} > 0,7 \right) \right), \quad (3.36)$$

kde  $E_{A(1)}$  je počet nenulových pixelů elementu,  $minA_{px}$  je jeho požadovaná minimální velikost, hodnoty  $E_W$  a  $E_H$  charakterizují jeho šířku a výšku,  $E_H N / H$  vyjadřuje skutečný poměr výšky elementu k výšce horizontální oblasti měřicího bodu definované výškou obrazu  $H$  a počtem měřicích bodů  $N$  a koeficient  $whR$  představuje uživatelsky volený parametr poměru akceptovatelné šířky a výšky. Poslední pravá část výrazu (3.36) vyjadřuje poměr velikosti (plochy) elementu  $E_{A(1)}$  tvořený nenulovými pixely k plošnému obsahu tvořený vlastní šířkou a výškou. Výraz (3.36) slouží k odstranění nežádoucího tvaru analyzovaného elementu z procesu měření. Je-li platná podmínka jeho levé strany logického



součtu nebo vše podmínky na pravé straně jsou platné zároveň, element je vynechán z procesu určení pozice měřeného bodu  $i$  a hodnotě  $ppx(i)$  je přiřazena 0.


Po základním vyhodnocení tvaru a obsahu elementu vztahem (3.36) je dále zkoumána jeho jasová složka nenulových pixelů pro případ výskytu širokého segmentovaného elementu pomocí analýzy maxima intenzity jasu  $maxI_G$  a její střední hodnoty barevného kanálu laseru  $\mu I_G$  podle vztahu

$$L_{CH} = \frac{\mu I_G}{maxI_G} < vR . \quad (3.37)$$

Poměrový koeficient  $vR$  je shodný s (3.33). Smysl výrazu (3.37) je lépe patrný při pohledu na prostorovou vizualizaci jasové složky na Obr. 3.41. V případě velmi vysoké hodnoty intenzity jasu nelze použít pouze barevnou složku laseru z důvodu její saturace znázorněné na Obr. 3.43 (c). Je zapotřebí přímo použít jasovou složku

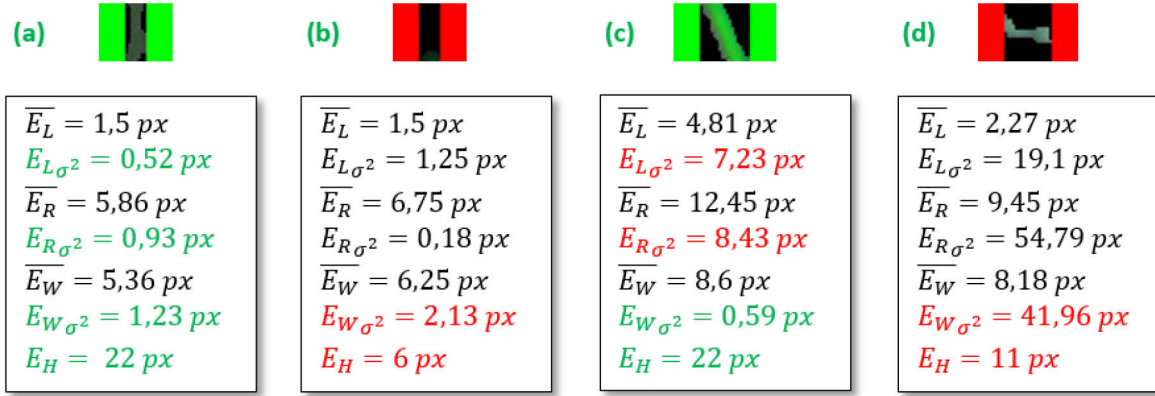
$$L_V = \frac{\mu I_V}{maxI_V} < 0,5vR . \quad (3.38)$$

Poměr prahu intenzity pro jasovou složku je snížen na  $0,5vR$  z důvodu spolehlivé detekce intenzivního laseru v saturaci. Na Obr. 3.43 (a) je uveden příklad saturované části laseru, Obr. 3.43 (b) zobrazuje prostorovou vizualizaci její jasové složky a Obr. 3.43 (c) je zobrazení průběhu všech kanálů obrazu 55. řádku. Průběhy odpovídají barevně kanálům RGB a šedivou barvou je vyznačena jasová složka.



**Obr. 3.43 – Ilustrace velmi blízké saturované laserové čáry, (a) vstupní obraz, (b) prostorová vizualizace jasové složky, (c) průběh jednotlivých složek obrazu**

Dalším důležitým krokem vyhodnocení segmentovaného elementu laseru je podrobnější zkoumání jeho tvaru statistickou analýzou, důležitou nejen pro přesné určení měřicí pozice laserové čáry. Pomocí statistické analýzy tvaru segmentovaného elementu lze vylepšit detekci čar pod úhlem Obr. 3.44 (c) a rovněž přispět eliminaci nesprávně určených pozic měření Obr. 3.44 (b) a Obr. 3.44 (d). Výsledek této funkce rozhoduje o určení měřené vzdálenosti na pozici měřicího bodu  $i$ . Funkce „GetElShapeProp“ použitá v pseudokódu na Obr. 9.3 počítá střední hodnotu a rozptyl šířky  $E_{W\sigma^2}$ , levé  $E_{L\sigma^2}$  a pravé  $E_{R\sigma^2}$  pozice analyzovaného elementu přes všechny jeho nenulové řádky. Získané parametry slouží jako rozhodovací kritérium akceptování tvaru úzkého elementu. Ukázka stanovených statistických parametrů pro čtyři elementy je zobrazena na Obr. 3.44. Akceptované elementy jsou označeny zelenou barvou, červené jsou naopak zamítnuty. Barevné odlišení parametrů




Obr. 3.44 – Statistická analýza tvaru elementu s ukázkou parametrů, (a) vertikální čára splňující  $E_{W\sigma^2}$ ,  $E_{L\sigma^2}$  a  $E_{R\sigma^2}$ , (b) element nesplňuje  $E_{W\sigma^2}$ , (c) čára splňuje  $E_{W\sigma^2}$ , (d) element nesplňuje  $E_{W\sigma^2}$

určuje přijetí nebo naopak zamítnutí pravé a levé části kritéria pro akceptování měřené pozice úzkého elementu definovaného jako

$$E_{\sigma^2} = \left( (E_{L\sigma^2} < 2 \vee E_{R\sigma^2} < 2 \vee E_{W\sigma^2} < 2) \wedge E_H > \frac{H}{N} \right) \vee \left( E_{W\sigma^2} < \frac{3N}{H} \left( \frac{H}{N} - E_H \right) \right). \quad (3.39)$$

Z vlastností detekovaných elementů v průběhu fáze testování byly stanoveny velikosti statistických parametrů uvedené v rovnici (3.39). Její pravá strana vyjadřuje akceptování tvaru pro výšku elementu  $E_H$  větší než polovina výšky měřicí pozice  $i$  určená poměrem  $H/N$ . Akceptován je rozptyl levé a pravé strany nebo šířky elementu menší jak 2. Pro element menší jak polovina výšky měřicí pozice  $i$  platí pravá strana rovnice (3.39) uvažující pouze rozptyl šířky elementu. Grafické znázornění elementů je uvedeno na následujícím Obr. 3.45.



Obr. 3.45 – Grafické znázornění akceptování parametrů elementu definované kritériem (3.39), (a) levá část, (b) pravá část

Finální rozhodnutí určení měřicího bodu pro segmentovaný element laseru spočívá ve splnění alespoň jedné z podmínky z definovaných vztahů

$$L_{CH} \vee L_V \vee E_{\sigma^2}. \quad (3.40)$$

Pozice segmentovaného laseru v obrazu  $L(x, y)$  je poté určena jako střední hodnota pozic maxim intenzity analyzovaného elementu


$$L_i(x, y) = \max(\overline{E_{I(x,y)}}). \quad (3.41)$$

Vertikální pozice laserového segmentu  $L_i(x)$  je důležitá pro tvorbu mračna bodů popsané v následující kapitole 3.8 pro správné umístění bodu v souřadné ose  $Z$ . Horizontální pozice

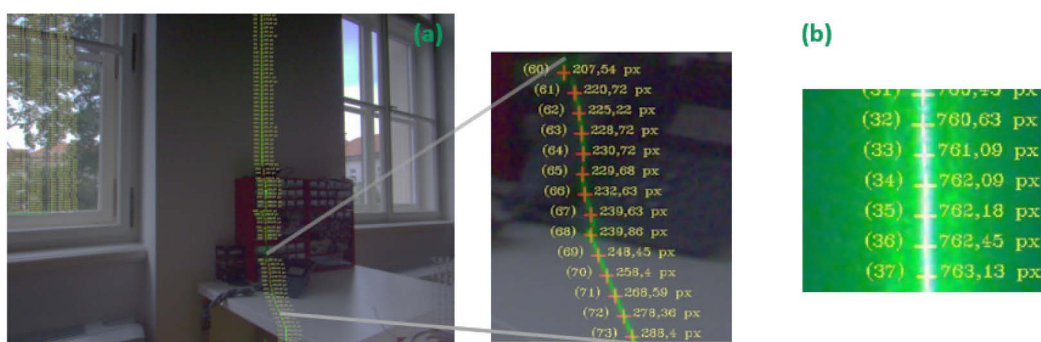
$L_i(y)$  je hlavní pro určení vzdálenosti měřeného bodu. Její rozdíl od středu obrazu určuje odchylku laserové čáry v měřicím bodě

$$ppx(i) = L_i(y) - Ic(y) . \quad (3.42)$$

Následující Obr. 3.46 zobrazuje správně určené pozice pro problematické případy uvedené na Obr. 3.41. Další Obr. 3.47 (a) ukazuje v detailu správně určené měřicí pozice funkcí „LaserLineAnalysis“ pro vstupní obraz Obr. 3.30 a Obr. 3.47 (b) použití kritéria (3.38) při detekci silně saturované čáry z Obr. 3.43 (a), kde kritérium uvažující samotný kanál (3.37) selhává při detekci silně saturovaných částí, jak ukazují průběhy intenzit na Obr. 3.43 (c).



Obr. 3.46 – Správně určené měřicí pozice funkcí „LaserLineAnalysis“ pro Obr. 3.41, (a) čára s odrazem, (b) zelený objekt, (c) rozdvojená čára, (d) saturovaná čára



Obr. 3.47 – Určené pozice laserové čáry s vyznačenými odchylkami pixelů od středu obrazu, (a) pro vstupní obraz Obr. 3.30, (b) pro velmi blízkou saturovanou čáru z Obr. 3.43 (a)

Ze správně určených pozic a vzdáleností jednotlivých měřicích snímků z celého procesu skenování okolního prostoru v rozsahu 360° lze sestavit výsledné mračno bodů. Popis jeho tvorby a využití barevné informace popisují v následujících kapitolách 3.8 a 3.8.1.

### 3.8 Tvorba prostorové mapy

Po provedení skenování okolního prostoru, první blok na schématu Obr. 5.1, a určení vzdálenosti na dostupných pozicích všech snímků měření podle algoritmu prezentovaného blokovým schématem na Obr. 3.16 následuje tvorba prostorové mapy zastoupená druhým blokem schématu Obr. 5.1. Algoritmus její tvorby byl poprvé představen v (Chmelar, 2013).

Pro její tvorbu je zapotřebí zvolit vhodný souřadnicový systém, do kterého budou transformovány jednotlivé body měření získané prostorovým skenováním. Z důvodu vhodné vizualizace jsem zvolil kartézský, kde každý bod vzniklého mračna nese informaci o jeho poloze na osách  $X$ ,  $Y$  a  $Z$ . Výchozím předpokladem pro tvorbu prostorové mapy a umístění získaných bodů prostředí na správnou pozici je znalost přesné výchozí pozice mobilní platformy  $P$  ve skenovaném prostoru určená souřadnicemi

$$\mathbf{P} = (P_x, P_y, P_z) . \quad (3.43)$$

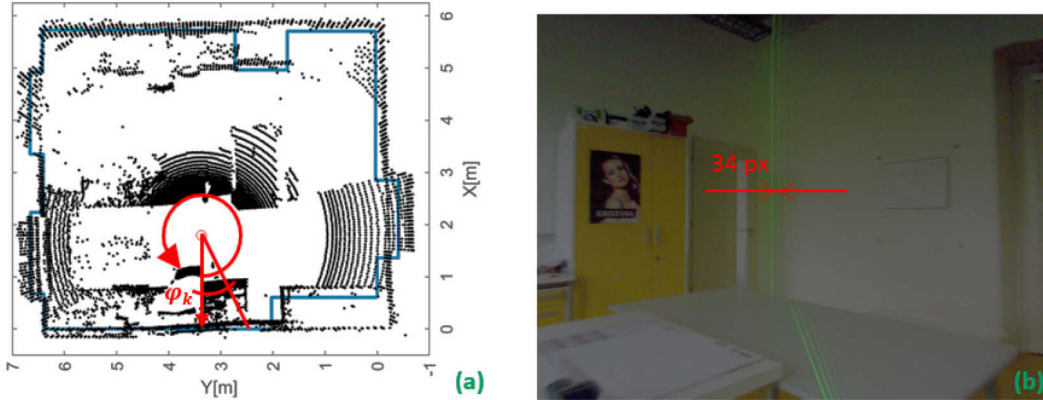
Další důležité parametry jsou aktuální úhel rotace měřicí hlavy  $\varphi_k$  a příslušná naměřená vzdálenosti  $D_{i,k}$  určená rovnicí (3.2), do které vstupují parametry aktuální konfigurace optického skeneru a odchylka od středu obrazu  $ppx(i)$  získaná rovnicí (3.42). Index  $i$  značí vertikální pozici měřeného bodu z jejich celkového počtu  $N$ . Nabývá hodnot z rozsahu  $i \in [0, 1, \dots, N - 1]$ . Index  $k$  u tvorby mračna bodů značí aktuální krok krokového motoru z celkového počtu  $K$  pro dosažení rotace měřicí hlavy v rozsahu  $360^\circ$ . Souřadnice měřených bodů  $p_{x,i,k}$  a  $p_{y,i,k}$  jsou určeny vztahy

$$p_{x,i,k} = P_x - \cos \varphi_k \cdot D_{i,k} \text{ a } p_{y,i,k} = P_y - \sin \varphi_k \cdot D_{i,k} . \quad (3.44)$$

Následující Obr. 3.48 (a) ilustruje směr skenování a význam úhlu  $\varphi_k$  z horního pohledu na výsledné mračno bodů. Vyznačený úhel odpovídá  $30^\circ$  z důvodu názornější ilustrace. V navrženém systému používám krok  $1^\circ$ . Úhel jednoho kroku lze ale uživatelsky libovolně měnit neboť řídicí obvod krokování TB6560AFG umožňuje i nastavení jemného krokování. Rozsah hodnot indexu  $k$  je definován  $k \in [1, 2, \dots, K]$  a aktuální úhel měření  $\varphi_k$  je určen vztahem

$$\varphi_k = k \frac{360^\circ}{K} . \quad (3.45)$$

Z rovnice (3.44) jsou vyjádřeny plošné souřadnice měřeného bodu  $p_x$  a  $p_y$  v hladině osy  $Z = 0$ . Pro reálnou pozici bodu v prostoru je zapotřebí ještě určit souřadnici bodu  $p_z$  v ose  $Z$  pomocí horizontální pozice pixelu měřicího bodu vstupního snímku.



Obr. 3.48 – Ilustrace způsobu skenování, (a) směr otáčení platformy, (b) posun laserové čáry

Určení chybějící souřadnice vyžaduje několik následujících kroků. Prvním je zpětné vyjádření odchylky pixelů od středu obrazu  $ppx_{i,k}$  úpravou rovnice (3.2) v případě, že je známá pouze určená vzdálenost bodu  $D_{i,k}$

$$ppx_{i,k} = \frac{h \cdot f}{D_{i,k} \cdot H_r} \quad (3.46)$$

nebo lze použít přímo parametr  $ppx(i)$  z rovnice (3.42) pro konkrétní obraz měření s indexem  $k$ . Z parametru  $h$ , vzdálenosti mezi středem objektivu a laseru, je určen fyzikální rozměr délky jednoho pixelu  $l_{pxD_{i,k}}$  ve vzdálenosti měřicího bodu podle rovnice




$$l_{pxD_{i,k}} = \frac{h}{ppx_{i,k}} \quad (3.47)$$

Stanovený parametr  $l_{pxD_{i,k}}$  umožňuje rovněž měřit fyzikální velikost objektů z počtu jeho pixelů ve stejné vzdálenosti jako stanovený měřicí bod. Konečný vztah pro určení  $Z$  souřadnice měřeného bodu s využitím rovnice (3.47) a horizontální pozice měřicího bodu  $L_{i,k}(x, y)$  z rovnice (3.41) má tvar

$$p_{z,i,k} = l_{pxD_{i,k}} \cdot L_{i,k}(x). \quad (3.48)$$

Ukázka monotónních mračen bodů je zobrazena na Obr. 3.49. Červený bod označuje pozici mobilní platformy.



Obr. 3.49 – Ukázka sestavených mračen bodů, (a) laboratoř, (b) chodba

U rozsáhlých mračen bodů působí monotónní vyjádření problém porozumět jeho jednotlivým částem a stávají se tak nepřehlednými. Z tohoto důvodu je výhodnější barevná prezentace představená v další kapitole.

### 3.8.1 Využití barevné informace

Tato část popisuje metodu vizualizace mračen bodů pro rotační optické měřiče vzdálenosti využívající kameru prezentovanou v (Chmelar, 2017a). Jejich vizualizace je důležitá zejména pro prezentační účely skenovaného prostoru. Monotónní barevné zobrazení jako například na Obr. 3.49 umožňuje prezentovat jeho prostorové rysy a celkový pohled na skenované prostředí, ale chybí v něm vizuální propojení s reálným pohledem. Z tohoto důvodu vzniklo mnoho metod, které jsou implementované ve specializovaných knihovnách a softwarech. Pro vizualizaci a práci s mračny bodu využívám výpočetní systém Matlab a specializovanou knihovnu PCL pro jejich zpracování. Naměřená vzdálenostní data s kombinací barevné informace z měřicích snímků nabízí možnost tvorby barevného mračna bodů. V případě navrženého optického měřiče je vzdálenost měřená vertikální laserovou čarou znemožňující přímé získání barevné informace z měřeného bodu na aktuálním snímku. Z tohoto důvodu k odečtení barvy měřicího bodu využívám snímek předchozí. Individuální posun jednotlivých snímků je určen pomocí metody template matching umožňující odečtení barvy měřeného bodu z odpovídající pozice předchozího snímku. Takto lze snadno zkombinovat fyzikální pozici individuálních bodů s barevnou informací ze snímků měření.

Barevná informace jednotlivých bodů výsledného mračna je získána přímo z měřicích snímků. Jasová hodnota pixelů je extrahována z odpovídajících pozic měření. Získaná obrazová data jsou uchována a slouží pro vizualizaci naměřených dat. Přímé získání barvy měřeného bodu z aktuálního měřicího snímku není možné z důvodu pokrytí určované pozice vertikální laserovou čarou. Předchozí ilustrace na Obr. 3.48 (b) ukazuje spojení 6 snímků měření do jednoho obrazu. Spojený obraz znázorňuje pohyb laserové vertikální čáry během měřicího procesu. Měřicích snímků je  $K$ . Jejich vyhodnocení začíná prvním snímkem a pokračuje, dokud nejsou všechny zpracovány. Pro aktuální snímek jsou pozice měření předchozích již známy. Zpracováváný snímek obsahuje barevnou informaci předchozího a pro poslední snímek z řady je využit první. K získání správné pozice odečtení barevné informace je nutné znát pixelový posun mezi nimi. Jako vhodný nástroj pro tento úkol se nabízí algoritmy template matching. Na Obr. 3.48 (b) je naznačen příklad posunu 34 pixelů mezi dvěma snímky. Tento údaj je platný pro šířku obrazu 2590 pixelů, 360 skenovacích kroků, vzdálenosti 3,5 m a úhlový krok jeden stupeň. Posun mezi jednotlivými snímky  $\Delta_{k,k+1}$  je téměř stejný, liší se maximálně v jednotkách pixelů. Použitím algoritmů template matching je docíleno odečtu barevné informace s přesností na 1 pixel.

Odpovídající barevná informace  $c_{p(x,y,z)}$  pro měřený bod  $p$  na aktuálním snímku s využitím pozice segmentu detekovaného laseru  $L_i(x,y)$  rovnicí (3.41) určuje následující vztah

$$c_{p(x,y,z)} = I_{k+1}(L_{i,k}(x), ppx_{i,k} + \Delta_{k,k+1}) , \quad (3.49)$$

kde  $\Delta_{k,k+1}$  je aktuální pixelový posun mezi  $k$ -tým a  $k + 1$ -ím snímkem označeným  $I_{k+1}$ . Ostatní parametry jsou známy z předchozích rovnic (3.46) a (3.48).

V průběhu testování byly porovnány tři běžně používané operátory template matching. Hlavním požadavkem jejich výběru byla nezávislost na aplikaci detekce hran vstupního obrazu. V určitých situacích, například při výskytu celistvých ploch s nevýraznými přechody intenzity jasu pixelů, nelze hrany detekovat. Jako první operátor byl vybrán SAD definovaný jako

$$SAD = \sum_{x,y} |I(x,y) - T(x,y)| , \quad (3.50)$$

kde  $I$  je vstupní obraz a  $T$  je hledaná předloha. Indexy označené  $x$  a  $y$  jsou souřadnice pixelu v obraze. Při použití operátoru SAD je v akumulátoru hledána pozice jeho minima určující posunutí. Jako druhý operátor byla použita 2D korelace definovaná jako

$$r(I,T) = \frac{\sum_{x,y} (I(x,y) - \mu_I) \cdot (T(x,y) - \mu_T)}{\sqrt{\sum_{x,y} (I(x,y) - \mu_I)^2 \cdot \sum_{x,y} (T(x,y) - \mu_T)^2}} , \quad (3.51)$$

kde  $\mu$  je průměr obrazu nebo šablony. Posledním testovaným operátorem je normalizovaná 2D křížová korelace

$$Rn(u,v) = \frac{\sum_{x,y} (I(x,y) - \overline{I(u,v)}) \cdot (T(x-u, y-v) - \overline{T})}{\sqrt{\sum_{x,y} (I(x,y) - \overline{I(u,v)})^2 \cdot \sum_{x,y} (T(x-u, y-v) - \overline{T})^2}} , \quad (3.52)$$


kde  $u$  a  $v$  jsou indexy křížených pixelů,  $I$  a  $T$  s linkou nahoře značí normalizovanou formu. V obou korelačních operátorech je hledána pozice maxima určující posunutí mezi šablonou a vstupním obrazem.

Všechny tři testované operátory lze použít pro hledání šablony  $T$  na snímku  $k + 1$ , poskytují informaci o posunutí mezi snímky. V Tab. 3.3 jsou uvedeny základní vlastnosti testovaných operátorů pro hledání posunu mezi dvěma měřicími snímky. Hlavním kritériem finálního výběru operátoru byla zejména rychlost hledání posunu. Z tohoto hlediska byl vybrán operátor normalizované 2D křížové korelace s nejkratší dobou zpracování.

Tab. 3.3 – Srovnání základních vlastností operátorů template matching


Metoda	Rychlost zpracování	Nezávislost na hranové detekci	Hledaný bod
SAD	pomalá	ano	min
Corr 2D	pomalá	ano	max
NXCorr 2D	rychlá	ano	max

Obr. 3.50 (b) ukazuje její korelační akumulátor s vyznačenou pozicí maxima pomocí červeného bodu. Obr. 3.50 (a) znázorňuje vstupní obraz aktuálního měřicího snímku  $I_k$ , označený číslem 2. Hledaná šablona ze snímku  $I_{k+1}$  je označena číslem 1.



Obr. 3.50 – Princip hledání šablony ve vstupním obraze, (a) vstupní obraz se šablonou, (b) akumulátor normalizované 2D korelace s vyznačeným bodem nalezeného posunu

Během skenovacího procesu se mohou při snímání měřeného prostoru vyskytovat objekty nebo plochy s malou variabilitou intenzity pixelů. Měření může probíhat za zhoršených světelných podmínek, v temnotě nebo přímo ve tmě.




Obr. 3.51 – Barevná vizualizace mračen bodů, (a) laboratoř z Obr. 3.49 (b), (b) chodba

V případě popsaných situací mohou algoritmy template matching selhávat a v analyzovaném obraze se nepodaří najít pozici hledané šablony. V těchto případech je zapotřebí využít předem zjištěnou hodnotu posuvu mezi dvěma měřicími snímky. Jeho hodnota závisí na parametrech měřicího systému včetně rozlišení kamery. Výhodou měření za šera nebo ve tmě je získání maxima měřících bodů, viz naměřené výsledky v (Chmelar, 2014b). Proces segmentace laserové čáry není zatížen přítomným okolním světlem. Tato vlastnost je podobná jako u ToF kamer, popsaných v kapitole 3, kde kamera zaznamenává pulzy generované z vlastního světelného zdroje.

Na Obr. 3.51 (a) výše je zobrazena barevná vizualizace původního mračka bodů laboratoře z Obr. 3.49 (b). Obr. 3.51 (b) je barevné mračno bodů chodby. Barevná informace slouží zejména pro vizualizaci a přehlednou prezentaci naměřených bodů, může být důležitá zejména pro architekty a uživatele zabývající se vizualizací, ale najde využití i v jiných oblastech výzkumu. Prezentovaná mračna bodů jsou výsledkem skenování z jednoho místa. Při měření vzdálenějších míst, jako například v případě Obr. 3.51 (b), je hustota bodů menší. Pro získání komplexnějších mraček bodů je zapotřebí provádět měření z více pozic ve zkoumaném prostoru a využít metod registrace popsané v kapitole 2.3.

### 3.9 Korekce měření při chybné kalibraci

Vlivem nepřesné kalibrace mohou nastat různé chyby měření. Mezi nejčastější chyby způsobené kalibrací patří například nedodržení stejné vzdálenosti mezi středem laseru a kamerou na straně mobilní platformy a vzdálenosti mezi dopadající laserovou čarou na objekt a středem obrazu viz Obr. 3.6 nebo laserová čára nesevívá přesně pravý úhel vůči horizontální rovině kamery. K první chybě dochází zřídka z důvodu pečlivé kontroly obou vzdáleností, ale druhou chybu lze při kalibraci opomenout snadno, jelikož při zkoumání náhledu měřicího snímku s vysokým rozlišením se může laserová čára jevit jako kolmá, ale odchylku několika pixelů laserové čáry v horní části obrazu oproti spodní části lze přehlédnout. Z charakteristiky závislosti rozdílu pozice laseru  $ppx$  od středu obrazu ukázané na Obr. 3.7 je patrné, že chyba šikmé čáry i pouze několika pixelů nelineárně roste se vzdáleností.

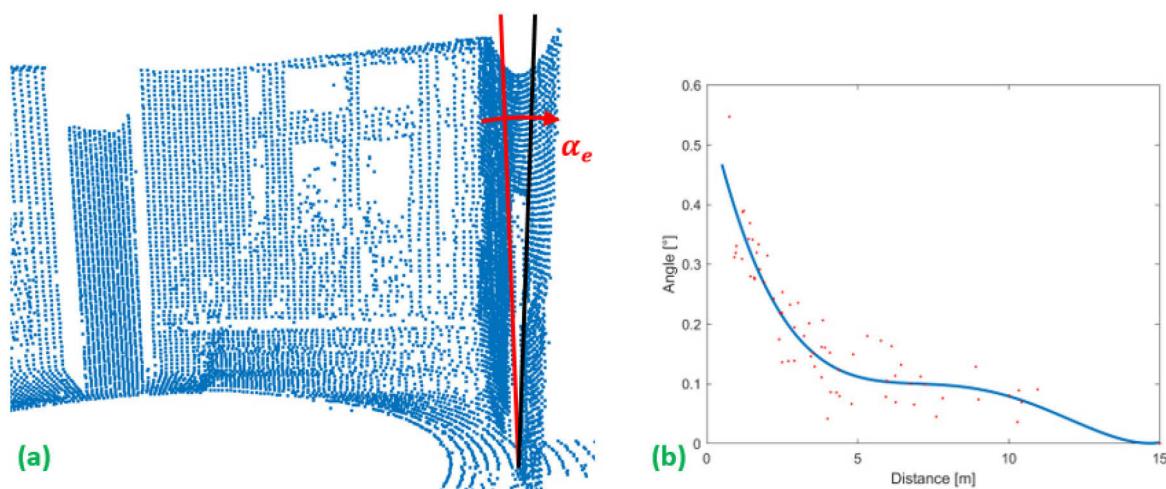


Obr. 3.52 – Chyba kolmosti laserové čáry při kalibraci, (a) celkový pohled se zvětšenými částmi obrazu, (b) detailní pohled s vyznačeným úhlem



Cílem kalibračního procesu je eliminace obou uvedených chyb, ale i v případě jejich výskytu, při přesné specifikaci jejich příčiny, lze popsateľné chyby eliminovat a měřené výsledky použít pro další zpracování. V následujícím textu popíši princip odstranění chyby nakloněné laserové čáry, ke které při praktickém měření v průběhu testování došlo. Vlivem nedokonalé analýzy kalibračního snímku jsem po naměření většího setu prostorových dat zjistil, že laserová čára nebyla dokonale kolmá. Obr. 3.52 na předchozí straně ilustruje vzniklou situaci. Do obrázku byla přidána svislá červená čára pro zvýraznění chyby.

Pixelová odchylka od správné pozice na Obr. 3.52 (b) je 4 pixely a tvoří úhel šikmosti s laserovou čarou 0,14 stupňů. Při přímém snímání rovného povrchu se problém projeví jeho různou hloubkou. Body laserové čáry vychýlené blíže ke středu obrazu budou ve výsledném prostorovém mračnu dále od měřicího zařízení a naopak. Výsledkem bude šikmá projekce svislého povrchu jako na následujícím Obr. 3.53 (a).



**Obr. 3.53 – Chybně vytvořené mračno bodů, (a) mračno bodů s vyznačeným úhlem chyby kolmosti, (b) korekční křivka pro celý rozsah optického měřiče vzdálenosti**

Míra efektu závisí rovněž na měřené vzdálenosti vlivem nelinearity popsané v kapitole 3.1.2. Pořízená data ale není nutné předem zavrhnout, vadu šikmosti laserové čáry lze odstranit. Měřič vzdálenosti je kalibrován na vertikální střed obrazu a na základě tohoto faktu je vertikální střed měřicího snímku korektně změřen. Nelze ale jako korekci aplikovat obecnou konstantu z důvodu nelineární závislosti odchylky pixelů od středu měřeného snímku na měřené vzdálenosti. Šikmost přímky eliminuji korekční křivkou. Pro její sestavení je zapotřebí analyzovat jednotlivé snímky měření a v celém měřicím rozsahu zaznamenat odpovídající odchylky pro určitou vzdálenost. Odpovídající hodnoty odchylek pro ilustrovaný případ na Obr. 3.52 jsou zaneseny do Tab. 3.4, kde  $f_A$  je korekční úhel.

**Tab. 3.4 – Hodnoty korekční křivky v závislosti na měřené vzdálenosti**

$D_i$ [m]	0,75	1,39	1,72	2,50	3,03	3,80	4,37	5,97	7,09	10,29
$px_{diff}$ [px]	15,59	9,32	11,11	4,00	7,59	4,00	2,00	1,54	2,13	1,09
$f_A$ [°]	0,55	0,34	0,33	0,14	0,24	0,16	0,12	0,11	0,11	0,10

Grafické znázornění odchylek je prezentováno v grafu na Obr. 3.53 (b) červenými body. Korekční křivka modré barvy vznikne interpolací jednotlivých odchylek. Analýzou hodnot Tab. 3.4 zjistíme, že úhel odchylky laserové čáry ani u jediné měřené vzdálenosti není větší než jeden stupeň. Takto malou odchylku lze nedopatřením přehlédnout. Po určení kořenů polynomu je korekční křivka platná pro určitou konfiguraci systému a lze ji aplikovat

na každé skenování prostoru, dokud se jeho konfigurace nezmění. Jako metodu interpolace jsem zvolil funkci polynomu. Jeho obecnou podobu popisuje rovnice

$$p(x) = \sum_{i=0}^n a_i x^i = a_0 + a_1 x + a_2 x^2 + \dots + a_n x^n . \quad (3.53)$$

Modrá křivka popisuje korekční úhel od očekávané pozice laseru stupněm polynomu 5, jehož kořeny jsou uvedené v Tab. 3.5.

**Tab. 3.5 – Stupně polynomu korekční křivky**

$A$	$a_{f4}$	$a_{f3}$	$a_{f2}$	$a_{f1}$	$a_{f0}$
$p(x)$	$0,07722e^{-3}$	$-0,00294$	$0,03912$	$-0,22322$	$0,56975$

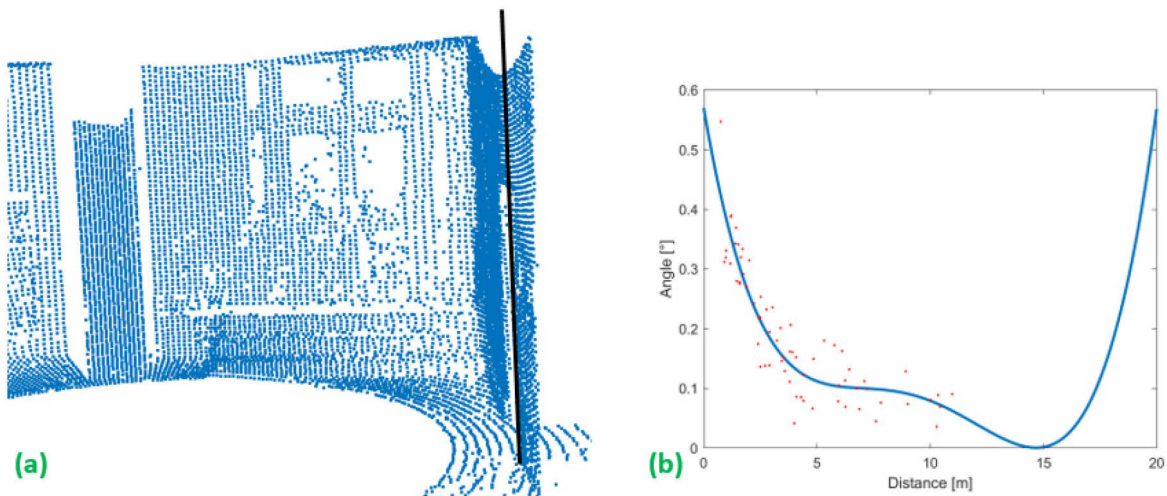
Pro každý měřicí bod je určena hodnota korekčního úhlu  $f_A$  úměrná změřené vzdálenosti  $D_{i,k}$  jako

$$f_A = a_{f4} \cdot D_{i,k}^4 + a_{f3} \cdot D_{i,k}^3 + a_{f2} \cdot D_{i,k}^2 + a_{f1} \cdot D_{i,k} + a_{f0} , \quad (3.54)$$

kde  $a_{fx}$  jsou kořeny korekčního polynomu a  $x$  označuje jeho index. Jak již bylo uvedeno výše, laserový dálkoměr je kalibrován na vertikální střed obrazu a určená vzdálenost na této pozici není zatížena chybou. V případě šikmé laserové čáry je korekce od tohoto středu přičítána a naopak odčítána v závislosti na orientaci úhlu zkosení a vertikální pozici měřicího bodu. Pro zjednodušení korekce jsem obě operace sjednotil do jedné rovnice (3.55) uvažující celou výšku měřeného snímku a úměrné posunutí na skutečnou pozici

$$ppx_c(D_{i,k}) = ppx_{D_{i,k}} + \tan(f_A) \cdot (1,5H - L_{i,k}(x)) - \tan(f_A) \cdot 0,5H , \quad (3.55)$$

kde  $f_A$  je určený úhel korekce z rovnice korekční křivky (3.54),  $ppx_{D_{i,k}}$  je původní odchylka od středu obrazu,  $ppx_c(D_{i,k})$  představuje korigovanou hodnotu,  $H$  značí výšku obrazu a  $L_{i,k}(x)$  je vertikální pozice pixelu měření z rovnice (3.41). Prostřední část rovnice (3.55) určuje vertikální korekci vztaženou k polovině obrazu a pravá část jí posouvá na správnou pozici. Korekce je individuálně aplikovaná na každý bod měření. Opravené mračno bodů pomocí vztahu (3.55) z Obr. 3.53 (a) je zobrazeno na Obr. 3.54 (a).



**Obr. 3.54 – Opravené mračno bodů, (a) mračno bodů, (b) korekční křivka za rozsahem měřidla**

Popsaná korekce prezentuje možnost opravy chybné kalibrace. Opravu chyby úhlu lze provádět pouze v měřicím rozsahu korekční křivky. Polynom může za hraničními hodnotami na ose  $X$  nabývat extrémních a neočekávaných hodnot viz Obr. 3.54 (b). Nevýhodou popsané korekce je její platnost jen pro jeden úhel náklonu. Při jeho změně je zapotřebí provést novou analýzu naměřených snímků v celém rozsahu měření a určit nové koeficienty aproximujícího polynomu korekční funkce. Pro odstranění chyb měření obecně platí pravidlo inverzní funkce. V případě známé příčiny chyby a jejího matematického popisu lze aplikovat inverzní postup pro její odstranění.

### 3.10 Praktické výsledky optického měřiče vzdálenosti

Na závěr této kapitoly uvádím vyhodnocení přesnosti navrženého optického měřiče vzdálenosti. Vyhodnocení je rozděleno na dvě části. V první se zabývám fyzickou přesností určení měřené vzdálenosti porovnávané oproti referenčnímu měřidlu. Tato část zahrnuje i ukázkou přesnosti tvorby výsledné prostorové mapy. V druhé části vyhodnocuji kvalitu použitých barevných modelů pro segmentaci laserové čáry podle celkového počtu detekovaných bodů, přítomných chyb a vizuální kvality.

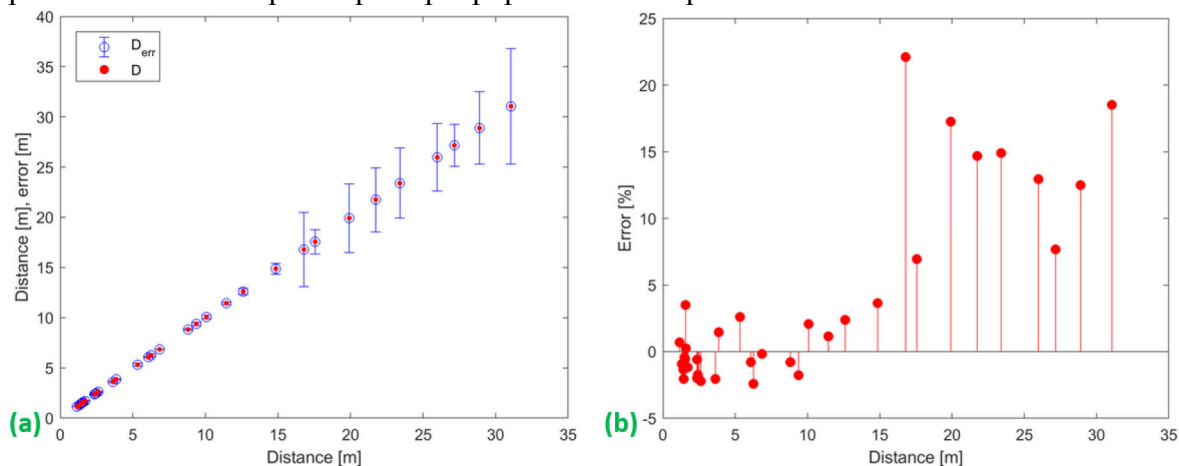
Tab. 3.6 – Porovnání času korekce barelového zkreslení

Filtrace (RGSS)	Průměrný čas [ms]	Průměrný čas s $M_{pixU}$ [ms]
úroveň 0 (bez filtrace)	1941,34	328,11
úroveň 1	6665	848,34
úroveň 2	11424,67	855
úroveň 3	16115,26	1040

Tab. 3.6 udává porovnání časů mezi různými úrovněmi filtrace včetně použití korekční matice. Časy uvedené v tabulce odpovídají průměru tisíce běhů algoritmu, rozlišení kamery je 2590 x 1942, algoritmus byl implementován v programovacím jazyku C# a použité CPU je Intel Core i5-4460, 3,2GHz. Z Tab. 3.6 je patrné urychlení s použitím korekční matice. Rozdíl mezi úrovní filtrace 1 a 2 je malý z důvodu opakujících se vzorků sousedních pixelů. Rozdíl v rychlosti algoritmu s využitím korekční matice při nejlepší úrovni filtrace je až 96,5 %.

#### 3.10.1 Přesnost měřicího systému

Pro vyhodnocení přesnosti určení měřené vzdálenosti byl navržený optický skener pečlivě kalibrován podle postupu popsánoho v kapitole 3.1.2. Jako referenční měřidlo



Obr. 3.55 – Graf přesnosti měření, (a) naměřená vzdálenost a chyba měření, (b) chyba v procentech

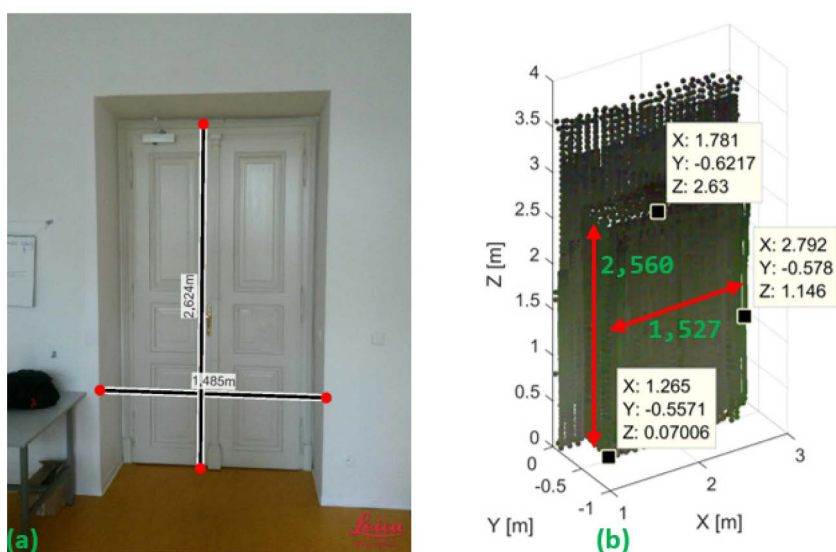
vzdálenosti je použit laserový dálkoměr od firmy Leica s přesností  $\pm 1,5$  mm viz technická dokumentace (Leica Geosystems, 2007). Na Obr. 3.55 (a) je uveden graf přesnosti určení měřené vzdálenosti v měřicím rozsahu do 30 m, kde červený bod v grafu odpovídá skutečné naměřené vzdálenosti a chyba měření je zobrazena chybovým grafem. Obr. 3.55 (b) prezentuje chybu vyjádřenou v procentech. Naměřené vzdálenosti včetně procentuálního vyjádření chyb jsou přehledně zobrazeny v Tab. 3.7. Z naměřených dat vyplývá, že dosažená přesnost měření se ve stanoveném rozsahu 15 m pohybuje do 2,5 % chyby.

**Tab. 3.7 – Porovnání přesnosti měření navrženého optického skeneru**

Leica Disto [m]	1,139	1,301	1,417	1,476	1,537	1,594	1,718	2,359	2,371	2,406	2,485
Optický měřič [m]	1,131	1,313	1,436	1,482	1,545	1,59	1,738	2,406	2,385	2,448	2,536
Chyba měření [m]	0,008	0,012	0,019	0,006	0,008	0,004	0,02	0,047	0,014	0,042	0,051
Chyba [%]	0,70	0,92	1,34	0,41	0,52	0,25	1,16	1,99	0,59	1,75	2,05
Leica Disto [m]	2,623	3,621	3,855	5,325	6,074	6,248	6,857	8,822	9,38	10,075	11,443
Optický měřič [m]	2,681	3,695	3,799	5,186	6,121	6,399	6,868	8,892	9,545	9,865	11,313
Chyba měření [m]	0,058	0,074	0,056	0,139	0,047	0,151	0,011	0,07	0,165	0,21	0,13
Chyba [%]	2,21	2,04	1,45	2,61	0,77	2,42	0,16	0,79	1,76	2,08	1,14
Leica Disto [m]	12,621	14,867	16,789	17,566	19,909	21,737	23,41	25,973	27,169	28,892	31,051
Optický měřič [m]	12,309	14,325	13,079	16,346	16,476	18,548	19,92	22,609	25,081	25,285	25,299
Chyba měření [m]	0,312	0,542	3,71	1,22	3,433	3,189	3,49	3,364	2,088	3,607	5,752
Chyba [%]	2,47	3,65	22,10	6,95	17,24	14,67	14,91	12,95	7,69	12,48	18,52

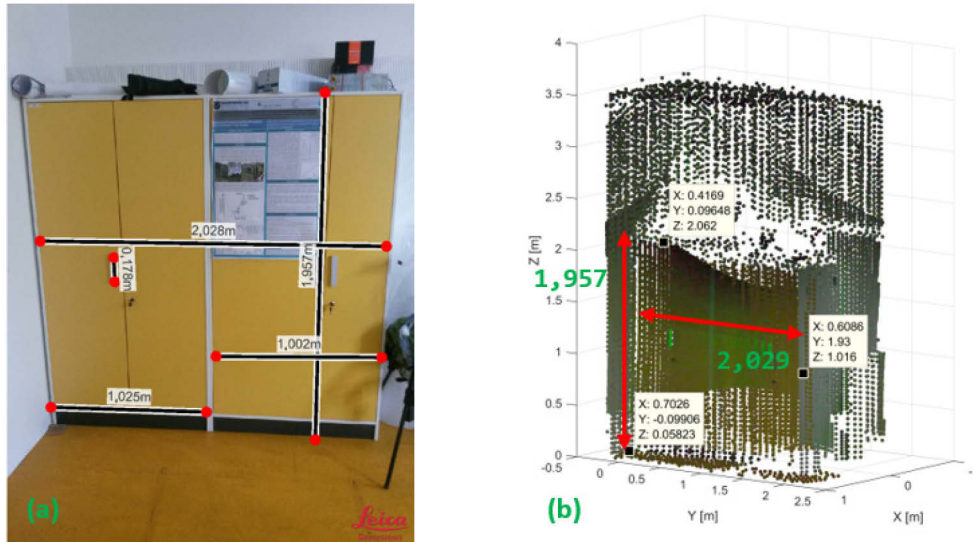
U vzdáleností vyšších než očekávaný měřicí rozsah 15 m je chyba jejího určení příliš velká a do výsledného mračna bodů by se zbytečně zanášely další chyby měření. Vzdálené body vlivem nízké zachycené intenzity laseru snímací kamerou je obtížné detekovat a jejich koncentrace je nízká. Výsledkem aplikace algoritmu odstranění odlehlých bodů popsaném v kapitole 5.1.1 jsou tyto měřicí body navíc odstraněny. Osamocené body nejsou ani pro další zpracování důležité, protože netvoří páry s ostatními body a nemohou tak popisovat žádný objekt nebo tvar ve skenovaném prostředí.

Na následujících Obr. 3.56 a Obr. 3.57 je ilustrována přesnost vytvořeného mračna bodů. Na Obr. 3.56 (a) a Obr. 3.57 (a) jsou zachyceny snímky skutečného prostředí



**Obr. 3.56 – Porovnání rozměrů výsledného mračna bodů se skutečným prostorem, (a) dveře ve skenovaném prostředí, (b) odpovídající výšek mračna bodů (zadní pohled)**





**Obr. 3.57 – Porovnání rozměrů výsledného mračka bodů se skutečným prostorem, (a) skříň ve skenovaném prostředí, (b) odpovídající výšek mračka bodů**


s vyznačenými skutečnými rozměry objektů naměřené přesným laserovým dálkoměrem. U odpovídajících mračen bodů na Obr. 3.56 (b) a Obr. 3.57 (b) jsou vyznačeny hraniční body zkoumaných objektů, ze kterých jsou určeny odpovídající délky. Zjištěné rozměry s procentuálním vyjádřením rozdílů určených odchylek jsou zaneseny do Tab. 3.8.

**Tab. 3.8 – Porovnání skutečných rozměrů prostředí a vytvořeného mračka bodů**

	Dveře H	Dveře W	Skříň H	Skříň W
Leica Disto [m]	2,624	1,485	1,957	2,028
Optický měřič [m]	2,560	1,527	2,004	2,029
Chyba měření [m]	0,064	-0,042	-0,047	-0,001
Chyba [%]	2,439	-2,828	-2,401	-0,049

Z porovnání se skutečnými rozměry je maximální změřená chyba necelé 3 %. Prostorová přesnost měření je důležitá zejména pro aplikaci algoritmů registrace mračen bodů popsané v další kapitole 5.3, kde nepřesné prostorové rozmístění bodů vede k chybám spojení vytvořených skenů měřeného prostředí.

Následující ukázka zobrazuje kvalitu výsledného mračka bodů získaného metodou určení vzdálenosti pomocí centroidu (3.31) je na Obr. 3.49 (a) a mračno sestavené z měřené vzdálenosti určené pomocí funkce „LaserLineAnalysis“ jehož pseudokód je na Obr. 9.4 ilustruje Obr. 3.49 (b).




**Obr. 3.58 – Porovnání kvality mračen bodů, (a) vzdálenost určená metodou centroidu, (b) vzdálenost určená funkcí „LaserLineAnalysis“**

Červený bod označuje pozici mobilní platformy. Z porovnání obou mračen je zřejmé, že navržený algoritmus „LaserLineAnalysis“ jasně dokazuje svoji schopnost přesného určení skutečné pozice hlavní intenzity laserové čáry zejména na vzdálenějších stěnách a skenovaný prostor je pokryt více body, konkrétně 24619 body na Obr. 3.49 (b) oproti 21371 bodům na Obr. 3.49 (a).

### 3.10.2 Praktické porovnání detekčních modelů

Prostřednictvím masek barevného modelu jsou prahovány pixely laseru. Konkrétní model má vliv zejména na množství segmentovaných pixelů, celistvost segmentovaných částí a přesnost detekce laserového světla s minimem pixelů pozadí skenované scény předcházející chybným detekčním měřicím bodům.

Následující Obr. 3.59 (a) - (d) ukazuje kompozici detekčních masek normálního GMM všech použitých detekčních modelů laseru. Porovnáním jejich masek je vidět, že přirozenou intenzitu detekovaného laseru nejlépe pokrývá model HSV Obr. 3.59 (c),




Obr. 3.59 – Kvalita segmentačních masek barevných modelů, (a) RGB, (b) YCbCr, (c) HSV, (d)  $L^*a^*b^*$  sestavená segmentační maska je přirozeně celistvá i bez provedení morfologických úprav. Dobrých výsledků segmentační kvality dosahuje rovněž model  $L^*a^*b^*$ . Dále v pořadí jsou modely YCbCr a RGB. I v případě testování a vývoje detekčních algoritmů zejména s modelem HSV nelze konstatovat, že byl nějakým způsobem zvýhodněn oproti ostatním barevným modelům. Trénovací pixely jsou pro všechny testované modely stejné. Jejich selekce probíhala pomocí RGB modelu a sledování histogramu jednotlivých kanálů.



Obr. 3.60 – Skenované prostory, (a) chodba č. 1, (b) chodba č. 2, (c) chodba č. 3, (d) laboratoř

Přesnost, kromě kalibrace celého systému, určuje algoritmus následného statistického zpracování segmentovaných částí, a tak barevný model nepřímo ovlivňuje minimální mírou i přesnost určení pozice laserové čáry. Barevný model má zejména vliv na počet určených měřicích bodů a počet bodů chybně určených v případě segmentace nežádoucích pixelů pozadí. Algoritmus určení nejlepší pozice segmentované laserové čáry má snahu eliminovat co největší množství chybně segmentovaných částí a objektů s blízkým barevným spektrem detekovanému laseru, ale i tak některé body mohou být na specifických místech, kde není na určité části snímku zachycena laserová čára, chybně určeny. Na základě těchto faktů je jako hodnotící kritérium popsanych barevných modelů zvolen souhrn počtu korektně změřených bodů, chybně určených bodů a času zpracování jednotlivých segmentačních masek.

K otestování kvality modelů byly vybrány čtyři typická skenovaná místa (tři rozsáhlé chodby a jedna laboratoř) s výskytem specifických míst pro detekci laserové čáry, jako jsou přítomné denní světlo v oknech, osvětlení a objekty s barevným spektrem použitého laseru. Skenované prostory jsou znázorněny panoramaty na předchozí straně Obr. 3.60 (a) - (d).



Obr. 3.61 – Grafické znázornění výsledků jednotlivých kroků skenování  $\varphi_k$ , (a) chodba č. 1, (b) chodba č. 2, (c) chodba č. 3, (d) laboratoř



Grafy na předchozí straně Obr. 3.61 (a) - (d) zobrazují přehledně počty korektně změřených a chybných bodů označené plnou a čárkovanou čarou respektive pro odpovídající prostory z Obr. 3.60 (a) - (d). Průběhy jsou upraveny pomocí klouzavého průměru o velikosti okna 8 z důvodu lepší čitelnosti jednotlivých křivek.

Pro určení chybných bodů jednotlivých snímků bylo pečlivě analyzováno 1440 snímků pro jeden barevný model. Celkové výsledky přehledně zobrazují Tab. 3.9 a Tab. 3.10. Nejlepší výsledky pro určitou místnost jsou vyznačeny tučně a nejlepší model je označen zelenou barvou. Barevné modely mají v závorce uvedeno číslo  $K$  popisující dohromady počet detekčních masek normálního a citlivostního GMM. Jsou posuzovány zejména z pohledu počtu korektně měřených bodů a celkového počtu chyb. Průměrný čas zpracování jednoho měřicího snímku je uveden pouze informativně.

Tab. 3.9 – Tabulka výsledků pro barevný model RGB a YCbCr

Místnost	RGB( $K - 23$ )					YCbCr( $K - 20$ )				
	$M_p$	$M_{err}$	$M_{err}[\%]$	$\sigma(M_{err})$	$T [ms]$	$M_p$	$M_{err}$	$M_{err}[\%]$	$\sigma(M_{err})$	$T [ms]$
chodba 1	10983	1872	17,04	4,24	905,36	16711	622	3,72	1,98	832,38
chodba 2	24604	526	2,14	2,78	1119,71	22221	62	0,28	0,53	867,45
chodba 3	12930	623	4,82	3,32	927,38	<b>16665</b>	325	1,95	2,58	1088,63
laboratoř	24021	842	3,51	3,68	1624,11	21866	1060	4,85	6,61	967,11

Tab. 3.10 – Tabulka výsledků pro barevný model HSV a  $L^*a^*b^*$

Místnost	HSV( $K - 21$ )					$L^*a^*b^*$ ( $K - 13$ )				
	$M_p$	$M_{err}$	$M_{err}[\%]$	$\sigma(M_{err})$	$T [ms]$	$M_p$	$M_{err}$	$M_{err}[\%]$	$\sigma(M_{err})$	$T [ms]$
chodba 1	<b>17774</b>	<b>296</b>	<b>1,67</b>	1,49	879,84	16743	343	2,05	1,65	<b>594,08</b>
chodba 2	<b>25112</b>	22	0,09	0,26	951,93	24561	<b>18</b>	<b>0,07</b>	0,26	<b>668,07</b>
chodba 3	16541	<b>236</b>	<b>1,43</b>	1,83	1120,97	16660	416	2,50	3,50	<b>642,85</b>
laboratoř	<b>24731</b>	<b>336</b>	<b>1,36</b>	2,24	1036,63	24377	488	2	3,04	<b>710,66</b>

Z analýzy hodnot obou Tab. 3.9 a Tab. 3.10 vyplývá, že nejlepší model pro detekci laserové čáry je model HSV z pohledu detekovaných měřených bodů  $M_p$  a nejmenšího počtu chyb měření  $M_{err}$ . Hodnoty kvality jednotlivých modelů reflektuje rovněž její směrodatná odchylka  $\sigma(M_{err})$ . Chybovost vztahovaná k celkovému počtu měřicích bodů je pro lepší představu uvedena v obou tabulkách i procentuálně hodnotou  $M_{err}[\%]$ . Z časového hlediska průměrného času  $T$  pro vyhodnocení jednoho měřicího snímku vychází nejlépe barevný model  $L^*a^*b^*$ , který potřeboval k pokrytí všech trénovacích pixelů 13 Gaussovských rozdělení normálního a citlivostního modelu, nejméně ze všech trénovaných barevných modelů.

Celkové pořadí detekční kvality jednotlivých modelů odpovídá kvalitě segmentace z Obr. 3.59. Barevný model HSV je přizpůsobený pro lidské vnímání světla a jako jediný model umožňuje vyjádřit barevnou informaci pomocí jednoho kanálu. Pro účel segmentace laserové čáry, která se ve skenovaném prostředí vyskytuje s různou intenzitou vlivem spektrálních vlastností odrazivosti okolních objektů prostředí a prostředí samotného je podle dosažených výsledků nejvhodnější barevný model HSV.

## 4 Transformace mračen bodů

Tato kapitola popisuje nástroje a terminologii transformace mračen bodů používané v této práci. Uvedené maticové operace se prakticky využívají v dalších kapitolách a je na ně odkazováno. Na začátku uvádím základní popis souřadnicových prostorů a transformací mezi nimi. Dále popisují základní typy transformací s ohledem na její aplikaci pomocí matice. Pouhým maticovým násobením je možné aplikovat transformaci na zpracovávané mračno bodů. V přehledu uvádím příklady základních často využívaných transformačních matic. Nemalá část kapitoly je věnovaná popisu a používání transformační matice  $4 \times 4$  umožňující nejen aplikaci rotace bodů včetně jejich posunu v prostoru, ale zároveň je možné aplikovat i perspektivní projekci využívanou pro tvorbu hloubkové mapy.

### 4.1 Vícero souřadnicových prostorů

Pro zobrazení bodu v prostorové mapě využívám Kartézský souřadnicový systém tvořený třemi osami  $X$ ,  $Y$  a  $Z$ . Bod  $p$  v prostoru je definován vektorem

$$\mathbf{p} = [p_x, p_y, p_z], \quad (4.1)$$

kde  $p_x$ ,  $p_y$ ,  $p_z$  jsou jeho souřadnice v příslušných osách. Jednotlivé body měření tvoří výsledné mračno bodů uložené ve sloupcové matici  $X$  o rozměrech  $N_{mp} \times 3$ , kde  $N_{mp}$  je celkový počet bodů mračna. Forma sloupcové matice je vhodná pro další zpracování a doporučuji ji také autoři knihy (Dunn, 2011).

Pojem vícero, uvedený v názvu této kapitoly, neznamená popis různých typů souřadnicových systémů používaných pro vyjádření pozice naměřených bodů v definovaném prostoru, ale vyjadřuje smysl použití více souřadnicových prostorů v jednom souřadnicovém systému s různým počátkem a rotací.

Souřadnicový prostor vytvořím tak, že zvolím libovolný bod v prostoru a určím k němu orientaci os. Pozici bodu a orientaci os nevolím náhodně, ale vždy se specifickým záměrem. Důvodem použití vícero souřadnicových prostorů lze shrnout výrazem „různý prostor pro různé situace“.

Pro zpracování mračen bodů využívám tři různé souřadnicové prostory: globální (World Space), vertikální (Upright Space) a objektu (Object Space). Jedná se o analogii souřadnicových prostorů používaných autory v knize (Dunn, 2011). Používáním více prostorů spočívá v jednodušším zpracování prostorových dat, souvisí zejména s jejich rotací a posunem. Je možné určit jeden bod, uvažovat ho jako globální počátek, a všechny body umístit do tohoto nově definovaného prostoru. Tvrzení zní racionálně, ale všichni zabývající se zpracováním mračen bodů, 3D objekty, 3D grafikou včetně herních vývojářů používají systém více prostorů. Určitá informace může být skryta v rámci globálního souřadnicového systému a je známá pouze při použití jiného referenčního bodu. Navíc lépe se pracuje s nižšími čísly, než kdybychom například vycházeli z počátku nultého poledníku v Greenwich (Spojené Království) a určovali pozici bodů a objektů v České republice. Při práci s mapou a posuzování pozic obou zemí je zapotřebí určit vhodný počátek, ale pro práci s body a objekty nacházející se v České republice nepotřebujeme znát, kde se Spojené Království nachází nebo dokonce, že vůbec existuje.

Uvažování o více souřadných prostorech má své historické základy už v době před naším letopočtem, kdy Aristoteles uvažoval jako centrum sluneční soustavy planetu Zemi

a všechno se točí kolem ní. O několik let později Aristokrates správně stanovil jako střed naší soustavy Slunce, okolo kterého se točí ostatní planety (Dunn, 2011).

#### 4.1.1 Globální souřadnicový prostor (World Space)

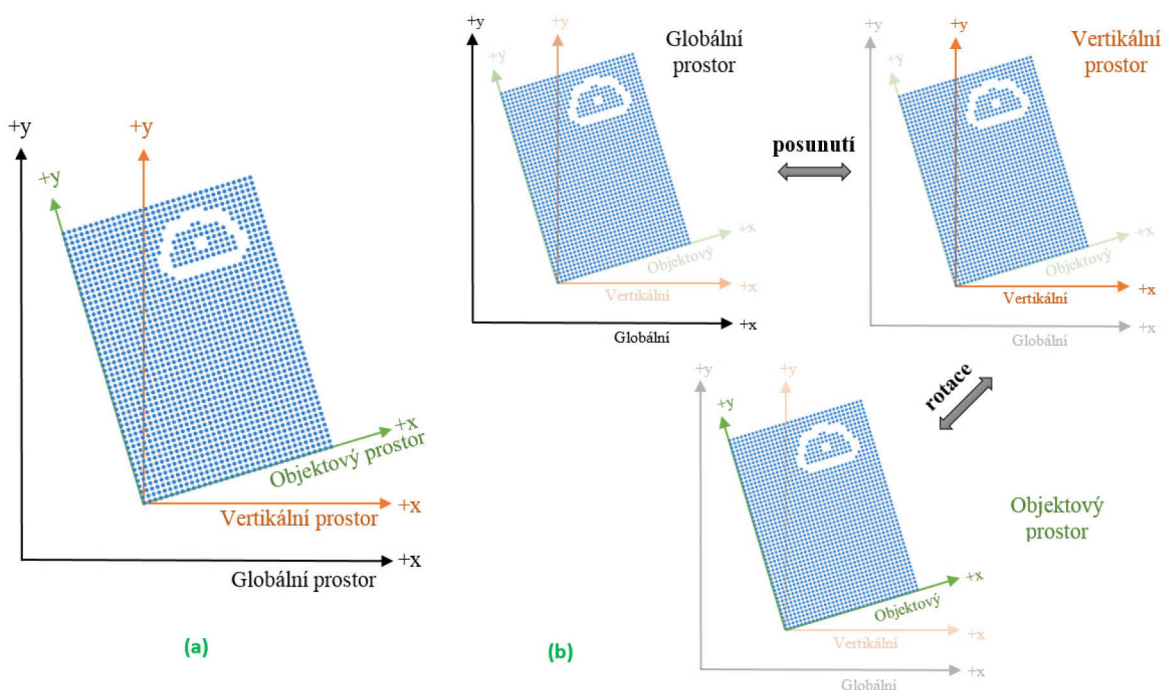
Slouží k vyjádření referenčního počátku, ke kterému jsou vztaženy všechny body i pozice podřadných souřadnicových systémů. Je to „největší“ prostor, který konkrétně používáme. V případě skenování vnitřních prostor budovy je právě budova „globální“ souřadnicový systém a není zapotřebí znát, kde se budova nachází na mapě. Pro různé zadání řešené úlohy je různý „globální“ souřadnicový systém.

#### 4.1.2 Souřadnicový prostor objektu (Object Space)

Váže se k vlastnímu objektu, v případě skenování prostoru je objekt konkrétní sken nebo skupina skenů po jejich spojení procesem registrace. Analýzou skenovaných dat lze segmentovat i jeho části, které se stanou dalšími objekty s jejich vlastními prostory. Při změně rotace nebo posunu objektu je přímo rotace i posun aplikován na prostor objektu, tzn. objekt je svázán s vlastním prostorem. Prostor objektu je často spojován s jeho fyzikální podstatou, prostorem tělesa (Body Space).

#### 4.1.3 Vertikální souřadnicový prostor (Upright Space)

Tento typ představuje mezistupeň globálního a objektového souřadnicového prostoru. Doposud není přijatý komunitou jako standard (Dunn, 2011), nicméně vhodné pojmenování řešených problémů může přispět k jejich snadnějšímu pochopení. Autoři používají toto pojmenování prostoru pro snadnější výklad a aplikaci procesu transformace mračen bodů. Rozdělení procesu na dvě části přispívá ke snadnějšímu pochopení problému i jednodušší implementaci algoritmu. Osy vertikálního prostoru jsou paralelní k osám globálního prostoru a jeho počátek je shodný s objektovým prostorem. Následující Obr. 4.1 ilustruje vztah popsaných souřadnicových systémů ve 2D zobrazení.



Obr. 4.1 – Používané souřadnicové prostory, (a) globální vztah, (b) přechody prostorů

Výhodou používání vertikálního souřadnicového prostoru je rozdělení operace transformace bodů na dvě části: posun v prostoru (translation) a rotace (rotation). V případě, že chceme přemístit bod z objektového prostoru do vertikálního, je zapotřebí pouze operace rotace a přemístění bodu z vertikálního prostoru do globálního je provedeno změnou pozice bodu. Přejechy mezi jednotlivými prostory přehledně shrnuje Obr. 4.1 (b).

## 4.2 Lineární transformace prostřednictvím matice

Lineární transformaci obecně definujeme jako  $F(a)$ . Z matematického hlediska je  $F(a)$  lineární jestliže platí pravidlo součtu

$$F(a + b) = F(a) + F(b). \quad (4.2)$$

Transformace součtu vektorů je rovná transformaci součtu jednotlivých obrazů. Musí platit rovněž pravidlo měřítkování skalární hodnotou

$$F(ka) = kF(a). \quad (4.3)$$

Transformace násobení vektoru skalárem je rovná násobení obrazu skalárem. Aplikace transformace s libovolnou čtvercovou maticí definovaná jako

$$F(a) = aM, \quad (4.4)$$

je rovněž lineární transformace, protože platí

$$F(a + b) = (a + b)M = aM + bM = F(a) + F(b) \quad (4.5)$$

a

$$F(ka) = (ka)M = k(aM) = kF(a) \quad (4.6)$$

Vztahy (4.5) a (4.6) dokazují, že každá transformace, kterou lze provést maticovým násobením je zároveň lineární transformací. Aplikace transformace maticovým násobením je výhodná s ohledem na jednoduchost a efektivitu.

### 4.2.1 Afinní transformace

Termín označuje lineární transformaci, po které je aplikován posun. Afinní transformace jsou hlavní množinou transformací, kde lineární transformace jsou jejich podmnožinou. Každá lineární transformace je současně afinní, ale ne všechny afinní transformace jsou lineární. Transformace zapsaná ve tvaru  $\mathbf{v}' = \mathbf{v}M + \mathbf{b}$  je také afinní transformace, protože obsahuje část posunu.

### 4.2.2 Inverzní transformace

Transformace  $F$  je inverzní, když existuje opačná transformace, která vrátí všechny aplikované změny. Pro inverzní transformaci  $F^{-1}$  platí

$$F^{-1}(F(a)) = F(F^{-1}(a)) = a, \quad (4.7)$$

pro všechny  $a$ . Inverzní transformace existuje i pro afinní transformaci, když je nejprve vráceno posunutí a následně provedena inverze. Afinní transformace je inverzní v případě existence inverzní lineární transformace. Lineární transformaci lze vyjádřit maticovým násobením (4.5) a (4.6) a z toho vyplývá, že nalezení inverze spočívá v hledání inverzní

matice. Matice, u které neexistuje inverze, je singulární a transformace je neinvertibilní. Její determinant je nulový.

### 4.2.3 Ortogonální transformace

Jsou užitečné díky snadnému určení jejich inverze, která je často vyžadována, pomocí pouhé transpozice matice. Posun, rotace a zrcadlení jsou ortogonální transformace. Všechny ortogonální transformace jsou zároveň afinní transformace a jsou invertibilní. Ortogonální matice zachovávají velikost úhlu, obsah a objem, hodnoty se mohou lišit znaménkem.

## 4.3 Základní lineární transformace pomocí matice

V této části uvedu dvě základní lineární transformace rotaci 2D a 3D. Při zpracování mračen bodů jsou často využívány a v dalších kapitolách je na ně odkazováno. Další transformace jako změna měřítka, zrcadlení nebo zkosení nemají pro práci s mračky bodů v této práci žádný význam. Jejím cílem je zachovat skenovaný prostor a získat z něho užitečné informace.

### 4.3.1 Rotace 2D

V dvourozměrném prostoru lze definovat rotaci kolem bodu. Naším požadavkem je aplikace lineární transformace a ta je splněna, neboť je rotace aplikována pouze kolem počátku a nedochází u ní k žádnému posunu. Standardně kladná rotace má směr proti pohybu hodinových ručiček a záporná rotace otáčí po směru hodinových ručiček. Rotaci v dvourozměrném prostoru používám zejména lokálně při aplikaci filtru barevého zkreslení objektivu v kapitole 3.2.1. Rotaci lze vyjádřit vztahem

$$R_{2D}(\varphi) = \begin{bmatrix} \cos(\varphi) & \sin(\varphi) \\ -\sin(\varphi) & \cos(\varphi) \end{bmatrix} \quad (4.8)$$

### 4.3.2 Rotace 3D

V trojrozměrném prostoru rotaci definuji většinou kolem určité osy ne pouze kolem bodu. Osou rotace mohou být základní osy prostoru  $X$ ,  $Y$  nebo  $Z$  nebo lze si zvolit osu vlastní. Konstrukce výsledné rotační matice v případě použití vlastní osy je odvozena v (Dunn, 2011). Pro účely zpracování naměřených mračen bodů postačují základní rotační matice  $R_X(\alpha)$  ( $x$ ),  $R_Y(\beta)$  ( $y$ ) a  $R_Z(\gamma)$ .

$$R_X(\alpha) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\alpha) & \sin(\alpha) \\ 0 & -\sin(\alpha) & \cos(\alpha) \end{bmatrix} \quad (4.9)$$

$$R_Y(\beta) = \begin{bmatrix} \cos(\beta) & 0 & -\sin(\beta) \\ 0 & 1 & 0 \\ \sin(\beta) & 0 & \cos(\beta) \end{bmatrix} \quad (4.10)$$

$$R_Z(\gamma) = \begin{bmatrix} \cos(\gamma) & \sin(\gamma) & 0 \\ -\sin(\gamma) & \cos(\gamma) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.11)$$

### 4.3.3 Zkosení 3D

Operace zkosení je běžně zřídka využívaná operace, kterou při požadavku zachování skenovaného prostoru v 3D ani nevyužívám. Transformace nezachovává úhly, ale objem a plochu ano. Má zejména význam v 4D prostoru, kde lze aplikovat afinní transformaci maticovým násobením široce používanou i v této práci. Parametry  $s$  a  $t$  ovládají velikost a směr zkosení v 3D (Dunn, 2011).

$$H_{xy}(s, t) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ s & t & 1 \end{bmatrix} H_{xz}(s, t) = \begin{bmatrix} 1 & 0 & 0 \\ s & 1 & t \\ 0 & 0 & 1 \end{bmatrix} H_{yz}(s, t) = \begin{bmatrix} 1 & s & t \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4.12)$$

### 4.3.4 Kombinace transformačních matic

Při zpracování mračen bodů je častým požadavkem jeho rotace ve více souřadných osách najednou. Lze aplikovat rotace separátně pro docílení požadovaného výsledku, ale zároveň dochází k navyšování času zpracování. Využitím pravidla asociativity matic lze kombinovat jednotlivé lineární maticové transformace  $M_{T_1}$  až  $M_{T_N}$  do výsledné transformace

$$M_T = M_{T_1} \cdot M_{T_2} \cdot \dots \cdot M_{T_N}. \quad (4.13)$$

Vzhledem tomu, že není násobení matic komutativní je zapotřebí uvažovat jejich pořadí. Při násobení transformací reprezentovanými maticemi platí pravidlo zleva doprava. Pro dosažení požadovaného výsledku transformace je zapotřebí řadit matice za sebou zleva ve stejném pořadí, jako by byly aplikovány separátně. Tímto způsobem je možné kombinovat libovolné typy transformací reprezentované čtvercovou maticí. Zpětná transformace  $(M_T)^{-1}$  vrací efekt všech transformací v obráceném pořadí, jak byly aplikovány


$$(M_T)^{-1} = M_{T_N} \cdot M_{T_{(N-1)}} \cdot \dots \cdot M_{T_1} \quad (4.14)$$

Využitím rovnice (4.13) lze snadno docílit požadované transformace mračna bodů a aplikovat jí jedním násobením. V případě potřeby je možné provést zpětnou transformaci rovnicí (4.14). Tímto způsobem je možné kombinovat libovolné transformace včetně neinvertibilních, ale efekt této transformace již nelze vrátit zpět.

## 4.4 Transformace souřadnicového prostoru

Tato část navazuje na již zmíněnou problematiku vícero souřadnicových prostorů ilustrovanou prostřednictvím Obr. 4.1. Uvádím zde praktický příklad rotace objektu v prostoru s rozborem jednotlivých kroků pro dosažení požadovaného výsledku. Rotace objektu prezentované mračenem bodů nebo jeho posun s rotací jsou právě častým požadavkem při jejich zpracování. Druhá uvedená operace se zdá být komplikovanější, ale z matematického pohledu se jedná o totožnou operaci.

Rotace okolo počátku je lineární transformace, oproti tomu rotace okolo libovolného bodu je afinní transformace vyžadující operaci posunu. Požadují-li rotovat určitý objekt okolo svojí osy, umístěný v globálním prostoru, nestačí jen aplikovat prostorovou rotaci. Výsledek je prezentován prostřednictvím Obr. 4.2.



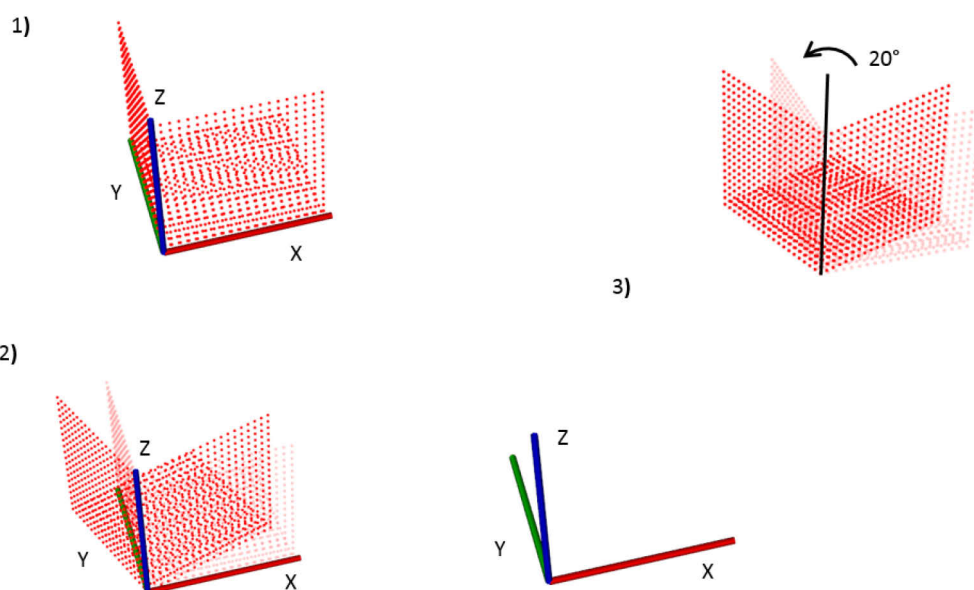
**Obr. 4.2 – Výsledek rotace objektu v prostoru kolem souřadné osy Z**

Rotace proběhla kolem osy počátku s poloměrem rozdílu počátků vertikálního a globálního souřadnicového systému. Světlejší objekt je původní pozice. Požadavkem je ale rotace samotného objektu, ne jen posun po kružnici o definovaný úhel. Pro provedení rotace v prostoru kolem vybraného bodu je zapotřebí postupovat v následujících krocích:

- 1) Posun do počátku souřadnic
- 2) Rotace objektu kolem počátku
- 3) Přesun zpátky na původní pozici

Je-li vyžadována rotace i posun v prostoru, provedou se kroky 1) a 2) a místo kroku 3) se objekt přesune na novou pozici. Na popsaném problému je dobře vidět, jak jsou od sebe odděleny operace posunu a rotace.

Pro rotaci objektu umístěného v globálním prostoru je zapotřebí aplikovat rotaci v jeho objektovém prostoru. V bodě 1) využijí vertikální prostor a posunu jeho počátek, aby se shodoval s globálním prostorem Obr. 4.3 (1).



**Obr. 4.3 – Požadovaná rotace objektu v prostoru, 1) posun vertikálního prostoru na počátek, 2) rotace objektového prostoru v počátku, 3) návrat objektu na původní pozici**



Dále provedu rotaci objektu podle bodu 2) v jeho prostoru Obr. 4.3 (2), který má shodný počátek s vertikálním prostorem, a nakonec posunu objekt zpátky na původní pozici v globálním prostoru podle bodu 3) Obr. 4.3 (3). Pro názornější ilustraci je na obou obrázcích vyznačena původní pozice objektu světlejší barvou.

Tímto postupem lze rotovat objekt v jeho objektovém prostoru včetně zachování jeho výchozí pozice, ale tato transformace vyžaduje provedení 3 maticových operací zvlášť, protože je zapotřebí posun v prostoru, který mění typ aplikované transformace na afinní. V následující kapitole 4.5 popisující transformační matici  $4 \times 4$  je ukázáno, jak tuto afinní transformaci aplikovat pouhým maticovým násobením.


## 4.5 Matice $4 \times 4$

Doposud byly v této kapitole použity pouze 2D a 3D vektory. V této části popíši použití 4D vektoru a tzv. „homogenní“ souřadnice při zpracování mračen bodů. Čtvrtý rozměr zde nepředstavuje „čas“, jak je běžně uvažováno. Použití 4D vektoru a matice  $4 \times 4$  je pouze formální označení 3D operace aplikace 3D transformace včetně posunu neboli afinní transformace prostřednictvím jediné matice, která je v práci často používána. Matici  $4 \times 4$  lze využít rovněž pro perspektivní projekci aplikovanou pro tvorbu hloubkové mapy z libovolné pozice analyzovaného mračen bodů uvedené v kapitole 6.1.

### 4.5.1 4D homogenní prostor

Má čtyři komponenty, z nichž tři tvoří známé složky  $x$ ,  $y$  a  $z$ . Čtvrtou komponentu tvoří  $w$  označované jako homogenní souřadnice.

Pro lepší představu, jak rozšířit 3D prostor do 4D prostoru, nejlépe poslouží homogenní 2D prostor  $[x, y, w]$ . Homogenní souřadnice  $w$  zde slouží jako projekční souřadnice. Například si můžeme představit rovinu ve 3D prostoru na hladině  $w = 1$  (Obr. 4.4). Rovina představuje homogenní prostor  $[x, y, 1]$ . Pro všechny body mimo rovinu lze vypočítat odpovídající projekci bodu na tuto rovinu dělením homogenní souřadnicí  $w$ . Homogenní souřadnice  $[x, y, w]$  změní projekci svoje souřadnice na  $[x/w, y/w]$  (Obr. 4.4) Pro libovolný fyzický bod ve 2D prostoru  $[x, y]$  existuje nekonečno odpovídajících bodů ve 2D prostoru, vše zapsané jako  $[kx, ky, k]$ , pro  $k \neq 0$ . Přímka tvořená těmito body prochází homogenním počátkem. Pro  $w = 0$  není dělení definováno a bod nemá odpovídající souřadnici ve 2D prostoru. Pro tento speciální případ můžeme definovat bod  $[x, y, 0]$  jako „bod v nekonečnu“ naznačující spíše směr než konkrétní pozici.



Obr. 4.4 – Projekce pomocí homogenní souřadnice na rovinu  $w = 1$  ve 2D

Stejná idea jako ve 2D prostoru se dá aplikovat na rozšíření 3D prostoru do 4D homogenního prostoru. Vizualizace rozšíření do 4D je složitější a proto zde nebude uvedena. Fyzický bod v 3D prostoru umístím na hyperplochu v 4D na ( $w = 1$ ). Bodu se souřadnicemi  $[x, y, z, w]$  odpovídá projekce bodu z 3D prostoru definovaná jako  $[x/w, y/w, z/w]$ . Stejně jako ve 2D prostoru pro  $w = 0$  je bod v 4D prostoru uvažován jako „bod v nekonečnu“ definující spíše směr než pozici. (Dunn, 2011)

V příští kapitole je popsán primární cíl používání matic  $4 \times 4$  a 4D prostoru, kterým je aplikace afinní transformace prostřednictvím jedné matice.

#### 4.5.2 Afinní transformace pomocí matice $4 \times 4$

Matici  $3 \times 3$  lze použít na aplikaci lineární transformace nezahrnující posun v prostoru. Z přirozenosti maticového násobení je nulový vektor vždy transformován na nulový vektor, a proto každá transformace vyjádřená maticovým násobením nemůže obsahovat posunutí v prostoru. Matice jsou vhodným nástrojem i pro provedení složitých transformací a nalezení způsobu aplikace kompletní transformace tzn. rotace a posunutí v jednom kroku značně usnadní práci s body v prostoru. Matice  $4 \times 4$  je vhodným prostředkem jak toho docílit.

Uvážením homogenního koeficientu  $w = 1$  pro 4D prostor lze každý bod 3D prostoru definovat jako  $[x, y, z, 1]$  a každou transformační matici  $3 \times 3$  potom zapsat v podobě 4D matice jako

$$\begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{23} & m_{33} \end{bmatrix} \Rightarrow \begin{bmatrix} m_{11} & m_{12} & m_{13} & 0 \\ m_{21} & m_{22} & m_{23} & 0 \\ m_{31} & m_{23} & m_{33} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.15)$$

Násobením rozšířeného vektoru maticí  $4 \times 4$  (4.15) získáme stejný výsledek jako v 3D prostoru (4.6). Jediným rozdílem je přítomnost homogenní souřadnice  $w = 1$ .

$$[x \quad y \quad z \quad 1] \begin{bmatrix} m_{11} & m_{12} & m_{13} & 0 \\ m_{21} & m_{22} & m_{23} & 0 \\ m_{31} & m_{23} & m_{33} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \quad (4.16)$$

$$[xm_{11} + ym_{21} + zm_{31} \quad xm_{12} + ym_{22} + zm_{23} \quad xm_{13} + ym_{23} + zm_{33} \quad 1]$$

Užitečnou vlastností umožňující 4D matice je aplikace posunu v prostoru pomocí maticového násobení

$$[x \quad y \quad z \quad 1] \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ \Delta x & \Delta y & \Delta z & 1 \end{bmatrix} = [x + \Delta x \quad y + \Delta y \quad z + \Delta z \quad 1]. \quad (4.17)$$

Je důležité poznamenat, že stále aplikují operaci lineární transformace, která nemůže obsahovat posun v 4D. Nulový vektor 4D prostoru musí být vždy transformován do nulového vektoru. Důvodem možnosti použití operace posunu pro bod v 3D prostoru je ve skutečnosti aplikace operace shearing (rovnice (4.12) pro 3D) v 4D prostoru. Hyperplocha odpovídající fyzicky 3D prostoru neprochází počátkem v 4D, a tak lze pomocí operace shearing ve 4D aplikovat posun ve 3D prostoru.

Matice lineární transformace  $R$  (např. obecná rotační matice) a matice posunu  $T$  mají v 4D prostoru tvar

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{23} & r_{33} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ \Delta x & \Delta y & \Delta z & 1 \end{bmatrix}. \quad (4.18)$$

Stejně jako ve 3D prostoru (4.13) platí pro matice v  $4 \times 4$  stejná pravidla o pořadí vykonání transformací maticovým násobením. Na řádkový vektor představující bod se jednotlivé transformace vykonávají zleva. Při požadavku aplikace a rotace s následným posunem má výsledný vztah následující formu

$$\mathbf{v}' = \mathbf{v}RT = \mathbf{v}M. \quad (4.19)$$

Vynásobením matic  $R$  a  $T$  (4.18) vznikne matice  $M$

$$M = \begin{bmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{23} & r_{33} & 0 \\ \Delta x & \Delta y & \Delta z & 1 \end{bmatrix} \quad (4.20)$$

Z analýzy obsahu výsledné matice  $M$ (4.20) vyplývá, že její levá horní část  $3 \times 3$  je matice rotace a spodní řádek zleva tvoří část posunu. Poslední sloupec tvoří stejný sloupec z identické matice  $4 \times 4$   $[0, 0, 0, 1]^T$ . Matici lze rovněž přepsat do blokového tvaru

$$M = \begin{bmatrix} R & 0 \\ t & 1 \end{bmatrix} \quad (4.21)$$

Užitečnou vlastností matice  $4 \times 4$  je tzv. „bod v nekonečnu“ při  $w = 0$  (4.16) reprezentující poslední sloupec vstupního vektoru. Násobením tohoto vektoru standardní maticí  $3 \times 3$  rozšířenou do  $4 \times 4$  je získán očekávaný výsledek jako ve 3D prostoru

$$[x \quad y \quad z \quad 0] \begin{bmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{23} & r_{33} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \quad (4.22)$$

$$[xm_{11} + ym_{21} + zm_{31} \quad xm_{12} + ym_{22} + zm_{23} \quad xm_{13} + ym_{23} + zm_{33} \quad 0].$$

Vektor  $[x, y, z, 0]$  je transformován na jiný bod v nekonečnu  $[x', y', z', 0]$ . Přidáním operace posunu v prostoru k rozšířené matici  $4 \times 4$  (4.20) a vynásobením vektoru touto maticí je výsledek

$$[x \quad y \quad z \quad 0] \begin{bmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{23} & r_{33} & 0 \\ \Delta x & \Delta y & \Delta z & 1 \end{bmatrix} = \quad (4.23)$$

$$[xm_{11} + ym_{21} + zm_{31} \quad xm_{12} + ym_{22} + zm_{23} \quad xm_{13} + ym_{23} + zm_{33} \quad 0].$$

Oba výsledky (4.22) a (4.23) jsou shodné. Jinými slovy, je-li homogenní souřadnice  $w = 0$ , neuplatňuje se operace posunutí, aplikuje se pouze část lineární transformace a výsledkem je nový „bod v nekonečnu“. Z geometrického hlediska v případě homogenní souřadnice  $w = 0$  jsou transformovaná data vektory (popisují spíše směr než pozici) a pro  $w = 1$  popisují body (je známa konkrétní pozice v prostoru). Těto vlastnosti se dá využít

jako „ovládání“ posunu bodů v prostoru při aplikaci lineární transformace maticovým násobením 4 x 4. Největší uplatnění má tato vlastnost v počítačové grafice (Dunn, 2011). V oblasti zpracování mračen bodů je rovněž často využívána díky svým žádoucím vlastnostem. Jednotlivé body jsou uloženy ve formě vektoru  $[x, y, z]$ . Homogenní souřadnici  $w$  není zapotřebí mít svázanou s každým bodem. Před každou lineární transformací ji lze k bodu podle potřeby aplikace posunu v prostoru přidat, aby bylo dodrženo blokové schéma ve výrazu (4.21).

### 4.5.3 Obecná afinní transformace

V kapitole 4.4 je uvedena aplikace afinní transformace pomocí postupné aplikace operací posunu, rotace kolem počátku a návratu zpět na výchozí pozici. Znalost matice 4 x 4 umožní definovat obecné afinní transformace:

- 1) Rotace kolem osy neprocházející počátkem
- 2) Měřítkování vůči rovině neprocházející počátkem
- 3) Zrdocadlení vůči rovině neprocházející počátkem
- 4) Projekci na rovinu neprocházející počátkem

Základní idea vychází z 3D prostoru postupnou aplikací operací posunu a lineárních transformací pro docílení požadovaného výsledku. Využitím pravidla pořadí aplikace transformací maticovým násobením (4.13) lze pomocí matic 4 x 4 sestavit výslednou matici. První krok je posun do počátku  $T$  (4.24), následně je provedena rotace  $R$  (4.25) a inverzní transformace  $T^{-1}$  (4.26), která vrátí objekt na původní pozici.

$$T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ -p_x & -p_y & -p_z & 1 \end{bmatrix} = \begin{bmatrix} I & 0 \\ -p & 1 \end{bmatrix} \quad (4.24)$$

$$R_{4 \times 4} = \begin{bmatrix} r_{11} & r_{12} & r_{13} & 0 \\ r_{21} & r_{22} & r_{23} & 0 \\ r_{31} & r_{23} & r_{33} & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} R_{3 \times 3} & 0 \\ 0 & 1 \end{bmatrix} \quad (4.25)$$

$$T^{-1} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ p_x & p_y & p_z & 1 \end{bmatrix} = \begin{bmatrix} I & 0 \\ p & 1 \end{bmatrix} \quad (4.26)$$

Vynásobením jednotlivých matic v požadovaném pořadí  $TR(T^{-1})$  vznikne výsledná transformační matice  $M$

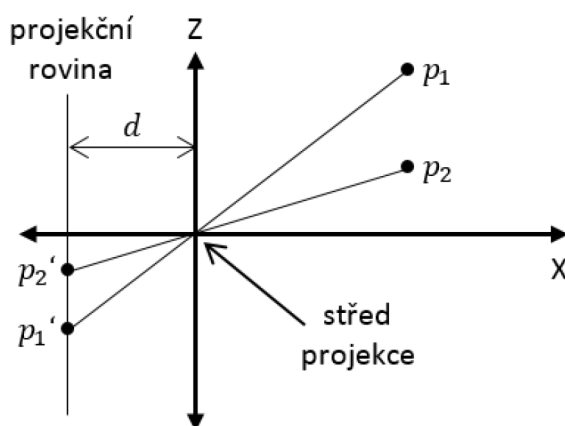
$$TR_{4 \times 4}T^{-1} = \begin{bmatrix} I & 0 \\ -p & 1 \end{bmatrix} \begin{bmatrix} R_{3 \times 3} & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} I & 0 \\ p & 1 \end{bmatrix} = \begin{bmatrix} R_{3 \times 3} & 0 \\ -p(R_{3 \times 3}) + p & 1 \end{bmatrix} \quad (4.27)$$

Z analýzy výsledné sestavené transformační matice (4.27) vyplývá, že je pouze ovlivněn poslední řádek s vektorem posunu. Horní část rotační matice 3 x 3 je nezměněna. Takto sestavenou maticí a použitím homogenní souřadnice  $w$  přidanou jako čtvrtý rozměr k transformovaným bodům lze pouhým maticovým násobením aplikovat afinní transformaci, pro kterou bylo v kapitole 4.4 zapotřebí provést tři oddělené operace.

#### 4.5.4 Matice 4 x 4 a perspektivní projekce

V úvodním popisu kapitoly 4.5 o matici 4 x 4 jsem naznačil jednu z možností jejího použití a tou je aplikace perspektivní projekce. Při popisu homogenního 4D prostoru je také definován homogenní koeficient  $w$ . Při projekci 4D vektoru do 3D prostoru jsou tímto koeficientem děleny ostatní souřadnice. Doposud jeho hodnota byla 0 nebo 1 podle požadavku na aplikaci posunu bodu pomocí transformační matice 4 x 4. Vhodným použitím koeficientu  $w$  se dá docílit i perspektivní projekce.

Výsledkem projekce na Obr. 4.5 je promítnutí objektu v prostoru na zvolenou 2D rovinu. Využívá se podobného principu jako dírková kamera.



Obr. 4.5 – Princip perspektivní projekce

Projekční přímky z bodu  $p_1$  a  $p_2$  protínají střed projekce a výsledkem je zmenšený převrácený obraz znázorněný body  $p_1'$  a  $p_2'$ , vůči středu projekce je zachována perspektiva. Pro projekci obecného bodu  $p$  v prostoru na bod  $p'$  ležící na projekční rovině využívám jeho prostorové souřadnice a vzdálenost  $d$  od projekční roviny. Na základě podobnosti trojúhelníků lze odvodit vztah

$$\frac{-p_z'}{d} = \frac{p_z}{x} \Rightarrow p_z' = \frac{-dp_z}{x}. \quad (4.28)$$

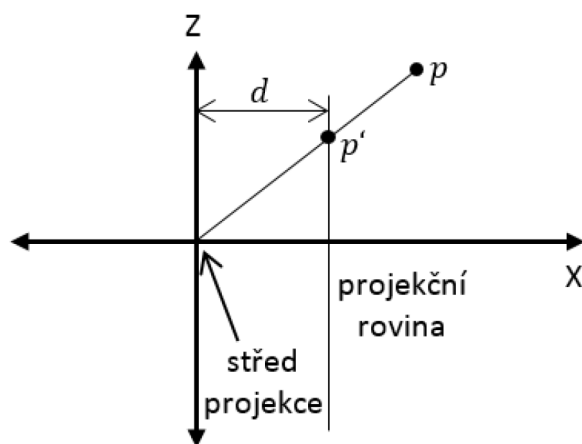
Objekt nacházející se za projekční rovinou je otočen a má záporné znaménko. Hodnotu  $p_x'$  lze odvodit podobným způsobem

$$p_y' = \frac{-dp_y}{x} \quad (4.29)$$

Souřadnice  $x$  všech promítaných bodů na rovinu je stejná a odpovídá  $-d$ . Promítnutí bodu  $p$  přes počátek na bod  $p'$  ležící na projekční rovině  $x = -d$  lze zapsat

$$p = [x \quad y \quad z] \rightarrow p' = [x' \quad y' \quad z'] = [-d \quad -dy/x \quad -dz/x] \quad (4.30)$$

Z praktického hlediska není zapotřebí bod promítat na rovinu ve vzdálenosti  $-d$ , lze vynechat záporné znaménko a promítat bod na rovinu umístěnou ve vzdálenosti  $d$  před počátek projekce viz Obr. 4.6. Kromě eliminace záporného znaménka není projektovaný bod (objekt) převrácen.



Obr. 4.6 – Posunutí projekční roviny

$$p' = [x' \quad y' \quad z'] = [d \quad dy/x \quad dz/x] \quad (4.31)$$

K přechodu ze 4D prostoru do 3D se využívá dělení, jak uvádím v předchozích kapitolách, a proto lze pro perspektivní projekci využít matici 4 x 4. Z definice bodu  $p'$  (4.31) je zapotřebí určit společný jmenovatel pro všechny souřadnice a vytvořit matici s homogenním koeficientem  $w$  rovným společnému jmenovateli (Dunn, 2011). Pro výchozí pozici bodů je  $w = 1$ .

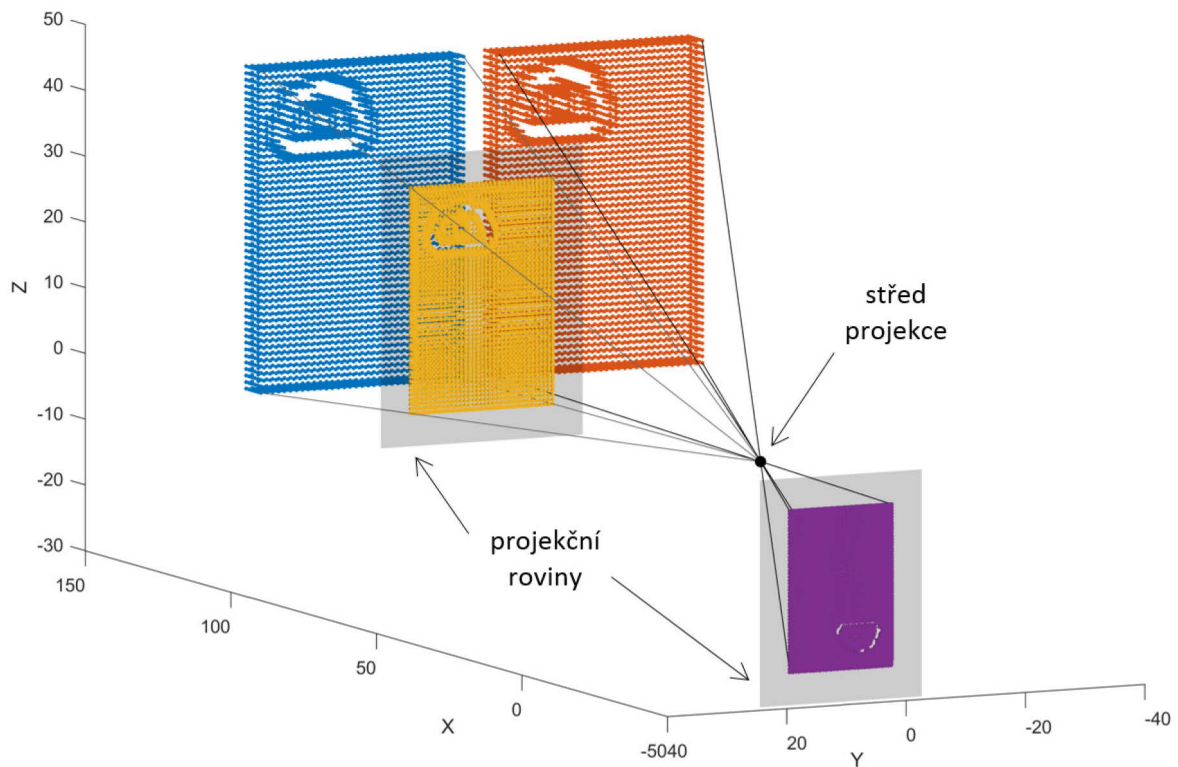
$$[d \quad dy/x \quad dz/x] = [dx/x \quad dy/x \quad dz/x] = \frac{[x \quad y \quad z]}{x/d} \quad (4.32)$$

Požadavkem je dělení tímto společným jmenovatelem. Promítaný bod ve 4D prostoru bude mít následující formu  $[x \quad y \quad z \quad x/d]$ .

Matrice 4 x 4 určující dělitel pro provedení projekce bodu  $p = [x, y, z, 1]$  v ose  $X$  má podobu

$$[x \quad y \quad z \quad 1] \begin{bmatrix} 1 & 0 & 0 & 1/d \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = [x \quad y \quad z \quad x/d]. \quad (4.33)$$

Uvedená konečná projekční matice (4.33) pro osu  $X$  pouze určí společný dělitel pro všechny osy. Samotný bod je projektován až při přechodu z 4D prostoru do 3D prostřednictvím operace dělení homogenním koeficientem  $w$ . Pro projekci do ostatních souřadnicových os je zapotřebí umístit společný dělitel v odpovídající ose. Matice 4 x 4 slouží jako kompaktní nástroj pro provedení projekce bodů, navíc jí lze kombinovat s ostatními transformacemi. V počítačové grafice se projekční matice nazývá clip matice a kromě projekce zajišťuje i měřítkování pro dosažení co nejlepšího obrazu (Dunn, 2011). Na Obr. 4.7 jsou uvedeny praktické příklady perspektivní projekce testovacích 3D objektů včetně ilustrace projekčních přímek jejich vrcholů.



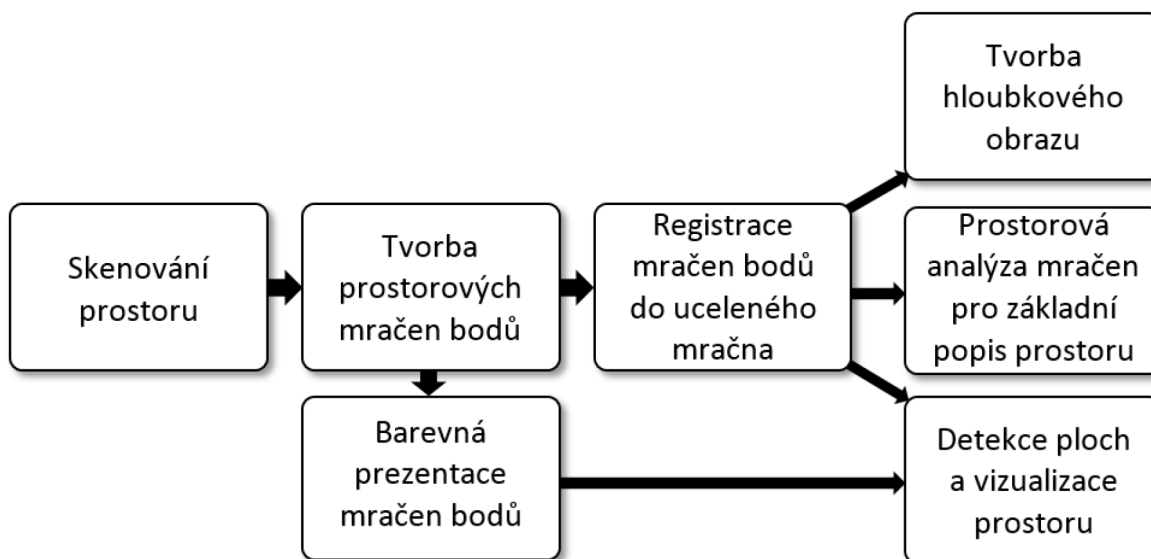
**Obr. 4.7 – Příklady perspektivní projekce**

Projekční roviny jsou naznačeny slabou šedivou barvou. Modrému objektu odpovídá žlutá projekce nacházející se v bodě  $x = 70$ , objekt je zmenšený, ale má zachovanou orientaci. Příkladem druhé projekce je oranžový objekt stejné velikosti jako modrý. Výsledkem jeho projekce je fialový objekt projektovaný na rovinu ve vzdálenosti  $x = -50$ . Projekce je zmenšená a převrácená, neboť se nachází za středem projekce, kde se uplatňuje efekt dírkové kamery. Perspektivní projekce je v této práci využita hlavně pro tvorbu hloubkové mapy uvedené v kapitole 6.1 včetně praktických příkladů s reálnými mračny bodů.



## 5 Systém automatického skenování a mapování prostoru

Navržený systém automatizovaného skenování a mapování prostoru se skládá z dílčích částí uvedených na následujícím Obr. 5.1.



Obr. 5.1 – Blokové schéma systému automatického skenování a mapování prostoru

První jeho část se zabývá problematikou skenování prostoru. Pro pořízení prostorových mračen bodů využívám vlastní navrženou mobilní platformu s vytvořeným optickým laserovým dálkoměrem. Po provedení prostorového skenu v rozsahu 360° jsou určeny vzdálenosti všech dostupných bodů laserové čáry a v další části systému je vytvořeno výsledné mračno bodů. S využitím obrazových dat lze extrahovat rovněž barevnou informaci. V kapitole 3 je uveden popis mobilní platformy, princip skenování, určení vzdálenosti a konstrukce mračna bodů včetně využití barevné informace. Kapitola zahrnuje i praktické výsledky měření a porovnání kvality detekčních modelů laserové čáry.

V této kapitole popisují vstupní úpravy mračen bodů, jako je eliminace odlehlých bodů a korekce orientace mračna pro přípravu tvorby ucelené mapy. Jednotlivé skeny prostředí je zapotřebí spojit procesem registrace, jehož význam a popis dostupných metod je uveden v kapitole 2.3. Aplikované úpravy mračen bodů napomáhají při tvorbě výsledné prostorové mapy a zvyšují její kvalitu. V praktické části uvádím výsledky experimentu procesu registrace na vlastních naměřených datech pomocí dvou základních metod ICP a NDT. Pro získání dalších prostorových informací, zjednodušení popisných bodů prostředí a vizualizace jeho částí je zapotřebí výsledná mračna dále zpracovávat. Navržené metody, prostředky a postupy zpracování uvádím v kapitole 6.

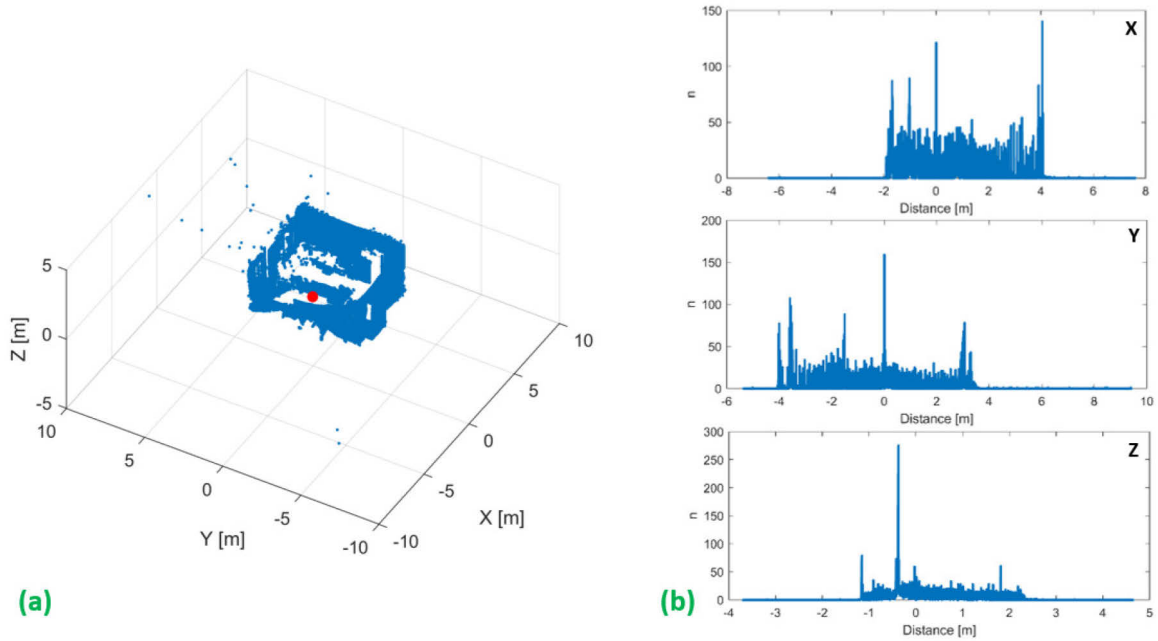
### 5.1 Úpravy mračen bodů

Vlivem chyb určení pozice měřicích bodů mohou ve výsledných mračech bodů vznikat nežádoucí odlehlé body ovlivňující zejména jejich vizualizaci zvyšováním rozsahu souřadných os například i při výskytu jednoho odlehlého bodu. Dále při pozicování mobilní platformy před začátkem skenování prostoru nemusí být vlivem její nepřesné manipulace orientace měřicí hlavy přímo kolmá na souřadné osy.

Popsané situace mohou mít vliv na další zpracování vzniklých mračen bodů, zejména druhá uvedená viz kapitola 6.3, kde je pro rychlejší zpracování vyžadována jejich kolmost na souřadné osy. V této podkapitole uvádím metody korekce obou uvedených problémů pomocí využití histogramu.

### 5.1.1 Eliminace odlehlých bodů

Vlivem chyb měření se mohou ve výsledném mračnu bodů vyskytovat odlehlé body způsobující problémy s jejich vizualizací, kdy rozsah některé ze souřadných os může být i příčinou jednoho odlehlého bodu neúměrně velký viz Obr. 5.2 (a).



Obr. 5.2 – Vstupní mračno s odlehlými body, (a) mračno bodů, (b) histogramy souřadných os

Pro odstranění odlehlých bodů využívám metodu histogramu určující počet četností jejich výskytu na určité pozici souřadné osy. Znázornění histogramů jednotlivých souřadných os  $h_X$ ,  $h_Y$  a  $h_Z$  je na Obr. 5.2 (b). Uživatelsky nastavitelný práh četností je označen jako  $h_T$ . Histogram vstupního mračna bodů označený jako  $h_d$  pro určitou dimenzi  $d$  je definován jako

$$h_d(n) = \#X(v_d(n, 1): v_d(n, 2), d) , \quad (5.1)$$

kde matice  $X$  je vstupní mračno bodů viz kapitola 4.1, symbol  $\#$  označuje počet bodů výběru definovaného rozsahu jednotlivých četností histogramu  $v_d$ . Hodnota  $n \in [1, 2, \dots, N_d]$  určuje index rozsahu z celkového počtu  $N_d$  definovaného vztahem

$$N_d = \left( \max(X(\forall, d)) - \min(X(\forall, d)) \right) \cdot 1e^3 . \quad (5.2)$$

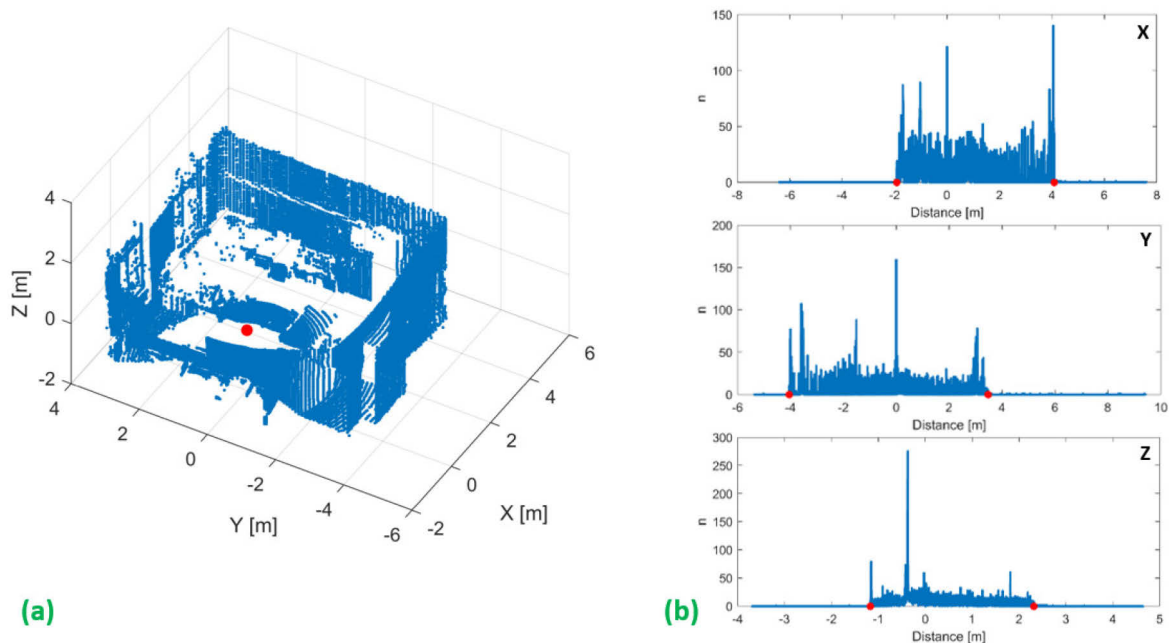
Výraz (5.2) je násoben konstantou  $1e^3$  zajišťující požadované rozlišení histogramu 1 mm označené jako jeho krok  $h_{St}$ . Hodnoty pole  $v_d$  tvoří rozsahy jednotlivých četností histogramu stanovené celkovým rozsahem analyzované souřadné osy  $hR_d$ , určeným jako

$$hR_d = \left[ \max(X(\forall, d)), \min(X(\forall, d)) \right] , \quad (5.3)$$

počtem hodnot histogramu  $N_d$  (5.2) a jeho krokem  $h_{st}$ . Pole  $v_d$  má  $N_d$  řádků a indexy sloupců 1 a 2 v rovnici (5.1) označují počátky a konce jeho rozsahů. Práh histogramu pro odstranění odlehlých bodů  $h_T$  je nastaven uživatelsky. Hodnota prahu je aplikována na obě strany histogramu. Hledaný rozsah osy po analýze histogramu  $h_d$  (5.1) je získán nalezením pozic jeho prvních prvků s četností větší nebo rovno požadované hodnoty prahu  $h_T$  z obou jeho stran

$$h_d(n) \geq h_T \quad (5.4)$$

Další Obr. 5.3 (a) zobrazuje mračno bodů po aplikaci metody histogramu a Obr. 5.3 (b) ukazuje histogramy jednotlivých souřadných os s nově vyznačenými rozsahy pomocí červených bodů. Hodnota prahu  $h_T = 5$  pro všechny souřadné osy.

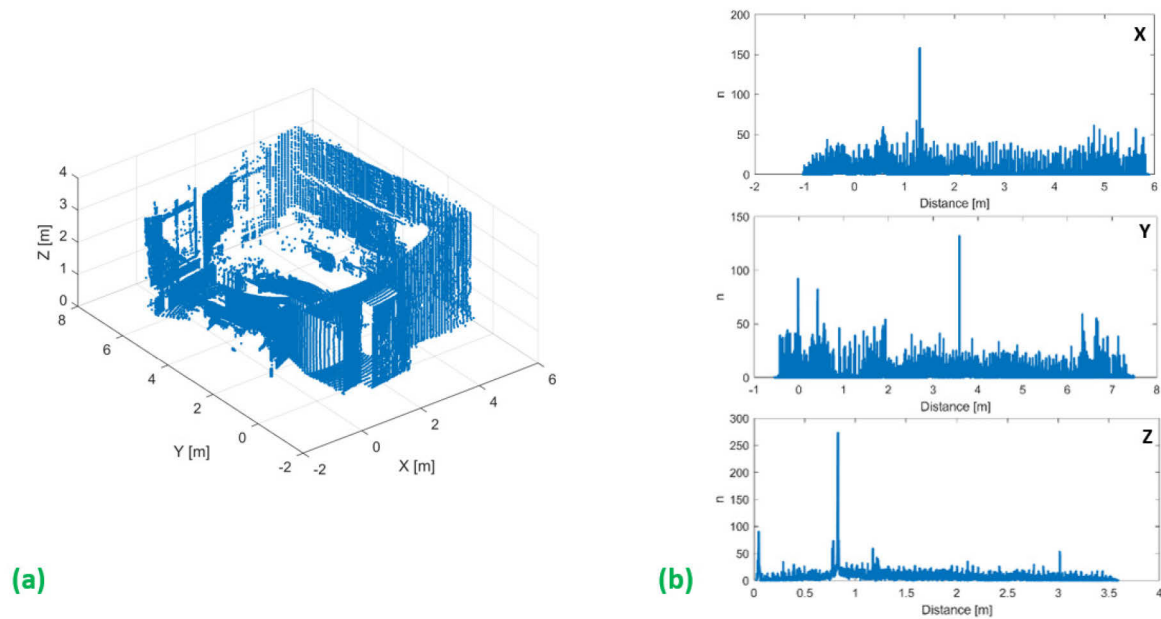


Obr. 5.3 – Výstupní mračno po odstranění odlehlých bodů, (a) mračno bodů, (b) histogramy souřadných os s nově vyznačenými rozsahy prostřednictvím červených bodů

### 5.1.2 Korekce orientace mračna bodů

Stejně jako lze využít metodu histogramu na odstranění odlehlých bodů popsanou výše, tak lze jeho pomocí nalézt i korekci jeho orientace. Korekci lze využít například v procesu registrace mračen popsanou v kapitole 2.3 nebo zejména pro analýzu jejich úrovní a detekci rovin uvedenou v kapitole 6.2, kde u správně orientovaného mračna bodů lze docílit zrychlení jeho zpracování.

Předpokladem navržené metody je výskyt rovných ploch v analyzovaném mračnu. Při skenování vnitřních prostor je požadavek až na specifické tvary skenovaného prostředí vždy splněn. Na Obr. 5.4 (a) je znázorněno vstupní mračno bodů se správnou orientací rotace v osách  $X$  a  $Y$  a neznámým úhlem rotace v ose  $Z$ . Na Obr. 5.4 (b) jsou zobrazeny odpovídající histogramy souřadných os. Histogramy jsou sestaveny s rozlišením 1 mm, stejně jako v případě odlehlých bodů.

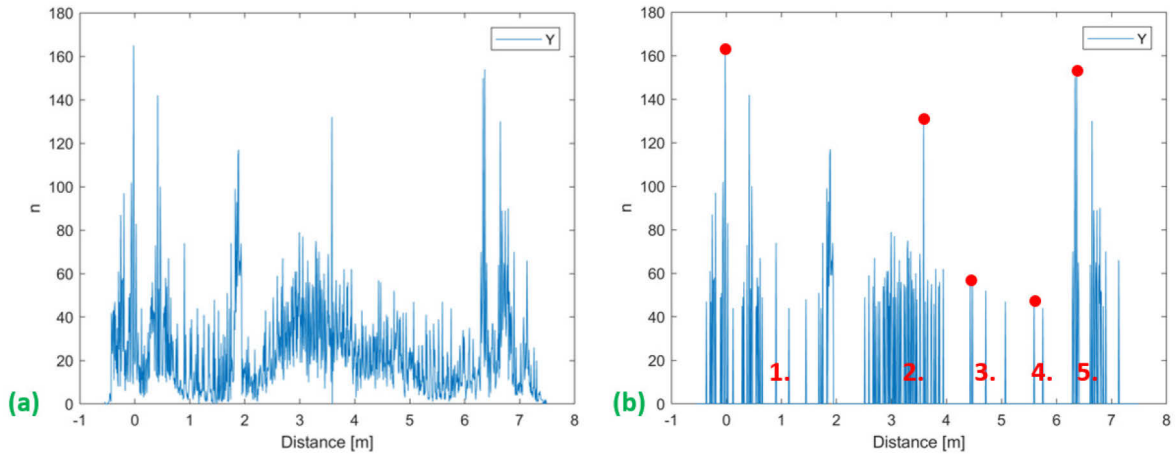


Obr. 5.4 – Vstupní mračno bodů pro určení jeho orientace, (a) mračno, (b) histogramy souřadných os

Navržený algoritmus korekce orientace mračen bodů je schopen v jednom průchodu najít korekční úhel jedné souřadné osy pomocí zbylých dvou. Na Obr. 5.4 (b) jsou v grafu histogramu osy  $Z$  patrná dvě maxima tvořená koncentrací bodů podlahy a stropu. Nejvyšší maximum v ose  $Z$  tvoří přítomné stoly. Princip korekce natočení osy využívá právě sledování maxim koncentrací bodů v odpovídajících osách. Popisovaný příklad řeší korekci orientace v ose  $Z$  pomocí sledování koncentrací bodů v histogramu osy  $X$  a  $Y$ . Jelikož se plochy mohou vyskytovat ve zpracovávaném mračnu bodů v různých úrovních zkoumané osy, tak nestačí pouze sledovat a vyhodnocovat největší lokální maximum, ale je zapotřebí uvažovat všechna dostupná lokální maxima. Pro jejich získání je vhodné využít navržený modifikovaný algoritmus hledání spojených komponent uvedený v kapitole 6.2. Histogram netvoří spojitý průběh v celé ose a vlastnost upraveného algoritmu sdružovat blízké oblasti menší než definovaný odstup  $iz$  je pro hledání lokálních maxim žádoucí. Vstupní mračno bodů je označeno jako  $X$ , stejně jako v případě odstranění odlehlých bodů popsané výše. Na Obr. 5.5 (a) je vyznačen detailní průběh histogramu v souřadné ose  $Y$   $h_Y$ . Pro oddělení lokálních maxim je vhodné navíc aplikovat práh hodnot definovaný jako

$$h_d \left( h_d < (\mu(h_d) + \sigma(h_d)) \right) = 0 , \quad (5.5)$$

kde  $d$  označuje zvolenou souřadnou osu. Hodnoty vytvořeného histogramu  $h_d$  menší než jeho průměr  $\mu(h_d)$  s přičtenou standardní odchylkou  $\sigma(h_d)$  jsou nulovány. Histogram po aplikaci rovnice (5.5) a použití modifikovaného algoritmu analýzy spojených komponent s velikostí parametru  $iz = 0.05 \cdot N_d$  získaného ze vztahu (5.3) představující 5% z počtu prvků histogramu  $N_d$  je zobrazen na Obr. 5.5 (b) s vyznačenými maximy jeho nalezených a očíslovaných částí.




Obr. 5.5 – Detailní pohled na histogram osy Y, (a) před úpravou, (b) po úpravě s vyznačenými maximy

Sumu všech lokálních maxim částí histogramu nalezené modifikovanou analýzou spojených komponent v souřadné ose  $d$  určuje vztah

$$\sum h_d(k) = \sum_{n=1}^{L_N} \max(h_d(L = n)) , \quad (5.6)$$

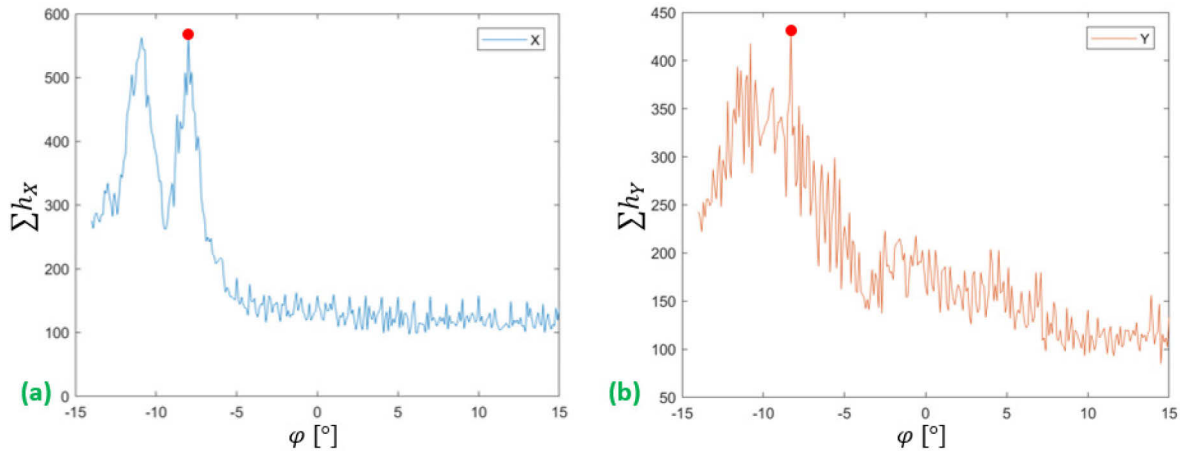
kde  $L_N$  je počet nalezených oblastí histogramu v poli jejich indexů  $L$ . Obr. 5.5 popisuje  $k$ -tý krok algoritmu, kde suma histogramu  $\sum h_d(k)$  odpovídá příslušné hodnotě rotace mračna bodů určené indexem  $k$ . Pro lepší ilustraci různých hodnot  $\sum h_d(k)$  je na Obr. 5.6 (a) zobrazen průběh histogramu v ose  $X$  a  $Y$  pro mračno bodů v původní pozici  $0^\circ$  a na Obr. 5.6 (b) pootočené o  $-8^\circ$ . Z analýzy histogramů obou rotací jsou zřejmé různé velikosti jejich lokálních maxim.



Obr. 5.6 – Histogramy os  $X$  a  $Y$  pro různé hodnoty natočení mračna, (a) původní  $0^\circ$ , (b) natočené o  $-8^\circ$

Na začátku algoritmu je zvolen rozsah analyzovaných stupňů  $R_\varphi = \langle \varphi_{RS}, \varphi_{Re} \rangle$ . Pro přesnější stanovení lze krok rotace  $s_R$  zvolit například na hodnotu  $0,1^\circ$ . Zkoumané mračno se otáčí do počátečního úhlu  $\varphi_{RS}$ , vytvoří se rotační matice jednoho kroku  $R(s_R)$  s využitím vztahů z kapitoly 4.3.2, se kterou se mračno bodů násobí na základě pravidla (4.13), dokud není dosaženo konečného úhlu  $\varphi_{Re}$ . V každém kroku se určí suma histogramu  $\sum h_d(k)$ . Obr. 5.7 znázorňuje průběh sumy rotace mračna bodů z Obr. 5.4 (a) pro souřadnou osu  $X$  a Obr. 5.7 (b) pro souřadnou osu  $Y$ . Pro nalezení rotace mračna bodů je rozsah rotace  $R_\varphi$  pro testovaný příklad zvolen v intervalu  $\langle -15^\circ, +14^\circ \rangle$  s krokem  $s_R = 0,1^\circ$ . Z analýzy

průběhů vyplývá, že maxima natočení pro každou osu mají nepatrně jinou pozici. Hledaný úhel orientace  $\varphi_o$  je průměrem zjištěných hodnot úhlů obou os stanoven na hodnotu  $-8,15^\circ$ . Pro uvedení příkladu korekce orientace mračna bodů bylo vstupní mračno bodů na Obr. 5.4 (a) úmyslně rotováno kolem osy Z o  $8^\circ$ .



Obr. 5.7 – Suma histogramu pro jednotlivá natočení mračna bodů, (a) pro osu X, (b) pro osu Y

Rozsah rotačního intervalu nelze volit zcela libovolně, protože histogram jedné z os je shodný s histogramem druhé osy při pootočení o  $90^\circ$ . Univerzálním řešením je stanovit aktuální rotaci mračna bodů na  $0^\circ$  a rotovat mračno bodů v určitém intervalu  $\pm \max. 45^\circ$ . Pomocí navrženého algoritmu je možné nalézt úhel orientace mračna bodů pro dosažení kolmosti na souřadné osy. Pro nalezení orientace v jedné souřadné ose je zapotřebí analyzovat histogramy mračna bodů zbylých dvou souřadných os. Předpokladem fungování algoritmu je výskyt rovných ploch v mračnu bodů, který je pro vnitřní prostory téměř vždy splněn.

## 5.2 Hledání sousedních bodů

Pro objektivní porovnání výsledků algoritmů registrace mračen bodů je zapotřebí použít stejnou metodu vyhodnocení výsledků. Jako základní kritérium používám metodu nejmenších čtverců vyjadřující vzdálenost mezi jednotlivými body.

Z procesu registrace, popsaném v kapitole 2.3, vystupuje mračno bodů  $PC_y = [p_1, p_2, \dots, p_{M_{mp}}]$  s počtem bodů  $M_{mp}$ . K určení kvality registrace je zapotřebí vyhodnotit vzájemnou pozici bodů referenčního mračna  $PC_x = [p_1, p_2, \dots, p_{N_{mp}}]$  s počtem bodů  $N_{mp}$ , ke kterému je  $PC_y$  registrováno. Velikosti obou mračen  $M_{mp}$  a  $N_{mp}$  nemusí být stejné. Ke každému bodu  $p_{PC_y}$  z  $PC_y$  je zapotřebí najít nejbližší bod z  $PC_x$ . Po nalezení všech nejbližších bodů  $p_{PC_{xc}}$  je  $RMS_{xy}$  určeno následujícím vztahem

$$RMS_{xy} = \sqrt{\sum \frac{(p_{PC_y} - p_{PC_{xc}})^2}{M_{mp}}} \quad (5.7)$$


Obecně hledání blízkých bodů v referenčním mračnu  $PC_x$  je často využíváno nejen pro vyhodnocení vzájemné pozice dvou mračen a proto bylo vyvinuto mnoho metod k jejich efektivnímu hledání za účelem snížení doby zpracování (Kjer, 2010) a (Nüchter, 2009). Úspora času je dosažena zejména prostřednictvím reprezentace cílového mračna, ve kterém jsou hledány blízké body pomocí datové struktury zefektivňující hledání.

Základní metodou hledání blízkých bodů v cílovém mračnu je porovnání vzdálenosti všech vlastních bodů s hledaným bodem. Hledaných bodů může být ale velký počet a s jejich rostoucím množstvím dochází k nežádoucímu zpomalení.

Zefektivnit hledání lze například použitím metody Delaunay triangulation (Kjer, 2010). Algoritmus uvažuje rozdělení prostoru na regiony ve fázi předzpracování. Každému bodu mračna  $PC_x$  je přidělen určitý region prostoru. Toto členění umožňuje snížit počet sekvenčních hledání. Další možností je rozdělení bodů v  $PC_x$  do skupin podle jejich pozice. Hledání nejbližšího bodu je urychleno vyřazením mnoha bodů, pro které není zapotřebí vyhodnocovat vzájemnou vzdálenost, na základě jejich pozice a zařazení do skupiny. Typickým zástupcem této struktury třídění dat je metoda kD tree. Prezentace vstupního mračna bodů ve formě této struktury je často využívána (Kjer, 2010). Určitý čas trvá i vytvoření stromové struktury, ale ta je vytvořena pouze jednou a poté je použita  $M_{mp}$  krát pro hledání nejbližšího bodu z porovnávaného mračna  $PC_y$ .

### 5.2.1 kD tree

Pro reprezentaci bodů strukturou kD tree je celá skupina rozdělena nalezením mediánu první souřadnice. Bod odpovídající určenému mediánu se stává kořenem stromu (tree root). Obě zbývající části jsou rozděleny mediánem druhé souřadnice. Proces, známý jako „binary space partitioning“ vytváří rovnoměrný binární strom ze všech bodů mračna. Obr. 5.8 znázorňuje příklad kD tree pro 3D prostor. Pro jednodušší ilustraci je použito pouze několik bodů. Jednotlivé jeho úrovně jsou odlišeny barvou, podle které dimenze je strom zrovna dělen. Modrá barva popisuje dimenzi  $X$ , zelená  $Y$  a červená  $Z$ .



Obr. 5.8 – Ukázka struktury kD tree pro prostorové body

Výpočetní náročnost tvorby kD tree není vyšší než  $O(kN \log_2 N_{mp})$  (Kjer, 2010), kde  $k$  značí počet dimenzí. Použitím kD tree je značně zkrácen čas hledání nejbližšího sousedního bodu. Za předpokladu tvorby kD tree z referenčního mračna bodů  $PC_x$ . Pozici nejbližšího sousedního bodu  $p_{PC_y}$  registrovaného mračna  $PC_y$  k bodu z referenčního mračna  $PC_x$  označený jako  $p_{PC_{xc}}$  lze získat následujícím postupem:

- 1) Procházet stromovou strukturou od kořene a porovnávat souřadnice podle aktuální dělicí dimenze dokud není dosaženo posledního prvku označovaného list.
- 2) Označit nalezený bod listu jako aktuální nejlepší shodu  $p_{PC_{xc}}$  a určit vzdálenost  $d$  mezi tímto bodem a bodem  $p_{PC_y}$ .




- 3) Prove se kontrola, zda ve zkoumané skupině bodů neexistuje bližší bod návratem o jeden uzel výše (jednu úroveň) ve stromové struktuře. V případě zjištění menší vzdálenosti mezi bodem  $p_{PC_y}$  a tímto uzlem než aktuální  $d$  je tento bod označen jako nejlepší shoda  $p_{PC_{xc}}$  a vzdálenost  $d$  je aktualizována na tuto hodnotu.  
V případě vzdálenosti větší jak  $d$  je vyřazena druhá strana větve tohoto uzlu a postupuje se směrem nahoru, dokud není dosaženo kořene stromu. V opačném případě jsou prohledány větve druhé strany testovaného uzlu jako celý strom.
- 4) Při dosažení vrchního uzlu a prohledání všech postranních větví je vybrán bod s nejmenší vzdáleností k hledanému bodu  $p_{PC_y}$ .

V závislosti na hustotě mračna bodů  $PC_x$  a jeho rozsahu může být jeho velká část nebo naopak malá část vynechána v průběhu hledání nejbližšího bodu. V případě, že vzdálenost k prvnímu nalezenému listu je menší než k jeho předkům, je nalezena nejlepší možnost a ostatní větve jsou z hledání vyřazeny, časová náročnost odpovídá  $O(1)$ . Očekávaná časová náročnost prohledání stromu byla stanovena na základě praktického testování autora kd tree na  $O(\log_2 N_{mp})$  (Kjer, 2010). V nejhorším případě nelze vynechat žádný list stromu a hledání bude odpovídat základnímu přístupu porovnání bodu  $p_{PC_y}$  se všemi body vstupního mračna, tedy  $O(N_{mp})$ .

### 5.3 Porovnání praktických výsledků registrace


Pro vytvoření ucelené mapy prostoru je zapotřebí vstupní naskenovaná data získaná navrženým měřidlem vzdálenosti spojit v jeden celek. Úpravy vzniklých mračen metodami popsanými v kapitole 5.1 zajistí nejlepší výsledek procesu registrace. Použitá sestava navrženého skeneru popsaného v kapitole 3.1 nelze použít přímo pro online SLAM z důvodu jeho rychlosti skenování a vyhodnocení měřicích bodů, větších rozměrů a váze. Skener je spíše určen pro ruční přemístění. Skenování začíná ve výchozí pozici a vzhledem k tomuto místu jsou zaznamenány rozdíly posunu ve všech souřadných osách vůči pozici nové. Tato část kapitoly popisuje porovnání výsledků registrace dvou nejčastěji používaných algoritmů ICP a NDT z naměřených dat vnitřních prostor budovy.

Na Obr. 5.9 je zobrazen horní pohled na skenovanou laboratoř s vyznačenými pozicemi umístění optického skeneru prostředí pomocí červených bodů. Čísla jsou seřazeny vzestupně podle pořadí skenování.



Obr. 5.9 – Horní pohled na skenovanou laboratoř


Po vytvoření prostorových mračen bodů ze všech měřicích pozic viz Obr. 5.11 a jejich podrobné analýze na Obr. 5.10 je patrné, že v určitých částech prostředí zejména plochy jednotlivých měření jako jsou stěny, dveře a skříně nelicují přesně do sebe.



Obr. 5.10 – Detail přímého zobrazení mračen bodů, (a) stěny, skříně a dveře, (b) stěny, stůl a okno

Důvodem může být nesprávně natočená měřicí hlava optického skeneru, nepřesné umístění mobilní platformy nebo chyby měření samotného přístroje. V praktickém testu porovnávám dva nejčastěji používané algoritmy registrace mračen bodů ICP a NDT, implementované v knihovně PCL. Implementace algoritmu ICP umožňuje nastavit vstupní parametry:  $i$  – maximální počet iterací algoritmu,  $d$  – maximální vzdálenost pro hledání sousedních bodů a  $r$  – práh odstranění odlehlých bodů pomocí RANSAC algoritmu. V případě registrace NDT je možné nastavovat více parametrů: parametr  $i$  má stejný význam jako v implementaci ICP,  $r$  – rozlišení mřížky NDT pro tvorbu buněk,  $s$  – maximální velikost kroku pro Newtonovu optimalizační metodu,  $\epsilon$  – hladina konvergence maximální změny výstupu algoritmu,  $f$  – rozlišení filtru pro referenční mračno bodů.

Na Obr. 5.11 (a) - (f) jsou uvedena jednotlivá mračna bodů z měřicích pozic naznačených na Obr. 5.9.




Obr. 5.11 – Původní mračna bodů z měřicích pozic z Obr. 5.9, (a) 1. pozice, (b) 2. pozice, (c) 3. pozice, (d) 4. pozice, (e) 5. pozice, (f) 6. pozice

Pro objektivní porovnání kvality spojení jednotlivých mračen jsem použil metodiku hledání nejbližších bodů zdrojového mračna v jeho registrovaném uvedené v kapitole 5.2. Kvalita spojení je souhrnně vyjádřena hodnotou RMS. V Tab. 5.1 jsou přehledně zobrazeny časy všech kroků algoritmů s hodnotami RMS.


**Tab. 5.1 – Porovnání výsledků algoritmů registrace mračen bodů ICP a NDT**

Registrace mračna	ICP				NDT			
	Kroků	RMS org.	RMS	Čas [ms]	Kroků	RMS org.	RMS	Čas [ms]
2	1	0,16745	<b>0,16585</b>	958	1	0,16745	0,16662	1845
3	1	0,18394	0,16779	374	1	0,17925	<b>0,16197</b>	668
4	2	0,15894	<b>0,10836</b>	772	2	0,14965	0,10984	1882
5	1	0,09901	<b>0,0635</b>	378	1	0,08623	0,06385	1094
6	1	0,114	<b>0,08034</b>	456	2	0,09931	0,08097	3712

Pro algoritmus ICP jsou vstupní parametry registrace:  $i = 10$ ,  $d = 0,1 m$  a  $r = 0,2 m$ . V případě algoritmu NDT jsou použity tyto parametry:  $i = 10$ ,  $r = 0,5 m$ ,  $s = 0,1 m$ ,  $\epsilon = 1e^{-7}$  a  $f = 0,2 m$ . Porovnáním obou algoritmů z časového hlediska vychází lépe algoritmus ICP. Nejdůležitějším parametrem hodnocení kvality registrace mračen bodů je RMS, který vyšel ve většině případů s nepatrným rozdílem necelého procenta lépe pro algoritmus ICP dokazující jeho bodovou orientaci. Z provedeného testu je zřejmé, že oba registrační algoritmy pro takto pokrytý prostor skenovanými body z navrženého optického skeneru jsou schopny dosáhnout požadovaných výsledků. Na Obr. 5.12 je zobrazen stejný




**Obr. 5.12 – Detail spojení mračen bodů po registraci, (a) stěny, skříň a dveře, (b) stěny, stůl a okno**



**Obr. 5.13 – Vizuální porovnání kvality registrace, (a) ICP, (b) NDT**






**Obr. 5.14 – Výsledek registrace podlaží složený z 64 individuálních skenů s vyznačenými detaily**

detail jako na Obr. 5.10 po provedení registrace. Jednotlivá mračna jsou již korektně spojena. Obr. 5.13 ilustruje výsledek registrace pro oba algoritmy ICP a NDT. Jeho bližším prozkoumáním není vizuálně téměř patrný žádný rozdíl. Porovnání lze objektivně zhodnotit pouze podle Tab. 5.1 a parametru RMS.

V rámci posuzování kvality obou algoritmů a získání ucelených mračen bodů bylo provedeno praktické měření na Katedře elektrotechniky, v prostorách Fakulty elektrotechniky a informatiky Univerzity Pardubice a výzkumné části zvané UNIT tvořící jedno poschodí univerzitní budovy na nám. Čs. legií. Výsledné ucelené prostorové mračno bodů tvořící 1 459 825 měřicích bodů složené z 64 individuálních měření je zobrazeno na Obr. 5.14 na předchozí straně včetně detailů jeho částí označených šipkami. Rozestupy mezi jednotlivými skeny prostoru jsou přibližně 3 m. Ucelené mračno bodů bylo získáno pomocí algoritmu registrace NDT popisující prostředí podle tvarů utvářející shluky bodů, oproti ICP využívající samotné body. Během praktického testování bylo zjištěno, že použité odstupy mezi skeny prostoru způsobují algoritmu ICP problémy zapříčiněné nepřesným určením pozice skeneru, natočením měřicí hlavy a také přesností měření samotného optického skeneru viz Obr. 5.15 ilustrující pravou část chodby z Obr. 5.14. Algoritmus ICP nemá k dispozici dostatečný počet společných bodů pro dosažení požadovaného spojení.



**Obr. 5.15 – Problémy algoritmu ICP při vytváření uceleného mračna, pravá část Obr. 5.14**

Zjištěné skutečnosti dokazují robustnost algoritmu NDT i pro méně kvalitní vstupní data. Těží hlavně ze způsobu reprezentace referenčního mračna bodů pomocí modelování jeho částí shluků bodů parametry normálního rozdělení oproti uvažování samostatných bodů jako v případě algoritmu ICP.

Pro dosažení požadované kvality spojení dvou skenů prostředí je důležité zajistit dostatečný počet společných bodů. Například chodba v levé části Obr. 5.14 a místnost zobrazená v jejím detailu nemohly být připojeny do uceleného mračna algoritmem registrace z důvodu jedné společné plochy zavřených dveří. Spojení je možné, ale není zaručeno, že rotační úhel v osách  $X$  a  $Y$  bude odpovídat  $0^\circ$ . Pro dosažení kvality spojení včetně výsledné orientace mračen je důležité, aby oba skeny zkoumaného prostoru obsahovaly společné body objektů a tvarů prostředí ve všech souřadných osách.

Získané mračno bodů na Obr. 5.14 je složené z velkého množství bodů. Jeho uchování v datovém souboru s binárně zakódovanými barevnými body vyžaduje 22,2 MB diskové paměti. Při použití ASCII formátu dokonce až 90,4 MB úložného prostoru. Pro využití sestavené mapy prostředí například pro navigaci robota je zapotřebí její zjednodušení. Výslednou mapu tvoří pouze body se společným počátkem, ze kterých lze například určit vertikální rozsah mračna 109 m na šířku, ale pro další použití mapy nás zajímají spíše přítomné objekty, tvary a další parametry skenovaného prostoru než pouhé individuální body. Dalším zjednodušením, zpracováním a získáním užitečných parametrů se zabývá následující kapitola 6.

## 6 Metody zpracování mračen bodů

Body uceleného mračna bodů, získaného procesem registrace jednotlivých skenů prostředí z různých pozic, nemají mezi sebou žádnou souvislost kromě jejich společného počátku. Z jednotlivých souřadných os lze vyzorovat jejich prostorové rozmístění, ale jiné detailní informace bez dalšího zpracování nelze získat. Zpracovávané mračno navíc obsahuje velké množství nadbytečných bodů, které neobsahují žádnou užitečnou informaci a kladou zbytečné paměťové nároky na jeho uložení v paměti. Tato kapitola popisuje několik vlastních navržených nástrojů jejich zpracování, analýzy a vizualizace včetně snížení paměťové náročnosti pro jejich uložení. Získané výsledky jsou porovnány se skutečným prostředím. Z blokového schématu na Obr. 5.1, prezentovaném v kapitole 5, tato kapitola popisuje bloky z jeho pravé části seřazené pod sebou.

Na jejím začátku je prezentován algoritmus tvorby hloubkového obrazu z mračna bodů. Virtuální kameru lze umístit do libovolného místa v prostoru a rovněž si lze zvolit vlastní pozorovací úhel. Hloubkový obraz umožňuje měřit rozměry a určovat parametry obsahu a obvodu jednotlivých částí analyzovaného prostředí. Slouží zároveň jako vizualizace prostoru z pohledu virtuální kamery. Na získaný obraz lze rovněž aplikovat různé metody zpracování obrazu a změněný obraz zpět transformovat na mračno bodů.

Další část kapitoly se zabývá úrovnovým skenováním prostorových dat. Navržený algoritmus umožňuje analyzovat jednotlivé úrovně s cílem detekce ploch včetně jejich statických i prostorových parametrů. Podle koncentrace a zvolených vstupních parametrů je detekovaná úroveň prezentována pomocí vlastního navrženého nástroje nazývaného úrovnový obraz (Level Image). Jeho pixely indikují přítomnost bodů v analyzované úrovni. Pixely úrovnového obrazu zároveň obsahují informaci o hladině bodů ve skenované dimenzi, ze kterých lze vyhodnotit kvalitu detekované plochy prostřednictvím statistických vlastností rozptylu nebo směrodatné odchylky. Spojení prostorových dat s metodami zpracování obrazu nabízí široké možnosti dalšího zpracování od základních úprav detekované plochy například zacelování nežádoucích mezer, snadné určení jejího obvodu a obsahu, které může mít složité matematické řešení z důvodu členitého tvaru plochy, až po její barevnou vizualizaci. Pro zpracování úrovnového obrazu jsem navrhl i několik úprav algoritmů označování spojených komponent pro získání požadovaných údajů. Algoritmy zpracování mračen bodů jsou otestovány na datech získaných pomocí navrženého optického měřiče vzdálenosti. Výsledky jsou porovnány i se skutečným skenovaným prostředím.

### 6.1 Hloubkový obraz mračna bodů

Prvním navrženým nástrojem pro zpracování mračen bodů je hloubková mapa, jejíž obraz je jinak označován jako RGB-D. Základní princip algoritmu je prezentován v (Chmelar, 2016), jeho finální podoba prezentovaná v této kapitole byla vylepšena o použití projekční matice  $4 \times 4$  představenou v kapitole 4.5.4. Vytvořená mapa poskytuje více informací o zkoumaném prostoru a umožňuje aplikaci metod zpracování obrazu pro získání fyzických rozměrů prostředí nebo úpravu mračna bodů po zpětné transformaci.

Pro tvorbu hloubkové mapy je zapotřebí znát tři základní parametry určující její konečnou podobu. Prvním je pozice kamery  $\mathbf{P}_C$  představující bod v prostoru, ze kterého je vytvářena hloubková mapa. Je definována jako vektor (6.1), jehož složky tvoří souřadnice prostoru v příslušných osách

$$\mathbf{P}_C = (P_X, P_Y, P_C). \quad (6.1)$$

Další důležitý parametr je zorné pole kamery  $C_{FOV}$  složený z vertikálního  $V_{FOV}$  a horizontálního  $H_{FOV}$  pozorovacího úhlu.

$$C_{FOV} = \left( \frac{H_{FOV}}{2}, \frac{H_{FOV}}{2}, \frac{V_{FOV}}{2}, \frac{V_{FOV}}{2} \right) \quad (6.2)$$

Jednotlivé složky výrazu (6.2) vyjadřují horní, dolní, levé a pravé zorné pole pokrývající objektiv kamery od středu pohledu. Posledním ze základních parametrů je její orientace v prostoru  $\mathbf{C}_O$  popsaná vektorem úhlů v příslušných souřadných osách

$$C_O = (C_\alpha, C_\beta, C_\gamma). \quad (6.3)$$

Definovaná orientace umožňuje pohled do prostoru s libovolnou orientací. Kombinace všech tří parametrů (6.1), (6.2) a (6.3) umožňuje vyjádřit libovolný pohled do prostoru s libovolnou orientací a vytvořit tak hloubkový obraz podle vlastních požadavků.

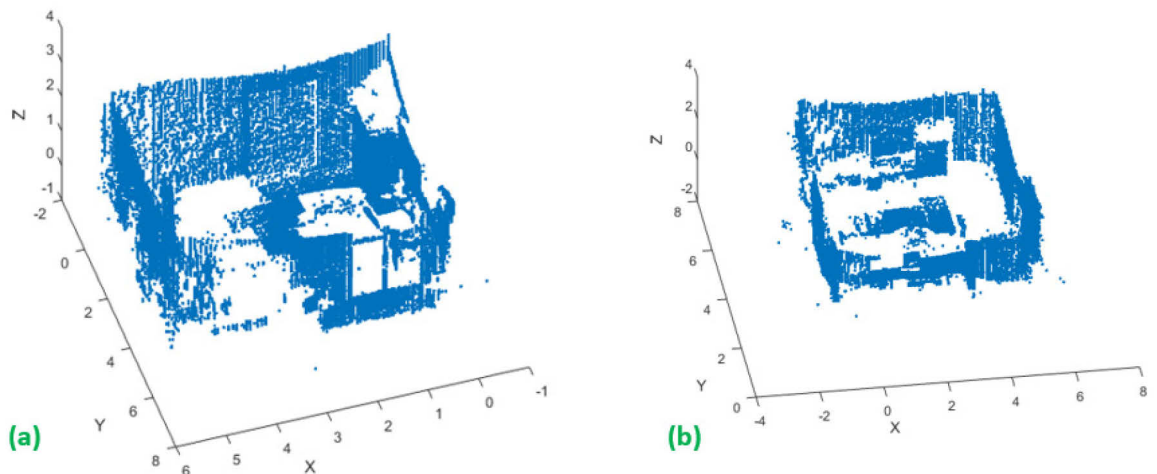
Pro popis jednotlivých kroků algoritmu jsou zapotřebí 3D rotační matice ve všech osách (4.9), (4.10) a (4.11) popsané v kapitole 4.3.2. K vyjádření zorného pole, výběru viditelných bodů virtuální kamerou a jejich transformace na rovinu hloubky je využito rovnice přímky vyjádřená pomocí úhlu

$$y = \tan(\alpha)x + b, \quad (6.4)$$

kde offset  $b$  je nula a úhel  $\tan(\alpha)$  vyjadřuje náklon přímky v jejím bodě  $x$ .

### 6.1.1 Příprava vstupního mračna bodů

Před začátkem procesu segmentace bodů podílející se na hloubkovém obrazu je zapotřebí aplikovat rotaci vstupního mračna bodů Obr. 6.1 (a) podle orientace kamery (6.3). Rotace je nutná z důvodu zachování univerzálnosti navrhovaného algoritmu. Pro ilustrační účely je zvolen rotační úhel  $\mathbf{C}_O = (0,0,90)$ . Na Obr. 6.1 (b) je zobrazeno rotované vstupní mračno bodů o  $90^\circ$  kolem osy  $Z$ . Po získání správné orientace následuje krok vytvoření pohledu hloubkového obrazu.

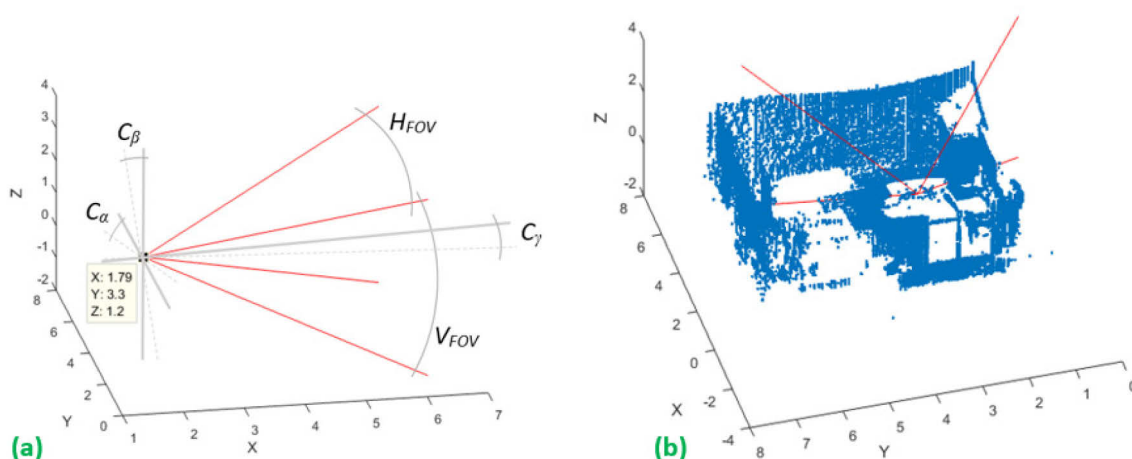


Obr. 6.1 – Změna orientace vstupního mračna bodů, (a) původní mračno, (b) rotované podle  $\mathbf{C}_O$



## 6.1.2 Konstrukce zorného pole kamery

Prvním krokem algoritmu je konstrukce zorného pole pomocí rovnice přímky (6.4) a rotačních matic v ose  $Y$  (4.10) a  $Z$  (4.11). Krok odstupů bodů tvořící přímku určuje parametr  $qL$ , ve vlastní implementaci jsem zvolil krok 1 cm. Nejprve je zapotřebí zkonstruovat zorné „V“ ze dvou přímek pod úhly  $C_{FOV}(3)$  a  $C_{FOV}(4)$  (horní a dolní zorné pole kamery) v hladině osy  $Z = 0$  s počátečním bodem v nule. Následně je vytvořené „V“ rotováno kolem osy  $Y$  o úhel  $90^\circ$  (4.10). Nakonec je vytvořené „V“ vertikálního pohledu kamery zdvojeno a každá část je rotována příslušnými úhly  $C_{FOV}(1)$  a  $C_{FOV}(2)$  do stran (pravý a levý úhel pohledu). Vytvořené zorné pole je posunuto na pozici kamery  $P_C$  Obr. 6.2 (a).

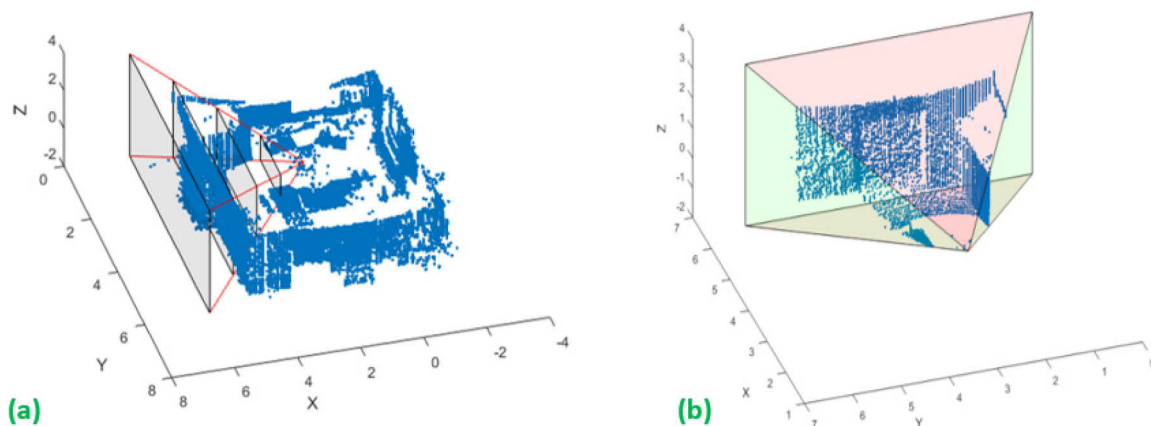


Obr. 6.2 – Vytvořené zorné pole kamery, (a) detailní pohled s popisky, (b) vyznačené v mračnu bodů

Vytvořením hranic zorného pole na Obr. 6.2 (b) lze realizovat výběr bodů ze vstupního mračna bodů vstupující do procesu tvorby hloubkového obrazu.

## 6.1.3 Segmentace bodů mračna v zorném poli

Výběr bodů přehledně ilustruje další Obr. 6.3 (a) s vyznačenými čtyřmi obdélníky. Jednotlivé šedé obdélníky znázorňují postupující fázi výběru bodů ze vstupního mračna bodů. Rovnice (6.6) popisuje výběr bodů ležících uvnitř jednotlivých šedých obdélníků označených jako  $R_{SYZ}$  (6.5). Obdélníky leží v ose  $Y$  a  $Z$  a jsou tvořeny hranicemi zorného pole sestaveného z přímek.



Obr. 6.3 – Postup segmentace bodů zorného pole, (a) segmentační obdélníky, (b) finální pohled

$$R_{SYZ}(n) = (PC(y) > R_S(n, y_{min})) \wedge (PC(y) < R_S(n, y_{max})) \wedge \Lambda \quad (6.5)$$

$$\wedge (PC(z) > R_S(n, z_{min})) \wedge (PC(z) < R_S(n, z_{max}))$$

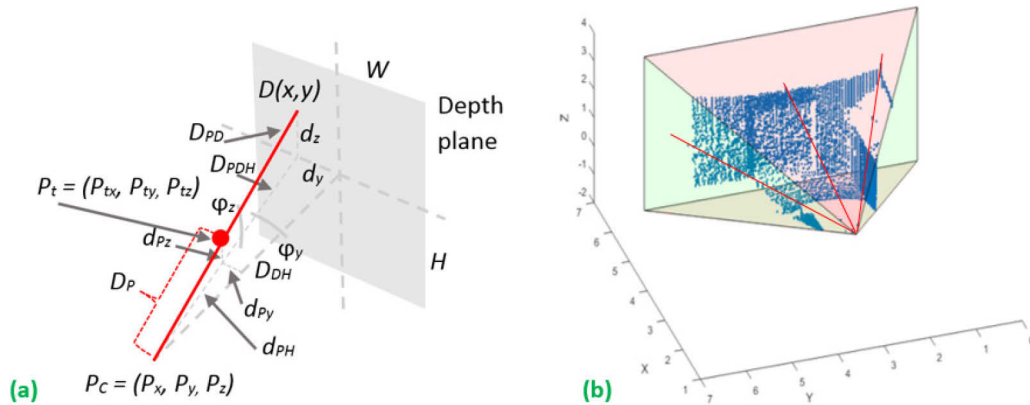
kde  $n$  je bod přímky zorného pole z celkového počtu bodů  $N_L$  a  $PC$  je vstupní mračno bodů. Hodnoty  $y$  a  $z$  představují body v příslušné souřadné ose  $Y$  a  $Z$ . Parametr  $R_S$  je segmentační obdélník a indexy  $min, max$  znamenají minimální pozici v příslušné ose a naopak. Konečná podoba segmentační rovnice pro výběr bodů vstupující do tvorby hloubkového obrazu (6.6) s využitím rovnice (6.5) má podobu

$$\bigcup_{n=1}^{N_L} PC(x) > R_S(n, x) \& R_{SYZ}(n) . \quad (6.6)$$

Poslední neznámá hodnota rovnice (6.6) je  $x$  představující body v souřadné ose  $X$ . Celý segmentační proces je logická suma všech bodů splňující podmínku (6.6), všechny body spadající do šedých obdélníků v osách  $Y$  a  $Z$  a před obdélníkem v ose  $X$ . Obr. 6.3 (b) výše znázorňuje segmentované mračno bodů s vyznačeným  $V_{FOV}$  a  $H_{FOV}$  rozdílnými barvami.

#### 6.1.4 Transformace bodu na rovinu hloubky

Posledním bodem tvorby hloubkové mapy je transformace jednotlivých bodů na rovinu hloubky. Obr. 6.4 (b) je ilustrace transformace bodů, kde jsou znázorněny na ukázkou 3 červené projekční přímky. Každý bod ze zorného pole musí být transformován na rovinu hloubky. Detailní schéma transformace popisuje Obr. 6.4 (a) s vyznačenými hlavními parametry transformace.



Obr. 6.4 – Transformace bodu na rovinu hloubky, (a) detail transformace, (b) transformační přímky

Parametry vzdáleností označené velkými písmeny na Obr. 6.4 (a) znamenají přímou vzdálenost k rovině hloubky, parametry značené malými písmeny jsou rozdíly mezi dvěma body. Parametry transformace bodu jsou následující:  $D(x, y)$  je pozice transformačního bodu  $P_t$  hloubkovém obraze na souřadnicích  $x, y$ ;  $D_P$  je přímá vzdálenost roviny hloubky od pozice kamery  $P_C$ ;  $d_y$  a  $d_z$  jsou offsety vzdálenosti od středu roviny hloubky v příslušných osách a úhly  $\phi_y$   $\phi_z$  vyjadřují orientaci transformační přímky. Pozice kamery  $P_C$ , vlastní bod  $P_t$  a jeho transformační přímka utvářejí dva trojúhelníky,  $D_P, d_{PZ}$  a  $d_{PH}$  jsou vrcholy trojúhelníku bodu. Pozice  $D_{PD}, d_z$  a  $D_{PDH}$  zastupují trojúhelník k rovině hloubky. Parametry  $W$  a  $H$  jsou rozlišení hloubkového obrazu.

Fyzikální rozměry roviny hloubky popisuje poslední největší šedý obdélník v řadě na Obr. 6.3 (a). Rozlišení hloubkového obrazu je možné nastavit parametrem  $qDM$  vyjadřující kvantizaci souřadnic vstupního mračna bodů nebo při volbě vlastního rozlišení hloubkového obrazu lze odvodit parametr  $qDM$  z rozlišení. Pro testovací účely jsem použil rozlišení kamery 2590 x 1942 pixelů, jež odpovídá kvantizaci vstupního mračna bodů z Obr. 6.4 (b) ve výšce  $qDMh = 2,3 \text{ mm}$  a  $qDMw = 2,1 \text{ mm}$  v šířce.

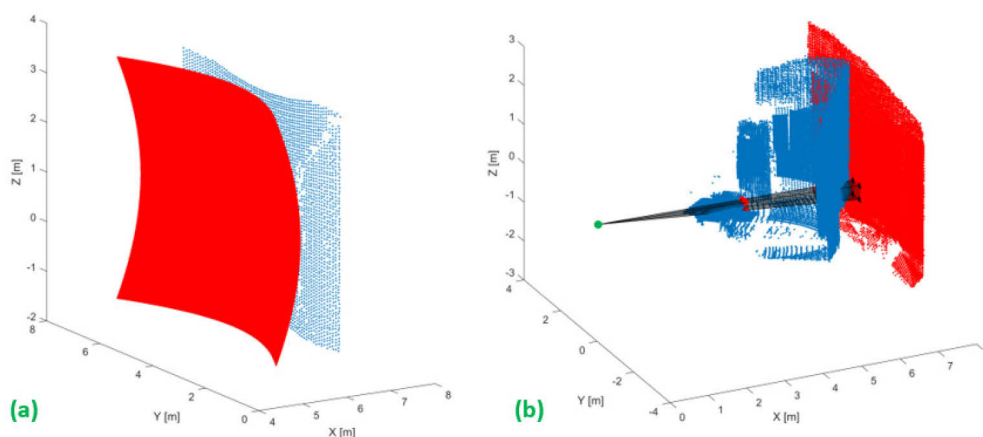
Přímá vzdálenost k rovině hloubky  $D_{DH}$  je známá z rozsahu dat na ose  $X$  a pozice kamery. Hodnoty  $d_{pz}$  a  $d_{py}$  jsou získány rozdílem vektorů  $\mathbf{P}_t$  a  $\mathbf{P}_c$ . Vzdálenost  $D_p$  od pozice kamery do bodu je norma rozdílu vektorů  $\mathbf{P}_t$  a  $\mathbf{P}_c$

$$D_p = \sqrt{\sum |\mathbf{P}_t - \mathbf{P}_c|} \quad (6.7)$$

Úhly  $\varphi_y$  a  $\varphi_z$  jsou vyjádřeny goniometrickými funkcemi. Ze známých parametrů je určen náklon červené projekční přímky a stanovena vzdálenost  $D_{PDH}$ . Postupně získané parametry umožní určení souřadnic bodu  $D(x, y)$  umístěného na rovině hloubky. Proces se opakuje pro všechny body vstupního mračna. V případě, že některý pixel hloubkového obrazu je již obsazen použije se bližší vzdálenost z důvodu stínění bližšími body.

Intenzita pixelu hloubkového obrazu odpovídá přímé vzdálenosti bodu  $D_p$  od pozice kamery kvantované hloubkou 16 bitů. Maximální intenzita  $2^{16}$  odpovídá hodnotě měřicího rozsahu 15 m.

Osovou vzdálenost bodů je možné určit přímo z jejich pozice v prostoru a lze ji zanést snadno do výstupního obrazu, hlavním cílem je ale tvorba pohledu přímo z pozice kamery, kde každý bod vytváří projekci na rovinu hloubky, jako je znázorněno na Obr. 6.4 (b). Pro zachování konzistence hloubkového obrazu a mračna bodů v případě zpětné transformace je zapotřebí ještě uvažovat zakřivení ve tvaru koule při přímém pohledu viz Obr. 6.5 (a). Při tvorbě hloubkového obrazu se musí rozdílová vzdálenost přičíst a při zpětné transformaci naopak odečíst. Mračno bodů složených z více jednotlivých skenů po procesu registrace obvykle obsahuje body, které mohou být zakryty jinými objekty, jako jsou přítomné stoly nebo skříně, rovněž i části snímané scény mohou zakrývat jiné. Při tvorbě hloubkového obrazu je důležité tyto body potlačit. V představeném algoritmu používám pro potlačení těchto bodů stejný princip techniky Z-bufferu, jako využívá počítačová grafika při tvorbě



Obr. 6.5 – Problémy tvorby hloubkové mapy, (a) zakřivení pohledu, (b) stínění bodů


3D scény (Wyman, 2016). Předtím než je objekt renderován do výstupního obrazu Z-buffer zajistí, aby zakryté body scény z pohledu kamery nebyly zobrazeny. Z-buffer je obecně také hloubkový obraz. Podle použité velikosti pixelu je promítaný bod reálně nahrazen čtvercem

nebo obdélníkem o jeho rozměru, ten je poté promítán na rovinu hloubkového obrazu a ta část, kterou projekce zastíní je odstraněna, jako je v patřičném zvětšení ilustrováno na Obr. 6.5 (b).

Popsaný princip projekce bodu na rovinu hloubky představený v (Chmelar, 2016) byl nahrazen perspektivní projekcí prostřednictvím matice 4 x 4 představenou v kapitole 4.5.4. Transformace zachovává odpovídající velikost předmětu vzhledem k bodu projekce. Její použití usnadnilo transformaci bodu na rovinu hloubky a zejména umožnila odpovídající stínění skrytých bodů podle vzdálenosti bodu od pozice kamery.

### 6.1.5 Výsledný hloubkový obraz


Při nízké hodnotě rozlišení hloubkové mapy *qDM* mohou v cílovém obrazu vznikat nespojitosti při menší hustotě mračna bodů. Z tohoto důvodu je vhodná aplikace morfologických operátorů. Operátor dilatace způsobí roztažení přítomných pixelů a dojde k zacelení mezer. Ve výsledných obrazech na Obr. 6.6 (a) a Obr. 6.6 (b) je použita operace dilatace elementem o velikosti 30. Pomocí hloubkového obrazu je možné při znalosti jeho rozlišení měřit také přibližné rozměry prostředí v pozadí obrazu, blízko roviny hloubky.



Obr. 6.6 – Ukázka hloubkových obrazů, (a) včetně měření vzdálenosti, (b) s rotací  $-40^\circ$  v ose Z

## 6.2 Modifikované algoritmy hledání spojených komponent

Některé algoritmy použité v této dizertační práci, například hledání optimálního parametru korekce barelového zkreslení v kapitole 3.2.2 nebo metoda určení správné orientace mračna bodů prezentovaná v kapitole 5.1.2, rovněž i některé postupy z této kapitoly vyžadují použití modifikovaného algoritmu spojených komponent s uvažováním výskytu blízkých elementů. Pro jejich další zpracování je zapotřebí znát i přesné pozice okrajů. Obr. 6.7 ilustruje principiální schémata hledání sousedních pixelů prezentovaných




Obr. 6.7 – Hledání sousedních pixelů, (a) pro blízké elementy, (b) směr hledání okrajů elementů

algoritmů. V této části kapitoly popíší jejich princip funkce. Obecně mají obě metody široké použití ne jen pro potřeby této problematiky.

### 6.2.1 Hledání spojených komponent s výskytem mezer

Pro účely objektivní analýzy průběhů signálu a práci s binárními obrazy jakým je i úrovnový obraz prezentovaný v kapitole 6.4 jsem modifikoval algoritmus spojených komponent pro analýzu blízkých sousedních elementů. V případech, kdy dvě i více sousedících komponent jsou od sebe menší vzdálenost než definovaný parametr  $iz$  jsou sousedící elementy propojeny a považovány za jeden větší element. Počty spojení 4 a 8 zůstaly stejné a v okolí pixelu s nenulovou hodnotou je hledán výskyt sousedního pixelu po směru hodinových ručiček, jako je ilustrováno na Obr. 6.7 (a).

Algoritmus začíná hledat první nenulový pixel z levého horního rohu v případě binárního 2D obrazu. V případě, nalezení pixelu je prohledáno jeho okolí podle směru, naznačeném na Obr. 6.7 (a). Všechny pozice nově nalezených spojených pixelů jsou uchovány pro další prohledávání. Detekované spojené pixely v aktuální smyčce jsou označeny společným indexem elementu  $Ie$  začínající hodnotou 1. Indexy jsou uchovány ve formě obrazu  $L$ . Je-li nalezen alespoň jeden nenulový pixel v přímé vzdálenosti menší rovno  $iz$  vznikne spojení mezi těmito pixely doplněním přímé vzdálenosti k novému pixelu hodnotou indexu elementu. V případě, že není nalezen další spojený pixel ani potenciaální sousední pixel ve vzdálenosti  $iz$  je celý element s indexem  $Ie$  nalezen a zvýší se index  $Ie$  o jedničku a ve zbývající části obrazu jsou hledány další elementy stejným způsobem, dokud nejsou nalezeny všechny elementy nebo nejsou prohledány všechny pozice vstupního obrazu. Výstup navrženého algoritmu ilustruje Obr. 6.8 zahrnující pro srovnání i klasickou variantu spojení 4 uvažující vertikální a horizontální směr Obr. 6.8 (a) a 8 zahrnující i diagonální směry Obr. 6.8 (b) bez uvážení spojení sousedních elementů.



Obr. 6.8 – Výstup modifikovaného algoritmu spojených komponent, (a) spojení 4, (b) spojení 8, (c) spojení 4 s  $iz = 1$ , (d) spojení 8 s  $iz = 1$

U navržené implementace je možné volit směr procházení vstupního obrazu po sloupcích nebo po řádcích. V případě Obr. 6.8 je obraz prohledáván po sloupcích zleva. Indexy na Obr. 6.8 (a) a (b) mají očekávané hodnoty a v případě použití varianty spojení 4 s ignorováním jedné nuly Obr. 6.8 (c) je prostřední element spojen s pravým dolním doplněním mezery v přímém směru mezi nimi. V případě spojení 8 Obr. 6.8 (d) jsou všechny elementy navzájem propojeny v odpovídajících směrech. Implementoval jsem i variantu pro 3D prostor podporující spojení 6, 18 a 26, ale nakonec v práci použita nebyla, jelikož pro požadovanou detekci hladin popisující přítomné roviny je vhodnější použít algoritmus úrovnového hledání spojených komponent LCCL speciálně navržený pro tento účel.

Popsaná modifikace algoritmu hledání spojených komponent je vhodná zejména pro analýzu průběhů signálu s výskytem blízkých extrémních hodnot, jako je akumulátor Houghovy transformace viz kapitola 3.2.2 nebo histogram pro hledání natočení mračna bodů v kapitole 5.1.2. Při použití klasické varianty navržené postupy hledání optimálních parametrů často selhávaly z důvodu detekce dvou blízkých rozdílných hodnot maxim, i když v průběhu bylo přítomno pouze jedno reálné maximum. Při práci s binárními 2D obrazy, jako například dále v této kapitole, je možné detekovat blízké elementy jako jeden, kde ve skutečnosti oba elementy popisují jeden objekt, ale pouze mohou chybět některá měřicí data.

## 6.2.2 Hledání pozic hrany elementu

Z analýzy spojených komponent je získán binární obraz s vyznačenými indexy jednotlivých elementů a jejich celkovým počtem. Zjištění prostorových parametrů vyžaduje jejich další zpracování. Například pro vizualizaci plochy pomocí úrovnového obrazu prezentovanou v kapitole 6.8 potřebuji zjistit přesné souřadnice hranic objektu, podle kterých je zakreslena celá plocha. K přesnému určení obvodu plochy v kapitole 6.5 potřebuji znát počet pixelů hrany a navíc detekovat směr vyhledávání hranice obvodu plochy zastoupené úrovnovým obrazem. Algoritmus byl poprvé představen v (Chmelar, 2018a).

Pro získání binárních hranic elementu obrazu jsem navrhl algoritmus využívající směru hledání sousedního pixelu podle Obr. 6.7 (b) a následujícího postupu. Na element je aplikována binární eroze morfologickým elementem „disk“ o velikosti 1, která způsobí jeho zúžení po obvodu o 1 pixel. Od původního elementu  $I_L E$  je binárně odečten element s erozí  $I_L E_E$  podle vztahu

$$I_L E_B = I_L E - I_L E_E . \quad (6.8)$$

Vstupní element je zobrazen na Obr. 6.9 (a) a výsledný obraz Obr. 6.9 (b) po aplikaci vztahu (6.8).




Obr. 6.9 – Získání hran elementu, (a) vstupní obraz, (b) jeho hrany

Pozice extrahovaných hranic analyzovaného elementu  $I_L E_B$  vstupují jako parametr do navržené funkce „ElementBorderPositions“ jejíž pseudokód je uveden na Obr. 9.5. Základem algoritmu získání souřadnic hranice elementu je upravený způsob hledání sousedního pixelu naznačený na Obr. 6.7 (b) a přerušení hledání dalšího při nalezení alespoň jednoho sousedního pixelu ve směru hledání.

Proces hledání pozic hranic elementu začíná v levém horním rohu obrazu a postupuje se po řádcích. Při výskytu nenulového pixelu je zaznamenána jeho pozice do pole  $E_B$  a hledá se další nenulový pixel ve směru hodinových ručiček na Obr. 6.7 (b). Je-li pixel nalezen, rovněž se poznamená jeho pozice do pole  $E_B$  a další prohledávání nenulových pixelů se přeruší. V dalším cyklu se z této pozice hledají další nenulové pixely stejným principem, dokud nejsou vyhledány všechny nenulové pozice hranice elementu. V tomto bodě algoritmus končí, všechny pozice hranice zkoumaného elementu jsou nalezeny.



V pseudokódu se vyskytuje index hranice elementu  $elidx$  a navíc algoritmus nabízí získat i záznam směru hledaných pixelů okraje označené jako  $dir_{EB}$ , který je užitečný pro další zpracování a získávání parametrů detekované plochy úrovněm obrazem. Znalost směru je důležitá i pro snížení paměťových nároků pro uchování detekovaných ploch. Znázornění pozic hranice prostřednictvím červené barvy ze vstupního obrazu uvedeného na Obr. 6.9 (a) je na dalším Obr. 6.10 (a).



Obr. 6.10 – Detekce hranice elementu, (a) výstupní hranice vyznačená červeně, (b) typická situace, při hledání hranic

Na Obr. 6.10 (b) je znázorněna typická situace výskytu hranice označená červeným (a). Pixely detekované hranice v (b) a (c) jsou označeny indexem 1. Varianty (b) a (c) závisí na zvoleném typu elementu eroze v (6.8). Požadovanou detekci v diagonálním směru (c) jsem dosáhl použitím morfologického elementu typu „disk“. Informace o pozici hranice elementu je již k dispozici ve vstupním obraze  $I_{LEB}$  na Obr. 6.9 (b), ale není zaručeno její správné pořadí. Navržený algoritmus poskytuje její pořadí seřazené po směru hodinových ručiček včetně informace o směru nalezených pixelů, důležité pro další zpracování.

### 6.3 Detekce ploch úrovněm skenováním prostoru

Hlubkový obraz prezentovaný v kapitole 6.1 umožnil kvantováním fyzických prostorových dat zanechat jejich podobu do formy obrazu, který lze dále modifikovat a zpracovávat dostupnými metodami zpracování obrazu. Jeho plocha navíc v sobě nese zároveň prostorové informace o kvalitě a struktuře zastoupeného povrchu. Hlubkový obraz vyjadřuje vzdálenost k objektům a prostředí pozorované scény formou jasu obrazu. Jednotlivé objekty je zapotřebí od sebe separovat a pro detekci základních struktur prostoru, jako jsou plochy, není příliš vhodný i z důvodu stínění částí přítomnými objekty. Koncept kvantování prostoru a jeho modelování obrazem je výhodné pro další zpracování, jak ukazují následující kapitoly. Pomocí něho lze snadno určovat prostorové vlastnosti zkoumaného prostředí, barevně ho vizualizovat a rovněž zjednodušovat jeho popis. Pro hledání ploch a jejich parametrizaci jsem navrhl následující algoritmus jeho skenování.

Klasický algoritmus označování spojených komponent uvažuje jedinou úroveň. Hledá jednotlivé elementy ve vstupním binárním obraze a vrací jejich počet s indexy výskytu. Pro potřeby analýzy mračna bodů a detekci jeho ploch jsem navrhl algoritmus úrovněm označování spojených komponent LCCL umožňující zkoumat jeho jednotlivé úrovně a určit odpovídající statistické parametry. Navržený algoritmus je široce aplikovatelný nejen pro prostorová data, jako jsou mračna bodů a lze ho aplikovat například i na obraz, kde skenovanou dimenzí je intenzita jasu. Algoritmus v obecné formě je prezentovaný v (Chmelar, 2018b). Je založen na postupném procházení jednotlivých úrovní podle definovaných parametrů a jejich značení společnými indexy.



Pseudokód algoritmu je naznačen na Obr. 9.7. Vstupní analyzovaná data jsou algoritmu předána jako matice  $X_L$ . Proces začíná stanovením rozsahu dat ve zpracovávané dimenzi  $dim_s$  nalezením její minimální  $minT$  a maximální hodnoty  $maxT$ . Důležitými vstupními parametry jsou  $lvlS$  a  $lvlRS$  označující maximální možnou odchylku od hladiny úrovně a násobek odchylky  $lvlS$  vyjadřující rozsah hledání další úrovně respektive. Algoritmus v každém svém kroku využívá hodnoty rozsahu hledání úrovně  $downT$  a  $upT$ . Pro první krok je hodnota  $downT$  stanovena jako minimální hodnota analyzovaných dat  $downT = \min(X_L(\forall, dim_s))$  ve skenované dimenzi  $dim_s$ . Hodnota  $upT$  je v každém kroku určena vztahem

$$upT = downT + lvlS \cdot lvlRS . \quad (6.9)$$

Algoritmus poté podle funkce „globalLvlStep“ prohledává jednotlivé úrovně, dokud nedosáhne hodnoty  $maxT$ . Rozsah dat  $lvlX_L$  spadající do analyzované úrovně je vyjádřen jako

$$lvlX_L = (X_L(\forall, dim_s) \geq downT) \wedge (X_L(\forall, dim_s) \leq upT) . \quad (6.10)$$

V každém kroku je sestaven histogram rozsahu zkoumané úrovně  $h_{lvl}$  a maximální bodová koncentrace ve skenované dimenzi  $dim_s$  je zvolena jako nalezená úroveň  $dL$ . Konečný výběr dat tvořící nalezenou úroveň je určen pomocí parametru maximální požadované odchylky  $lvlS$  jako


$$X_L lvlR = X_L(\forall, dim_s) \geq (dL - lvlS) \wedge X_L(\forall, dim_s) \leq (dL + lvlS) . \quad (6.11)$$

Po určení úrovně v  $n$ -tém kroku je jako nové minimum  $downT$  pro dalšího kroku algoritmu ( $n + 1$ ) stanoveno následovně

$$downT = dL + lvlS \quad (6.12)$$

a hodnota  $upT$  je znovu určena podle vztahu (6.9).

Vhodnou kombinací parametrů rovnic (6.9) a (6.12) je docíleno rovnoměrné rozložení úrovní ve vstupních datech  $X_L$  podle jejich koncentrace v analyzované dimenzi. Po získání rozsahu  $X_L lvlR$  je vybraným bodům přiřazen odpovídající index úrovně  $idxL$  a jsou určeny statistické parametry úrovně  $L_{stat}$  ve všech souřadných osách popisující její kvalitu. Mezi vybrané parametry patří:  $\mu$  průměrná hodnota;  $\sigma^2$  rozptyl;  $\sigma$  standardní odchylka a  $\hat{x}$  modus. Aktuální krok algoritmu končí a zvýší se hodnota počtu nalezených úrovní  $numL$  a aktuální index úrovně  $idxL$ . Pomocí rovnic (6.9) a (6.12) je určen nový rozsah prohledávání a popsany postup se opakuje. Na Obr. 6.11 je uveden příklad odhadu první úrovně v souřadné ose  $Z$ .




Obr. 6.11 – Odhad první úrovně v ose  $Z$ , (a) vizualizace rozsahu šedivými plochami a zvýrazněná detekovaná hladina červenou plochou, (b) histogram výskytu bodů v  $dim_s$  s vyznačeným maximem

Zejména při nevhodně zvoleném parametru  $lvlS$  (příliš malém) s ohledem na vstupní data může docházet ke generaci dvojité plochy. Z praktického testování vyplynulo doporučení volit parametr  $lvlS$  raději větší, než je od vstupních dat očekáváno. Optimální rozsah úrovně stanoví další zpracování uvedené níže.

V první implementaci algoritmu v (Chmelar, 2017b) jsem pro odhad úrovně využíval průměr souřadnic bodů ve skenované ose  $dim_s$ . Průměr úrovně  $\overline{lvlX_L}$  je vyznačen oranžovým bodem na ose v Obr. 6.11 (b). Jako nejlepší odhad výskytu detekované plochy na základě předpokladu maximální koncentrace bodů v ploše ve skenované dimenzi je hodnota maxima histogramu rozsahu aktuálního výběru dat podle (6.10) definovaná jako  $max(h_{lvl}(lvlX_L))$ . Rozsah bodů plochy udává parametr  $\pm lvlS$ .

Detekovaná plocha v analyzované úrovni je prezentována pomocí navrženého nástroje zvaného úrovněvý obraz LI, který vyjadřuje přítomnost bodů v úrovni jejich kvantizací pozic ve zbylých souřadných osách. Výsledný LI z Obr. 6.11 včetně zacelení mezer morfologickým uzavřením je zobrazen na Obr. 6.12.



Obr. 6.12 – Úrovněvý obraz, (a) obraz odpovídající detekované úrovni z Obr. 6.11 (a), (b) maska po zacelení operací morfologického uzavření

Úrovněvý obraz je přímá analogie k hloubkovému obrazu prezentovaného v kapitole 6.1 s rozdílem, že úrovněvý obraz je tvořen z určité úrovně mračna bodů ve zvolené souřadné ose. Oproti tomu hloubkový obraz je vytvářen z celého rozsahu mračna bodů v této ose od pozice virtuální kamery v prostoru. Výsledný tvar na Obr. 6.12 (a) byl získán kvantováním pozic bodů  $qD = 0,05 m$ . Bližší popis úrovněvého obrazu je uveden v další kapitole 6.4. Vyjádření plochy pomocí obrazových dat nabízí použití metod zpracování obrazu pro získání dalších důležitých parametrů analyzovaného prostoru. Možnosti dalšího zpracování jsou popsány v následujících kapitolách.

V Tab. 6.1 jsou uvedeny zjištěné parametry pro analyzovanou úroveň zastoupenou úrovněvým obrazem na Obr. 6.12 (b).


Tab. 6.1 – Parametry detekované úrovně z Obr. 6.11

$dL [m]$	$Angle [^\circ]$	$N_{px}$	$N_{mp}$	$\sigma [m]$
-0.005	[0, 0, 0]	3664	2761	0.0396

Parametr  $Angle$  značí úhel orientace detekované plochy, hodnota  $N_{px}$  vyjadřuje počet nenulových pixelů zaceleného úrovněvého obrazu Obr. 6.12 (b) a  $N_{mp}$  je počet skutečných bodů tvořící plochu a  $\sigma$  je standardní odchylka prostorových bodů tvořící detekovanou úroveň.

Z porovnání hodnot  $N_{px}$  a  $N_{mp}$  je patrný větší počet bodů úrovněvého obrazu. Z toho vyplývá, že zacelením mezer úrovněvého obrazu morfologickým uzavřením je možné rekonstruovat plochu zpět na jednotlivé body a zvýšit tak hustotu bodů popisujících plochu.

Při práci s úrovnovým obrazem mohou jednotlivé úrovně tvořit nespojité plochy, jako v případě modelové úrovně na Obr. 6.13.



**Obr. 6.13 – Modelový příklad výskytu nespojitých ploch v mračnu bodů, (a) mračno bodů, (b) odpovídající úrovnový obraz bez dalších úprav s vyznačenými indexy ploch**

Pro analýzu jednotlivých elementů lze v detekované úrovni využít skupinu algoritmů označování spojených komponent pro binární obraz, jako například modifikovanou variantu uvedenou v kapitole 6.2.1. Jednotlivé plochy je poté možné rozlišovat podle jejich velikosti a statistických parametrů.

Prezentovaný algoritmus LCCL má široké využití od analýzy obrazových dat, až po hledání úrovní v rozsáhlých prostorových datech. Jeho nevýhodou je závislost na výchozí orientaci mračna bodů, kterou lze eliminovat například korekcí popsanou v kapitole 5.1.2. V případě známé orientace lze jeho třemi průchody rychle analyzovat všechny úrovně ve všech souřadných osách. Při neznámé orientaci je zapotřebí použít přístup prezentovaný v (Chmelar, 2017b) a vstupní mračno postupně rotovat pro nalezení všech požadovaných ploch.

### 6.3.1 Zpřesnění odhadu plochy


Získaný rozsah kolem detekované úrovně  $dL$  na Obr. 6.11 obsahuje body hledané roviny, ale vlivem volby parametru  $lvlS$  se v něm mohou vyskytnout i odlehlé body, které s ní přímo nesouvisí a ovlivňují statistické parametry detekované plochy. Z tohoto důvodu je zapotřebí její rozsah zpřesnit.

Jak již bylo uvedeno největší koncentrace bodů roviny je ve stanovené hladině  $dL$ . V případě, že platí následující poměr

$$\frac{\overline{h_{lvl}}}{\max(h_{lvl})} \leq r_{lvl} , \quad (6.13)$$

kde  $r_{lvl}$  je zvolený poměr hodnoty histogramu  $\overline{h_{lvl}}$  a jeho maxima  $\max(h_{lvl})$ , je hladina dále analyzována pro zpřesnění odlehlých bodů roviny. Situaci znázorňuje další Obr. 6.14 (a) na následující straně, kde je ukázán histogram první úrovně z Obr. 6.11. Jako vhodnou hodnotu poměru  $r_{lvl}$  jsem z testování zvolil 45%.

Modrý průběh četnosti výskytu bodů kolem detekované hladiny  $dL$  v souřadné ose skenování  $dim_s$  na Obr. 6.14 (a) se jeví jako zašuměn a je zapotřebí filtrovat. Pro filtraci a další zpracování průběhu histogramu jsem zavedl krok derivace  $ds$ . Zelená čára na Obr. 6.14 (b) je filtr plovoucího průměru  $mAh_{lvl}$  o velikosti okna  $2ds$  aplikovaný na histogram  $h_{lvl}$ . V případě Obr. 6.14 (b) je parametr  $ds = 1 \text{ cm}$ . Z průběhu  $mAh_{lvl}$  je patrné maximum na pozici  $max_{idx}$  a po obou jeho stranách se hodnota strmě snižuje až k hladině četnosti okolo 10. Od tohoto zlomu se průběh pohybuje okolo střední hodnoty histogramu.



Obr. 6.14 – Detail histogramu hledané úrovně, (a) histogram v ose Z, (b) nalezený optimální rozsah

Detekovaná plocha je zastoupena maximem histogramu výskytu bodů a místy, kdy četnost přechází ve střední hodnotu četnosti výskytu bodů vybraného rozsahu úrovně. Požadavkem pro zpřesnění rozsahu plochy je automatizované určení těchto „kolen“ přechodu. Pro zpřesnění rozsahu jsem navrhl metodu „finePlaneRange“ na Obr. 9.7 sledující hodnotu derivace  $\Delta h_{lvl} / \Delta ds$  posouváním okna o velikosti  $ds$  od maxima na obě strany a finálního zpřesnění pozice sledováním poměru hodnot plovoucího průměru  $mAh_{lvl}$ . V první fázi je sledovaná hodnota derivace

$$\frac{\Delta h_{lvl}}{\Delta ds} = \frac{mAh_{lvl}(max_{idx} \pm ds \cdot nL) - mAh_{lvl}(max_{idx} \pm ds \cdot (nL + 1))}{ds}, \quad (6.14)$$


kde znaménko  $\pm$  označuje stranu sledování derivace  $\Delta h_{lvl} / \Delta ds$  a index  $nL$  pravé strany  $nL \in [1, 2, \dots, max_{idx} + n \cdot ds \leq Nh_{lvl}]$  a levé  $nL \in [1, 2, \dots, max_{idx} + n \cdot ds \geq 1]$ . Hodnota  $Nh_{lvl}$  je počet četností histogramu. Derivační okno  $ds$  je posouváno od maxima histogramu na obě strany a sleduje se hodnota derivace, než klesne pod hodnotu 25% derivačního kroku  $ds$

$$\frac{\Delta h_{lvl}}{\Delta ds} < 0,25. \quad (6.15)$$

Pro zpřesnění pozice algoritmus postupuje dále bodově pomocí dalšího indexu  $mL$  od posledního nalezeného místa  $ds \cdot nL$  a kontroluje se poměr hodnot histogramu, než klesne pod požadovanou úroveň  $v_{diff}$  následovně

$$\frac{mAh_{lvl}(max_{idx} \pm ds \cdot nL + 0,5ds + mL)}{mAh_{lvl}(max_{idx} \pm ds \cdot nL + mL)} \leq v_{diff}. \quad (6.16)$$

Hodnota poloviny derivačního kroku  $0,5ds$  zajišťuje offset mezi porovnávanými hodnotami a index  $mL \in [0, 1, \dots, ds]$ . V případě, že není nalezena očekávaná hodnota podle (6.16) algoritmus končí hledání a konečná hodnota nalezeného přechodu se nachází na indexu  $mAh_{lvl}(max_{idx} \pm ds \cdot (nL + 1))$ . Na Obr. 6.14 (b) jsou červenými body vyznačeny hledané pozice přechodu červenými body. Odpovídající zpřesnění rozsahu plochy je ilustrováno na skutečném mračnu bodů v Obr. 6.15 (b).



Obr. 6.15 – Zpřesnění rozsahu detekované plochy, (a) původní rozsah odpovídající Obr. 6.14 (a), (b) upravený podle červených bodů na Obr. 6.14 (b)

Z analýzy Obr. 6.15 (a) jsou patrné přítomné body ploch stěn ze souřadných os  $X$  a  $Y$ . Po jejich odstranění na Obr. 6.15 (b) zůstávají pouze body detekované plochy.

## 6.4 Úrovňový obraz

Je vlastním navrženým nástrojem pro zpracování a vizualizaci mračen bodů. Označuje se jako LI nebo častěji  $I_L$ . Slouží pro další zpracování výstupu procesu prostorového skenování úrovní popsaném v kapitole 6.3. Základní koncept úrovňového obrazu a jeho použití je rozpracován v publikacích (Chmelar, 2017b), (Chmelar, 2018a) a (Chmelar, 2018b) V analyzovaném mračnu indikuje přítomnost bodů na určité pozici v prostoru. Obraz úrovně se dále využívá pro vizualizaci ploch mračen bodů popsané v kapitole 6.8. Při vytváření je uložena jeho počáteční pozice v prostoru a úhel vůči počátku analyzovaného mračna bodů. Znalostí parametru  $qD$ , kterými jsou kvantovány body plochy ve zbylých dvou souřadnicích, lze snadno vizuálně prezentovat zkoumanou scénu. Znalost fyzikální velikosti jednoho pixelu nabízí mnoho dalších výhod. Při jeho úpravě a analýze metodami zpracování obrazu lze získat několik užitečných parametrů popisující detekovanou plochu, jako je její obsah, obvod nebo celkový plošný rozsah včetně mezer vzniklých například nedokonalostí skenovacího zařízení viz kapitola 6.5, 6.7 a 6.8.

### 6.4.1 Tvorba úrovňového obrazu

Cílem jeho konstrukce je znázornit prostřednictvím kvantovacího parametru  $qD$  obsazenost plochy tvořené analyzovanými body v určité úrovni  $dL$  zkoumaného mračna získanou procesem skenování úrovní LCCL. Navržený algoritmus tvorby úrovňového obrazu je uveden prostřednictvím pseudokódu na Obr. 9.6.

Na jeho začátku je zapotřebí zvolit dimenzi, ze které bude obraz tvořen. Z algoritmu skenování úrovní LCCL aplikovaného před tímto procesem je dimenze předána parametrem  $dim_s$ . Z celkového mračna bodů je vybrána pouze jeho část pomocí indexu úrovně  $idxL$  vstupující jako parametr  $PC$  do funkce „PC2ImageLevel“. Prvním krokem algoritmu je zjištění rozsahu vstupní části  $PC$  ve všech osách označené indexem  $A$  podle vztahu

$$R_A = [\min(PC(\forall, A)), \max(PC(\forall, A))] . \quad (6.17)$$

Zvolená skenovací dimenze je z pohledu tvorby úrovňového obrazu osou  $Z$ . Pozice bodů zbylých dvou dimenzí tvoří souřadnice  $X$  a  $Y$  úrovňového obrazu. V případě analýzy úrovní v ose  $Z$  je osou obrazu  $X$  souřadnicová osa  $Y$  a opačně. Je-li například skenována úroveň v ose  $X$ , tak pro vytváření obrazu se stává osou  $Z$ . Jeho souřadnice  $X$  je zastoupena osou  $Z$ . Osa  $Y$  zůstává stejná. Obdobná situace přeznačení souřadných os odpovídajícím způsobem platí i pro osu  $Y$  zvolenou pro skenování úrovní. Ve vývojovém diagramu na Obr. 9.6 jsou osy  $X$ ,  $Y$  a  $Z$  chápány v uvedeném smyslu popsání přeznačení, a proto je u nich použit index  $I_L$ .



Ze zjištěného rozsahu  $R$  podle rovnice (6.17) v jednotlivých souřadných osách jsou vyjádřeny rozměry  $I_L$  podle kvantovacího parametru  $qD$  následovně

$$H_{X_{I_L}} = \frac{R_{X_{I_L}}(2) - R_{X_{I_L}}(1)}{qD}, \quad W_{Y_{I_L}} = \frac{R_{Y_{I_L}}(2) - R_{Y_{I_L}}(1)}{qD}, \quad (6.18)$$

kde  $H$  je výška a  $W$  šířka úrovně obrazu. Obě hodnoty jsou následně použity k zjištění odpovídající pozice skutečného bodu v obraze  $I_{L_x}$  a  $I_{L_y}$  podle vztahu

$$I_{L_x} = H_{X_{I_L}} - \frac{R_{X_{I_L}}(2) - PC(\forall, X_{I_L})}{qD}, \quad I_{L_y} = W_{Y_{I_L}} - \frac{R_{Y_{I_L}}(2) - PC(\forall, Y_{I_L})}{qD}. \quad (6.19)$$

Ve vzniklých vektorech  $I_{L_x}$  a  $I_{L_y}$  jsou uloženy souřadnice všech bodů úrovně obrazu. Jednomu pixelu úrovně obrazu může náležet více než jeden bod z analyzovaného mračna bodů. Jednotlivé pixely úrovně obrazu tvoří hodnota souřadnice osy  $Z_{I_L}$  odpovídajícího bodu. Hodnota přiřazená pixelu v úrovně obrazu je průměrem hodnot všech bodů na pozici určené indexy  $x$  a  $y$


$$I_L(x, y) = \overline{PC(\sigma_{I_{L_x}=x} I_{L_x} \wedge \sigma_{I_{L_y}=y} I_{L_y}, dim_s)}. \quad (6.20)$$

Výraz  $\sigma$  označuje matematicky výběr všech prvků množiny specifikovaný podmínkou v uvedené v dolním indexu.

Posledním krokem algoritmu je přiřazení informace fyzického počátku úrovně obrazu z minima rozsahu  $R$  v rovině obrazu

$$I_{L_{phys}}(x, y) = [R_{X_{I_L}}(1), R_{Y_{I_L}}(1)] \quad (6.21)$$

Fyzický počátek mračna bodů tvoří minimální hodnoty rozsahů získané výrazem (6.17). Na Obr. 6.16 (a) je znázorněno mračno bodů s vyznačenou úrovní, kterému odpovídá úrovně obraz Obr. 6.16 (b).




Obr. 6.16 – Ilustrace tvorby úrovně obrazu, (a) vstupní mračno bodů, (b) výsledný úrovně obraz odpovídající ploše vyznačené šipkou

V případě zpracování mračna bodů s barevnou informací definovaného jako  $PC(N_{mp}, 6)$ , kde poslední tři dimenze tvoří barevné kanály RGB, je vytvořen druhý obraz  $I_{L_C}$  nesoucí barevnou informaci získanou stejným principem jako u rovnice (6.20) aplikovaným na barevnou informaci

$$I_{L_C}(x, y) = \overline{PC(\sigma_{I_{L_x}=x} I_{L_x} \wedge \sigma_{I_{L_y}=y} I_{L_y}, PC_{RGB})}. \quad (6.22)$$

Barvu pixelu tvoří průměr barev všech bodů mračna na pozici pixelu  $x$  a  $y$  úrovně obrazu. Ukázka barevného mračna bodů a jemu odpovídající úrovně obrazu je


na Obr. 6.17. Další příklady barevné vizualizace jsou uvedeny v praktické části v kapitole 6.9



Obr. 6.17 – Ilustrace barevného úrovněového obrazu, (a) vstupní mračno bodů v RGB, (b) odpovídající úrovněový obraz plochy vyznačené šipkou

### 6.4.2 Význam úrovněového obrazu

Pro praktickou ukázkou tvorby a významu úrovněového obrazu je na Obr. 6.18 (a) zobrazeno v centimetrovém měřítku několik bodů v prostoru, mezi kterými není zatím známá žádná souvislost. Pozice všech bodů je přehledně uvedena v Tab. 6.2.




Obr. 6.18 – Modelové mračno bodů pro tvorbu úrovněového obrazu, (a) mračno bodů, (b) po výstupu algoritmu LCCL s vyznačenými odlehlými body červenou barvou

Tab. 6.2 – Seznam bodů modelového mračna s vyznačenými odlehlými body

$x$ [cm]	1	2	3	4	2	3	4	5	3	4	5	1,2	2,4
$y$ [cm]	1	1	1	1	2	2	2	2	3	3	3	0,7	0,56
$z$ [cm]	2,99	3,01	2,88	3,19	2,93	3,08	3,10	3,05	3,02	3,06	2,90	2,90	2,97
$x$ [cm]	3,3	1,6	2,5	2,5	3,6	4,3	3,8	3,33	4,63	3,23	4,3	3,5	2,43
$y$ [cm]	0,8	1,4	2,5	1,5	1,7	1,9	2,3	2,45	2,82	1,32	2,1	1,9	1,83
$z$ [cm]	2,77	2,96	3,24	3,03	3,03	2,98	2,99	2,93	3,14	3,80	3,52	2,41	2,27

Výstupem algoritmu úrovněového skenování prostoru LCCL, prezentovaného v předchozí kapitole 6.3, v souřadné ose  $Z$  je pomocí histogramu rozsahu osy  $h_{lvl}$  stanovené vztahem  $\max(h_{lvl}(lvlX_L))$  detekovaná největší koncentrace výskytu bodů na hladině  $dL = 3,068 \text{ cm}$  viz Obr. 6.20 (a). Vstupními parametry algoritmu skenování prostorových úrovní jsou  $lvlS = 0,5 \text{ cm}$  a krok výběru  $lvlRS = 3$ . Vyznačené body modrou barvou na Obr. 6.18 (b) spadají do rozsahu úrovně definované vztahem (6.11). Z bodů tvořící detekovanou hladinu je sestaven úrovněový obraz pomocí funkce „PC2LevelImage“ uvedené na Obr. 9.6. Pixely vytvořeného obrazu na Obr. 6.19 (a) pomocí parametru kvantizace  $qD = 1 \text{ cm}$  jsou patřičně zvětšeny pro lepší vizualizaci.





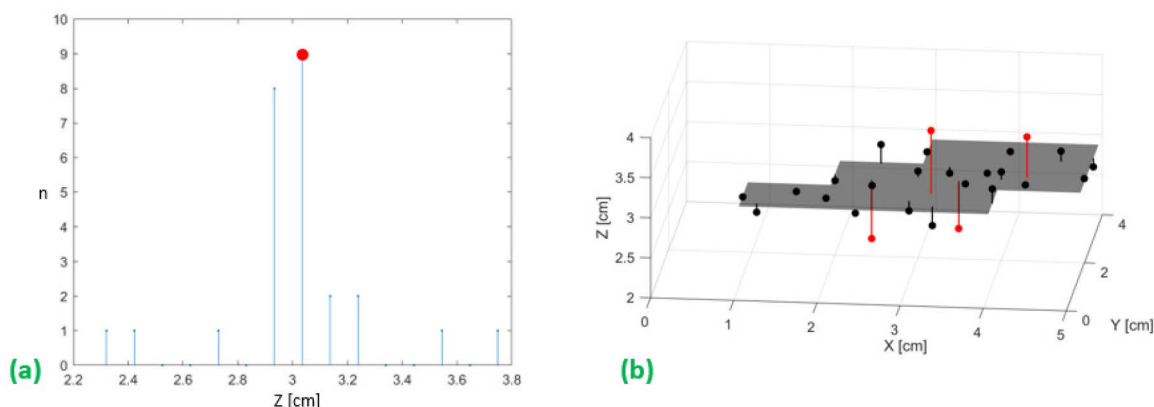
Obr. 6.19 – Úrovňový obraz prostorových bodů z Obr. 6.18 (b), (a) úrovňový obraz, (b) hodnoty pixelů

Pixely na Obr. 6.19 (a) jsou označeny indexy odpovídající číslům v tabulce Obr. 6.19 (b) popisující intenzitu jednotlivých pixelů úrovňového obrazu. Intenzita pixelu je určena průměrem pozic bodů ve skenované dimenzi zastoupené pixelem. Zjištěné parametry detekované hladiny jsou uvedené v následující Tab. 6.3

Tab. 6.3 – Parametry detekované plochy z Obr. 6.19 (a)

	Pos XYZ [cm]	dL [cm]	$P_E$ [cm]	$A_E$ [cm <sup>2</sup> ]	$\sigma$ [cm]
úroveň 1	1; 0,6; 3	3,0068	7,41	8	0,0001137

V tabulce se vyskytují parametry obvodu  $P_E$  a obsahu  $A_E$ . Jejich určením se zabýváme v další kapitole 6.5. Detail histogramu úrovně je zobrazen na dalším Obr. 6.20 (a) a prostorová vizualizace s vyznačenými odchylkami od detekované úrovně na Obr. 6.20 (b). Černou barvou jsou znázorněny body tvořící nalezenou rovinu a červenou barvou body s větší vzdáleností než zvolený parametr  $lvlS$ . Princip vizualizace plochy popisují v kapitole 6.8.



Obr. 6.20 – Detail histogramu úrovně a její prostorová vizualizace, (a) histogram, (b) vizualizace

Z výběru libovolných tří bodů detekované roviny například  $\mathbf{p}_1 = [2.5, 2.5, 3.007]$ ,  $\mathbf{p}_2 = [2.5, 1.5, 3.007]$  a  $\mathbf{p}_3 = [3, 2, 3.007]$  lze stanovit její matematický popis. Rovnice roviny je definována vztahem

$$ax + by + cz + d = 0. \quad (6.23)$$

Pomocí vyjádření dvou vektorů roviny  $\mathbf{p}_1\mathbf{p}_2$  a  $\mathbf{p}_1\mathbf{p}_3$  a jejich vektorovým součinem  $\mathbf{p}_1\mathbf{p}_2 \times \mathbf{p}_1\mathbf{p}_3$  lze určit normálový vektor  $\mathbf{n} = [a, b, c] = [0, 0, 0.5]$ . Dosazením bodu  $\mathbf{p}_1$  do rovnice (6.23) je hodnota  $d = -1.5$ . Určené hodnoty utvářejí výsledný matematický popis detekované roviny tvořené body v Tab. 6.2 ve tvaru  $0x + 0y + 0.5z - 1.5 = 0$ .

Z původního počtu 22 bodů, modré body na Obr. 6.18 (b) popisující prostor hladiny úrovňový obraz potřebuje pouze 8 pixelů. V případě, kdyby fyzický prostor detekované hladiny popisovalo například 100 bodů, tak počet bodů úrovňového obrazu zůstane

nezměněn. Zde je patrná úspora paměťových nároků pro uchování detekované hladiny reprezentující rovinu. Vždy závisí na velikosti kvantovacího parametru  $qD$  a hustotě mračna bodů. Například v případě Obr. 6.12 (b) po zacelení mezer morfologickými operacemi došlo k nárůstu popisných bodů vlivem nízké hustoty fyzických bodů vstupního mračna tvořící plochu. Při volbě parametru  $qD = 4 \text{ cm}$  by pro tvorbu úrovněového obrazu z Obr. 6.20 (b) byl zapotřebí pouze 1 pixel.

## 6.5 Určení prostorových vlastností mračna bodů

Úrovněový obraz je konstruován pomocí kvantizačního parametru vzdálenosti  $qD$ . Každý jeho pixel nese fyzikální informaci o pokryté ploše. Strana jednoho pixelu má rozměr  $1 qD$ . Zkoumaná plocha může mít nepravidelný tvar a určení jejího obvodu a obsahu nemusí mít snadné matematické řešení. Znalost velikosti pixelu nabízí využití metod zpracování obrazu pro jejich určení. Aplikací binárních operací na obraz a upravené analýzy označování spojených komponent pro účel určení souřadnic hranice elementu včetně záznamu historie její cesty prezentované v kapitole 6.2.2 lze poměrně snadno tyto parametry vyjádřit. Princip získání prostorových vlastností jsem představil v nejnovější publikaci (Chmelar, 2018b).

### 6.5.1 Určení obsahu a obvodu plochy

Výpočet obsahu plochy vyjádřené úrovněovým obrazem, kde každý pixel vyjadřuje přítomnost bodů ve zkoumaném mračnu, je definován jako plošný obsah všech pixelů


$$A_{E_x} = N_{E_x} \cdot qD^2, \quad (6.24)$$

kde  $N_{E_x}$  je počet nenulových pixelů úrovněového obrazu.

Určení obvodu elementu  $P_{E_x}$  nelze získat pouze násobením počtu pixelů  $i$  v případě, že je k dispozici samotná hranice elementu  $I_L E_{xB}$  získaná odečtením samotného elementu s aplikovanou erozí  $I_L E_{xE}$  od původního tvaru elementu  $I_L E_x$  podle rovnice (6.8). Při určování obvodu elementu mohou nastat dvě typické situace: hranice elementu uzavírají kruh nebo mohou mít tloušťku pouze jeden pixel a kruh neuzavírají. Dalším úskalím je volba optimální cesty pro určování jeho obvodu. Každý pixel je tvořen čtyřmi hranami o velikosti  $qD$ . Při řešení obvodu nelze stejně jako u obsahu násobit všechny hrany počtem nenulových pixelů. Tento případ platí pouze pro jeden pixel. Pseudokód funkce „GetElementPerimeter“ pro určení obvodu elementu úrovněového obrazu je uveden na Obr. 9.8.

Požadavkem určování obvodu je nalézt co nejpřesnější cestu opisující zkoumaný element v úrovněovém obrazu. Všechny popsání problémy řeší modifikovaný algoritmus označování spojených komponent pro účel hledání hran elementu v obraze prezentovaný v kapitole 6.2.2. Proces používá upravený mechanismus hledání sousedního pixelu ilustrovaný na Obr. 6.7. Při určování obvodu je sledována rovněž historie cesty nalezených sousedních pixelů  $P_p \in [1, 2, \dots, 8]$  podle toho, v jakém směru byl nalezen nový sousední pixel. Hodnoty odpovídají indexům na Obr. 6.7 (b). Analýza historie směrů umožní také zjistit, zda hranice zkoumaného elementu uzavírá kruh a zejména umožní určení optimální délky jednotlivých pixelů hranice pro přímý i diagonální směr. Pro přímý směr cesty prezentovaný indexy 1, 3, 5 a 7 je délka stanovena hranou pixelu  $qD$ . Pro diagonální směry zastoupené indexy 2, 4, 6 a 8 je délka určena úhlopříčkou pixelu. Za účelem snadnějšího pochopení principu i efektivnější implementace jsem ve zpracování zavedl obraz pole  $P_p$  o stejné velikosti označený jako  $P_d$  vyjadřující délku pixelu pro výpočet obvodu podle směrů

zaznamenaných v  $P_p$ . Pro přehlednost nabývají pouze dvou hodnot. Přímý směr je označen hodnotou 1 a diagonální hodnotou 0. Následující Obr. 6.21 prezentuje ukázkou všech variant směru procházení hranic elementu s vyznačeným obvodem. Číslo v rohu pixelu označuje pořadí pixelu tvořící hranici elementu a větší číslo uprostřed je směr jeho detekce podle Obr. 6.7 (b). Slabá červená linka určuje délku pixelu použitou pro výpočet obvodu.



**Obr. 6.21 – Určení optimální cesty pro stanovení obvodu s vyznačením délek pixelů červenou čarou**

Například u pixelu číslo 11 byl zaznamenán diagonální směr, ale ve výsledném obraze je vzdálenost určena jako přímá. Podmínkou pro úpravu přiřazení vzdálenosti je hodnota sousedního pixelu  $P_d(n + 1)$ . Rozhodovací podmínka má tvar

$$\sigma_{P_d(n)=0} P_d = \begin{cases} 1 & \text{for } P_d(n + 1) = 1 \\ 0 & \text{for } P_d(n + 1) = 0 \end{cases} . \quad (6.25)$$

Na místech, kde  $P_d(n)$  je rovno nule a následující prvek  $P_d(n + 1)$  je roven jedné, je prvku  $P_d(n)$  přiřazena také hodnota jedna, neboť se sousedním pixelem tvoří přímou dvojici. Symbol  $\sigma$  použitý v rovnicích (6.25), (6.28) a (6.29) označuje matematicky výběr prvků z množiny. Pro ilustraci důležitosti uvažování diagonálního směru použijte velikost parametru  $qD = 0,05 m$ . Když není uvažován diagonální směr a vyjádřím obvod elementu z Obr. 6.21 násobením počtu pixelů hranice jeho délkou, získám výsledný obvod 0,95 m. Zahrnutím diagonálních směrů je obvod roven 1,0536 m. Rozdíl obou hodnot je téměř 10%, který značí poměrně vysokou chybu určení obvodu pro pouhých 19 pixelů.

Pro detekci, zda hranice elementu uzavírá kruh, je v implementaci využita bodovací funkce. Podle směru procházení hranice uložené v  $P_p$  jsou přičítány a odčítány souřadnice v jednotlivých osách  $X$  a  $Y$ . Bodovací funkce  $X_s Y_s(N_{P_p}, 2)$ , kde  $N_{P_p}$  je počet prvků pole  $P_p$ , začíná s nulovými hodnotami v obou souřadných osách na pozici prvního nalezeného pixelu hranice, na Obr. 6.21 pixel číslo 1. Postupně jsou po směru jednotlivých pixelů hranice přičítány body v ose  $Y$  při pohybu vpravo nebo v ose  $X$  při pohybu nahoru. Při pohybech na opačnou stranu jsou body odčítány. Po naplnění všech pozic směrů je bodovací funkce vyhodnocena sumou jako

$$[X_s, Y_s] = \sum_{n=1}^{N_{P_p}} x_s y_s(n, \forall) . \quad (6.26)$$

Element s kruhovými hranicemi musí splňovat podmínku

$$N_{P_p} \geq 3 \wedge |x_s| \leq 1 \wedge |y_s| \leq 1 . \quad (6.27)$$

Stanovená podmínka v (6.27) říká, že element může být kruhový pouze v případě splnění minimálního počtu pixelů 3 a hodnota bodovacích koeficientů  $x_s$  a  $y_s$  nesmí přesáhnout hodnotu jedna v absolutní hodnotě. Hodnota 1 vyjadřuje sousedící pixel s prvním pixelem v diagonálním nebo v přímém směru a signalizuje tak dokončení kruhu. Při splnění podmínky (6.27) je obvod úrovnového obrazu  $P_{E_x}$  určen podle standardního vztahu v závislosti na určených směrech v poli  $P_d$  jako počet prvků, vyjádřený matematickým symbolem #, v přímém směru násobených rozměrem  $qD$  a počet prvků diagonálních násobených délkou diagonály pixelu

$$P_{E_x} = \#(\sigma_{P_d=0}P_d)qD + \#(\sigma_{P_d=1}P_d)\sqrt{2qD^2} . \quad (6.28)$$

V případě nesplnění podmínky (6.27) jsou počty prvků pole  $P_d$  násobeny dvakrát ve vztahu


$$P_{E_x} = 2\#(\sigma_{P_d=0}P_d)qD + 2\#(\sigma_{P_d=1}P_d)\sqrt{2qD^2} , \quad (6.29)$$

kteřý vyjadřuje součet stran pixelů dopředu a nazpět pro šířku elementu 1 pixel. Praktické výsledky na reálných mračech bodů porovnaných se skutečným prostředím jsou uvedeny v kapitole 6.9.

## 6.6 Vektorizace popisných bodů prostředí

Cílem zpracování mračen bodů je také snížení jejich celkového počtu. Například pro popis celistvé plochy jsou důležité pouze její vrcholy a ostatní body lze snadno dopočítat. Ze znalosti historie cesty hledání hranice elementu  $P_p$ , získané funkcí „ElementBorderPosition“ uvedené na Obr. 9.5, hodnoty skóre  $Y_s$  v ose  $Y$  a znalosti kruhové hranice  $cirP$ , oba parametry vystupující z metody určení obvodu funkcí „GetElementPerimeter“ představené v předchozí kapitole, jsem navrhl postup získání vrcholů zastoupené plochy úrovnovým obrazem. Pseudokód algoritmu „GetElCorners“ je uveden na Obr. 9.9.

Proces získání vrcholových bodů tvaru představující plochu prostřednictvím úrovnového obrazu začíná poznamenáním první pozice  $i$  směru v poli  $cPos$ . Následuje průchod celého pole historie cesty hranice  $P_p$  od indexu  $n = 2$  a hledají se změny směru cesty oproti poslednímu výskytu vrcholu určeného indexem  $cP_i$ . Při nalezené změně je zaznamenán směr historie cesty  $P_p$  i její index aktuální pozice, kam ukazuje  $n$ , i předchozí pozice  $(n - 1)$ . Důvodem pamatování obou pozic je patrný z Obr. 6.21. Pro připomenutí směr sousedního pixelu hranice je získán podle schématu uvedeného na Obr. 6.7 (b). Například změna směru z 5 na 6 u pixelu s číslem 9 je detekována u pixelu 10, ale vrchol tvoří právě pixel číslo 9. Po průchodu celé historie cesty se v poli  $cPos$  vyskytují na některých místech zdvojené směry zapříčiněné způsobem zaznamenávání uvedeným výše, například u pixelu 7 a 9 nebo 10 a 11. Z výsledného pole  $cPos$  jsou vynechány první prvky zdvojených směrů. Zbývá vyřešit poslední prvek pole  $P_p$ . Jestliže není hranice kruhová podle hodnoty parametru  $cirP$ , tak je poslední pozice hranice vždy přidána. Pro kruhovou hranici musí být vyhodnocen směr uzavření kruhu a pozice posledního pixelu vůči prvnímu. V případě hodnoty bodovací funkce  $Y_s$  pro osu  $Y$  větší nebo rovno 1 je poslední pixel s prvním spojen diagonálně a poslední pozice historie hranice  $P_p$  je přidána. Diagonální směr může být i delší než 1 pixel. V tomto případě je poslední pixel nalezen v diagonálním směru a je rovněž vynechán. Výsledky pro testovací obrazce z Obr. 6.21 a Obr. 6.19 (a) jsou zobrazeny na dalším Obr. 6.22 (a) a Obr. 6.22 (b) respektive.




Obr. 6.22 – Vyznačené vrcholy hranice elementu, (a) pro Obr. 6.21, (b) pro Obr. 6.19 (a)

Červeně vyznačené pixely tvoří vrcholy úrovnových obrazů. Pro Obr. 6.22 (a), kde původní celistvý obraz tvoří 39 pixelů je zapotřebí pouze 13 bodů popisující plochu a pro Obr. 6.22 (b) je zapotřebí 5 pixelů z původního počtu 8. Uvedený postup je platný pro celistvé plochy. Ty lze detekovat algoritmem pro označení spojených komponent. V případě necelistvé plochy lze aplikovat binární inverzi úrovnového obrazu a stejným postupem tak najít všechny vrcholové body tvořící mezery uvnitř detekované plochy prezentované úrovnovým obrazem. V kapitole 6.9 popisující praktické výsledky uvádím příklady zjednodušení popisných bodů na reálném prostředí.

## 6.7 Úprava prostorových dat pro zjištění dalších parametrů

Při zpracování detekovaných ploch je většinou požadavkem zjistit jejich celkový plošný obsah včetně přítomných mezer. Při měření může nastat také situace, kdy skenovaný prostor není dostatečně pokryt měřicími body. Taková situace nastala například při analýze parametrů podlahy nebo stropu. Na Obr. 6.23 je ukázka mračna bodů s chybějícími body podlahy, kde navržený optický skener nedostatečně pokrýl zkoumaný prostor.



Obr. 6.23 – Mračno bodů s chybějícími body na podlaze a stropu

Při zpracování a analýze naměřených dat může být k dispozici informace, že skenované plochy jsou celistvé bez mezer a při jejich zpracování je zapotřebí chybějící data doplnit. Použití úrovnového obrazu pro zpracování mračna bodů nabízí využití algoritmů zpracování obrazu, které napomohou při získání důležitých parametrů zkoumaného mračna bodů. K zacelení mezer v úrovnovém obrazu  $I_L$  využívám techniku práce s binárním obrazem a analýzu označování spojených komponent. Pseudokód algoritmu „FillElementArea“ je uveden na Obr. 9.10.

Obecně může úrovnový obraz obsahovat více elementů reprezentující jednotlivé plochy. Index analyzovaného elementu je označen indexem  $I_L E_x$ . Algoritmem detekce hranic elementu uvedeném v kapitole 6.2.2 je získán binární obraz ohraničení elementu  $E_{xB}$ . Pro zachování očekávaného pořadí označování komponent je zapotřebí rozšířit binární obraz hranice elementu alespoň o jeden pixel  $I_{E_{Bext}}$ . Vytvoří se druhý binární obraz stejné velikosti hodnoty 1  $I_{one}$ . Na místech detekované hranice je nastavena hodnota nula

$$I_{one}(I_{E_{Bext}} = 1) = 0 . \quad (6.30)$$

Na získaný obraz je aplikován algoritmus označování spojených komponent s hledáním 4 spojení. Spojení 8 nelze použít z důvodu šířky hranice 1 pixel, které by zapříčinilo nalezení pouze jedné komponenty v místech diagonální hranice elementu, kde by byl detekován sousední pixel. Výsledkem označení komponent jsou tak dvě oblasti v binárním obrazu  $L$ . Pixely označené indexem 1 tvoří okolí analyzovaného elementu a pixely s hodnotou 2 je požadovaná vyplněná oblast. Na počátku byla logicky odečtena hranice elementu a posledním krokem algoritmu je tedy její logické přičtení k vyplněnému elementu. Výsledná rovnice pro zacelený element  $I_{E_{fill}}$  má tvar

$$I_{E_{fill}} = (L = 2) \vee I_{E_{Bext}} . \quad (6.31)$$

Obr. 6.24 (a) ukazuje získaný úrovnový obraz podlahy analýzou mračna bodů z Obr. 6.23 a Obr. 6.24 (b) je nový zacelený elementu úrovnového obrazu. Zacelený element umožní ze znalosti kvantovacího parametru  $qD$  určit celkovou plochu podlahy, který lze využít k výpočtu objemu zkoumaného prostoru.



Obr. 6.24 – Zacelení úrovnového obrazu, (a) původní obraz, (b) zacelený obraz

Vstupní mračno na Obr. 6.23 je kvantováno parametrem  $qD = 0,05 m$ . Zacelený úrovnový obraz na Obr. 6.24 (b) tvoří 8335 nenulových pixelů. Celková plocha zastoupená úrovnovým obrazem je  $20,84 m^2$ . Z výšky místnosti  $2,3 m$  vychází přibližný objem skenované místnosti  $47,93 m^3$ .

## 6.8 Vizualizace ploch

Cílem zpracování mračen bodů je rovněž vhodná vizualizace dosažených výsledků. Úrovnový obraz zastupující detekované plochy lze využít i pro tento účel. Navíc, při dostupnosti barevné informace, lze skenovaný prostor vizualizovat i barevně. Pro vizualizaci je nutná znalost pozice vykreslovaných bodů v prostoru, kterou úrovnový obraz poskytuje. Algoritmus hledání pozic hranice elementů prezentovaný v kapitole 6.2.2 byl navržen zpočátku zejména pro potřeby vizualizace, kde je rovněž důležité pořadí pozic hranice pixelů pro vykreslení celistvé plochy. Poprvé byl využit při představení konceptu úrovnového obrazu v (Chmelar, 2017b).



Ke každému úrovněovému obrazu je k dispozici informace o jeho počátku  $I_{Lphys}(x, y)$  a parametr  $qD$  udává každému pixelu reálný rozměr a pozici v prostoru. Detekční úhel roviny je rovněž znám. Vizualizaci plochy v prostoru jsem implementoval ve výpočetním prostředí Matlab použitím funkce „patch“ vyžadující konkrétní body a jejich pořadí, mezi kterými je plocha kreslena. Obr. 6.25 popisuje podrobně celý proces vizualizace



Obr. 6.25 – Vizualizace úrovněového obrazu, (a) vstupní obraz s vyznačeným výběrovým oknem, počátkem a koncem, (b) část s krokem 1 px, (c) část s krokem 3 px, (d) vyznačené hranice, (e) vizualizace

v jednotlivých krocích. Vstupní obraz může obecně obsahovat mezery, a pokud je vyžadováno detailní vykreslení plochy nelze přímo na vykreslení elementu použít algoritmus na hledání pozic hranice elementů z Obr. 9.5. Celý proces vizualizace plochy je zapotřebí rozdělit na dílčí části. Algoritmus vykreslení plochy je shrnut pseudokódem na Obr. 9.11.

Proces vykreslování plochy začíná konstrukcí rotační matice  $R$  sestavenou vynásobením všech dílčích rotací souřadných os  $X$ ,  $Y$  a  $Z$ . Následuje analýza vstupního úrovněového obrazu  $I_L$ , ze které je určena pozice rozsahu elementu  $start_e$  a  $end_e$  v jeho šířce, na Obr. 6.25 (a) znázorněno šipkami. Koeficient  $nS$ , definovaný uživatelem, určuje krok procházení jednotlivých sloupců elementu určující šířku výběrového okna. Pro detailní vykreslení plochy je zapotřebí zvolit krok  $nS = 1$ , jelikož koeficient kvantování vzdálenosti  $qD$  může mít vysokou hodnotu a některé detaily by mohly být potlačeny. Vizualizace je tedy rozdělena do

$$\left\lfloor \frac{end_E - start_E}{nS} \right\rfloor \quad (6.32)$$

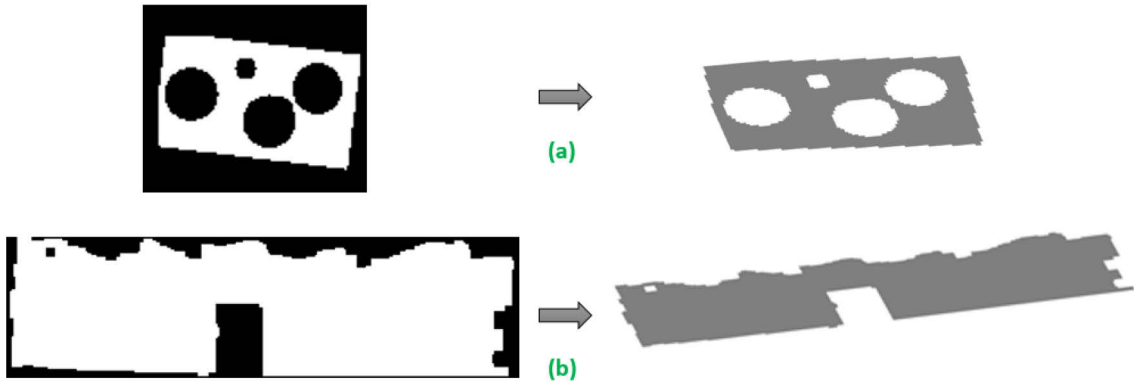
kroků zaokrouhlených nahoru z důvodu zajištění vykreslení celé plochy. Podle zvoleného kroku je vybrána část ze vstupního úrovněového obrazu. Obr. 6.25 (b) a (c) ukazuje rozdíl dvou šířek. Pro názornou ukázkou je zvolena část s přerušením obrazu. Zkontroluje se šířka všech řádků a všechny řádky s šířkou 1px jsou odstraněny. Výsledná vizualizace tak nejlépe popisuje plochu prezentovanou úrovněovým obrazem  $I_L$ . Pro nalezení všech částí původního elementu je využit algoritmus hledání spojených komponent. Pro každou nalezenou část je odečtena její eroze pro získání vlastních hranic vztahem (6.8). Souřadnice analyzované části jsou získány funkcí „ElementBorderPositions“ viz Obr. 6.25 (d). Ze známé počáteční pozice vstupního úrovněového obrazu  $I_{Lphys}(x, y)$ , kvanta vzdálenosti  $qD$  a pozice pixelu hranice  $e_B(x, y)$  v úrovněovém obrazu lze určit přesnou pozici bodu v prostoru jako

$$point(x, y) = I_{Lphys}(x, y) + e_B(x, y)qD \quad (6.33)$$

Z jednotlivých bodů hranice je poté vykreslena část plochy, Obr. 6.25 (d). V případě, že byla plocha, ze které je tvořen úrovněový obraz, detekována pod úhlem jsou body před vykreslením rotovány sestavenou rotační maticí  $R$

$$points_R = points \cdot R(\angle x, \angle y, \angle z) . \quad (6.34)$$

Proces se opakuje, dokud není vykreslena celá plocha úrovnňového obrazu. Příklady vizualizací jsou uvedené na dalším Obr. 6.26.




Obr. 6.26 – Vizualizace úrovnňového obrazu, (a) testovací element, (b) skutečný úrovnňový obraz

### 6.8.1 Barevná vizualizace

Z mračna bodů  $PC(N_{mp}, 6)$  vstupujícího do procesu tvorby úrovnňového obrazu uvedeném v kapitole 6.4.1 je získán barevný obraz RGB. Vizualizovat každý jeho pixel zvlášť jako plochu představuje zátěž HW prostředků. Proto je na vstupní obraz transformovaný do odstínů šedi aplikován algoritmus úrovnňové označování komponent prezentovaný v kapitole 6.3. Pomocí parametrů  $lvlS$  a  $lvlRS$  je volen rozsah analýzy změny intenzity jasu pixelu pro vizualizaci. Výstupem algoritmu LCCL jsou jednotlivé úrovně s různou intenzitou jasu. V případě přítomnosti více elementů v jedné úrovni je použit algoritmus označování komponent. Jednotlivé elementy jsou vykresleny stejným algoritmem uvedeným na Obr. 9.11. Vykreslovaná barva elementu  $I_{LeC}$  je získána následující rovnicí

$$I_{LeC}(R, G, B) = [\overline{I_{LeR}}, \overline{I_{LeG}}, \overline{I_{LeB}}] . \quad (6.35)$$

Výsledná barva části plochy je získána jako průměr všech pixelů elementu tvořící určitou úroveň. Ukázka vizualizace mračna bodů s barevnou informací je uvedena na Obr. 6.27. Jako detekční parametry algoritmu LCCL jsou  $lvlS = 10$  a  $lvlRS = 3$ .



Obr. 6.27 – Vizualizace úrovnňového obrazu s barevnou informací

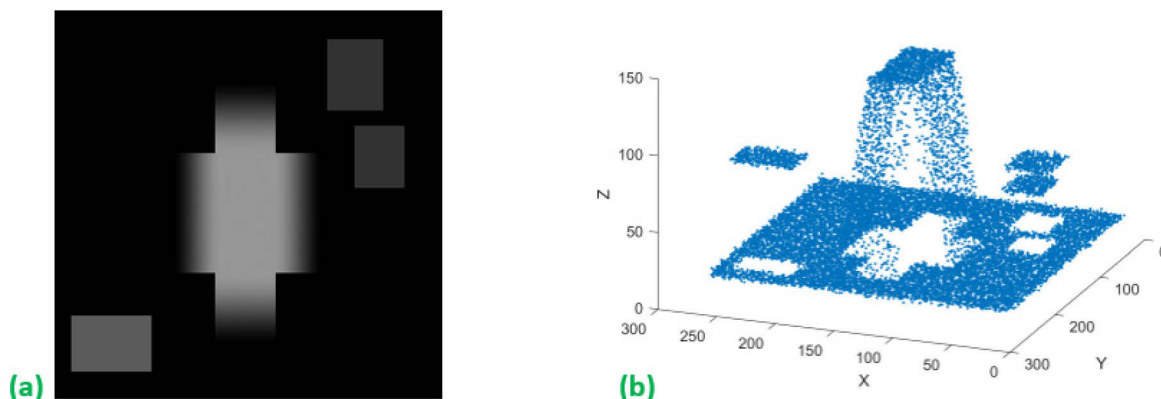
## 6.9 Praktické výsledky

V této části prezentuji praktické výsledky zpracování mračen bodů pomocí navržených metod. Nejprve diskutuji výsledky a vlastnosti navrženého algoritmu LCCL a konceptu úrovnňového obrazu na testovacích datech a později i na reálném prostředí skenované vlastním optickým měřičem. Výstupy navržených algoritmů jsou ukázány na

třech ucelených mračnech bodů vnitřních částí budov. Vyhodnocena je nejen přesnost určení parametrů ale i výhody, které zpracování pomocí úrovněového obrazu přináší včetně snížení počtu popisných bodů prostředí.

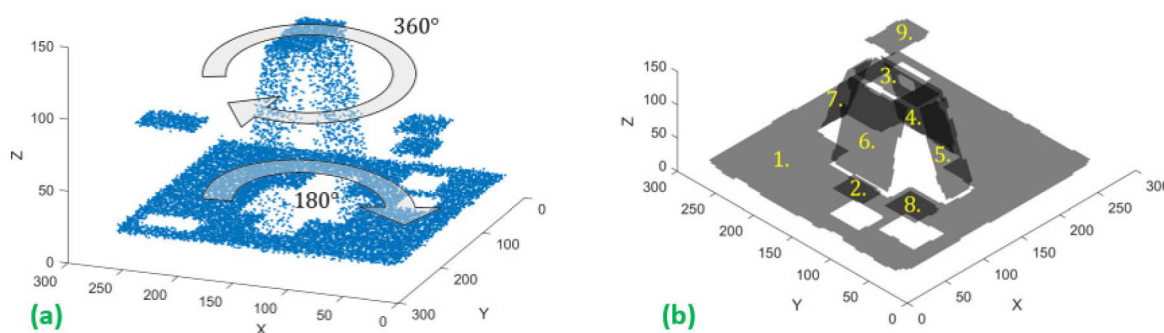
### 6.9.1 Testovací model mračna bodů

Koncept algoritmu úrovněového skenování prostorových dat jsem poprvé představil v (Chmelar, 2017b). Byl vyvíjen na připraveném testovacím modelu obrazu prezentující různé hladiny, více ploch v jedné úrovni a šikmé plochy vytvořené gradientem intenzity jasu viz Obr. 6.28.



Obr. 6.28 – Testovací model, (a) vstupní obraz, (b) mračno bodů z jasové složky

Ke vstupním datům byl přidán navíc šum s nulovou střední hodnotou  $\mu = 0$  a standardní odchylkou  $\sigma = 2$  pro simulaci reálného měření. Algoritmem LCCL lze přímo skenovat pouze určitou dimenzi. Pro detekci ploch pod různými úhly je zapotřebí vstupní mračno rotovat ve smyslu naznačeném na Obr. 6.29 (a). V každém úhlu rotace byl aplikován algoritmus LCCL pro prověření přítomnosti rovin. Jednotlivé body byly přiřazeny detekovaným plochám podle kritéria největší utvářené plochy. Postupnou rotací byly nalezeny všechny plochy vizualizované Obr. 6.29 (b).



Obr. 6.29 – Zpracování testovacího mračna, (a) naznačení rotace, (b) detekované plochy

Parametry detekovaných ploch jsou uvedeny Tab. 6.4. I v případě, že jedno skenování pomocí algoritmu LCCL je rychlé, přibližně 100 ms ve výpočetním systému Matlab na procesoru Intel i5-2410M, tak zpracování všech úhlů a detekce ploch trvá cca 1,8 hodiny. Z tohoto důvodu je výhodnější skenovat mračno bodů pouze v určitých dimenzích nebo pouze několika krocích. Stěny vnitřních prostor se vyznačují svojí kolmostí

na souřadné osy a pro detekci ploch může být požadavek skenovat pouze tyto tři základní dimenze, jako v dalších příkladech uvedených v této části kapitoly.

**Tab. 6.4 – Parametry detekovaných ploch testovacího modelu**

<i>Idx</i>	$A_E [m^2]$	$R(h; v) [^\circ]$	$I_{L_{phys}}(x; y) [cm]$	$dL [cm]$	$\sigma [cm] (x; y; z)$
1	5,09	0; 0	10; 19	20	79,33; 78,96; 0,89
2	0,167	0; 0	35; 96	59	9,62; 11,79; 0,9
3	0,324	0; 0	122; 111	137	9,9; 25,15; 0,9
4	0,93	0; 79	-107; 114	183	41,46; 23,05; 1,76
5	0,493	90; 73	-71; -136	232	35,35; 11,67; 0,96
6	0,973	180; 78	-163; -195	-86	40,35; 22,94; 1,28
7	0,479	270; 73	-164; -120	-62	38,37; 11,40; 1,29
8	0,18	0; 0	49; 39	59	10,69; 12,18; 0,83
9	0,235	0; 0	202; 220	90	15,14; 10,64; 0,89

Parametry v tabulce odpovídají rozměru  $qD = 1 \text{ cm}$  na pixel vstupního obrazu na Obr. 6.28. Položka *Idx* označuje indexy ploch z Obr. 6.29 (b). Třetí sloupec  $R(h; v)$  označuje horizontální a vertikální úhel. Hodnota  $I_{L_{phys}}(x; y)$  určuje fyzickou pozici úrovně obrazu v prostoru,  $dL$  detekční hladinu a  $\sigma$  směrodatnou odchylku plochy v jednotlivých souřadných osách. Záporné hodnoty úrovně a pozice odpovídají pozici mračna bodů po rotaci.

Pro detekci ploch je často výzkumníky využívaná metoda detekce RANSAC například v (Hulik, 2014) nebo (Kurban, 2015) nebo Houghova transformace (Hulik, 2014). V případě RANSAC jsou hledány v jednotlivých iteracích společně parametry definující model roviny. Jeho výstupem je segmentovaná část mračna bodů popisující nalezenou plochu. Se získaným modelem lze určit její orientaci v prostoru. Stále ale plochu tvoří jednotlivé body vyžadující další zpracování pro určení rozšiřujících parametrů. V případě navrženého nástroje úrovně obrazu lze zpětně rekonstruovat jím zastupovanou část původního mračna bodů využitím znalosti bodu jeho počátku  $I_{L_{phys}}(x; y)$ , úhlu orientace v prostoru  $R(x, y, z)$ , detekované úrovně  $dL$ , parametru velikosti pixelu  $qD$  a rozptylu bodů detekované roviny  $lvls$ . Získá se tak stejný výstup jako například přístupem RANSAC. Jak již bylo popsáno nevýhodou algoritmu LCCL je jeho závislost na orientaci mračna bodů, kterou lze eliminovat korekcí popsanou v kapitole 5.1.2. Při zajištění správné orientace vstupního mračna lze těžit z jeho rychlosti zpracování a poskytovaných statistických parametrů detekovaných úrovní popisující kvalitu povrchu nalezených ploch. Jedním průchodem algoritmu v určité dimenzi jsou takto získány všechny její plochy. Při neznámé orientaci vstupního mračna bodů je možné využít principu detekce naznačený na Obr. 6.29 (a), který je časově náročný, jelikož vyžaduje mnoho kroků postupné rotace mračna. Výhodou přístupu RANSAC je naopak nezávislost na orientaci plochy a postupným jejich extrahováním a odstraňováním použitých bodů jsou získány všechny přítomné plochy.

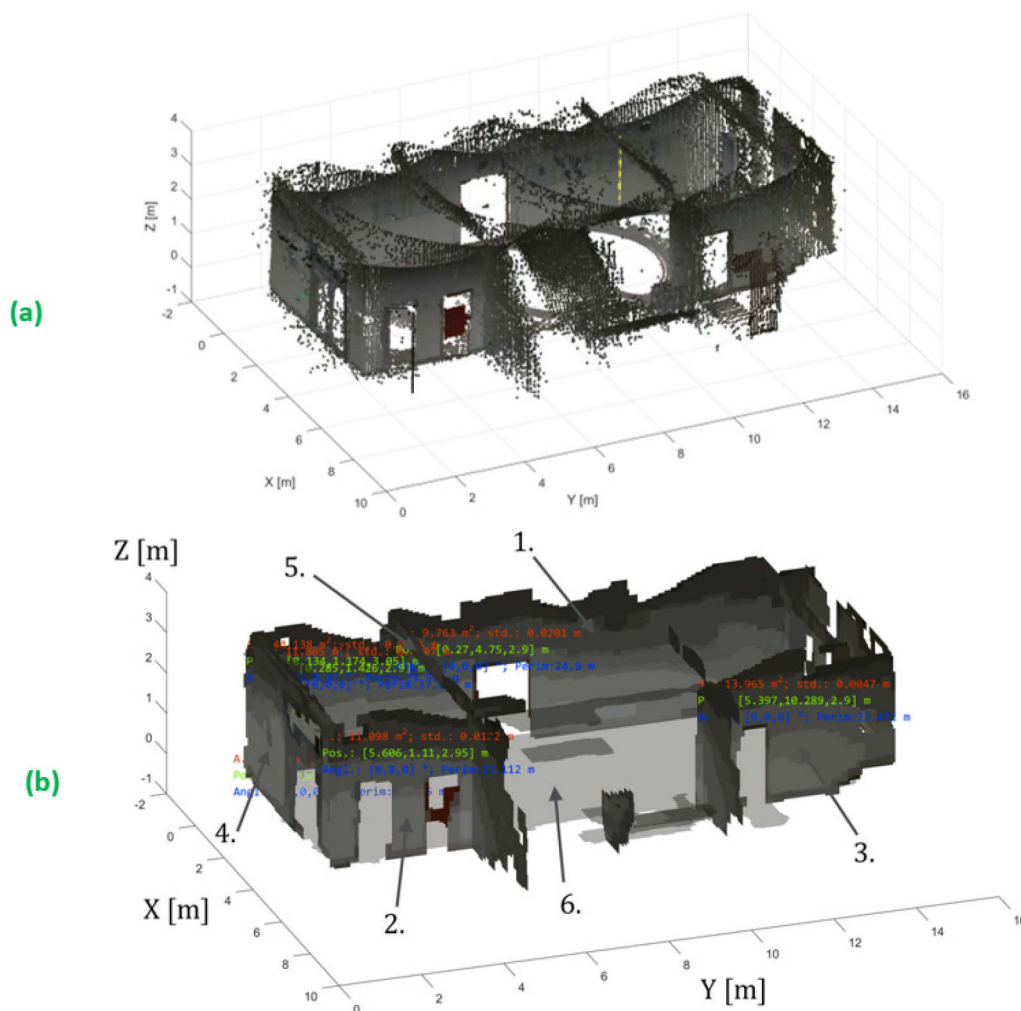
Při zpracování mračen bodů lze obecně detekovat plochy libovolným přístupem a prezentovat je pomocí funkce „PC2LevelImage“ z Obr. 9.6 v podobě úrovně obrazu s využitím všech jeho předností popsaných v dalších částech této kapitoly.

## 6.9.2 Reálná mračna bodů

K praktickému ověření navržených metod diskutovaných v kapitole 6 jsem vybral tři vnitřní prostory budov, dvě místnosti a jednu chodbu. Vstupní mračna byla vždy před

začátkem zpracování prověřena testem na kolmost k souřadným osám prezentovaným v kapitole 5.1.2. Dodržení orientace je zaručena kolmost na souřadné osy vyžadující algoritmus LCCL.

Chodbu reprezentuje vstupní část ucelené mapy z Obr. 5.14 uprostřed ukázaná v kapitole 5. Její výsledné mračno je spojeno procesem registrace čtyř skenů prostoru viz Obr. 6.30 (a). Ucelená mapa je kompaktní, ale jsou z ní zřejmé nedostatky. Například v ní




Obr. 6.30 – Testovací místnost chodba, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry

Tab. 6.5 – Parametry detekovaných ploch prostoru chodby

$Idx$	$dL$ [m]	$I_{Lphys}(x; y; z)$ [m]	$A_E$ [m <sup>2</sup> ]	$P_E$ [m]	$\sigma$ [m]	$dim_s$
1	0,134	0,134; 1,174; 0,026	44,138	39,962	0,013	X
2	5,606	5,606; 1,11; 2,95	11,098	23,112	0,012	X
3	5,397	5,397; 10,28; 2,9	13,965	23,471	0,0046	X
4	1,426	0,285; 1,426; 0,01	11,805	37,062	0,0097	Y
5	4,749	0,27; 4,75; 2,9	9,7625	24,8	0,0201	Y
6	0,154	0,947; 0,154; -0,111	81,97	45,645	0,0128	Z

chybí prostorové body stropu a podlaha není celistvá. Navržený skener měl rovněž problémy s detekcí laserové čáry na vzdáleném povrchu červených dveří. Nedokonalosti vytvořeného mračna bodů nejsou překážkou, ale spíše výzvou pro navržený koncept zpracování a vizualizace pomocí úrovně obrazu. Vizualizované plochy vstupního mračna bodů

jsou zobrazeny pomocí úrovnňového obrazu s vyznačenými parametry jednotlivých ploch a obvodem větším než 20 m na Obr. 6.30 (b). Parametry jsou přehledně zobrazeny v Tab. 6.5. V souřadné ose  $Z$  byl využit postup vyplnění mezer v úrovnňovém obraze pro získání celkové plochy podlahy prezentovaný v kapitole 6.7, v Tab. 6.5 šestý řádek  $A_E = 81,97 \text{ m}^2$ . Výška zpracovávaného mračna je v ose  $Z$  3,5 m. Kombinací těchto dvou parametrů je získán přibližný objem prostoru chodby  $287 \text{ m}^3$ . Sloupec v tabulkách Tab. 6.5, Tab. 6.6 a Tab. 6.7 označený  $dim_s$  určuje souřadnou osu skenování detekované plochy. Na dalším Obr. 6.31 jsou zobrazeny hloubkové obrazy vytvořené ze vstupního mračna bodů na Obr. 6.30 (a). Jeho levá strana ukazuje pohled do prostoru v pravé části mračna a pravá strana pohled na schody v prostřední části prostoru chodby.



Obr. 6.31 – Hloubkové obrazy prostoru chodby z Obr. 6.30 (a) pravá část, (b) prostor schodiště

Z obou hloubkových obrazů na Obr. 6.31 jsou patrné chybějící části vstupního mračna, které jsou částečně způsobené vysokým rozlišením hloubkového obrazu odpovídající rozlišení použité kamery. Kvalita a celistvost vytvořeného obrazu je závislá pouze na detailnosti vstupního mračna bodů. Oba obrazy jsou pořízené ze stejného místa v prostoru. Obr. 6.31 (a) se jeví jako méně výrazný, neboť vzdálenost je kvantována na hodnotu z rozsahu 0 až  $(2^{16} - 1)$  odpovídající maximální vzdálenosti 15 m. Ostatní hloubkové obrazy v této dizertační práci jsou zobrazeny s upraveným jasnem v rozsahu 0 až maximální vzdálenost na konkrétním obraze pro lepší zvýraznění detailů.

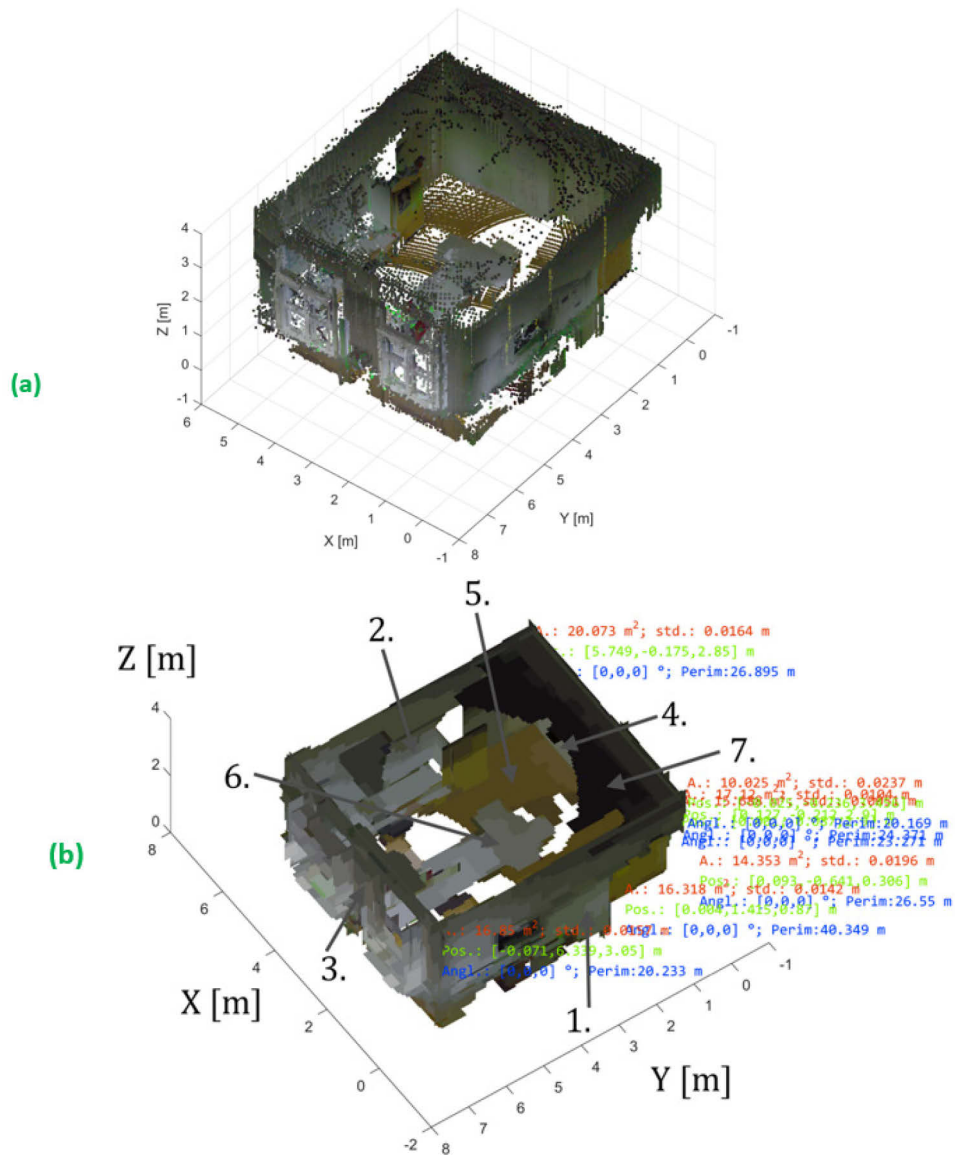
Další analyzovanou místností je laboratoř použitá pro ukázkou procesu registrace mračen bodů představená v kapitole 5 na Obr. 5.9. Výsledné mračno je složeno z šesti skenů. Tab. 6.6 popisuje stanovené parametry zpracovaného mračna bodů z Obr. 6.34 (b) s vizualizovanými plochami. Skenovaný prostor na Obr. 6.34 (a) je lépe pokryt, než v případě chodby, jelikož není tak rozsáhlý, ale část podlahy rovněž chybí. V prostoru u oken

Tab. 6.6 – Parametry detekovaných ploch místnosti laboratoře


$Idx$	$dL$ [m]	$I_{Lphys}(x; y; z)$ [m]	$A_E$ [m <sup>2</sup> ]	$P_E$ [m]	$\sigma$ [m]	$dim_s$
1	0,127	0,127; -0,212; 3,7	17,12	24,371	0,01	X
2	5,749	5,749; -0,175; 3,65	20,073	26,895	0,0164	X
3	6,339	-0,071; 6,339; 3,85	16,85	20,233	0,0157	Y
4	-0,087	0,001; -0,087; 3,7	15,688	23,271	0,005	Y
5	0,306	0,093; -0,641; 0,306	14,353	26,55	0,0196	Z
6	0,87	0,004; 1,415; 0,87	16,318	40,349	0,0142	Z
7	3,456	-0,025; -0,236; 3,456	10,025	20,169	0,0237	Z



byla podlaha osvětlena přítomným denním světlem a laserová čára neměla dostatečnou intenzitu, aby byla rozlišitelná od pozadí. Tabulka popisuje plochy označené indexy s obvodem větším než 20 m.



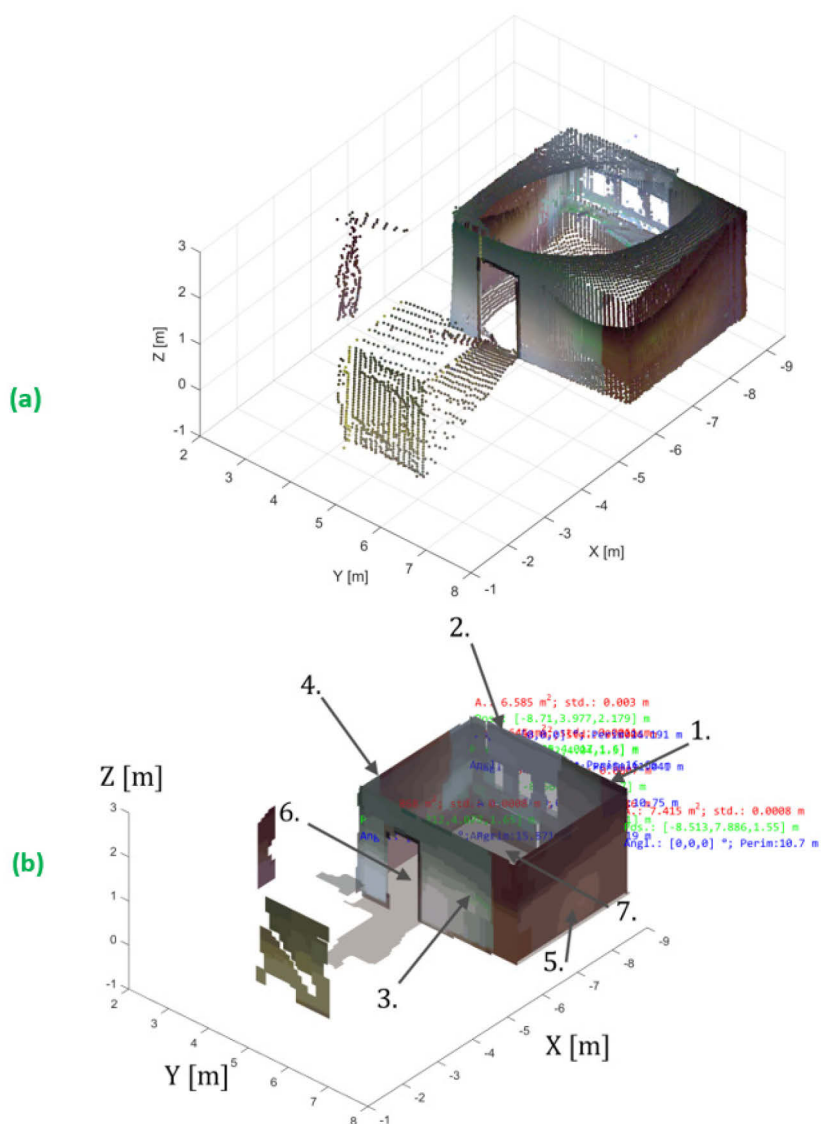
Obr. 6.32 – Místnost laboratoře, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry



Obr. 6.33 – Hloubkové obrazy prostoru laboratoře z Obr. 6.34, (a) pohled pod úhlem +5° do horního rohu místnosti se stolem skříní a částí dveří, (b) pohled od stolu na okna

V porovnání s hloubkovými obrazy prostoru chodby na Obr. 6.31 jsou obrazy laboratoře celistvější vlivem detailnějšího vstupního mračna.

Poslední místností Obr. 6.34 (a) je menší bytový pokoj složený ze dvou skenů. Jednodušší mračno bodů přehledněji ilustruje výstupy navržených algoritmů na Obr. 6.34 (b). Výsledky pro detekované plochy s obvodem větším než 10 m jsou zobrazeny v Tab. 6.7. Vizualizované plochy umožňují prezentovat základní tvar místnosti včetně výklenku pro okno a radiátor. Okna mají nepravidelný tvar z důvodu rozdílné výšky žaluzií.



Obr. 6.34 – Bytový pokoj, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry

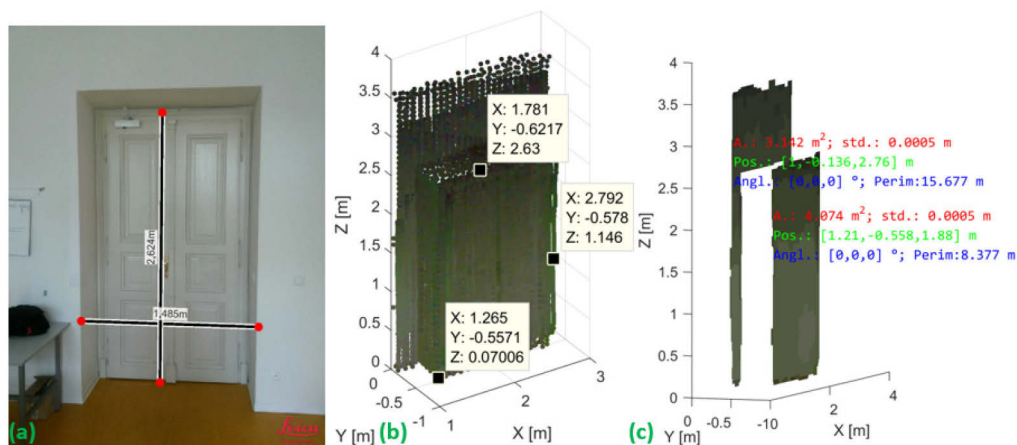
Tab. 6.7 – Parametry detekovaných ploch bytového pokoje

$Idx$	$dL [m]$	$I_{Lphys}(x; y; z) [m]$	$A_E [m^2]$	$P_E [m]$	$\sigma [m]$	$dim_s$
1	-8,6645	-8,664; 4,078; 1,5	2,34	10,75	0,0007	X
2	-8,5247	-8,525; 4,017; 2,4	5,645	16,05	0,001	X
3	-5,3121	-5,312; 4,077; 2,45	7,8675	15,571	0,0008	X
4	4,0398	-8,672; 4,04; 2,3	7,6575	11,041	0,0006	Y
5	7,8861	-8,513; 7,886; 2,35	7,415	10,7	0,0008	Y
6	-0,0051	-8,57; 3,977; -0,0051	15,34	19	0,0015	Z
7	2,1792	-8,71; 3,977; 2,179	13,234	14,191	0,003	Z

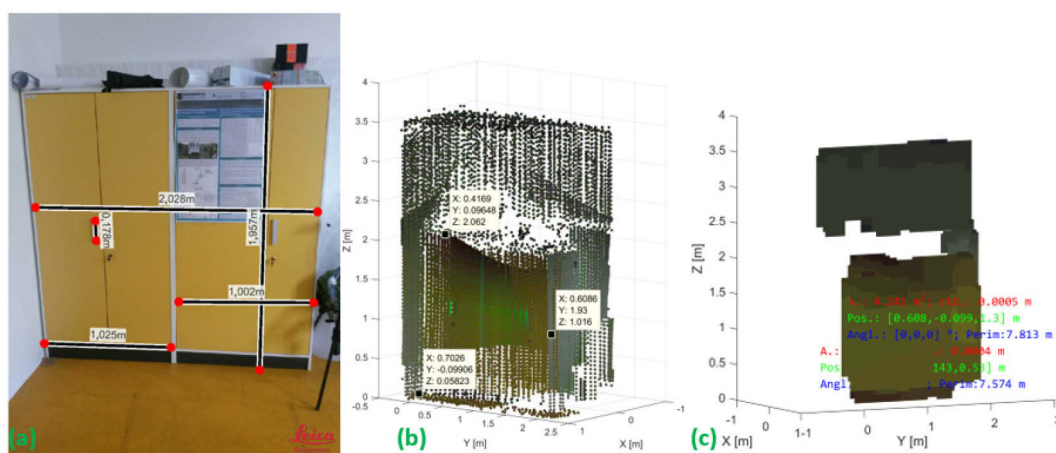
V případě analyzované místnosti bylo možné zcelit úroňový obraz podlahy a stropu postupem prezentovaným v kapitole 6.7. Plocha podlahy je tvořena i částí druhého pokoje. K určení objemu místnosti je vhodné využít plochu stropu  $A_E = 13,234 \text{ m}^2$ . Výška místnosti je 2,179 m. Její přibližný objem vychází  $28,84 \text{ m}^3$ .

### 6.9.3 Přesnost určení parametrů

Pro ověření přesnosti určení parametrů jsem vybral stejné dvě části mračna bodů jako pro ověření přesnosti jejich tvorby v kapitole 3.10, dveře Obr. 6.35 a skříň Obr. 6.36.



Obr. 6.35 – Ověření přesnosti určení prostorových parametrů pro prostor dveří, (a) skenovaná scéna, (b) mračno bodů (pohled zezadu), (c) vyznačené parametry obvodu a obsahu plochy



Obr. 6.36 – Ověření přesnosti určení prostorových parametrů pro prostor skříně, (a) skenovaná scéna, (b) mračno bodů, (c) vyznačené parametry obvodu a obsahu plochy

Obr. 6.35 ilustruje určení parametrů pro plochu dveří. Na Obr. 6.35 (a) je zobrazen skenovaný prostor, jehož mračno bodů ukazuje Obr. 6.35 (b) a barevně vizualizovaná plocha s vyznačenými parametry je znázorněna na Obr. 6.35 (c). Stejně pořadí obrázků platí i pro část se skříní zobrazenou na Obr. 6.36. Zjištěné parametry obvodu a obsahu s určenou odchylkou od skutečných parametrů a procentuálně vyjádřenými chybami jsou přehledně uvedeny v Tab. 6.8.


Tab. 6.8 – Tabulka porovnání určených parametrů s reálným prostředím

	$dL$ [m]	$P_E$ [m]	skut. $P$ [m]	ch. $P_E$ [%]	$A_E$ [m <sup>2</sup> ]	skut. $A$ [m <sup>2</sup> ]	ch. $A_E$ [%]	$\sigma$ [m]
dveře	0,558	8,376	8,218	1,92	4,074	3,8966	4,55	0,000471
skříň	-0,608	7,8135	7,964	-1,89	4,241	3,9627	7,02	0,000504

Zjištěné odchylky odpovídají přesnosti vytvořeného mračna bodů. Přesnost určení parametrů hloubkového obrazu tedy závisí zejména na přesnosti vstupního mračna bodů a na volbě kvantovacího parametru  $qD$ . Ten lze zvolit uživatelsky podle požadovaného rozlišení a jemnosti nebo například metodou histogramu a počtu požadovaných bodů zpracovávaného mračna na jeden pixel.


#### 6.9.4 Zjednodušení popisných bodů

Na příkladu části mračna bodů dveří a skříně z Obr. 6.35 a Obr. 6.36 také ilustrují možnost zjednodušení jejich popisných bodů podle postupu prezentovaného v kapitole 6.6. Na Obr. 6.37 (a) je zobrazeno mračno bodů popisující dveře a je na něm vyznačena plocha vizualizovaná pomocí úrovně obrazu. Obr. 6.37 (b) ukazuje odpovídající úrovně obraz s vyznačenými vrcholy metodou „GetElCorners“ z Obr. 9.9. Zakreslenou plochu pomocí určených bodů prostřednictvím Matlab funkce „patch“ ilustruje Obr. 6.37 (c).



**Obr. 6.37 – Ilustrace zjednodušení popisných bodů plochy dveří, (a) vstupní mračno s vizualizovanou plochou pomocí LI, (b) detekované vrcholy, (c) vizualizace plochy prostřednictvím nalezených vrcholů**

Podobně je vizualizována na Obr. 6.38 také část skříně. Pro lepší přehlednost Tab. 6.9 na další stránce ukazuje číselně zjednodušení popisných bodů pro oba případy Obr. 6.35 a Obr. 6.36.



**Obr. 6.38 – Ilustrace zjednodušení popisných bodů plochy skříně, (a) vstupní mračno s vizualizovanou plochou pomocí LI, (b) detekované vrcholy, (c) vizualizace plochy prostřednictvím nalezených vrcholů**




Tab. 6.9 – Tabulka zjednodušení popisných bodů ploch

	$Np$	$qD$ [m]	$Npx$	$WxH$	$Nc$	$Nc/Np$ [%]
dveře	6302	0,02	10069	81x134	59	0,936 %
skříň	9261	0,035	3281	60x61	44	0,475 %


První sloupec  $Np$  ukazuje počet bodů vstupního mračna, další sloupec  $qD$  popisuje kvantovací parametr pro tvorbu úrovnového obrazu. Hodnota  $Npx$  je počet pixelů úrovnového obrazu. Sloupec označen  $WxH$  udává rozlišení vytvořeného obrazu. Důležitý parametr  $Nc$  udává počet bodů vrcholů nutných na vykreslení plochy (červené pixely na Obr. 6.37 (b) a Obr. 6.38 (b)). Poslední sloupec  $Nc/Np$  vyjadřuje procenty, kolik bodů je zapotřebí k přesnému prostorovému popisu plochy, oproti původnímu počtu bodů mračna. V případě dveří i skříně je pro vizualizaci plochy využito méně než jedno procento vstupních bodů. Například v případě dveří je počet bodů mračna menší než počet nenulových pixelů úrovnového obrazu. K uchování bodu v paměti jsou zapotřebí tři souřadnice  $x$ ,  $y$  a  $z$ . Úrovnový obraz potřebuje jen souřadnice  $x$ ,  $y$ . Třetí souřadnice je daná detekovanou úrovní  $dL$  uchovanou společně s fyzickým počátkem obrazu  $I_{Lphys}(x, y)$ . Zjednodušení popisných bodů má pouze nevýhodu ztráty barevné informace plochy, kterou již nelze tak v detailních barvách vizualizovat.

### 6.9.5 Hloubkové obrazy

Další hloubkový obraz místnosti z Obr. 6.39 (a) je zobrazen na Obr. 6.39 (b),



Obr. 6.39 – Hloubkový obraz, (a) vstupní mračno bodů, (b) pohled na stůl a podlahu pravé části mračna




Obr. 6.40 – Hloubkový obraz, (a) s rotací 90° v ose Z, (b) ilustrace surf grafu

kde je pohled od dveří na levou stranu stolu směrem na podlahu. Na obrazu je zřetelná nedostatečná hustota mračna bodů v blízkosti virtuální kamery. Zpětný pohled od okna do prostoru dveří na Obr. 6.40 (a) ukazuje celistvý obraz. Z toho vyplývá, že hloubkovou mapu lze vytvořit z libovolného místa, ale výsledek vždy záleží na detailnosti vstupních dat představující mračno bodů. Nelze tedy například očekávat, že z mračna bodů pokrývající celou místnost lze vytvořit detailní hloubkový obraz z virtuální kamery nasměrovanou na hrneček stojící na stole.

### 6.9.6 Úpravy hloubkového obrazu a zpětná rekonstrukce mračna bodů

Výslednou hloubkovou mapu lze libovolně upravovat metodami zpracování obrazu a reverzním postupem vytvořit zpátky mračno bodů. Například z hloubkového obrazu na Obr. 6.40 (a) byly odstraněny dveře a upravený obraz byl následně transformován zpět na mračno bodů. Provedené úpravy a výsledek zpětné transformace ilustruje další Obr. 6.41.



Obr. 6.41 – Ilustrace úprav hloubkového obrazu a zpětná transformace, (a) upravený obraz, (b) mračno bodů získané reverzním postupem algoritmu tvorby prostorové mapy

Hloubkový obraz na Obr. 6.40 (a) byl vytvořen z mračna o velikosti 31 216 bodů v zorném poli kamery. Vlivem použití vysokého rozlišení a zacelení mezer pomocí morfologických úprav má rekonstruované mračno bodů velikost 3 976 483. Velký nárůst bodů souvisí s vysokým rozlišením hloubkového obrazu a zacelením jeho mezer morfologickými operátory. Prezentovaný postup ukazuje možnosti použití metod zpracování obrazu na hloubkový obraz.

Reverzní postup transformace hloubkového obrazu zpět na mračno bodů nelze provést pomocí inverzní transformace projekční matice  $4 \times 4$ . Projekce patří do skupiny transformací, pro které neexistuje inverze. V případě aplikace její projekce je nevratně ztracena původní pozice transformovaného bodu, z tohoto důvodu je zapotřebí použít přístup přes projekční přímky.

Prezentované výsledky přehledně ukázaly možnosti zpracování mračen bodů a jejich barevnou vizualizaci pomocí úrovnového obrazu. Spojení mračen bodů s metodami zpracování obrazu umožňuje získat užitečné prostorové parametry obvodu a obsahu detekovaných ploch prostředí, které mohou mít komplikovanou strukturu a jejich matematické určení by bylo komplikované. Znalost plochy a rozsahu mračna bodů umožňuje určit i objem skenovaného prostoru. Úpravou úrovnového obrazu lze dokonce opravovat nedokonalosti výsledného skenu prostředí. Jeho následné zpracování umožní také zjednodušit bodový popis prostoru. Jeho hlavní výhoda spočívá zejména i v kombinovatelnosti s jinými metodami detekce ploch, jejichž výstup je následně zpracován pomocí úrovnového obrazu.



## 7 Závěr

V dizertační práci jsem se zabýval automatizovaným skenováním prostoru od samotné tvorby optického měřiče vzdálenosti, konstrukce mračna bodů, až po fúzi měřených dat z různých míst zkoumaného prostoru, barevné vizualizace a zjednodušení výsledného mračna bodů za účelem snížení paměťových nároků a snadnější prezentace celé skenované scény.

Na začátku popisují aktuální stav zkoumané problematiky včetně dostupných systémů skenování prostoru. Jelikož ve svém výzkumu využívám navržený optický laserový dálkoměr, tak je část dizertační práce věnovaná jeho detailnímu popisu, principu určení vzdálenosti, segmentace laserové čáry a určení její přesné pozice v měřicím bodě. Kombinace prostorových dat s měřicími snímky umožňuje i tvorbu barevného mračna bodů.

Praktické porovnání výsledků měření dokazuje dosažení odpovídající přesnosti navržených algoritmů segmentace a detekce laserové čáry určené konstrukcí měřicího systému. Pro přesné měření je klíčová jeho správná kalibrace. Laserovou čáru je možné detekovat se subpixelovou přesností. Výsledky registrace vytvořených mračen bodů potvrdily i vyhovující přesnost tvorby prostorových map. Přesnost vytvořených mračen bodů je pro proces registrace klíčová. Z 64 individuálních měření se podařilo sestavit ucelené mračno bodů rozsáhlého patra budovy, avšak ne všechny části bylo možné spojit dohromady procesem registrace. Některé části mračen, například za zavřenými dveřmi, neobsahují společné části, které se překrývají a není tak možné zaručit očekávaný výsledek spojení částí skenovaného prostoru. Dodržovaný přibližný odstup pozic jednotlivých měření okolo 3 m byl v některých případech limitní pro nalezení společných částí prostoru pro použité algoritmy registrace. Z pohledu robustnosti zpracování pro méně přesná vstupní prostorová data s chybovostí okolo 5 %, jako v případě vlastního skeneru prostředí, dosahuje algoritmus NDT lepších výsledků. Jeho hlavní výhoda spočívá v modelování částí prostoru pomocí normálního rozdělení oproti vzdálenosti individuálních bodů v případě algoritmu ICP. Při detailně pokrytém prostoru ICP algoritmus dosahoval nepatrně lepší výsledků v rámci několika jednotek procent, ale při registraci rozsáhlejších skenů, jako jsou chodby, měl problém méně přesná mračna bodů spojit a docházelo k nežádoucím chybám při tvorbě celkové mapy. Z tohoto důvodu doporučuji využívat modernější a robustnější algoritmus NDT, který umožňuje lépe parametricky specifikovat kvalitu a podrobnost vstupních mračen bodů. Získané ucelené mračno bez dalšího zpracování představuje pouze skupinu měřicích bodů se společným počátkem. Proto jsem se v další části dizertační práce zabýval jejich zpracováním pro získání užitečných informací o skenovaném prostředí, jeho zjednodušením a vizualizací.

Spojením dostupných map z místa skenování získávám vizuální informaci o tvaru prostoru, který je ale tvořen mnoha popisnými body zbytečně zvyšující paměťové nároky na uchování mračna bodů a navíc není k dispozici žádná další informace o zkoumaném prostoru, kromě jeho rozsahu zjistitelného ze souřadnicových os. V poslední kapitole dizertační práce jsem se věnoval metodám zpracování mračen bodů včetně detekce základních elementů ploch, jejich prostorovému popisu, vektorizaci a vizualizaci. Část kapitoly popisuje navržený algoritmus pro tvorbu hloubkového obrazu využívající projekční matici  $4 \times 4$ . Hloubkový obraz lze vytvořit z libovolného místa v prostoru a s libovolnou orientací pohledu virtuální kamery. Vstupní parametry algoritmu je možné zvolit libovolně a to činí navržený algoritmus obecným pro použití na různá mračna bodů. Pomocí znalosti parametru kvantování vstupního mračna je možné využít jeho výstup pro měření velikosti

nebo plochy analyzovaných objektů na scéně. Zastínění jiných objektů prostoru měřicími body v popředí je řešeno rovněž pomocí projekční matice. Získanou hloubkovou mapu lze transformovat zpět na mračno bodů. Aplikací algoritmů zpracování obrazu je možné hloubkový obraz upravovat a měnit. Jeho zpětná transformace umožňuje dosáhnout například zacelení mezer nebo eliminaci objektů určité velikosti. Hloubkový obraz ale není příliš vhodný pro podrobnou detekci objektů. Myšlenka kvantování prostoru se nakonec ukázala jako velmi výhodná a dala vzniknout nově navrženému konceptu zpracování mračen bodů pomocí úrovnového obrazu, který doplňuje možnosti rozšířeného zpracování ke stávajícím dostupným metodám.

Úrovnový obraz je výsledkem navržené analýzy prostorových dat indikující přítomnost bodů na určité pozici v prostoru. Skupina bodů rozmístěná v jedné hladině pak signalizuje přítomnost plochy. Svým obsahem vyjadřuje jak kvalitu detekované plochy prostřednictvím stanovených statistických parametrů, tak nakvantovaná prostorová data ve formě pixelů umožňují použití metod zpracování obrazu na získání dalších fyzikálních rozměrů jako je plocha nebo obvod, které by jinak vyžadovalo složité matematické řešení při komplikovaných tvarech zpracovávaných ploch. Další úpravy pomocí úrovnového obrazu umožňují doplnit chybějící části skenovaných dat a získat další rozšiřující údaje jako například objem skenovaného prostoru. Úrovnový obraz sám o sobě snižuje paměťové nároky na množství uchovávaných dat zastupující plochu. Při dalším zpracování navíc upravená výstupní data funkce pro zjištění pozice hranice úrovnového obrazu umožňuje určit jeho vrcholy a získat tak vektorový popis detekované plochy značně minimalizující počet popisných bodů na jednotky procent. Jeho zpracování po částech a určení jejich hranic umožňuje prostorovou vizualizaci detekovaných ploch. Doplnění barevné informace ze vstupního mračen bodů nabízí navíc interaktivnější vizualizaci skenovaného prostoru. Praktické výsledky prezentují jeho široké možnosti použití. Přesnost určení parametrů je závislá zejména na kvalitě vstupního zpracovávaného mračen bodů.

Prezentovaný koncept zpracování mračen bodů pomocí úrovnového obrazu nabízí široké možnosti aplikace rozšířených metod zpracování obrazu. Plochy je možné detekovat libovolnou dostupnou metodou a následně potom využít všech předností nabízející úrovnový obraz. Navržený koncept může být dále používán a rozšiřován jinými výzkumníky pro pokročilé zpracování mračen bodů jako je detekce přítomných objektů na pozorované scéně, robotická navigace a další. Stejně, jako lze vytvořit mračno bodů z libovolného 2D obrazu, kde dimenzi  $Z$  tvoří jeho jasová složka nebo hloubkový obraz zpětně transformovat na mračno bodů, by v budoucnu mohl úrovnový obraz sloužit pro detekci prostorových objektů a tvarů, ne pouze plochy. Po rozšíření rozsahu úrovně jeho jednotlivé pixely mohou popisovat tvar objektů v prostoru. Navíc by tak vznikl klasický šedotónový obraz, na který lze aplikovat další metody zpracování obrazu například segmentační nebo hranové detektory a další. Hodnoty jeho pixelů budou mít stále reálnou pozici ve zkoumaném prostoru a kombinací získaných výstupů jejich zpracování s reálným prostorem by bylo možné i segmentovat jeho určité části. Vzniklý obraz úrovně není zatím zkoumán s ohledem na jeho tvar. V budoucnu může být také obraz analyzován s ohledem na detekci základních geometrických tvarů, které dále sníží nutný počet popisných bodů a zjednoduší vizualizaci pozorované scény. U hrubých obrazových dat bude možné rozpracovat i další metody vylepšení kvality jeho tvaru, než je nyní využívaná funkce zacelování jeho mezer, s cílem odhadování přítomných tvarů v analyzovaném prostředí, které bude mít pozitivní vliv i na jeho celkovou vizualizaci.

## 8 Reference

- ALEC, 2016. HP acquires 3D scanning companies David Vision Systems and David 3D Solutions. *3ders* [online]. [cit. 2018-07-05]. Dostupné z: <https://www.3ders.org/articles/20160705-hp-acquires-3d-scanning-david-vision-systems-and-david-3d-solutions.html>
- ARCORE DEVELOPERS, 2018. Fundamental Concepts. *ARCore - Google Developer* [online]. Google [cit. 2018-08-02]. Dostupné z: <https://developers.google.com/ar/discover/concepts>
- ARIKAN, Murat, Reinhold PREINER, Claus SCHEIBLAUER, Stefan JESCHKE a Michael WIMMER, 2014. Large-Scale Point-Cloud Visualization through Localized Textured Surface Reconstruction. *IEEE Transactions on Visualization and Computer Graphics* [online]. **20**(9), 1280-1292 [cit. 2017-03-20]. DOI: 10.1109/TVCG.2014.2312011. ISSN 1077-2626. Dostupné z: <http://ieeexplore.ieee.org/document/6774475/>
- BATAINEH, Safaa, Alfonso BAHILLO, Luis DÍEZ, Enrique ONIEVA a Ikram BATAINEH, 2016. Conditional Random Field-Based Offline Map Matching for Indoor Environments. *Sensors* [online]. **16**(8), 1302- [cit. 2017-04-15]. DOI: 10.3390/s16081302. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/16/8/1302>
- BERAN, Ladislav, Pavel CHMELAR a Lubos REJFEK, 2015. Navigation of robotics platform using monocular visual odometry. In: *2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 213-216 [cit. 2017-05-19]. DOI: 10.1109/RADIOELEK.2015.7129012. ISBN 978-1-4799-8117-5. Dostupné z: <http://ieeexplore.ieee.org/document/7129012/>
- BERGE, Louis-Pierre, Nabil AOUF, Thierry DUVAL a Gilles COPPIN, 2016. Generation and VR visualization of 3D point clouds for drone target validation assisted by an operator. In: *2016 8th Computer Science and Electronic Engineering (CEECE)* [online]. IEEE, s. 66-70 [cit. 2017-03-20]. DOI: 10.1109/CEECE.2016.7835890. ISBN 978-1-5090-2050-8. Dostupné z: <http://ieeexplore.ieee.org/document/7835890/>
- BERGER, Ivan, 2017. First Map-Based Car Navigation System Debuted 14 Years Before GPS. *The IEEE news source* [online]. [cit. 2018-01-11]. Dostupné z: <http://theinstitute.ieee.org/tech-history/technology-history/first-mapbased-car-navigation-system-debuted-14years-before-gps>
- BISMPIGIANNIS, Athanasios, 2007. *Measurements and correction of geometric distortion*. 22 s. Dostupné také z: <http://scien.stanford.edu/pages/labsite/2007/psych221/projects/07/geometric—distortion/geometric—distortion—project.pdf>. Semetrální projekt. Stanford University.
- BOHN, Dieter, 2015. Slamdance: inside the weird virtual reality of Google's Project Tango. *The Verge* [online]. New York: The Verge [cit. 2018-08-05]. Dostupné z: <https://www.theverge.com/a/sundars-google/project-tango-google-io-2015>
- BOUGHORBEL, Faysal, Andreas KOSCHAN, Bisma ABIDI a Mongi ABIDI, 2004. Gaussian fields: a new criterion for 3D rigid registration. *Pattern Recognition* [online]. **37**(7), 1567-1571 [cit. 2017-04-15]. DOI: 10.1016/j.patcog.2004.02.005. ISSN 00313203. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0031320304000615>

- BURGUERA, A., Y. GONZALEZ a G. OLIVER, 2008. The likelihood field approach to sonar scan matching. In: *2008 IEEE/RSJ International Conference on Intelligent Robots and Systems* [online]. IEEE, s. 2977-2982 [cit. 2017-04-30]. DOI: 10.1109/IROS.2008.4650631. ISBN 978-1-4244-2057-5. Dostupné z: <http://ieeexplore.ieee.org/document/4650631/>
- BURGUERA, Antoni, Yolanda GONZÁLEZ a Gabriel OLIVER, 2012. A Probabilistic Framework for Sonar Scan Matching Localization. *Advanced Robotics* [online]. **22**(11), 1223-1241 [cit. 2017-04-12]. DOI: 10.1163/156855308X338447. ISSN 0169-1864. Dostupné z: <https://www.tandfonline.com/doi/full/10.1163/156855308X338447>
- COLANTONI, Philippe, 2004. *Color Space Transformations* [online]. [cit. 2017-08-08]. Dostupné z: <http://faculty.kfupm.edu.sa/ics/lahouari/Teaching/colorspacetransform-1.0.pdf>
- CRANZ, Alex, 2018. Microsoft Kinect Refuses to Die. *GIZMODO* [online]. GIZMODO [cit. 2018-07-30]. Dostupné z: <https://gizmodo.com/microsoft-kinect-refuses-to-die-1825847023>
- CyArk* [online], 2018. USA: CYARK [cit. 2018-06-25]. Dostupné z: <http://cyark.org/>
- CZERNIAWSKI, Tomas, Bharathwaj SANKARAN, Mohamamd NAHANGI, Carl T.M. HAAS a Fernanda L. LEITE, 2018. 6D DBSCAN-based segmentation of building point clouds for planar object classification. *Automation in Construction* [online]. **88**, 44-58 [cit. 2018-03-20]. DOI: 10.1016/j.autcon.2017.12.029. ISSN 09265805. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S092658051730393X>
- DAO, Nguyen-Luc, Yuzhe ZHANG, Jianmin ZHENG a Jianfei CAI, 2015. Kinect-based non-intrusive human gait analysis and visualization. In: *2015 IEEE 17th International Workshop on Multimedia Signal Processing (MMSP)* [online]. IEEE, s. 1-6 [cit. 2017-03-20]. DOI: 10.1109/MMSP.2015.7340804. ISBN 978-1-4673-7478-1. Dostupné z: <http://ieeexplore.ieee.org/document/7340804/>
- DEEPAK, Rajawat, 2016. Lenovo Phab 2 Pro becomes First Google Tango Smartphone. *Smartprix* [online]. New Delhi: Smartprix [cit. 2018-08-21]. Dostupné z: <https://www.smartprix.com/bytes/lenovo-phab-2-pro-becomes-first-google-tango-smartphone/>
- DEVAUX, Alexandre a Mathieu BRÉDIF, 2016. Realtime projective multi-texturing of pointclouds and meshes for a realistic street-view web navigation. In: *Proceedings of the 21st International Conference on Web3D Technology - Web3D '16* [online]. New York, New York, USA: ACM Press, s. 105-108 [cit. 2017-03-20]. DOI: 10.1145/2945292.2945311. ISBN 9781450344289. Dostupné z: <http://dl.acm.org/citation.cfm?doid=2945292.2945311>
- DUNN, Fletcher a Ian PARBERRY, 2011. *3D math primer for graphics and game development*. 2nd ed. Boca Raton, FL: A K Peters/CRC Press. ISBN 1568817231.
- Emgu CV, 2018. *Emgu CV: OpenCV in .NET (C#, VB, C++ and more)* [online]. [cit. 2018-07-15]. Dostupné z: [http://www.emgu.com/wiki/index.php/Main\\_Page](http://www.emgu.com/wiki/index.php/Main_Page)
- EVANS, Scott, 2013. 1993 EUNOS/MAZDA COSMO CLASSIC DRIVE. *MOTORTREND* [online]. [cit. 2018-01-11]. Dostupné z: <http://www.motortrend.com/news/12q2-1993-eunos-mazda-cosmo-drive/>

- FINTEL, René, 2015. Modern CMOS Cameras as Replacements for CCD Cameras. In: *Basler AG* [online]. Německo [cit. 2017-08-05]. Dostupné z: <https://www.baslerweb.com/en/sales-support/downloads/document-downloads/modern-cmos-cameras/>
- GONZALEZ, Rafael, Richard WOODS a Steven EDDINS, 2009. *Digital Image processing using MATLAB*. 2nd ed. S.I.: Gatesmark Pub. ISBN 978-0-9820854-0-0.
- GRAMATKE, Martin, 2015. High-Resolution Time-of-Flight Cameras. In: *Basler AG* [online]. Německo [cit. 2018-06-06]. Dostupné z: <https://www.baslerweb.com/en/sales-support/downloads/document-downloads/time-of-flight-cameras/>
- HAN, Kevin a Mani GOLPARVAR-FARD, 2017. Potential of big visual data and building information modeling for construction performance analytics: An exploratory study. *Automation in Construction* [online]. **73**, 184-198 [cit. 2017-03-20]. DOI: 10.1016/j.autcon.2016.11.004. ISSN 09265805. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0926580516303466>
- HELLAND, Tanner, 2013. A simple algorithm for correcting lens distortion. *Tanner Helland (dot) com* [online]. [cit. 2015-05-04]. Dostupné z: <http://www.tannerhelland.com/4743/simple-algorithm-correcting-lens-distortion/>
- HERN, Alex, 2015. Project Tango: Google is building it, but will they come?. *The Guardian* [online]. London: The Guardian [cit. 2018-08-01]. Dostupné z: <https://www.theguardian.com/technology/2015/dec/28/google-project-tango-nexus-mobile-space-awareness>
- HULIK, Rostislav, Michal SPANEL, Pavel SMRZ a Zdenek MATERNA, 2014. Continuous plane detection in point-cloud data based on 3D Hough Transform. *Journal of Visual Communication and Image Representation* [online]. **25**(1), 86-97 [cit. 2018-03-05]. DOI: 10.1016/j.jvcir.2013.04.001. ISSN 10473203. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S104732031300062X>
- CHEN, Chi, Bisheng S. YANG a Shuang SONG, 2016. Low Cost and Efficient 3d Indoor Mapping Using Multiple Consumer Rgb-D Cameras. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* [online]. **-1**, 169-174 [cit. 2017-03-20]. DOI: 10.5194/isprs-archives-XLI-B1-169-2016. ISSN 2194-9034. Dostupné z: <http://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLI-B1/169/2016/>
- CHMELAROVA, Natalija, Pavel CHMELAR, Ladislav BERAN a Lubos REJFEK, 2016. Improving precision of laser line detection in 3D range scanning systems. In: *2016 26th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 207-212 [cit. 2017-01-09]. DOI: 10.1109/RADIOELEK.2016.7477409. ISBN 978-1-5090-1674-7. Dostupné z: <http://ieeexplore.ieee.org/document/7477409/>
- CHMELAR, Pavel a Abdsamad BENKRID, 2014a. Efficiency of HSV over RGB Gaussian Mixture Model for fire detection. In: *2014 24th International Conference Radioelektronika* [online]. IEEE, s. 1-4 [cit. 2017-07-24]. DOI: 10.1109/Radioelek.2014.6828426. ISBN 978-1-4799-3715-8. Dostupné z: <http://ieeexplore.ieee.org/document/6828426/>

- CHMELAR, Pavel, Ladislav BERAN, Natalija CHMELAROVA a Lubos REJFEK, 2018b. Advanced plane properties by using level image. In: *2018 28th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 1-6 [cit. 2018-06-11]. DOI: 10.1109/RADIOELEK.2018.8376365. ISBN 978-1-5386-2485-2. Dostupné z: <https://ieeexplore.ieee.org/document/8376365/>
- CHMELAR, Pavel, Ladislav BERAN a Nataliia KUDRIAVTSEVA, 2014c. Projection of point cloud for basic object detection. In: *Proceedings ELMAR-2014* [online]. IEEE, s. 1-4 [cit. 2018-08-20]. DOI: 10.1109/ELMAR.2014.6923303. ISBN 978-953-184-199-3. Dostupné z: <http://ieeexplore.ieee.org/document/6923303/>
- CHMELAR, Pavel, Ladislav BERAN a Nataliia KUDRIAVTSEVA, 2015b. The laser color detection for 3D range scanning using Gaussian mixture model. In: *2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 248-253 [cit. 2017-02-04]. DOI: 10.1109/RADIOELEK.2015.7129023. ISBN 978-1-4799-8117-5. Dostupné z: <http://ieeexplore.ieee.org/document/7129023/>
- CHMELAR, Pavel, Ladislav BERAN a Lubos REJFEK, 2016. The Depth Map Construction from a 3D Point Cloud. *MATEC Web of Conferences* [online]. **75**, 03005- [cit. 2016-10-12]. DOI: 10.1051/mateconf/20167503005. ISSN 2261-236X. Dostupné z: <http://www.mateconferences.org/10.1051/mateconf/20167503005>
- CHMELAR, Pavel, Ladislav BERAN, Lubos REJFEK a Natalija CHMELAROVA, 2017a. The point cloud visualisation for rotary optical rangefinders. In: *2017 27th International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 1-6 [cit. 2017-03-06]. DOI: 10.1109/RADIOELEK.2017.7937589. ISBN 978-1-5090-4591-4. Dostupné z: <http://ieeexplore.ieee.org/document/7937589/>
- CHMELAR, Pavel, Ladislav BERAN, Lubos REJFEK a Nataliia KUDRIAVTSEVA, 2015a. Effective lens distortion correction for 3D range scanning systems. In: *2015 57th International Symposium ELMAR (ELMAR)* [online]. IEEE, s. 37-40 [cit. 2017-09-08]. DOI: 10.1109/ELMAR.2015.7334490. ISBN 978-953-184-209-9. Dostupné z: <http://ieeexplore.ieee.org/document/7334490/>
- CHMELAR, Pavel a Martin DOBROVOLNY, 2013. The fusion of ultrasonic and optical measurement devices for autonomous mapping. In: *2013 23rd International Conference Radioelektronika (RADIOELEKTRONIKA)* [online]. IEEE, s. 292-296 [cit. 2017-02-06]. DOI: 10.1109/RadioElek.2013.6530934. ISBN 978-1-4673-5519-3. Dostupné z: <http://ieeexplore.ieee.org/document/6530934/>
- CHMELAR, Pavel a Martin DOBROVOLNY, 2014b. The Laser Line Detection for Autonomous Mapping Based on Color Segmentation. In: *International Journal of Computer and Information Engineering* [online]. Vol. 8. World Academy of Science, Engineering and Technology, s. 19-24 [cit. 2017-02-04].
- CHMELAR, Pavel, Lubos REJFEK, Ladislav BERAN a Martin DOBROVOLNY, 2017b. A point cloud decomposition by the 3D level scanning for planes detection. *International Journal of ADVANCED AND APPLIED SCIENCES* [online]. **4**(11), 121-126 [cit. 2017-11-27]. DOI: 10.21833/ijaas.2017.011.019. ISSN 2313626X. Dostupné z: <http://www.sciencegate.com/IJAAS/V4I11/Chmelar.html>



- CHMELAR, Pavel, Lubos REJFEK, Ladislav BERAN, Natalija CHMELAROVA a Martin DOBROVOLNY, 2018a. Point Cloud Plane Visualization by Using Level Image. *Journal of Fundamental and Applied Sciences* [online]. 2018(10), 547-560 [cit. 2018-04-05]. DOI: 10.4314/jfas.v10i3s.46. ISSN 1112-9867. Dostupné z: <https://www.ajol.info/index.php/jfas/article/view/171552>
- CHMELAR, Pavel, 2013. *Automatizované mapování prostoru*. Pardubice. Doktorské disertační minimum. Univerzita Pardubice.
- CHMELAR, Pavel a Martin DOBROVOLNÝ, 2012. The Optical Measuring Device for the Autonomous Exploration and Mapping of unknown Environments. In: *Perner's Contacts* [online]. Universita Pardubice, s. 41-50 [cit. 2017-01-15]. VII.: 4. ISSN 1801-674X.
- JIN, Zhi, Tammam TILLO, Wenbin ZOU, Yao ZHAO a Xia LI, 2017. Robust Plane Detection using Depth Information from a Consumer Depth Camera. *IEEE Transactions on Circuits and Systems for Video Technology* [online]. [cit. 2018-03-05]. DOI: 10.1109/TCSVT.2017.2780181. ISSN 1051-8215. Dostupné z: <http://ieeexplore.ieee.org/document/8166766/>
- JOHNSON, Micah a Hany FARID, 2006. Exposing digital forgeries through chromatic aberration. In: *Proceeding of the 8th workshop on Multimedia and security - MM&Sec '06* [online]. New York, New York, USA: ACM Press, s. 48- [cit. 2017-09-29]. DOI: 10.1145/1161366.1161376. ISBN 1595934936. Dostupné z: <http://portal.acm.org/citation.cfm?doid=1161366.1161376>
- KIM, Dongchul, Seungho CHAE, Jonghoon SEO, Yoonsik YANG a Tack-Don HAN, 2017. Realtime plane detection for projection Augmented Reality in an unknown environment. In: *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* [online]. IEEE, s. 5985-5989 [cit. 2018-03-06]. DOI: 10.1109/ICASSP.2017.7953305. ISBN 978-1-5090-4117-6. Dostupné z: <http://ieeexplore.ieee.org/document/7953305/>
- KJER, Hans a Jakob WILM, 2010. *Evaluation of surface registration algorithms for PET motion correction*. Bakalářská práce. Technical University of Denmark.
- KOT, Tomas, Petr NOVAK a Jan BABJAK, 2016. Visualization of point clouds built from 3D scanning in coal mines. In: *2016 17th International Carpathian Control Conference (ICCC)* [online]. IEEE, s. 372-377 [cit. 2017-03-20]. DOI: 10.1109/CarpathianCC.2016.7501126. ISBN 978-1-4673-8606-7. Dostupné z: <http://ieeexplore.ieee.org/document/7501126/>
- KURBAN, Rifat, Florenc SKUKA a Hakki BOZPOLAT, 2015. Plane Segmentation of Kinect Point Clouds using RANSAC. In: *The 7th International Conference on Information Technology* [online]. Al-Zaytoonah University of Jordan, s. 545-551 [cit. 2017-11-15]. DOI: 10.15849/icit.2015.0098. ISBN 9789957858339. Dostupné z: [http://icit.zuj.edu.jo/icit15/DOI/Modeling\\_and\\_Simulations/0098.pdf](http://icit.zuj.edu.jo/icit15/DOI/Modeling_and_Simulations/0098.pdf)
- LEICA GEOSYSTEMS, 2007. *Leica DISTO™ D3*. Dostupné také z: <http://www.rigstar.com/DistoD3Manual.pdf>

- LI, Jiang-Wei, Ding-Fu ZHENG, Zhi-Hong GUAN, Chao-Yang CHEN, Xiao-Wei JIANG a Xian-He ZHANG, 2016a. Indoor 3D scene reconstruction for mobile robots using Microsoft kinect sensor. In: *2016 35th Chinese Control Conference (CCC)* [online]. IEEE, s. 6324-6328 [cit. 2017-03-20]. DOI: 10.1109/ChiCC.2016.7554350. ISBN 978-9-8815-6391-0. Dostupné z: <http://ieeexplore.ieee.org/document/7554350/>
- LI, Jinbo, Xiuli MA, Yangyang JIA a Xueli ZHOU, 2012. 3D visualization for heart model from point clouds. In: *2012 International Conference on Audio, Language and Image Processing* [online]. IEEE, s. 1077-1081 [cit. 2017-03-20]. DOI: 10.1109/ICALIP.2012.6376776. ISBN 978-1-4673-0174-9. Dostupné z: <http://ieeexplore.ieee.org/document/6376776/>
- LI, Mantian, Mingming ZHANG, Yu FU, Wei GUO, Xingneng ZHONG, Xin WANG a Fei CHEN, 2016b. Fast and robust mapping with low-cost Kinect V2 for photovoltaic panel cleaning robot. In: *2016 International Conference on Advanced Robotics and Mechatronics (ICARM)* [online]. IEEE, s. 95-100 [cit. 2017-03-20]. DOI: 10.1109/ICARM.2016.7606901. ISBN 978-1-5090-3364-5. Dostupné z: <http://ieeexplore.ieee.org/document/7606901/>
- LONG, Fuhui, Jianlong ZHOU, Hanchuan PENG a Fran LEWITTER, 2012. Visualization and Analysis of 3D Microscopic Images. *PLoS Computational Biology* [online]. **8**(6) [cit. 2018-10-16]. DOI: 10.1371/journal.pcbi.1002519. ISSN 1553-7358. Dostupné z: <https://dx.plos.org/10.1371/journal.pcbi.1002519>
- LO, Raymond a William LO, 2015. *OpenGL Data Visualization Cookbook*. Packt Publishing. ISBN 978-1782169727.
- LU, Feng a Evangelos MILIOS, 1997. Robot pose estimation in unknown environments by matching 2D range scans. *Journal of Intelligent and Robotic Systems* [online]. **18**(3), 249-275 [cit. 2017-03-15]. DOI: 10.1023/A:1007957421070. ISSN 09210296. Dostupné z: <http://link.springer.com/10.1023/A:1007957421070>
- MAGNUSSON, Martin, 2013. *The three-dimensional normal-distributions transform: an efficient representation for registration, surface analysis, and loop detection*. Dizertační práce. Örebro universitet.
- MITRA, Niloy, Natasha GELFAND, Helmut POTTMANN a Leonidas GUIBAS, 2004. Registration of point cloud data from a geometric optimization perspective. In: *Proceedings of the 2004 Eurographics/ACM SIGGRAPH symposium on Geometry processing - SGP '04* [online]. New York, New York, USA: ACM Press, s. 22- [cit. 2017-04-26]. DOI: 10.1145/1057432.1057435. ISBN 3905673134. ISSN 17278384. Dostupné z: <http://portal.acm.org/citation.cfm?doid=1057432.1057435>
- MONTESANO, L., J. MINGUEZ a L. MONTANO, 2005. Probabilistic scan matching for motion estimation in unstructured environments. In: *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems* [online]. IEEE, s. 3499-3504 [cit. 2017-03-15]. DOI: 10.1109/IROS.2005.1545182. ISBN 0-7803-8912-3. Dostupné z: <http://ieeexplore.ieee.org/document/1545182/>
- NÜCHTER, Andreas., 2009. *3D robotic mapping: the simultaneous localization and mapping problem with six degrees of freedom*. Heidelberg: Springer. ISBN 9783540898849.

- NÜCHTER, Andreas, Jan ELSEBERG, Peter SCHNEIDER a Dietrich PAULUS, 2010. Study of parameterizations for the rigid body transformations of the scan registration problem. *Computer Vision and Image Understanding* [online]. **114**(8), 963-980 [cit. 2017-05-19]. DOI: 10.1016/j.cviu.2010.03.007. ISSN 10773142. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S107731421000072X>
- O'HARA, Andrew, 2018. Hands on with the new ARKit Measure app in iOS 12. *Appleinsider* [online]. Appleinsider [cit. 2018-08-10]. Dostupné z: <https://appleinsider.com/articles/18/06/11/hands-on-with-the-new-arkit-measure-app-in-ios-12>
- OCHMANN, Sebastian, Richard VOCK, Raoul WESSEL a Reinhard KLEIN, 2016. Automatic reconstruction of parametric building models from indoor point clouds. *Computers & Graphics* [online]. **54**, 94-103 [cit. 2017-03-20]. DOI: 10.1016/j.cag.2015.07.008. ISSN 00978493. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0097849315001119>
- OLSEN, Michael, Elizabeth JOHNSTONE, Falko KUESTER, Neal DRISCOLL a Scott ASHFORD, 2011. New Automated Point-Cloud Alignment for Ground-Based Light Detection and Ranging Data of Long Coastal Sections. *Journal of Surveying Engineering* [online]. **137**(1), 14-25 [cit. 2017-03-20]. DOI: 10.1061/(ASCE)SU.1943-5428.0000030. ISSN 0733-9453. Dostupné z: <http://ascelibrary.org/doi/10.1061/%28ASCE%29SU.1943-5428.0000030>
- ON SEMICONDUCTOR, 2017. *MT9P031: 5 MP 1/3" CMOS Image Sensor*. Rev. 10. Semiconductor Components Industries, LLC. Dostupné také z: <http://www.onsemi.com/pub/Collateral/MT9P031-D.PDF>
- PALLADINO, Tommy, 2018. Google Flips the Switch on Web-Based Augmented Reality Experiences for ARCore. *Next Reality* [online]. New York: Next Reality [cit. 2018-08-05]. Dostupné z: <https://next.reality.news/news/google-flips-switch-web-based-augmented-reality-experiences-for-arcore-0185317/>
- PointCloudLibrary, 2018. *GitHub* [online]. USA: Microsoft [cit. 2018-11-11]. Dostupné z: <https://github.com/PointCloudLibrary/pcl/releases>
- POYNTON, Charles, 1996. *A technical introduction to digital video*. New York: J. Wiley. ISBN 9780471122531.
- RIPKA, Pavel, ed. a Alois TIPEK, ed., 2003. *Master books on sensors: modular courses on modern sensors Leonardo da Vinci project CZ/PP-134026*. Praha: BEN - technical literature. ISBN 80-7300-129-2.
- RUSU, Radu a Steve COUSINS, 2011. 3D is here: Point Cloud Library (PCL). In: *2011 IEEE International Conference on Robotics and Automation* [online]. IEEE, s. 1-4 [cit. 2017-03-20]. DOI: 10.1109/ICRA.2011.5980567. ISBN 978-1-61284-386-5. Dostupné z: <http://ieeexplore.ieee.org/document/5980567/>
- SHANMUGAM, Akshaya, Mohammad USMANI, Addison MAYBERRY, David PERKINS, Daniel HOLCOMB a James BRODY, 2018. Imaging systems and algorithms to analyze biological samples in real-time using mobile phone microscopy. *PLOS ONE* [online]. **13**(3) [cit. 2018-10-12]. DOI: 10.1371/journal.pone.0193797. ISSN 1932-6203. Dostupné z: <https://dx.plos.org/10.1371/journal.pone.0193797>

- SKULIMOWSKI, Piotr, Mateusz OWCZAREK a Paweł STRUMIHO, 2017. *Ground plane detection in 3D scenes for an arbitrary camera roll rotation through "V-disparity" representation* [online]. In: . s. 669-674 [cit. 2018-03-15]. DOI: 10.15439/2017F40. Dostupné z: <https://fedcsis.org/proceedings/2017/drp/40.html>
- SUGAR, Catherine a Gareth JAMES, 2003. Finding the Number of Clusters in a Dataset. *Journal of the American Statistical Association* [online]. **98**(463), 750-763 [cit. 2017-02-06]. DOI: 10.1198/016214503000000666. ISSN 0162-1459. Dostupné z: <http://www.tandfonline.com/doi/abs/10.1198/016214503000000666>
- SURÝNEK, Tomáš, 2008. *Určení vzdálenosti cíle hloubkoměrným principem se strukturovaným světlem*. Zlín: Univerzita Tomáše Bati ve Zlíně, 60 s., 3 s. příloh. Dostupné také z: <http://hdl.handle.net/10563/7410>. Diplomová práce. Tomas Bata University in Zlín. Faculty of Applied Informatics, Ústav automatizace a řídicí techniky. Vedoucí práce Kvasnica, Milan.
- TESS, 2018. New Artec Ray 3D scanner lets you digitize large-scale objects with the touch of a button. *3ders* [online]. [cit. 2018-07-07]. Dostupné z: <https://www.3ders.org/articles/20180322-new-artec-ray-3d-scanner-lets-you-digitize-large-scale-objects-with-the-touch-of-a-button.html>
- TÖREYIN, B., Yiğithan DEDEOĞLU, Uğur GÜDÜKBAY a A. ÇETIN, 2006. Computer vision based method for real-time fire and flame detection. *Pattern Recognition Letters* [online]. **27**(1), 49-58 [cit. 2017-07-27]. DOI: 10.1016/j.patrec.2005.06.015. ISSN 01678655. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0167865505001819>
- WYMAN, Chris, Rama HOETZLEIN a Aaron LEFOHN, 2016. Frustum-Traced Irregular Z-Buffers: Fast, Sub-Pixel Accurate Hard Shadows. *IEEE Transactions on Visualization and Computer Graphics* [online]. **22**(10), 2249-2261 [cit. 2017-04-06]. DOI: 10.1109/TVCG.2016.2572689. ISSN 1077-2626. Dostupné z: <http://ieeexplore.ieee.org/document/7478644/>
- YOUSIF, Khalid, Alireza BAB-HADIASHAR a Reza HOSEINNEZHAD, 2013. 3D Registration in Dark Environments Using RGB-D Cameras. In: *2013 International Conference on Digital Image Computing: Techniques and Applications (DICTA)* [online]. IEEE, s. 1-8 [cit. 2016-02-15]. DOI: 10.1109/DICTA.2013.6691470. ISBN 978-1-4799-2126-3. Dostupné z: <http://ieeexplore.ieee.org/document/6691470/>
- ZEINELDIN, Ramy a Nawal EL-FISHAWY, 2016. Fast and accurate ground plane detection for the visually impaired from 3D organized point clouds. In: *2016 SAI Computing Conference (SAI)* [online]. IEEE, s. 373-379 [cit. 2018-03-10]. DOI: 10.1109/SAI.2016.7556009. ISBN 978-1-4673-8460-5. Dostupné z: <http://ieeexplore.ieee.org/document/7556009/>

## Seznam obrázků

Obr. 2.1 – Reprezentace povrchu buňky v NDT vlastními čísly, (a) kolmá stěna, (b) rovina .....	16
Obr. 3.1 – Systémy bezdotykového měření.....	19
Obr. 3.2 – Mobilní platforma, (a) blokové schéma, (b) QE charakteristika kamerového čipu MT9P031 (ON Semiconductor, 2017) .....	22
Obr. 3.3 – Mobilní platforma, (a) měření vzdálenosti, (b) snímek měření .....	22
Obr. 3.4 – Princip triangulační metody, (a) horizontální řez kamerou s označenými parametry, (b) ilustrace vodorovného řezu na reálné scéně .....	23
Obr. 3.5 – Blokové schéma skenování prostoru.....	23
Obr. 3.6 – Kalibrace optického měřiče vzdálenosti.....	24
Obr. 3.7 – Nelinearita optického měřiče vlivem změny parametru $h$ .....	25
Obr. 3.8 – Příklady vhodně nastavené saturace laserové čáry v procesu kalibrace .....	25
Obr. 3.9 – Ukázka barelového zkreslení, (a) zkreslený obraz, (b) korigovaný obraz .....	27
Obr. 3.10 – Ukázka hranové detekce Canny na vstupním obrazu, (a) $sDist = 1$ , (b) $sDist = 1,8$ .....	28
Obr. 3.11 – Porovnání akumulátorů Houghovy transformace, (a) rovná čára, (b) čára zakřivená.....	29
Obr. 3.12 – Maximum $Ha$ přes všechny sloupce po aplikaci (3.8), (a) $sDist = 1$ , (b) $sDist = 1,8$ .....	29
Obr. 3.13 – Graf sumy gradientů pro parametr $sDist = [1,3]$ .....	30
Obr. 3.14 – Ilustrace zkreslení chromatické aberace.....	31
Obr. 3.15 – Chromatická aberace použitého objektivu, (a) snímek měření s detailem, (b) výstup korekce.....	32
Obr. 3.16 – Blokové schéma algoritmu určení vzdálenosti na pozicích segmentovaného laseru.....	33
Obr. 3.17 – Zobrazení zeleného kanálu laseru před filtrací, (a) prostorové, (b) plošné - řádek 100 .....	33
Obr. 3.18 – Zobrazení zeleného kanálu laseru po filtraci, (a) prostorové, (b) plošné - řádek 100 .....	34
Obr. 3.19 – Ukázka Gaussian mixture modelu pro $K = 3$ .....	36
Obr. 3.20 – Trénovací pixely GMM použitého laseru, (a) původní pixely, (b) seřazené podle jasu.....	36
Obr. 3.21 – Pixely laseru z Obr. 3.20 zobrazené v barevném prostoru RGB, (a) původní, (b) seřazené.....	37
Obr. 3.22 – Výsledek EM algoritmu pro vstupní data z Obr. 3.21 (a), (a) GMM $K = 8$ , (b) $\ln p$ .....	39
Obr. 3.23 – Výsledek EM algoritmu pro vstupní data z Obr. 3.21 (b), (a) GMM $K = 14$ , (b) $\ln p$ .....	39
Obr. 3.24 – Určení optimálního $K$ pro HSV GMM, (a) normální model, (b) detailní model .....	40
Obr. 3.25 – GMM pro RGB prostor, (a) normální, (b) detailní, (c) saturační.....	41
Obr. 3.26 – GMM pro YCbCr prostor, (a) normální, (b) detailní, (c) saturační .....	41
Obr. 3.27 – GMM pro HSV prostor, (a) normální, (b) detailní, (c) saturační.....	42
Obr. 3.28 – GMM pro $L^*a^*b^*$ prostor, (a) normální, (b) detailní, (c) saturační.....	42
Obr. 3.29 – Skupina trénovacích pixelů GMM, (a) normální, (b) detailní, (c) saturační....	43
Obr. 3.30 – Vstupní obraz z procesu měření pro ilustraci algoritmu skládání masek detekčních modelů laseru, (a) obraz, (b) jasová složka v prostorovém zobrazení .....	43
Obr. 3.31 – Jednotlivé kanály vstupního obrazu z Obr. 3.30, (a) RGB, (b) HSV .....	44

Obr. 3.32 – Sestavení normální masky podle (3.22), (a) maska, (b) prostorová vizualizace aplikované masky na vstupní obraz Obr. 3.30 (a), (c) segmentované pixely normální maskou.....	44
Obr. 3.33 – Rozdíly normální masky <i>MLN</i> a normální citlivostní masky <i>MLNs</i> , (a) 4. maska, (b) 6. maska .....	45
Obr. 3.34 – Zkomponovaná saturační maska, (a) maska, (b) prostorová vizualizace s vyznačenými komponentami laserové čáry – červené šipky, (c) segmentované pixely saturační maskou .....	45
Obr. 3.35 – Detailní pohled na měřicí bod laseru s přítomností saturačních pixelů, (a) normální maska s prostorovou vizualizací, (b) logický součet normální a saturační masky včetně vizualizace.....	46
Obr. 3.36 – Využití saturační masky pro kompozici finální, (a) využití elementy zobrazené zelenou barvou, (b) maska pro odstranění nežádoucích elementů finální masky .....	46
Obr. 3.37 – Ukázka vyhodnocení kritéria (3.27), (a) akceptovaná šířka, (b) příliš široká laserová čára .....	47
Obr. 3.38 – Ukázka vyhodnocení kritéria (3.28), (a) vertikální čára, (b) diagonální čára ..	48
Obr. 3.39 – Ukázka vyhodnocení kritéria (3.29), (a) výsledky pro tři měřicí body, (b) prostorová vizualizace segmentované části.....	49
Obr. 3.40 – Finální segmentační maska pro obraz Obr. 3.30, (a) maska, (b) prostorová vizualizace .....	49
Obr. 3.41 – Nežádoucí jevy segmentace, (a) odražený paprsek v rohu místnosti, (b) přítomný objekt ve spektru detekovaného laseru, (c) rozdělená přímka na noze stolu, (d) satureovaná čára s okolím .....	50
Obr. 3.42 – Rozdělení měřicích bodů za účelem analýzy, (a) vizualizace s měřicími body, (b) prostorová vizualizace rozdělení.....	51
Obr. 3.43 – Ilustrace velmi blízké satureované laserové čáry, (a) vstupní obraz, (b) prostorová vizualizace jasové složky, (c) průběh jednotlivých složek obrazu.....	53
Obr. 3.44 – Statistická analýza tvaru elementu s ukázkou parametrů, (a) vertikální čára splňující $EW\sigma_2$ , $EL\sigma_2$ a $EW\sigma_2$ , (b) element nespĺňuje $EW\sigma_2$ , (c) čára splňuje $EW\sigma_2$ , (d) element nespĺňuje $EW\sigma_2$ .....	54
Obr. 3.45 – Grafické znázornění akceptování parametrů elementu definované kritériem (3.39), (a) levá část, (b) pravá část .....	54
Obr. 3.46 – Správně určené měřicí pozice funkcí „LaserLineAnalysis“ pro Obr. 3.41, (a) čára s odrazem, (b) zelený objekt, (c) rozdvojená čára, (d) satureovaná čára .....	55
Obr. 3.47 – Určené pozice laserové čáry s vyznačenými odchylkami pixelů od středu obrazu, (a) pro vstupní obraz Obr. 3.30, (b) pro velmi blízkou satureovanou čáru z Obr. 3.43 (a).....	55
Obr. 3.48 – Ilustrace způsobu skenování, (a) směr otáčení platformy, (b) posun laserové čáry .....	56
Obr. 3.49 – Ukázka sestrojených mračen bodů, (a) laboratoř, (b) chodba.....	57
Obr. 3.50 – Princip hledání šablony ve vstupním obraze, (a) vstupní obraz se šablonou, (b) akumulátor normalizované 2D korelace s vyznačeným bodem nalezeného posunu.....	59
Obr. 3.51 – Barevná vizualizace mračen bodů, (a) laboratoř z Obr. 3.49 (b), (b) chodba ..	59
Obr. 3.52 – Chyba kolmosti laserové čáry při kalibraci, (a) celkový pohled se zvětšenými částmi obrazu, (b) detailní pohled s vyznačeným úhlem.....	60
Obr. 3.53 – Chybně vytvořené mračno bodů, (a) mračno bodů s vyznačeným úhlem chyby kolmosti, (b) korekční křivka pro celý rozsah optického měřiče vzdálenosti .....	61
Obr. 3.54 – Opravené mračno bodů, (a) mračno bodů, (b) korekční křivka za rozsahem měřidla .....	62



Obr. 3.55 – Graf přesnosti měření, (a) naměřená vzdálenost a chyba měření, (b) chyba v procentech.....	63
Obr. 3.56 – Porovnání rozměrů výsledného mračna bodů se skutečným prostorem, (a) dveře ve skenovaném prostředí, (b) odpovídající výsek mračna bodů (zadní pohled) .....	64
Obr. 3.57 – Porovnání rozměrů výsledného mračna bodů se skutečným prostorem, (a) skříň ve skenovaném prostředí, (b) odpovídající výsek mračna bodů .....	65
Obr. 3.58 – Porovnání kvality mračen bodů, (a) vzdálenost určená metodou centroidu, (b) vzdálenost určená funkcí „LaserLineAnalysis“ .....	65
Obr. 3.59 – Kvalita segmentačních masek barevných modelů, (a) RGB, (b) YCbCr, (c) HSV, (d) $L^*a^*b^*$ .....	66
Obr. 3.60 – Skenované prostory, (a) chodba č. 1, (b) chodba č. 2, (c) chodba č. 3, (d) laboratoř .....	66
Obr. 3.61 – Grafické znázornění výsledků jednotlivých kroků skenování $\varphi_k$ , (a) chodba č. 1, (b) chodba č. 2, (c) chodba č. 3, (d) laboratoř .....	67
Obr. 4.1 – Používané souřadnicové prostory, (a) globální vztah, (b) přechody prostorů....	70
Obr. 4.2 – Výsledek rotace objektu v prostoru kolem souřadné osy Z .....	74
Obr. 4.3 – Požadovaná rotace objektu v prostoru, 1) posun vertikálního prostoru na počátek, 2) rotace objektového prostoru v počátku, 3) návrat objektu na původní pozici..	74
Obr. 4.4 – Projekce pomocí homogenní souřadnice na rovinu $w = 1$ ve 2D.....	75
Obr. 4.5 – Princip perspektivní projekce .....	79
Obr. 4.6 – Posunutí projekční roviny .....	80
Obr. 4.7 – Příklady perspektivní projekce .....	81
Obr. 5.1 – Blokové schéma systému automatického skenování a mapování prostoru.....	82
Obr. 5.2 – Vstupní mračno s odlehlými body, (a) mračno bodů, (b) histogramy souřadných os.....	83
Obr. 5.3 – Výstupní mračno po odstranění odlehlých bodů, (a) mračno bodů, (b) histogramy souřadných os s nově vyznačenými rozsahy prostřednictvím červených bodů	84
Obr. 5.4 – Vstupní mračno bodů pro určení jeho orientace, (a) mračno, (b) histogramy souřadných os .....	85
Obr. 5.5 – Detailní pohled na histogram osy Y, (a) před úpravou, (b) po úpravě s vyznačenými maximy .....	86
Obr. 5.6 – Histogramy os X a Y pro různé hodnoty natočení mračna, (a) původní $0^\circ$ , (b) natočené o $-8^\circ$ .....	86
Obr. 5.7 – Suma histogramu pro jednotlivá natočení mračna bodů, (a) pro osu X, (b) pro osu Y .....	87
Obr. 5.8 – Ukázka struktury kD tree pro prostorové body .....	88
Obr. 5.9 – Horní pohled na skenovanou laboratoř .....	89
Obr. 5.10 – Detail přímého zobrazení mračen bodů, (a) stěny, skříň a dveře, (b) stěny, stůl a okno .....	90
Obr. 5.11 – Původní mračna bodů z měřicích pozic z Obr. 5.9, (a) 1. pozice, (b) 2. pozice, (c) 3. pozice, (d) 4. pozice, (e) 5. pozice, (f) 6. pozice .....	90
Obr. 5.12 – Detail spojení mračen bodů po registraci, (a) stěny, skříň a dveře, (b) stěny, stůl a okno.....	91
Obr. 5.13 – Vizuální porovnání kvality registrace, (a) ICP, (b) NDT .....	91
Obr. 5.14 – Výsledek registrace podlaží složený z 64 individuálních skenů s vyznačenými detaily .....	92
Obr. 5.15 – Problémy algoritmu ICP při vytváření uceleného mračna, pravá část Obr. 5.14 .....	92
Obr. 6.1 – Změna orientace vstupního mračna bodů, (a) původní mračno, (b) rotované podle $CO$ .....	95

Obr. 6.2 – Vytvořené zorné pole kamery, (a) detailní pohled s popisky, (b) vyznačené v mračnu bodů .....	96
Obr. 6.3 – Postup segmentace bodů zorného pole, (a) segmentační obdélníky, (b) finální pohled .....	96
Obr. 6.4 – Transformace bodu na rovinu hloubky, (a) detail transformace, (b) transformační přímky .....	97
Obr. 6.5 – Problémy tvorby hloubkové mapy, (a) zakřivení pohledu, (b) stínění bodů.....	98
Obr. 6.6 – Ukázka hloubkových obrazů, (a) včetně měření vzdálenosti, (b) s rotací $-40^\circ$ v ose $Z$ .....	99
Obr. 6.7 – Hledání sousedních pixelů, (a) pro blízké elementy, (b) směr hledání okrajů elementů .....	99
Obr. 6.8 – Výstup modifikovaného algoritmu spojených komponent, (a) spojení 4, (b) spojení 8, (c) spojení 4 s $iz = 1$ , (d) spojení 8 s $iz = 1$ .....	100
Obr. 6.9 – Získání hran elementu, (a) vstupní obraz, (b) jeho hrany .....	101
Obr. 6.10 – Detekce hranice elementu, (a) výstupní hranice vyznačená červeně, (b) typická situace, při hledání hranic .....	102
Obr. 6.11 – Odhad první úrovně v ose $Z$ , (a) vizualizace rozsahu šedivými plochami a zvýrazněná detekovaná hladina červenou plochou, (b) histogram výskytu bodů v $dims$ s vyznačeným maximem .....	103
Obr. 6.12 – Úrovňový obraz, (a) obraz odpovídající detekované úrovni z Obr. 6.11 (a), (b) maska po zacelení operací morfologického uzavření.....	104
Obr. 6.13 – Modelový příklad výskytu nespojitých ploch v mračnu bodů, (a) mračno bodů, (b) odpovídající úrovňový obraz bez dalších úprav s vyznačenými indexy ploch.....	105
Obr. 6.14 – Detail histogramu hledané úrovně, (a) histogram v ose $Z$ , (b) nalezený optimální rozsah .....	106
Obr. 6.15 – Zpřesnění rozsahu detekované plochy, (a) původní rozsah odpovídající Obr. 6.14 (a), (b) upravený podle červených bodů na Obr. 6.14 (b) .....	107
Obr. 6.16 – Ilustrace tvorby úrovňového obrazu, (a) vstupní mračno bodů, (b) výsledný úrovňový obraz odpovídající ploše vyznačené šipkou .....	108
Obr. 6.17 – Ilustrace barevného úrovňového obrazu, (a) vstupní mračno bodů v RGB, (b) odpovídající úrovňový obraz plochy vyznačené šipkou.....	109
Obr. 6.18 – Modelové mračno bodů pro tvorbu úrovňového obrazu, (a) mračno bodů, (b) po výstupu algoritmu LCCL s vyznačenými odlehými body červenou barvou .....	109
Obr. 6.19 – Úrovňový obraz prostorových bodů z Obr. 6.18 (b), (a) úrovňový obraz, (b) hodnoty pixelů .....	110
Obr. 6.20 – Detail histogramu úrovně a její prostorová vizualizace, (a) histogram, (b) vizualizace .....	110
Obr. 6.21 – Určení optimální cesty pro stanovení obvodu s vyznačením délek pixelů červenou čarou.....	112
Obr. 6.22 – Vyznačené vrcholy hranice elementu, (a) pro Obr. 6.21, (b) pro Obr. 6.19 (a) .....	114
Obr. 6.23 – Mračno bodů s chybějícími body na podlaze a stropu .....	114
Obr. 6.24 – Zacelení úrovňového obrazu, (a) původní obraz, (b) zacelený obraz .....	115
Obr. 6.25 – Vizualizace úrovňového obrazu, (a) vstupní obraz s vyznačeným výběrovým oknem, počátkem a koncem, (b) část s krokem 1 px, (c) část s krokem 3 px, (d) vyznačené hranice, (e) vizualizace .....	116
Obr. 6.26 – Vizualizace úrovňového obrazu, (a) testovací element, (b) skutečný úrovňový obraz .....	117
Obr. 6.27 – Vizualizace úrovňového obrazu s barevnou informací .....	117
Obr. 6.28 – Testovací model, (a) vstupní obraz, (b) mračno bodů z jasové složky .....	118

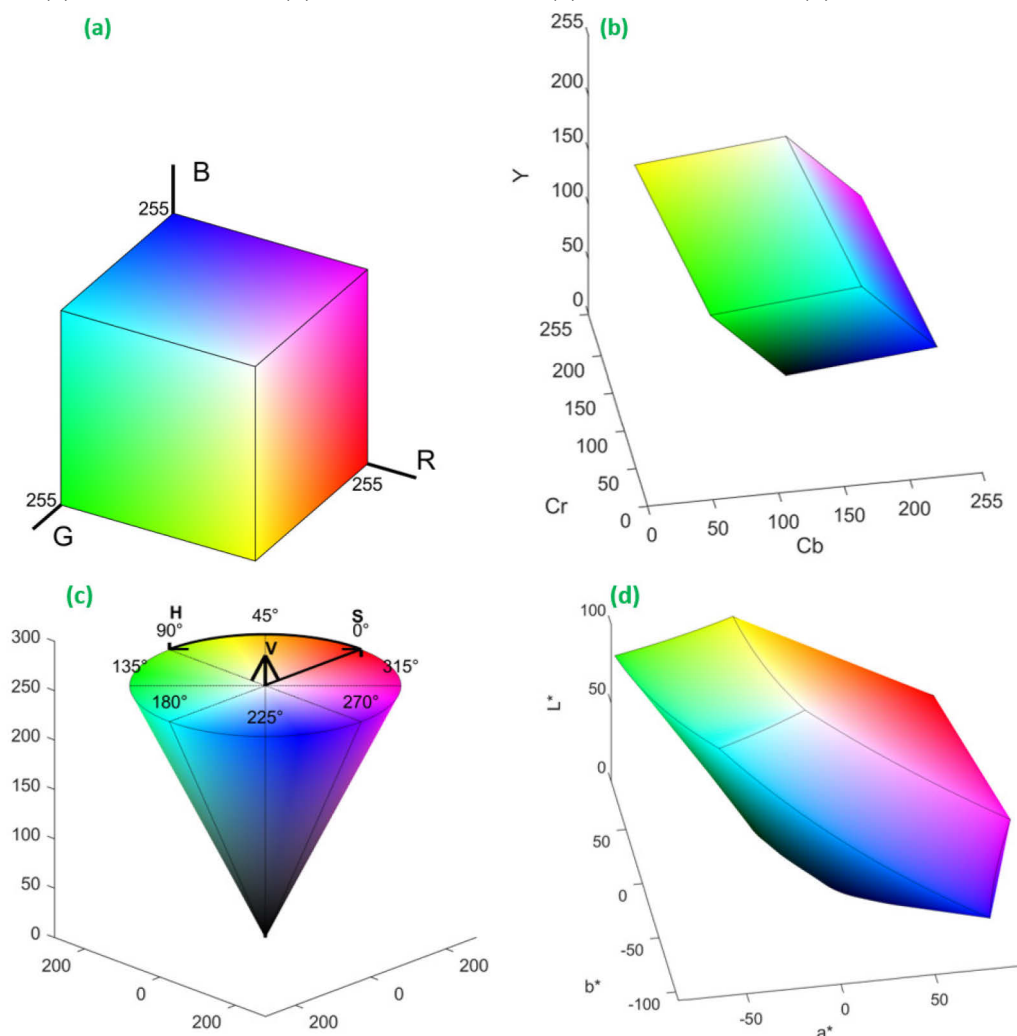
Obr. 6.29 – Zpracování testovacího mračna, (a) označení rotace, (b) detekované plochy .....	118
Obr. 6.30 – Testovací místnost chodba, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry .....	120
Obr. 6.31 – Hloubkové obrazy prostoru chodby z Obr. 6.30 (a) pravá část, (b) prostor schodiště .....	121
Obr. 6.32 – Místnost laboratoře, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry .....	122
Obr. 6.33 – Hloubkové obrazy prostoru laboratoře z Obr. 6.34, (a) pohled pod úhlem +5° do horního rohu místnosti se stolem skříní a části dveří, (b) pohled od stolu na okna .....	122
Obr. 6.34 – Bytový pokoj, (a) vstupní mračno bodů, (b) vizualizované plochy s parametry .....	123
Obr. 6.35 – Ověření přesnosti určení prostorových parametrů pro prostor dveří, (a) skenovaná scéna, (b) mračno bodů (pohled zezadu), (c) vyznačené parametry obvodu a obsahu plochy .....	124
Obr. 6.36 – Ověření přesnosti určení prostorových parametrů pro prostor skříně, (a) skenovaná scéna, (b) mračno bodů, (c) vyznačené parametry obvodu a obsahu plochy ..	124
Obr. 6.37 – Ilustrace zjednodušení popisných bodů plochy dveří, (a) vstupní mračno s vizualizovanou plochou pomocí LI, (b) detekované vrcholy, (c) vizualizace plochy prostřednictvím nalezených vrcholů .....	125
Obr. 6.38 – Ilustrace zjednodušení popisných bodů plochy skříně, (a) vstupní mračno s vizualizovanou plochou pomocí LI, (b) detekované vrcholy, (c) vizualizace plochy prostřednictvím nalezených vrcholů .....	125
Obr. 6.39 – Hloubkový obraz, (a) vstupní mračno bodů, (b) pohled na stůl a podlahu pravé části mračna .....	126
Obr. 6.40 – Hloubkový obraz, (a) s rotací 90° v ose Z, (b) ilustrace surf grafu .....	126
Obr. 6.41 – Ilustrace úprav hloubkového obrazu a zpětná transformace, (a) upravený obraz, (b) mračno bodů získané reverzním postupem algoritmu tvorby prostorové mapy .....	127
Obr. 9.1 – Gamut barevných modelů, (a) RGB, (b) YCbCr, (c) HSV a (d) $L^*a^*b^*$ .....	144
Obr. 9.2 – Pseudokód přidání informace detailních masek .....	146
Obr. 9.3 – Pseudokód funkce určení středu laserové čáry „GetPpxOffset“ .....	146
Obr. 9.4 – Pseudokód funkce analýzy laserové čáry „LaserLineAnalysis“ .....	147
Obr. 9.5 – Pseudokód funkce „ElementBorderPosition“ .....	148
Obr. 9.6 – Pseudokód funkce „PC2LevelImage“ pro tvorbu úrovněového obrazu .....	148
Obr. 9.7 – Pseudokód algoritmu „LCCL“ .....	149
Obr. 9.8 – Pseudokód funkce „GetElementPerimeter“ .....	150
Obr. 9.9 – Pseudokód funkce „GetElCorners“ .....	150
Obr. 9.10 – Pseudokód funkce „FillElementArea“ .....	151
Obr. 9.11 – Pseudokód funkce „PlaneVisualization“ .....	151
Obr. 9.12 – Vývoj mobilní platformy, (a) principiální koncept, (b) s ultrazvukovým měřičem, (c) s LiDAREm Hokuyo URG-04LX-UG01 a multifokálním objektivem kamery, (d) se zeleným laserem a hloubkovým senzorem Microsoft Kinect .....	152
Obr. 9.13 – Ukázka SW vybavení mobilní platformy a zpracování dat, (a) SW pro skenování, (b) SW pro následné zpracování vyhodnocení měřicích snímků .....	153

## Seznam tabulek

Tab. 3.1 – Tabulka určení optimálních $K$ pro všechny barevné modely.....	40
Tab. 3.2 – Tabulka hodnot rozdělení GMM pro barevný model HSV.....	42
Tab. 3.3 – Srovnání základních vlastností operátorů template matching.....	59
Tab. 3.4 – Hodnoty korekční křivky v závislosti na měřené vzdálenosti.....	61
Tab. 3.5 – Stupně polynomu korekční křivky .....	62
Tab. 3.6 – Porovnání času korekce barelového zkreslení.....	63
Tab. 3.7 – Porovnání přesnosti měření navrženého optického skeneru .....	64
Tab. 3.8 – Porovnání skutečných rozměrů prostředí a vytvořeného mračna bodů .....	65
Tab. 3.9 – Tabulka výsledků pro barevný model RGB a YCbCr.....	68
Tab. 3.10 – Tabulka výsledků pro barevný model HSV a $L^*a^*b^*$ .....	68
Tab. 5.1 – Porovnání výsledků algoritmů registrace mračen bodů ICP a NDT .....	91
Tab. 6.1 – Parametry detekované úrovně z Obr. 6.11 .....	104
Tab. 6.2 – Seznam bodů modelového mračna s vyznačenými odlehlými body.....	109
Tab. 6.3 – Parametry detekované plochy z Obr. 6.19 (a).....	110
Tab. 6.4 – Parametry detekovaných ploch testovacího modelu .....	119
Tab. 6.5 – Parametry detekovaných ploch prostoru chodby .....	120
Tab. 6.6 – Parametry detekovaných ploch místnosti laboratoře .....	121
Tab. 6.7 – Parametry detekovaných ploch bytového pokoje.....	123
Tab. 6.8 – Tabulka porovnání určených parametrů s reálným prostředím.....	124
Tab. 6.9 – Tabulka zjednodušení popisných bodů ploch .....	126

## Příloha A – Popis barevných modelů použitých pro detekci laserové čáry

Gamuty barevných modelů použitých pro detekci laserové čáry jsou uvedeny na Obr. 9.1 (a) RGB, Obr. 9.1 (b) YCbCr, Obr. 9.1 (c) HSV a Obr. 9.1 (d)  $L^*a^*b^*$ .



Obr. 9.1 – Gamut barevných modelů, (a) RGB, (b) YCbCr, (c) HSV a (d)  $L^*a^*b^*$

### RGB

Model RGB je nejpoužívanějším barevným modelem v počítačové grafice komponovaný ze tří základních barev spektra bílého světla - červené, zelené a modré. Vychází z principu lidského vnímání barev pomocí tří druhů čípků umístěných na sítnici oka, citlivých právě na spektrum těchto tří barev. Kombinací jednotlivých barevných kanálů lze získat konkrétní barvu. Model RGB je proto označován aditivním modelem, jeho gamut je uveden na Obr. 9.1 (a). Hodnota jasu barevného kanálu nabývá velikosti v závislosti na bitové hloubce obrazu. Běžně je využívána 8bitová hloubka a jas barevného kanálu nabývá hodnot z rozsahu 0 – 255. Kombinací všech intenzit je možno docílit šestnácti miliónů barev. Barevné složky lze jednotlivě oddělit a dále následně zpracovávat. Segmentace pomocí RGB modelu je implementačně jednoduchá, ale používá se jen zřídka v ideálních případech. Důvodem je velká korelace jednotlivých barevných kanálů mezi sebou. V případě požadavku změny intenzity určité barvy zastoupené ve všech složkách je zapotřebí změnit hodnotu všech barevných kanálů. Proto bylo vyvinuto mnoho jiných barevných modelů více uzpůsobených lidskému vnímání barev.

## YCbCr

Model YCbCr je často využíván pro digitalizované video. Jeho složka Y vyjadřuje jas obrazu a barevná informace je uložena ve dvou zbývajících kanálech Cb a Cr. Tato vlastnost odlišuje ostatní použité barevné modely od základního modelu RGB s neoddělitelným barevným kanálem. Kanál Cb tvoří rozdíl mezi modrou barvou a jasovou složkou Y a kanál Cr je rozdíl mezi červenou barvou a jasovou složkou Y. Vlastnost separability jasové složky od barevné informace je právě často využívána v kompresi videosignálu a televizním vysílání. Gamut modelu je uveden na Obr. 9.1 (b). Barevný model rovněž patří do skupiny modelů závislých na konkrétním zařízení. Rozsahy jednotlivých kanálů v 8bitové reprezentaci jsou 0 – 255.

## HSV

Barevný model HSV je zástupcem modelů uzpůsobených pro přirozenější interpretaci barvy lidskému pozorovateli. Motivací k jeho tvorbě bylo vytvoření modelu odpovídajícího interpretaci barev člověkem. Grafické znázornění gamutu je na Obr. 9.1 (c). Skládá se ze složek hue (barevný tón), saturation (sytnost barvy) a value (jas). Složka H je po obvodu kružnice a určuje konkrétní barvu pixelu. Hodnota S určuje sytnost barvy, jinými slovy příměs bílé barvy s černou. Její hodnota stoupá od středu kružnice až k okraji. Běžně se vyjadřuje v jednotkách procent. Barva se 100% sytností popisuje skutečnou barvu bez žádné příměsi bílé a černé. Zbývajícím hodnotou V určuje jasovou složku barvy, která je stejná jako u obrázku v odstínech šedi. Nulové hodnoty reprezentují černou barvu, maximální představují bílou barvu. Volbou vhodných rozsahů zejména složky H a S lze docílit požadované segmentace specifické barvy, která umožní segmentaci barevných objektů. Pro 8bitovou prezentaci mají složky S a V typický rozsah 0 – 255 a kanál H je uváděn často v rozsahu polovičním 0 - 128, aby se hodnoty úhlu kružnice vešly do omezeného rozsahu. Model je závislý na konkrétním zařízení i přes to, že je uzpůsoben pro lidské vnímání barvy. Jeho výhodou je vyjádření konkrétní barvy pouze jedním kanálem H.

## L\* a\* b\*

Barevný model L\* a\* b\* podobně jako YCbCr a HSV má odlišenou jasovou složku L\* od barevné informace a\* a b\*. Model L\* a\* b\* využívá vhodně volenou euklidovskou vzdálenost mezi jednotlivými barevnými složkami, aby bylo dosaženo jeho rovnoměrného vjemu. Z důvodu složitosti lidského vnímání světla je rovnoměrnost jen aproximována. Kanál L\* odpovídá lineárně lidskému vjemu jasu. Má-li určitá barva dvojnásobnou velikost složky L\*, je reálně dvakrát světlejší. Barevné kanály a\* a b\* vyjadřují barevnou informaci přechodu od zelené do purpurové a modré do žluté respektive. Jak už bylo uvedeno výše, model je nezávislý na konkrétním zařízení. Gamut barevného modelu ukazuje Obr. 9.1 (d). Rozsah hodnot pro 8bitové vyjádření složky L je 0 – 100, s využitím celého rozsahu  $L = L \cdot 255/100$ . Pro barevné kanály a\* a b\* jsou rozsahy  $-127 \leq a \leq 127$ ,  $-127 \leq b \leq 127$ . V bezznaménkové interpretaci se vyjadřují jako  $a = a + 128$  a  $b = b + 128$ . Porovnáním jednotlivých gamutů barevných modelů je patrné, že model L\* a\* b\* pokrývá největší prostor. Barevné kanály a\* a b\* mají v 8bitovém vyjádření limit  $-127$  až  $127$ , ale teoreticky nemají definované žádné limity (Poynton, 1996). Model byl primárně vyvinut pro vyjádření celého spektra viditelného světla lidským okem. Z toho vyplývá, že například převodem pixelů z RGB do barevného prostoru L\* a\* b\* nelze pokrýt jeho celý rozsah, jelikož má ve srovnání obou barevných prostorů RGB model omezený rozsah vyjádření barvy. Využívá se zejména v grafických editorech.

## Příloha B – Vývojové diagramy navržených funkcí

```

Function AddDetailMasks( $M_{LF}$ )
for  $k_{nd}=1:K_{NSD}$ 
     $PM_{LF} = \text{GetFinalMaskPosition}(M_{LF})$  (3.23)
     $M_{DA} = (k_{nd} < k_s)? M_{LF} \vee M_{LNS}(k_{nd}): M_{LF} \vee M_{LD}(k_{nd})$  (3.26)
     $M_{DA} = \text{ApplyMorphologicalOperation}(M_{DA}, m_E)$ 
    for  $i=1:N$ 
         $WM_{DA} = \text{GetLaserWidth}(M_{DA}(i:i+1, \forall))$ 
         $AM_{DA} = \text{GetLaserArea}(M_{DA}(i:i+1, \forall))$ 
         $L_W = \text{CheckLaserWidth}(WM_{DA}, l_W)$  (3.27)
         $L_D = \text{CheckLaserDiagonal}(WM_{DA}, AM_{DA}, A_r)$  (3.28)
        if  $((PM_{LF}(i)w > 0) \vee (k_{nd} < k_s))$ 
             $L_{AC} = \text{CheckLaserAreaCoverage}(WM_{DA}, AM_{DA}, A_r)$  (3.29)
             $L_A = \text{CheckLaserArea}(M_{LNS}(i:i+1, \forall))$  (3.30)
        end
        if  $(L_W \vee L_{AC} \vee L_D \vee L_A)$ 
             $M_{LF}(i:i+1, \forall) = (k_{nd} < k_s)? M_{LNS}(i:i+1, \forall): M_{LD}(i:i+1, \forall)$ 
        end
    end
end
end
end

```

Obr. 9.2 – Pseudokód přidání informace detailních masek

```

Function GetPpxOffset( $E_{idx}, i$ )
 $E = \text{Elements}(E_{idx})$ 
 $E_{Ash} = \text{CheckBasicElementAndAreaProperties}(E)$  (3.36)
if  $(E_{Ash})$ 
     $ppx(i) = \emptyset$ 
else
     $L_{CH} = \text{CheckMuMaxIntensityLaserChannel}(I_G)$  (3.37)
     $L_V = \text{CheckMuMaxIntensityLaser}(I_V)$  (3.38)
     $E_{prop} = \text{GetElShapeProp}(E)$ 
     $E_{\sigma^2} = \text{CheckShapeVariances}(E_{prop})$  (3.39)
    if  $(L_{CH} \vee L_V \vee E_{\sigma^2})$  (3.40)
         $L_i(x, y) = \text{GetMainIntensityLaserPosition}(E_I(x, y))$  (3.41)
         $ppx(i) = L_i(y) - I_c(y)$  (3.42)
    else
         $ppx(i) = \emptyset$ 
    end
end
end

```

Obr. 9.3 – Pseudokód funkce určení středu laserové čáry „GetPpxOffset“



```

Function LaserLineAnalysis( $I, M_{LF}$ )
for  $i=1:N$ 
   $M_{line} = I(M_{LF}(i:i+1, \forall))$ 
   $[L, n] = \text{ComponentLabeling}(M_{line})$ 
  if( $n > 0$ )
    if( $n > 1$ )
      //more elements
       $EP = \text{ElementsProperties}(L)$ 
      //classify elements into groups
       $EG = \text{ElementsGroup}(EP)$ 
      //select main element from groups
       $GBE = \text{SelectBestElementGroup}(EG)$ 
      //compare groups intensities
       $[eMaxI, eMaxIidx] = \text{EmaxIntensity}(GBE)$ 
       $[eMinI, eMinIidx] = \text{EminIntensity}(GBE)$ 
       $[eMaxA, eMaxAidx] = \text{EmaxArea}(GBE)$ 
       $[eMinA, eMinAidx] = \text{EminArea}(GBE)$ 
      if( $eMinA / eMaxA > hR$ ) (3.32)
        //similar areas -> compare intensity
        if( $eMinI / eMaxI < vR$ ) (3.33)
          //different intensity
           $\text{GetPpxOffset}(eMaxIidx, i)$  (Obr. 9.4)
        else
          //same intensity
           $ppx(i) = 0$ 
        end
      else
        if( $eMaxAidx = eMaxIidx$ )
          //same area and intensity index
           $\text{GetPpxOffset}(eMaxIidx, i)$  (Obr. 9.4)
        else
           $E_A = EP_A(eMaxIidx) / EP_A(eMaxAidx) > hR/2$  (3.34)
           $E_H = EP_H(eMaxIidx) / EP_H(eMaxAidx) > hR$  (3.35)
          if( $E_A \wedge E_H$ )
            //max intensity
             $\text{GetPpxOffset}(eMaxIidx, i)$  (Obr. 9.4)
          else
            //max area
             $\text{GetPpxOffset}(eMaxAidx, i)$  (Obr. 9.4)
          end
        end
      end
    end
  end
  else
     $\text{GetPpxOffset}(n)$  //one element (Obr. 9.4)
  end
end
end
end

```

Obr. 9.4 – Pseudokód funkce analýzy laserové čáry „LaserLineAnalysis“

```

Function [ $E_B$ , ( $dir_{E_B}$ )] = ElementBorderPositions( $I_L E_B$ )
  for x=1:size( $I_L E_B$ ,1)
    for y=1:size( $I_L E_B$ ,2)
      if( $I_L E_B(x,y) = true$ )
         $eldx = 1$ 
         $E_B(eldx, \forall) = [x, y]$ 
         $checkArray = [x, y]$ 
         $continueSearch = true$ 
        while (continueSearch)
          [ $found$ ,  $pos$ , ( $dir$ )] = SearchNeighbourPixel (Obr. 6.7 (b))
          if(found)
             $eldx++$ 
             $E_B(eldx, \forall) = [pos_x, pos_y]$ 
             $checkArray = [pos_x, pos_y]$ 
            ( $dir_{E_B}(eldx) = dir$ )
          else
             $continueSearch = false$ 
          end
        end
      end
    end
  end
end
end
end
end

```

Obr. 9.5 – Pseudokód funkce „ElementBorderPosition“

```

Function [ $I_L, (I_{L_C})$ ] = PC2LevelImage( $PC$ ,  $qD$ ,  $dim_s$ )
  Get  $R$  for all axis  $X$ ,  $Y$  and  $Z$  (6.17)
  Get image level size  $H_{I_L}$  and  $W_{I_L}$  from  $qD$  (6.18)
  Find real points' position in  $I_{L_x}$  and  $I_{L_y}$  (6.19)
  Estimate level image intensity  $I_L(x,y)$  (6.20)
  Get level image origin  $I_{L_{phys}}(x,y)$  (6.21)
  if(size( $PC,2$ ) = 6)
    Create  $I_{L_C}$  from RGB point intensity (6.22)
  end
end
end

```

Obr. 9.6 – Pseudokód funkce „PC2LevelImage“ pro tvorbu úrovněvého obrazu

```

Function [L, numL, Lstat] = LCCL( $X_L, dim_s, r_{lvl}, ds, v_{diff}$ )
  idxL = 1
  numL = 0
  maxT = max( $X_L(\forall, dim_s)$ )
  downT = min( $X_L(\forall, dim_s)$ )
  upT = downT + lvlS · lvlRS (6.9)
  while(upT ≤ maxT)
    //actual level
    dL = globalLvlStep(downT, upT, dims, numL, rlvl, ds, vdiff)
    //select new level
    downT = dL + lvlS (6.12)
    upT = downT + lvlS · lvlRS (6.9)
    if(upT > maxT)
      //last level
      if(downT ≤ maxT)
        upT = max( $X_L(\forall, dim_s)$ ) + lvlS
        globalLvlStep(downT, upT, dims, numL, rlvl, ds, vdiff)
        break
      end
    end
  end
end

Function dL = globalLvlStep(downT, upT, dims)
  lvlXL = ( $X_L(\forall, dim_s) \geq downT$ ) ∧ ( $X_L(\forall, dim_s) \leq upT$ ) (6.10)
  if(lvlXL ~ ∅)
    dL = max(hlvl(lvlXL))
    XLlvlR =  $X_L(\forall, dim_s) \geq (dL - lvlS) \wedge X_L(\forall, dim_s) \leq$  (6.11)
                $\leq (dL + lvlS) \wedge L(\forall) = 0$ 
    if( $\overline{h_{lvl}} / \max(h_{lvl}) \leq r_{lvl}$ )
      XLlvlR = finePlaneRange(XLlvlR, rlvl, ds, vdiff) (6.16)
    end
    L(XLlvlR) = idxL
    write Lstat(idxL, XLlvlR)
    idxL = idxL + 1
    numL = numL + 1
  else
    dL = downT + lvlS
  end
end
end

```

Obr. 9.7 – Pseudokód algoritmu „LCCL“

```

Function [ $P_{Ex}$ , ( $Y_s$ ,  $cirP$ )] = GetElementPerimeter( $I_L E_x$ )
   $I_L E_{xB} = I_L E_x - I_L E_{xE}$ 
  [ $E_{xB}$ ,  $P_p$ ] = ElementBorderPositions( $I_L E_{xB}$ )           (Obr. 9.5)
   $P_d(n) = \begin{cases} 1 & \text{for } P_p(P_p=1,3,5,7) \\ 0 & \text{for } P_p(P_p=2,4,6,8) \end{cases}$ 
   $\sigma_{P_d(n)} = {}_0P_d = \begin{cases} 1 & \text{for } P_d(n+1) = 1 \\ 0 & \text{for } P_d(n+1) = 0 \end{cases}$            (6.25)
  //fix first direction
  if( $P_d(2) \neq 1 \wedge P_d(2) \neq 3$ )
     $P_d(1) = 0$ 
  end
  //check circle path by score function from  $P_d(2)$ 
   $x_s(n) = \begin{cases} +1 & \text{for } P_p = 4,5,6 \\ +0 & \text{for } P_p = 3,7 \\ -1 & \text{for } P_p = 1,2,3 \end{cases}$ 
   $y_s(n) = \begin{cases} +1 & \text{for } P_p = 2,3,4 \\ +0 & \text{for } P_p = 1,5 \\ -1 & \text{for } P_p = 6,7,8 \end{cases}$ 
  Calculate score sum [ $X_s, Y_s$ ]           (6.26)
   $cirP =$  Evaluate round perimeter condition           (6.27)
  if( $cirP$ )
    Calculate round perimeter           (6.28)
  else
    Calculate line perimeter           (6.29)
  end
end
end

```

Obr. 9.8 – Pseudokód funkce „GetElementPerimeter“

```

Function [ $cPos$ ] = GetElCorners( $P_p, Y_s, cirP$ )
   $cPos(cP_i++, \forall) = [P_p(1), 1]$ 
  for  $n=2:\text{length}(P_p)$ 
    if( $cPos(cP_i, 1) \neq P_p(n)$ )
      //last position before change
       $cPos(cP_i++, \forall) = [P_p(n-1), n-1]$ 
      //actual position
       $cPos(cP_i++, \forall) = [P_p(n), n]$ 
    end
  end
  ExcludeRepeatedItems( $cPos$ )
  IncludeLastDiagonal( $cPos, Y_s, cirP$ )
  CheckCircleCondition( $cPos, cirP$ )
end
end

```

Obr. 9.9 – Pseudokód funkce „GetElCorners“

```

Function  $I_{E_{fill}} = \text{FillElementArea}(I_L E_x)$ 
 $E_{x_B} = \text{ElementBorderPositions}(I_L E_x)$ 
 $I_{E_{Bext}} = \text{Extend } E_{x_B} \text{ borders about 1 px}$ 
 $I_{one} = \text{true}(\text{size}(I_{E_{Bext}}))$ 
 $I_{one}(I_{E_{Bext}} > 0) = \text{false}$  (6.30)
//find separate areas (1 - surroundings, 2 - filled element)
 $L = \text{ConnectedComponentLabeling}(I_{one}, 4)$ 
//add edges back
 $I_{E_{fill}} = (L = 2) \mid I_{E_{Bext}}$  (6.31)
end

```

Obr. 9.10 – Pseudokód funkce „FillElementArea“

```

Function PlaneVisualization( $I_L, qD, [\angle x, \angle y, \angle z], nS$ )
  Create  $R(\angle x, \angle y, \angle z)$ 
  Determine element's  $start_E$  and  $end_e$  (6.32)
  for  $n = start_e : nS : end_e$ 
    [ $eP, numP$ ] = findElementParts( $I_L(\forall, n : n + nS)$ ) (6.31)
    for  $p = 1 : numP$ 
       $e = eP(eP = p)$ 
      [ $e_B$ ] = ElementBorderPositions( $e$ ) (Obr. 9.5)
      Calculate  $points$  (6.33)
       $points_R = points \cdot R(\angle x, \angle y, \angle z)$  (6.34)
      Draw a plane part by function patch( $points_R$ )
    end
  end
end
end
end


```

Obr. 9.11 – Pseudokód funkce „PlaneVisualization“



## Příloha C – Ukázky mobilní platformy

Navržená mobilní platforma prošla několika fázemi vývoje. Tato příloha znázorňuje základní koncept principu měření Obr. 9.12 (a). Na počátku byl použit červený laser s výkonem do 5 mW. Jeho výkon byl pro detekci bodu dostačující. Obrázek zahrnuje rovněž ukázkou snímku měření s vyznačením středem laserového bodu. Na stativu je umístěna snímací kamera Basler Scout scA1300-32gc a laserový paprsek je vzdálený od středu objektivu 5 cm. Obr. 9.12 (b) ukazuje první verzi finální podoby měřicího systému. Na stativu je umístěn krokový motor otáčející měřicí hlavou, u které je možné měnit odstup laserového paprsku od středu objektivu kamery. Paprsek je navíc filtrem rozptýlen do vertikální čáry umožňující určení pozice bodu v prostoru v její libovolné vertikální pozici, viz ukázkou měřicího snímku s vyznačenými body. Na Obr. 9.12 (c) je snímek platformy s přítomným LiDARem Hokuyo URG-04LX-UG01. Kamera má již multifokální objektiv s minimální ohniskovou vzdáleností 4 mm umožňující široký záběr pozorované scény oproti původnímu objektivu s ohniskovou vzdáleností 10 mm. Obr. 9.12 (d) představuje finální konfiguraci optického měřiče vzdálenosti komponovaného ze zeleného laseru s výkonem 200mW pro zajištění dostatečné intenzity laserové čáry a kamery Basler Ace 2500-14gc s vysokým rozlišením pro zvýšení přesnosti měření. Na platformě je rovněž umístěn hloubkový senzor Microsoft Kinect. Obr. 9.12 (b), Obr. 9.12 (c) a Obr. 9.12 (d) ukazují kombinaci navrženého optického měřiče vzdálenosti s jinými senzory. Ve výsledném řešení fáze více senzorů použita nebyla a práci jsem zaměřil zejména na vývoj vlastního měřiče.

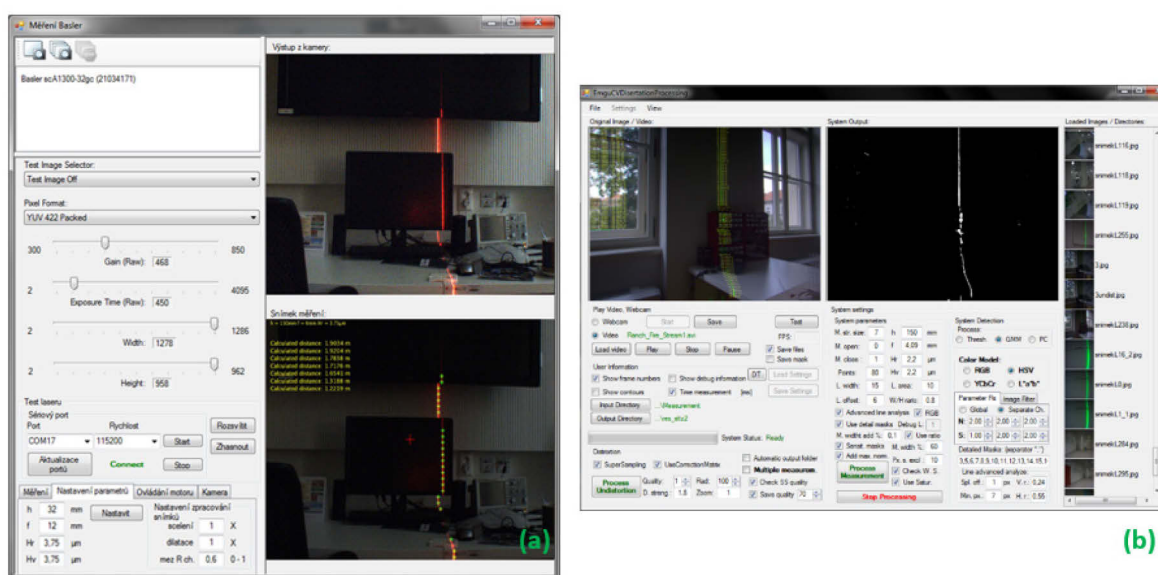


Obr. 9.12 – Vývoj mobilní platformy, (a) principiální koncept, (b) s ultrazvukovým měřičem, (c) s LiDARem Hokuyo URG-04LX-UG01 a multifokálním objektivem kamery, (d) se zeleným laserem a hloubkovým senzorem Microsoft Kinect

## Příloha D – Softwarové vybavení mobilní platformy a optického měřiče

Na Obr. 9.13 jsou ilustrovány snímky hlavních oken navržených programů pro skenování Obr. 9.13 (a) a následné zpracování a vyhodnocení měřicích snímků Obr. 9.13 (b). Oba programy jsou napsané v jazyce C#. Program pro zpracování je ještě vybaven funkcemi pro tvorbu barevné prostorové mapy a zpracování mračen bodů. Pro vizualizaci mračen bodů jsou implementovány funkce z SW knihovny PCL (Rusu, 2011). Pro urychlení práce s měřicími snímky je v navrženém SW použita knihovna OpenCV prostřednictvím wrapperu Emgu CV (Emgu CV, 2018).

Rychlost jednoho skenování prostředí závisí na nastavení snímkové rychlosti kamery a nastavení rychlosti krokového motoru. Pro spolehlivé skenování využívám mikrokrokování a nižší snímkovou rychlost kamery. Doba jednoho skenu trvá cca 37 s. Na získaných snímcích je zapotřebí odstranit barevné zkreslení a vady chromatické aberace. Zpracování a vyhodnocení měřicích snímků bylo provedeno na CPU Intel Core i5-4460, 3,2GHz. Z Tab. 3.6 při použití korekce s filtrem druhé úrovně vyplývá čas zpracování 5 minut a 8 s. Po vstupní úpravě pořízených snímků následuje jejich vyhodnocení. Použitím průměrné hodnoty doby zpracování z Tab. 3.10 pro barevný model HSV vychází doba vyhodnocení měřicích snímků na 5 minut a 57 s. Celková doba skenování a následného získání mračen bodů měřeného prostoru je cca 12 minut. Vývoj SW nicméně pokračuje dál a doba zpracování se v budoucnu ještě sníží.



Obr. 9.13 – Ukázka SW vybavení mobilní platformy a zpracování dat, (a) SW pro skenování, (b) SW pro následné zpracování vyhodnocení měřicích snímků

K dalšímu zpracování mračen bodů se kromě uvedených nástrojů využívá výpočetní systém Matlab, ve kterém byly laděny popsané algoritmy zpracování měřicích snímků před jejich finální implementací v popisovaných programech.