

Mendelova univerzita v Brně
Provozně ekonomická fakulta

Automatizovaná detekce objektů v mraku bodů

Disertační práce

Vedoucí práce:
prof. RNDr. Ing. Jiří Šťastný, CSc.

Ing. Jaromír Landa

Brno 2014

Hlavní poděkování patří „celé“ mé rodině a „všem“ přátelům, bez jejichž podpory by tato práce nikdy nevznikla. Dále bych chtěl poděkovat prof. Štastnému za jeho rady a podporu jak při psaní práce, tak v průběhu celého mého doktorského studia. Poslední díky patří dr. Davidu Procházkovi za jeho pomoc a podporu jak při psaní práce, tak především při výzkumu, který k napsání práce vedl.

Čestné prohlášení

Prohlašuji, že jsem práci **Automatizovaná detekce objektů v mraku bodů** vypracoval samostatně a veškeré použité prameny a informace jsou uvedeny v seznamu použité literatury. Souhlasím, aby moje práce byla zveřejněna v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů, a v souladu s platnou *Směrnicí o zveřejňování vysokoškolských závěrečných prací*.

Jsem si vědom, že se na moji práci vztahuje zákon č. 121/2000 Sb., autorský zákon, a že Mendelova univerzita v Brně má právo na uzavření licenční smlouvy a užití této práce jako školního díla podle § 60 odst. 1 Autorského zákona.

Dále se zavazuji, že před sepsáním licenční smlouvy o využití díla jinou osobou (subjektem) si vyžádám písemné stanovisko univerzity o tom, že předmětná licenční smlouva není v rozporu s oprávněnými zájmy univerzity, a zavazuji se uhradit případný příspěvek na úhradu nákladů spojených se vznikem díla, a to až do jejich skutečné výše.

V Brně 23. listopadu 2014

.....

Abstract

LANDA, J. *Automatic object detection in point clouds* Ph.D. thesis. Brno, 2014

Nowadays an efficient property management is an integral part of the management of any company, government authorities or local governments. With the increasing amount of property it is necessary to find effective ways to not only store the information about the property, but also to collect the information. This dissertation deals with an automatic detection of real world objects in point clouds. The goal is to create new methods for automated detection of objects located on the road, or in its vicinity.

The thesis describes new methods for the detection of pole-like objects, traffic signs, and road markings (specifically solid and dashed lines). The proposed methods enable to automate the entire process of obtaining information about objects and thereby streamline the property management, including reducing the cost of their acquisition.

An integral part of many methods for the detection and identification of objects is also identifying points on the ground, thus (in a certain tolerance) identifying the lowest points in the point cloud. The paper describes a new method for the identification of these points.

All new method described in this paper are tested on real world data captured during mobile mapping in Brno.

Abstrakt

LANDA, J. *Automatizovaná detekce objektů v mraku bodů* Disertační práce. Brno, 2014

Efektivní evidence majetku je v dnešní době nedílnou součástí řízení jakékoliv firmy nebo orgánů státní správy a samosprávy. Se vzrůstajícím objemem majetku je nutné nalézt efektivní způsoby nejen uchování informací o tomto majetku, ale i způsoby pořízení těchto informací. Disertační práce se zabývá automatizovanou detekcí objektů z reálného světa v mraku bodů. Cílem práce je vytvoření nových metod pro automatizovanou detekci objektů nacházejících se na vozovce, nebo v její blízkosti.

V práci jsou popsány nové metody pro detekci sloupovitých objektů, svislého dopravního značení a vodorovného dopravního značení (konkrétně plných a přerušovaných čar). Navržené metody umožňují automatizovat celý proces získávání informací o objektech a tím zefektivnit správu majetku včetně snížení nákladů na jejich pořízení.

Nedílnou součástí mnoha metod pro detekci a identifikaci objektů je také identifikace bodů na zemi, tedy (v určité toleranci) nejnižších bodů v mraku bodů. V práci je popsána nová metoda sloužící k identifikaci těchto bodů.

Všechny nové metody popsané v této práci jsou otestovány na reálných datech pořízených pomocí mobilního mapování v městě Brně.

Obsah

1	Úvod a cíl práce	9
1.1	Cíl práce	10
1.2	Struktura práce	10
2	Laserové skenování a mračna bodů	13
2.1	Pořízení mračna bodů	14
2.2	Způsoby pořízení mračna bodů	15
2.2.1	Letecké mapování	15
2.2.2	Mobilní mapování	15
2.2.3	Pozemní mapování	16
2.3	Uložení mračna bodů	17
2.3.1	Textové soubory	17
2.3.2	Binární soubory	18
3	Geografické informační systémy (GIS)	20
3.1	Geografická poloha a souřadné systémy	20
3.2	Geodata	21
3.2.1	Rastrová data	21
3.2.2	Vektorová data	22
3.2.3	Atributové vlastnosti	22
3.3	GPS a diferenciální GPS	23
4	Využití mračna bodů	25
4.1	Hledání objektů v mračnech bodů	25
4.1.1	Země a vozovka	25
4.1.2	Sloupovité objekty	27
4.1.3	Svislé dopravní značky	29
4.1.4	Vodorovné dopravní značení	31
4.1.5	Ostatní objekty	35
4.2	Generování digitálního výškového modelu	37
4.3	Pasportizace	38
4.4	Asistenční systémy pro vozidla	39
4.5	3D rekonstrukce	39
5	Zpracování mračna bodů	43
5.1	Registrace	43
5.2	Segmentace	44
5.2.1	Segmentace pomocí Euklidovské vzdálenosti	45
5.2.2	Region Growing segmentace	46
5.3	Vzorkování (zjednodušení)	46
5.4	Odstranění šumu	48

6	Metodika vývoje a testování metod	50
6.1	Možné získané informace	50
6.1.1	Sloupovité objekty	50
6.1.2	Svislé dopravní značení	51
6.1.3	Vodorovné značení	52
6.2	Způsob hodnocení úspěšnosti metod	53
6.3	Testovaná mračna bodů	54
7	Algoritmus pro identifikaci bodů na zemi	57
7.1	Popis algoritmu pro identifikaci bodů na zemi	57
7.2	Testování algoritmu	58
7.2.1	Testování na prvním vzorku mračen bodů	59
7.2.2	Testování na druhém vzorku mračen bodů	60
7.3	Shrnutí	61
8	Detekce pozice sloupovitých objektů v mračnách bodů	63
8.1	Popis metody pro detekci pozice sloupovitých objektů	63
8.1.1	Předzpracování mračna bodů	63
8.1.2	Segmentace	64
8.1.3	Detekce sloupovitých objektů pomocí směrového vektoru	65
8.1.4	Algoritmus pro snížení počtu špatně určených sloupovitých objektů	67
8.2	Výsledky a testování	68
8.3	Shrnutí	70
9	Detekce pozice svislého dopravního značení	72
9.1	Metoda pro detekci dopravního značení	72
9.2	Výsledky a testování	75
9.3	Spojení detekce značek s detekcí sloupovitých objektů	77
9.4	Shrnutí	78
10	Detekce pozice, identifikace typu a rekonstrukce tvaru vodorovného značení	79
10.1	Shrnutí současných metod pro detekci a identifikaci vodorovného značení	79
10.2	Motivace pro vytvoření metody	80
10.3	Detekce potenciálního značení	81
10.3.1	Předzpracování mračna bodů	81
10.3.2	Zpracování a filtrace segmentů	83
10.3.3	Vytvoření koster značení	83
10.3.4	Zhodnocení detekce potenciálního značení	87
10.4	Identifikace značení	88
10.5	Rekonstrukce tvaru značení	90
10.6	Výsledky a testování	92

10.6.1	Testování detekce pozice potenciálního značení na prvním vzorku mračen bodů	93
10.6.2	Testování identifikace plných a přerušovaných čar	94
10.6.3	Testování rekonstrukce tvaru vodorovného značení	95
10.6.4	Porovnání detekce a identifikace na prvním a druhém vzorku mračen bodů	96
10.6.5	Časová náročnost metody	99
10.7	Shrnutí	99
11	Diskuse	101
11.1	Ekonomické zhodnocení	103
11.2	Budoucnost využití mračen bodů pro orgány státní správy a samosprávy	104
12	Závěr	106
13	Literatura	108
	Přílohy	117
A	Rozřezání mračen bodů na 40 horizontálních řezů	118
B	Výsledek detekce pozice sloupovitých objektů importovaný do programu ArcMap	119

1 Úvod a cíl práce

Efektivní evidence majetku je v dnešní době nedílnou součástí řízení jakékoliv firmy nebo orgánů státní správy a samosprávy. Se vzrůstajícím objemem majetku je nutné nalézt efektivní způsoby nejen uchování informací o tomto majetku, ale i způsoby pořízení těchto informací. A právě mraky, resp. mračna bodů nabízejí velký potenciál při pořizování informací o objektech reálného světa, tedy i o majetku.

Mračno bodů je množina bodů, ve většině případů trojrozměrných. Každý bod má určenu svoji pozici v daném souřadném systému. V praxi se většinou používají mračna bodů reprezentující reálné objekty nebo oblasti, např. části města. Taková mračna bodů obsahují stovky tisíc, ovšem většinou až milióny bodů naměřených s velmi velkou přesností (až na milimetry). Mračna bodů jsou nejběžněji pořizována pomocí profesionálních laserových skenerů. Skener vyšle laserový paprsek a následně měří čas, který paprsek potřebuje, aby se vrátil ke skeneru. Pomocí měření času je pak možné určit vzdálenost k objektu, od kterého se paprsek odrazil.

Existuje mnoho způsobů, jak mračna bodů pořídit. Těmi nejběžnějšími je pořízení pomocí leteckého, pozemního nebo mobilního mapování. U leteckého mapování je mračno bodů pořízeno z letícího letadla nebo helikoptéry. U pozemního mapování je mračno bodů pořízeno ze skeneru umístěného v jednom bodě. Značný potenciál pak nabízí mobilní mapování. U mobilního mapování je mračno bodů pořízeno např. z automobilu, který projíždí danou oblastí. Profesionální systémy pro mapování ovšem nepořizují pouze mračna bodů, ale i mnoho dalších informací, jako například polohu skeneru, jeho natočení, obrazová data a další. Takovýto systém se nazývá LIDAR (Light Detection and Ranging).

Je nutné si ovšem uvědomit, že mračna bodů neposkytují informace o majetku automaticky. Příkladem může být svislé dopravní značení. Evidence a správa svislého dopravního značení je běžnou úlohou státní správy. Eviduje se poloha značky, její stav, typ značky a další informace. Tato evidence se v praxi provádí manuálně pomocí specializovaných programů. Expertní personál na monitoru počítače vidí panoramatické snímky (pořízené pomocí mobilního mapování) a v nich „vyklikává“ jednotlivá značení a zapisuje informace k nim. Druhou variantou je zaměření dat přímo v terénu. Tento proces je samozřejmě náročný časově i finančně (mzdové náklady). A právě v této oblasti nabízejí mračna bodů značný potenciál. Je totiž možné díky nim objekty detekovat automaticky (nebo částečně automaticky) a tím ušetřit čas i peníze. Rozšíříme-li příklad se svislým dopravním značením, je díky mračnu bodů možné s velkou přesností určit polohu dopravního značení.

Takto navrhovaná automatizace, nebo spíše částečná automatizace má za cíl usnadnit detekci a identifikaci objektů především v oblastech s větší rozlohou. Termín částečná automatizace je použit záměrně. V dnešní době ještě neexistují systémy umožňující stoprocentně automatizovanou evidenci majetku. Vždy je nutné využít expertní personál. A právě automatizováním procesu evidence majetku se zabývá tato práce. Práce se zaměřuje především na evidenci majetku nacházejícího se na

silnici nebo v jejím okolí, jako například dopravní značení (vodorovné nebo svislé), sloupy a další.

1.1 Cíl práce

Hlavním důvodem a motivací pro vytvoření této práce je zefektivnění procesu evidence majetku. Jedná se především o majetek nacházející se v blízkosti silnice. U tohoto typu majetku se v praxi eviduje velký objem informací. Ovšem tyto informace se získávají manuálně. Automatizací celého procesu je možné ho nejen zefektivnit, ale především zrychlit. Je důležité uvést, že práce si neklade za cíl plnou automatizaci procesu evidence majetku, ale pouze jeho podporu. Plná automatizace není v dnešní době možná.

Cílem této disertační práce je vytvoření nových metod pro automatizovanou detekci objektů reálného světa v mračnecích bodů.

Kroky vedoucí ke splnění cíle jsou následující:

- Popis současných metod detekce a identifikace objektů v mračnecích bodů.
- Specifikace informací, které je možné získat z mračnecích bodů.
- Návrh nových metod pro detekci a identifikaci objektů reálného světa v mračnecích bodů.
- Otestování navržených metod na reálných datech.
- Zhodnocení dosažených výsledků a navržení dalšího vývoje v oblasti detekce a identifikace objektů v mračnecích bodů.

1.2 Struktura práce

Práce je rozdělena do dvou logických bloků. V první části jsou popsána teoretická východiska týkající se mračnecích bodů. Druhou část pak tvoří popis nových metod pro detekci objektů v mračnecích bodů.

Laserové skenování a mračnecí bodů

Kapitola popisuje co je mračnecí bodů a dále pak způsoby jeho pořízení. V dnešní době se mračnecí bodů pořizují buď pomocí leteckého, mobilního nebo pozemního mapování. Na konci jsou pak popsány dva nejběžnější způsoby uložení mračnecích bodů (textové a binární soubory).

Geografické informační systémy (GIS)

Práce má značné využití v geografických informačních systémech. V této kapitole je popsáno, co jsou geografické informační systémy. Dále pak co jsou geodata a jaké jsou jejich typy. V kapitole jsou také popsány dva důležité termíny, a to GPS a diferenciální GPS.

Využití mračna bodů

Jedním z nejběžnějších využití mračna bodů je hledání objektů v něm. V kapitole jsou popsány přístupy k hledání objektů jako dopravní značení, sloupovité objekty a země a vozovka. Dále jsou v kapitole popsány i další způsoby využití mračna bodů, ať už pasportizace majetku nebo 3D rekonstrukce.

Zpracování mračna bodů

Kapitola zpracování mračna bodů se soustředí na popis metod běžně používaných při práci s mračny bodů. Jedná se především o registraci, segmentaci, zjednodušení a metody pro odstranění šumu. Kapitola se také soustředí na dvě nejvíce používané metody segmentace, a to segmentace pomocí Euklidovské vzdálenosti a Region Growing Segmentace.

Metodika vývoje a testování metod

Prvním krokem detekce objektů v mračnu bodů je identifikace údajů, které je možné o jednotlivých objektech získat z mračna bodů. V kapitole jsou identifikovány údaje, které je možné získat o sloupovitých objektech, dopravních značkách a vodorovném dopravním značení. Dále je v kapitole popsán způsob hodnocení úspěšnosti jednotlivých metod. Na konci kapitoly jsou pak popsány mračna bodů, na nichž bude prováděno testování metod.

Algoritmus pro identifikaci bodů na zemi

V kapitole je popsán algoritmus pro identifikaci množiny nejnižších bodů v mračnu bodů. Identifikace nejnižších bodů je jedním ze základů mnoha metod používaných při zpracování mračna bodů. Algoritmus rozdělí mračno bodů do určitého počtu bloků a v každém z nich izoluje nejnižše položené body podle daného kritéria.

Detekce pozice sloupovitých objektů v mračnu bodů

Kapitola popisuje detekci sloupovitých objektů v mračnu bodů. Metoda popsaná v kapitole funguje na principu rozřezání mračna bodů na určitý počet horizontálních řezů. Nad každým řezem je provedena segmentace a následně jsou pomocí směrového vektoru identifikovány sloupovité objekty. Výsledkem metody je seznam pozic sloupovitých objektů.

Detekce pozice svislého dopravního značení

Dopravní značky (svislé dopravní značení) jsou jedním z nejběžnějších objektů detekovaných v mračnech bodů. V kapitole je popsána metoda pro detekci dopravních značek. Tato metoda využívá odrazivosti a pomocí nastavení pravidel pro dopravní značku je schopná s velkou přesností identifikovat dopravní značky.

Detekce pozice, identifikace typu a rekonstrukce tvaru vodorovného značení

V kapitole je popsána nová metoda pro detekci pozice, identifikaci typu a rekonstrukci tvaru vodorovného dopravního značení. Tato metoda využívá pro reprezentaci značení koster. Metoda se soustředí na plné a přerušované čáry. Díky použití koster umožňuje rekonstruovat i případy, kdy dojde ke křížení značení.

Diskuse

Kapitola diskuse se soustředí především na shrnutí praktického přínosu pro praxi a zhodnocení přispění jednotlivých metod k automatizaci evidence majetku. V kapitole je také nastíněno ekonomické zhodnocení práce. Na konci kapitoly je navrženo další možné využití mračen bodů, a to pro směrnici INSPIRE.

2 Laserové skenování a mračna bodů


Mračno bodů je množina bodů v předem určeném souřadném systému. V té nejjednodušší podobě je mračno bodů definováno jako množina bodů s 2D souřadnicemi (tedy x a y), ovšem mnohem častější jsou mračna bodů s 3D souřadnicemi (x , y , z).

Souřadnice 3D bodu vždy reprezentují jeho polohu v rámci souřadného systému. Takový souřadný systém musí splňovat tři požadavky:

- Definice polohy je jednoznačná (objekty se stejnou polohou jsou identické a naopak).
- Definice polohy je kvantifikovatelná (lze definovat jednotku a v té měřit).
- Musí být definována metrika tak, že lze měřit vzdálenost mezi objekty (Hrubý, 2006).

Souřadné systémy lze rozdělit na lokální, nebo globální. Lokální souřadné systémy reprezentují pouze část prostoru. Typickým lokálním souřadným systémem může být poloha pixelu (souřadnice x a y) v obraze. Globální souřadný systém slouží pro popsání polohy v rámci celého světa.

Kromě souřadnic, se v praxi k bodu uchovávají i další informace, např. odrazivost nebo barva.



Obrázek 1: Příklad mračna bodů (Mederos, Velho a de Figueiredo, 2003b).

2.1 Pořizování mračka bodů

Existuje mnoho zařízení, které jsou schopné pořídit data ve formě mračka bodů. Ty nejběžnější fungují na principu triangulace. Na povrch objektu je laserem promítnut světelný vzor (ve formě paprsku nebo např. čáry). Tento světelný vzor se následně vrací zpět ke skeneru (většinou ve formě kamery), který tento odraz světla zachytí. Odraz světla je pak zpracován v softwaru dodaném ke skeneru. Tento software vytvoří pole hloubkových hodnot (hloubkový obraz), které je následně možné převést na mračko bodů.

Alternativním typem skenerů jsou tzv. time-of-flight skenery. Tyto skenery vyšlou krátký puls světla a vzdálenost je následně změřena pomocí času, který trvá odraženému paprsku vrátit se zpět ke skeneru (Bernardini a Rushmeier, 2002).

Dnešní sensory mají dvě základní vlastnosti: rozlišení a přesnost. Jak rozlišení, tak přesnost jsou dopředu známé a jsou součástí specifikací skeneru. Přesnost definuje chybu mezi skutečnými hodnotami a hodnotami pořízenými skenerem. Jedná se o odchylku od absolutní přesnosti skeneru, kterou není možné změřit a není proto známá. Přesnost skeneru se snižuje s přibývajícím vzdáleností mezi skenerem a měřeným objektem (Bernardini a Rushmeier, 2002). Rozlišení je definováno jako nejmenší vzdálenost mezi dvěma body naměřenými zařízením. Měřením přesnosti a rozlišení se zabývají například Cuartero a kol. (2010), Kadobayashia a kol. (2004) nebo Mechelke, Kersten a Lindstaedt (2007).

Největší nevýhodou 3D skenerů na bázi triangulace je nutnost mít neustále jasný výhled na snímaný objekt. V případě, že výhled není jasný, povrch objektu nebude změřen správně. Další nevýhodou je náchylnost skenerů k lesklým povrchům. Nevýhodou skenerů na principu time-of-flight je pak nutnost přesných výpočtů času letu paprsku. Mechelke, Kersten a Lindstaedt (2007) také upozorňují na nutnost přesné kalibrace skenerů, bez níž není možné pořídit hodnoty s požadovanou přesností. Příklady 3D skenerů jsou na obrázku 2.



Obrázek 2: 3D skenery: Trimble GX, Leica ScanStation, FARO LS 880 HE, Z+F IAGER 5006 (Mechelke, Kersten a Lindstaedt, 2007).

LIDAR

LIDAR je zkratkou pro Light Detection and Ranging. Jedná se o metodu dálkového průzkumu, která používá pulsy laserových paprsků k měření vzdálenosti. LIDAR se většinou skládá z laseru, skeneru a přijímače GPS signálu. Existují dva typy LIDARů, a to topografické a hloubkové. Topografické většinou používají infračervené laserové paprsky a používají se pro mapování zemského povrchu. Naopak hloubkové používají světlo zelené části spektra, díky kterému je možné mapovat i vodní dno (What is LIDAR?, 2014).

2.2 Způsoby pořízení mračna bodů

V předchozí kapitole byly stručně popsány 3D skenery a LIDAR. V praxi existují tři způsoby pořízení mračna bodů pomocí LIDARů. Jedná se o letecké, pozemní a mobilní mapování.

2.2.1 Letecké mapování

Letecké mapování, jak již název naznačuje, probíhá většinou z letadla. Ovšem nejsou výjimkou ani systémy využívající helikoptéry (Solberg, Næsset a Bollandsås, 2006). Typickými součástmi systému pro letecké mapování jsou:


- 3D skener napojený na počítač.
- INS/IMU (Inertial Navigation System / Inertial Measurement Unit).
- GNSS (Global Navigation Satellite System), pozemní stanice GNSS (Tamás, 2010a).

Všechny tyto části pak umožňují zachycení georeferencovaného mračna bodů. Výhodou těchto mračen bodů je jejich rozloha. Díky leteckému snímkování je možné pokrýt oblast o velké rozloze. Nevýhodou je ovšem nižší hustota bodů a možnost chyb především při georeferencování. Právě díky velké rozloze, kterou je možné pomocí leteckého mapování pokrýt, existuje mnoho různých využití, od detekce a identifikace stromů (Suárez, 2005) nebo lesů (Peterson a kol., 2005) až například po segmentaci povrchů ledovců (Höfle, 2007).

2.2.2 Mobilní mapování

Na rozdíl od leteckého mapování mobilní nevyužívá letecké prostředky, ale ve většině případů se jedná o komplexní systém připevněný na střechu automobilu. Díky němu je pak možné pořídit mračna bodů z jedoucího automobilu. Systémy pro mobilní mapování se většinou skládají z běžných skenerů pro pozemní mapování, které jsou kombinovány s mnoha dalšími zařízeními (viz obr. 4).

Díky nutnosti velké přesnosti tohoto mapování je při měření používaná technologie Diferenciální GPS (viz kapitola 3.3). Díky ní je možné několikanásobně zlepšit



Obrázek 3: Princip leteckého mapování (Tamás, 2010a).


přesnost výsledného georeferencovaného mračna bodů. Jak uvádí (Tamás, 2010b) mobilní mapování má mnoho použití:

- 3D rekonstrukce měst,
- mapování vozovky a jejího okolí,
- klasifikace vegetace,
- mapování silničních tunelů.

Výhodou mobilního mapování je mnohem větší přesnost než u leteckého. Další výhodou je schopnost pokrýt i oblasti, které není možné pomocí leteckého snímkování pokrýt (např. kmeny stromů nebo oblasti pod mosty).

2.2.3 Pozemní mapování

Letecké a mobilní mapování je určeno pro mapování větších oblastí. Ovšem v praxi je nutné použít mapování i v místech, ve kterých je nutné co nejpřesněji zmapovat danou oblast a není přitom nutné mít schopnost být při mapování mobilní. V těchto případech se používá pozemní mapování. U pozemního mapování jsou využívány skenery, které jsou malé a lehké a je možné je jednoduše přepravit. Pozemní mapování má velké využití při mapování malých oblastí, např. jedna křižovatka, výrobní hala nebo historická památka – viz Tamás (2010c), Alshawabkeh (2005).



Obrázek 4: Systém pro mobilní mapování (Tamás, 2010b).

2.3 Uložení mračna bodů

Existuje několik způsobů jak uložit mračno bodů. Zjednodušeně řečeno jakýkoliv způsob, který umožňuje uložení tří hodnot, je možné považovat za formát pro uložení mračna bodů. Existují ovšem dva základní typy souborů, do kterých lze mračna bodů ukládat, a to textové soubory a binární soubory.

2.3.1 Textové soubory

Textové soubory představují nejzákladnější způsob uložení mračna bodů. Strukturu takového souboru si může uživatel navrhnout sám, ovšem existuje i standardizovaná struktura například v podobě PLY souboru.

PLY (PoLYgon) je textový soubor primárně používaný pro uložení 3D povrchu. PLY se skládá ze dvou částí, a to hlavičky a seznamu vrcholů. V hlavičce je definováno, jaká informace je ke každému vrcholu uložena (souřadnice, barva, ...). (PLY Files—an ASCII Polygon Format, 2014)

```
ply
format ascii 1.0
comment made by anonymous
comment this file is a-cube
element vertex 8
property float32 x
property float32 y
property float32 z
element face 6
property list uint8 int32 vertex_index
end_header
```

```
0 0 0
0 0 1
0 1 1
0 1 0
1 0 0
1 0 1
1 1 1
1 1 0
4 0 1 2 3
4 7 6 5 4
4 0 4 5 1
4 1 5 6 2
4 2 6 7 3
4 3 7 4 0
```

Dalším příkladem textového souboru je PCD (Point Cloud Data). PCD je velmi podobný PLY a je používán v open source knihovně PCL¹ (PCD file format, 2014).

Výhodou textových souborů je jejich otevřenost. Díky ní je možné velice jednoduše do nich zapisovat a zároveň z nich jednoduše číst. Nevýhodou je ovšem delší doba nutná k načtení souboru. Je to dáno především velkými množstvími informace, protože v souborech bývají uloženy až miliony vrcholů. Další nevýhodou je pak velikost, která je mnohem větší než u binárních souborů.

2.3.2 Binární soubory

U binárních souborů platí to stejné co u textových, je tedy možné si navrhnout vlastní strukturu, ovšem mnohem častěji se používají standardizované formáty. Tím nejznámějším a nejvíce používaným je LAS (LASer). LAS je otevřený formát pro uložení mračna bodů a skládá se z veřejné hlavičky a následně pak jednotlivých záznamů o bodech (LAS Specification, 2010). Výhodou LAS souboru je jeho schopnost uchovat i dodatečné informace o bodu, jako například jeho odrazivost, klasifikaci a mnoho dalších (viz tab. 1). Další výhodou LAS je jeho rychlost. Načítání mračna bodů z LAS souboru je několikanásobně rychlejší než načítání z textového souboru.

Kromě jednotlivých souřadnic (x, y, z) jsou v praxi nejvíce používány další dvě hodnoty, a to intenzita (odrazivost) a klasifikace. Hodnota odrazivosti je celočíselnou reprezentací síly návratu paprsku. Díky klasifikaci je možné přímo u konkrétního mračna bodů definovat kategorii, do které bod patří. Jednotlivé kategorie jsou definovány přímo ve standardu LAS souborů – např. 1 = země, 6 = budova, 9 = voda (LAS Specification, 2010).

¹Point Cloud Library (<http://pointclouds.org/>)

Tabulka 1: Údaje uchovávané o jednotlivých bodech ve formátu LAS (LAS Specification, 2010).

Položka	Formát	Velikost	Povinná
X	long	4 bytes	*
Y	long	4 bytes	*
Z	long	4 bytes	*
Intensity	unsigned short	2 bytes	
Return Number	3 bits (bits 0, 1, 2)	3 bits	*
Number of Returns (given pulse)	3 bits (bits 3, 4, 5)	3 bits	*
Scan Direction Flag	1 bit (bit 6)	1 bit	*
Edge of Flight Line	1 bit (bit 7)	1 bit	*
Classification	unsigned char	1 byte	*
Scan Angle Rank (-90 to +90)	char	1 byte	*
User Data	unsigned char	1 byte	
Point Source ID	unsigned short	2 bytes	*

3 Geografické informační systémy (GIS)

Geografické informační systémy (GIS) jsou systémy zaměřené na uchovávání, správu, vizualizaci, analýzu a zpřístupnění dat s geografickým rozměrem. Ke GIS se dá přistupovat třemi způsoby. První způsob je vnímání GIS jako nástroje pro zpracování map. Druhý způsob spočívá ve vnímání GIS jako databázového nástroje pro správu, aktualizaci a zpřístupnění velkých objemů dat. Třetí pohled na GIS je jejich vnímání jako analytický nástroj (Hlásný, 2007).

Ať už se budeme dívat na GIS jakkoliv, faktem zůstává, že spravují a produkují velké množství dat (geodat). Tato data jsou většinou uchovávána ve dvou formách – jako rastrová nebo vektorová. Nedílnou součástí uchovávání geodat je uchování polohy jednotlivých objektů. Pro definici polohy objektu se používají souřadné systémy umožňující vyjádřit polohu objektu na zemském povrchu. Poslední, nedílnou součástí geodat, jsou pak způsoby jejich pořízení.

3.1 Geografická poloha a souřadné systémy

Při správě dat v GIS je přirozeným požadavkem definování jejich polohy v určitém, matematicky definovaném souřadném systému. Při určování prostorových souřadnic reálných objektů v prostředí GIS uvažujeme tři komponenty:

- Objekty reálného světa.
- Matematické objekty, které jsou objekty reálného světa vyjádřené formou množiny geometrických objektů na určitém elipsoidu, anebo v jeho blízkosti. Tyto objekty jsou abstrakcí reálných objektů.
- Vztahy mezi objekty, které definují vztah objektů reálného světa k matematickým objektům. Také určují sémantiku a syntaxi zápisu prostorových souřadnic (Hlásný, 2007).

Souřadný systém slouží k vyjádření polohy bodu v nějakém prostoru. V GIS mluvíme o geografickém prostoru, tedy obvykle o povrchu Země. Povrch Země ovšem není list papíru, ale v lepším případě to je povrch elipsoidu. Rozlišujeme dva typy souřadných systémů, a to globální (WGS-84) a lokální (např. S-JTSK) (Hrubý, 2006).

World Geodesic System (WGS)

WGS je globální souřadnicový systém, který dovoluje jednoznačně definovat polohu na Zemi. Využívají ho moderní navigační systémy globálního zjištění polohy – Global Positioning System (GPS). WGS poskytuje základní souřadnicový rámec, geometrickou reprezentaci tvaru zemského tělesa – elipsoid i gravitační model Země (Tuček, 1998).

Souřadnicový systém S-JTSK – Křovák

Souřadnicový systém Jednotné trigonometrické sítě katastrální (S-JTSK) je závazným geodetickým referenčním systémem na území ČR dle nařízení vlády č. 430/2006 Sb. v platném znění. S-JTSK je definován v rovině Křovákova zobrazení (dvojitého konformního kuželového zobrazení v obecné poloze). Osa x směřuje k jihu, osa y směřuje k západu. Osa x je obrazem základního poledníku umístěného $42^{\circ}30'$ východně od nultého poledníku Ferro.

Definici S-JTSK odpovídá projekce, která je v GIS aplikacích registrována pod EPSG kódem 2065: S-JTSK (Ferro) / Krovak. Užívají se však také projekce vztažené k nultému poledníku Greenwiche, nebo projekce zachovávající matematickou orientaci souřadnicových os (osa x na východ, osa y na sever) (Souřadnicové systémy, 2014).

3.2 Geodata

Prostorové objekty mohou mít obecně různé dimenze, nebo přesněji mohou být modelovány v různých dimenzích. Dimenze prostorového objektu charakterizuje jeho rozšíření v různých směrech prostoru. Bereme-li do úvahy geometrii a topologii geobjektů, pracuje se v geovědách maximálně s trojrozměrným prostorem. Někdy se hovoří o čase jako o čtvrté dimenzi. Pro potřeby geometrického modelování můžeme uvažovat s objekty různých dimenzí:

- Objekty bezrozměrné 0-D. Jde o body, které mají definovanou polohu v prostoru, ale nemají délku nebo plochu.
- Objekty jednorozměrné 1-D. Jsou to (přímé) úseky čar, které mají konečnou délku, ale ne plochu.
- Objekty dvojrozměrné 2-D. Jsou to polygony, které mají konečnou plochu.
- Objekty trojrozměrné 3-D. Jsou to tělesa, která mají objem nebo plochy ohraničující tělesa (polyhedrony), které nemají objem (Tuček, 1998).

Dvěma základními způsoby sběru geodat jsou primární a sekundární sběr. Primárním sběrem je myšleno měření přímo v terénu. Sekundárním se pak získávají geodata z jiných zdrojů než z primárních. Jak uvádí Longley a kol. (2001) porovnání geodat může pokrýt až 85 % nákladů v GIS.

3.2.1 Rastrová data

V současnosti je množství geografických údajů zaznamenaných v rastrovém formátu. Jsou to například snímky dálkového průzkumu Země, výškové modely, rozložení proměnných v prostoru (např. radiace) a další.

Rastrové formáty, využívané pro práci s geografickými údaji se skládají ze dvou částí, které mohou být fyzicky reprezentovány jedním nebo dvěma soubory – těla rastrového souboru a jeho hlavičky. Tělo rastrového souboru je tvořeno atributy

popisujícími vybrané kvalitativní a kvantitativní charakteristiky reálného světa. Hlavníčka rastrového souboru obsahuje, v závislosti na použitém formátu, větší množství informací. Tyto informace se týkají především uvedených parametrů, jako je například poloha v souřadnicovém systému, rozlišení, počet sloupců a řádků, možná rotace a spolehlivost (Hlásný, 2007).

3.2.2 Vektorová data

Druhým, velice rozšířeným způsobem reprezentace geografických údajů jsou vektorová data. Jsou využívána především v oblastech, kde je potřeba uchovávat velké množství údajů s vysokou přesností. Všechny objekty reálného světa jsou ukládány formou bodů, křivek nebo polygonů, jejichž souřadnice jsou vyjádřeny v reálných číslech.


Bodový objekt je označován jako čára nulové délky, definovaná alespoň trojicí souřadnic. Bod slouží pro reprezentaci geografických prvků, které jsou příliš malé na to, aby byly zobrazeny jako plochy (např. poloha obce na mapách s malým měřítkem). Tedy objekty, které jsou v jednom měřítku zobrazeny jako plošné, se v menším měřítku vyjadřují formou bodových objektů. Na mapách mohou být vyjádřeny formou rozličných geografických symbolů.

Křivkové objekty jsou tvořeny spojením dvou nebo více bodů. Nejjednodušším typem křivkového objektu je úsečka, která vznikne spojením dvou bodů. Komplexnějším útvarem je řetězec, který vzniká spojením více křivkových segmentů. Důležitým aspektem využívání vektorových křivkových objektů je jejich matematická reprezentace. V praxi je nejčastější využití řetězců úseček, s nimiž je možné relativně jednoduše manipulovat. U řetězců úseček je ovšem často problém s jejich nevyhlazeností a křivkostí. Tento problém se řeší vyjádřením úseček jako křivek, např. polynomiálních nebo Bézierových.

Polygony jsou vektorové prvky využívané při reprezentaci plošných útvarů, jako jsou například plochy států, pozemků a jiných umělých nebo přírodních objektů. K polygonům se váže pojem polyhedron, který vyjadřuje trojrozměrný polygonální objekt (Hlásný (2007), Longley a kol. (2001)). Pro pokročilejší vektorovou reprezentaci povrchu se používají TIN modely (Triangulated irregular network). TIN je trojúhelníková síť definující 3D povrch. Základní jednotkou je tedy trojúhelník. Výhodou TIN reprezentace je fakt, že umožňuje lépe reprezentovat složitější povrchy, než je tomu např. u polygonu. Další výhodou je fakt, že jednotlivé body trojúhelníkové sítě jsou v některém z běžně používaných souřadných systémů. Nevýhodou TIN je nutnost přesného vytvoření. Další nevýhodou je náročnost TIN modelů na zpracování, protože složitá data se mohou skládat i ze stovek milionů bodů (Parmerter, 2007).

3.2.3 Atributové vlastnosti

Velice důležitou vlastností geodat jsou i jejich atributy. Geografická poloha nám říká, kde se objekt nachází, ovšem neříká nám nic o tom, co je to za objekt. Objektem



Obrázek 5: Kombinace rastrových a vektorových dat (Week 5: Monitoring Invasive Species, 2014).

může být například lesní porost. Jeho atributem pak může být dřevinná skladba, průměrná výška a další. Tyto atributy se někdy nazývají i „neprostorové atributy“, protože nereprezentují informaci o lokalizaci, ani o prostorových vztazích (Tuček, 1998).

Atributy jsou v programech pro práci s GIS uchovávány v atributové tabulce. Například v programu ArcMap je možné k jednotlivým záznamům přiřadit atributy typu jako float, double, integer, text nebo date.

Výhodou přidání atributů ke geodatům je možnost provádění atributových dotazů nad nimi. Příkladem může být seznam měst v ČR. U každého města je atribut počet obyvatel. Díky atributovým dotazům je možné izolovat pouze města s např. více jak 50 000 obyvateli.

3.3 GPS a diferenciální GPS

Základem přímého pořízení geodat je získání polohy na povrchu Země. Pro získání polohy se nejčastěji používá GPS (Global Positioning System) systém. GPS se skládá z 31 NAVSTAR satelitů obíhajících zemi ve výšce 20 350 km, hlavní řídicí stanice, 12 řídicích antén a 16 monitorovacích stanic. GPS funguje na jednoduchém principu – na výpočtu délky času signálu cestujícího ze satelitu k přijímači. GPS satelity neustále vysílají kódované rádiové signály, které indikují jejich přesnou polohu v prostoru a čase. Přijímač pak měří, jak dlouho trvá signálu cesta k přijímači. Díky měření času z tří a více satelitů je možné určit polohu přijímače pomocí triangulace. Pokud jsou satelity čtyři, je možné získat i nadmořskou výšku.

Standardní přijímače mají horizontální přesnost kolem 5 metrů, a vertikální přibližně 1,5× až 3× větší než horizontální. Při terénním měření jsou ovšem situace, kdy je nutné získat mnohem přesnější měření. Proto se používá systém diferenciální GPS. Diferenciální GPS používá dva přijímače. Jeden pevný a druhý pohyblivý

(sloužící pro sběr dat). Pokud je známa pozice pevného přijímače, je možné, pomocí porovnání pozice přijímače s informací získanou ze satelitů, odhadnout chybu v měření. Tato chyba je pak použita pro zpřesnění polohy pohyblivého přijímače (Longley a kol., 2001).

4 Využití mračna bodů

V předchozích dvou kapitolách bylo představeno mračno bodů a dále pak geografické informační systémy. V této kapitole budou popsány různé způsoby využití mračna bodů. Pro potřeby této práce je tím hlavním způsobem využití mračna bodů detekce objektů. Mračna bodů ovšem mají i jiná využití. Tím v praxi nejběžnějším je generování digitálního výškového modelu. Stejně tak jako hledání objektů i generování digitálního výškového modelu má značné využití právě v geografických informačních systémech.

Kromě výše zmíněných využití nabízejí mračna bodů velký potenciál i v jiných oblastech, jako například pasportizace, asistenční systémy pro vozidla nebo 3D rekonstrukce.

4.1 Hledání objektů v mračnech bodů

Existuje řada objektů, které lze hledat v mračnu bodů. Ve většině případů jsou hledány objekty nacházející se v blízkosti vozovek, resp. objekty nacházející se v městech. Tato podkapitola popisuje různé přístupy k detekci několika základních objektů: země, sloupovitých objektů, svislého dopravního značení a vodorovného dopravního značení. Na konci kapitoly jsou pak popsány i další objekty, které je možné detekovat v mračnech bodů. V kapitole jsou často používány dva termíny, detekce a identifikace. Detekcí objektu je myšleno nalezení jeho pozice. Identifikací pak určení, o jaký objekt se jedná.

4.1.1 Země a vozovka

Identifikace bodů na zemi je jednou z nejdůležitějších operací při zpracování mračen bodů. Je to operace, na které jsou závislé další operace, jako například identifikace sloupů nebo horizontálního dopravního značení. Metody pro identifikaci bodů na zemi by se daly rozdělit do dvou kategorií. První kategorií je identifikace určitého procenta nejnižších bodů v mračnu bodů. V podstatě se jedná o izolaci nejnižších bodů ve scéně, protože právě vozovka a země jsou obvykle nejnižšími body v mračnu bodů. Nejjednodušší metodou v této kategorii je pak identifikace například 5 % nejnižše položených bodů ve scéně. Je ovšem jasné, že tuto metodu lze použít pouze na kompletně rovném úseku scény a tím pádem je její použití v praxi extrémně omezené.


Druhou kategorií jsou pak metody soustřeďující se na identifikaci bodů ležících přímo na vozovce. Metody v této kategorii obecně předpokládají, že body na vozovce (zemi) splňují nějaké základní parametry. Belton a Bae (2010) definují skupinu bodů na vozovce jako nejnižše položené, horizontální a nacházející se na hladkém povrchu.

Velice obvyklým způsobem detekce bodů na vozovce je využití obrubníků a podobných prvků oddělující vozovku od okolí. Obrubník je ve většině případů výše než povrch vozovky a toto vyvýšení je možné detekovat a tím určit hraniční body vozovky. Jak poukazují Li a Li (2009), pomocí detekce obrubníků vzniká síť křivek, které

jsou ovšem přerušované a je nutné provést jejich spojení. Na to se používá například Kalmanův filtr. Další přístup pro detekci vozovky pomocí obrubníků popisují Ibrahim a Lichti (2012). Tento postup kombinuje mnoho běžně používaných metod při detekci vozovky. Nejdříve je mračno bodů seřazeno pomocí KD-Tree. Následně je mračno bodů rozděleno na dva segmenty, a to body na zemi a nad ní. V další fázi je mračno dále filtrováno pomocí kritérií jako například úhel normálových vektorů. V poslední fázi je mračno bodů proloženo plochou a pouze body ležící u této plochy jsou označeny jako body na vozovce. Výsledkem jejich postupu je okrajový polygon definující pozici obrubníků a tím pádem i definující body náležející k vozovce.

Toth, Paska a Brzezinska (2008) navrhují detekci vozovky pomocí horizontálního značení nacházejícího se přímo u patníků chodníků. Tento přístup ovšem vyžaduje přítomnost značení a jeho dobrou kvalitu, což ho nedělá velice univerzálním.

Belton a Bae (2008) používají upravený algoritmus pro detekci ploch. Jak poukazuje, detekce ploch je jednou z možností jak identifikovat body na vozovce. Vstupní mračno bodů je rozděleno do mnoha buněk a v každé buňce je pomocí běžných metod (RANSEC², Houghova transformace) identifikována plocha která je pravděpodobně vozovkou. Belton a Bae (2008) nejdříve seřadí všechny body v jedné buňce podle velikosti. Následně je jimi pomocí lineární regrese proložena křivka a pomocí ní jsou body rozděleny do segmentů. Na těchto segmentech je pak opět provedena lineární regrese a jsou izolovány křivky (resp. body u nich) které jsou nízko a zároveň jsou co nejvíce horizontální.



Obrázek 6: Výsledek detekce bodů na vozovce z Belton a Bae (2008).

Li a Li (2009) používají pro detekci vozovky metodu založenou na detekci rysů (features) vozovky. Pomocí těchto rysů je možné reprezentovat plochý povrch vozovky.

²Random Sample Consensus

Velice zajímavý přístup pro detekci bodů na vozovce je zmíněn v Bentley Innovation (2013). Jejich algoritmus funguje na principu vytvoření TIN modelu zahrnujícími nejnižší body v modelu. Následně je pak každý bod v mračnu bodů otestován na základě tohoto TIN modelu, a pokud odpovídá běžným vlastnostem vozovky, je označen jako bod nacházející se na vozovce. Jedná se v podstatě o jinou verzi Region Growing algoritmu (viz podkapitola 5.2.2).

Další metody pro detekci vozovky je možné nalézt v Chen a kol. (2013), Moosmann, Pink a Stiller (2009) a Yo a kol. (2011).


4.1.2 Sloupovité objekty

U detekce sloupů je nutné nejdříve definovat co je myšleno pod pojmem sloup. V mnoha zdrojích se uvádí detekce sloupů jako detekce „pole-like“ objektu, tedy zjednodušeně řečeno detekce sloupovitého objektu. Sloupovitým objektem je pak objekt, jehož body jsou uspořádány ve válcovitém tvaru směřující svisle vzhůru (Pu a kol., 2011). A právě takové uspořádání bodů se pak různé metody snaží detekovat.

Yokoyama a kol. (2013) popisují metodu pro detekci sloupovitých objektů pomocí klasifikace jednotlivých bodů. Nejdříve je vstupní mračno bodů segmentováno a následně jsou jednotlivé segmenty vyhlazeny. Po vyhlazení segmentů následuje jejich klasifikace. Jednotlivé body v segmentu jsou klasifikovány do 3 kategorií: bod na sloupu, bod na plochém objektu a bod na jiném objektu. Body na sloupech jsou určeny pomocí analyzování okolí bodů. Pokud je bod a jeho okolí uspořádáno v jedné ose směřující nahoru je tento bod klasifikován jako bod na sloupu. V posledním kroku jsou pak jednotlivé segmenty filtrovány podle jejich výšky, celkového počtu bodů a počtu bodů klasifikovaných jako sloupových. Výsledkem detekce je seznam sloupovitých objektů. Ty jsou následně dále analyzovány, aby bylo možné s větší přesností určit konkrétní body na sloupu. Výhodou této metody je možnost detekovat i objekty přidružené ke sloupům. Nevýhodou je předpoklad kvalitního odstranění bodů na zemi a dobrý výsledek segmentace.

Další metoda pro detekci nejen sloupů popisují v Ishikawa a kol. (2013). Tato metoda je určena pro detekci sloupů, stěn a zábradlí. Jejich metoda je založena na principu soustředění se na menší oblasti mračna bodů a dále využití SVM (Support Vector Machine). Prvními kroky jsou opět odstranění země a segmentace. Autoři zde poukazují na jeden běžný problém při segmentaci, a to možnost přesegmentování (jeden objekt je rozdělen na více samostatných objektů) nebo podsegmentování (do jednoho segmentu je zařazeno mnoho rozdílných objektů). Dalším krokem je extrakce rysů jednotlivých bodů v menší části mračna bodů (1 m^2). Problémem rozdělení mračna bodů na menší části je možnost špatné detekce okraje části budov jako sloupu. Proto autoři také zkoumají stupeň samostatnosti detekovaných částí, tedy jak daleko je detekovaný sloup od ostatních bodů.

Lehtomäki a kol. (2010) vytvořili metodu založenou na segmentaci skenovací linie. Každá skenovací linie je segmentovaná samostatně a jednotlivé segmenty jsou následně skládány na sebe. Pokud se nějaký segment nachází přímo nad jiným, jsou



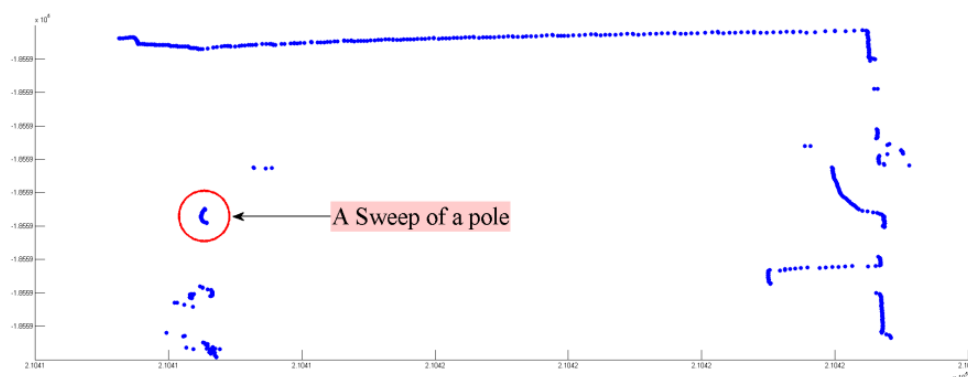
Obrázek 7: Výsledek klasifikace bodů z Yokoyama a kol. (2013). Zelenou barvou jsou znázorněny body na sloupovitém objektu, oranžovou body na plochem objektu a černou ostatní body.

oba segmenty zařazeny do jednoho shluku. Aby bylo možné shluk označit za sloup, musí splňovat následující pravidla:

- výška shluku musí být dostatečně velká,
- shluk musí obsahovat minimálně tři segmenty,
- shluk musí mít tvar sloupu,
- hlavní osa shluku musí být vertikální (v malé toleranci),
- v blízkém okolí shluku by se neměli nacházet jiné body.

U této metody autoři uvádějí přibližně 80% úspěšnost detekce sloupů.

Cabo a kol. (2014) navrhuje detekci sloupovitých objektů pomocí zjednodušení mračna bodů voxelizací. Celé mračno bodů je rozděleno do pravidelné trojrozměrné mřížky a každý bod v něm je tím pádem zařazen do jednoho trojrozměrného políčka mřížky (voxelu). Ke každému voxelu je pak uložena informace o jeho středu a počtu bodů které obsahuje. Díky tomu je možné velice zjednodušit původní mračno bodů. Výsledná trojrozměrná mřížka je rozdělena do horizontálních řezů, které jsou dále filtrovány podle kritérií jako počet bodů ve voxelu nebo jeho izolace od



Obrázek 8: Horizontální projekce jedné skenovací linie (Lehtomäki a kol., 2010).

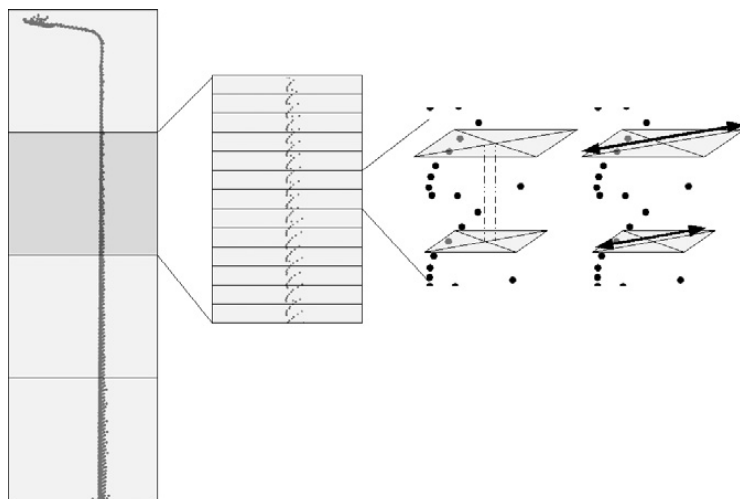
okolí. V posledním kroku jsou jednotlivé voxely spojeny se svými sousedy. Výhodou této metody je zjednodušení výpočtů pomocí voxelizace, ovšem její nevýhodou je závislost na správném určení velikosti voxelu.

Pu a kol. (2011) se zabývají detekcí základních struktur, které je možné nalézt v zalidněných oblastech, včetně sloupovitých objektů. Jejich algoritmus je založen na rozdělení potenciálního sloupu do výškových percentilů. Potenciální sloup je například rozdělen na 4 čtyři části. Jejich přístup pak spočívá v analýze například 3 odspodu. Jak autoři uvádí, je možné se takto vyhnout objektům, které jsou na spodní části sloupu a objektům na vrchní části (například listy stromů). Vybraná část je pak dále rozřezána na horizontální řezy. V každém řezu je kolem bodů vytvořen nejmenší možný obdélník, u něhož je uložen jeho středový bod a jeho diagonála. Následně jsou jednotlivé obdélníky analyzovány, a pokud splňují kritéria, je celé mračno označeno jako sloup. Tento přístup je ovšem velice závislý na správné první segmentaci a dále pak na předpokladu, že ve vybrané části nejsou jiné body než body odpovídající sloupu (tj. není tam například reklamní cedule). Li a Oude Elberink (2013) se ve svém článku zabývají optimalizací tohoto algoritmu.

Další přístup pro detekci sloupovitých objektů popisují Liberge a kol. (2010). Tento přístup spočívá v převedení mračna bodů do 2D obrazu, konkrétně součtového obrazu. Součtový obraz je vytvořený pomocí sčítání bodů, které patří do konkrétního pixelu. Následně jsou pak identifikovány pixely s velkým počtem bodů a tyto body klasifikovány jako potenciální sloupy. Potenciální sloupy jsou pak klasifikovány pomocí rozhodovacího stromu s využitím předem definovaných vzorů. Je nutné ovšem dodat, že tento algoritmus předpokládá na vstupu mračno bodů ve kterém jsou korektně odstraněny fasády domů.

4.1.3 Svislé dopravní značky

Obecně lze proces hledání svislého dopravního značení rozdělit do dvou různých operací, a to detekce a identifikace dopravní značky. Detekce dopravní značky spočívá pouze v určení pozice značky. Zjednodušeně řečeno detekci řekneme: na těchto



Obrázek 9: Princip rozdělení sloupovitých objektů do výškových percentilů (Pu a kol., 2011).

souřadnicích se nachází dopravní značka. Naopak identifikace dopravního značení spočívá v určení, o jakou značku se konkrétně jedná.

K detekci dopravního značení se v praxi používají dvě oddělené skupiny metod. První skupina využívá pro detekci značení mračna bodů a druhá RGB data. Pro identifikaci značení se pak používají pouze metody využívající RGB data. Pomocí mračna bodů nelze, s velkou přesností určit, o jakou značku se konkrétně jedná. V následujícím textu budou popsány výhradně metody využívající mračna bodů.

Většina metod pro detekci dopravního značení z mračen bodů využívá zvýšenou odrazivost dopravních značek. Z důvodů zvýšení viditelnosti dopravního značení v noci jsou značky natřeny vysoce odrazivou barvou. Ve chvíli, kdy LIDAR snímá takovou značku, je bodu na značce přiřazena vyšší odrazivost než okolním bodům (Nebiker, Bleisch a Christen, 2010).

Chen a kol. (2009) popisují systém schopný detekovat dopravní značení v mračnu bodů a na základě této detekce značku označit v obraze. Prvním krokem detekce je opět filtrace mračna bodů na základě odrazivosti jednotlivých bodů. Dalším krokem je segmentace jednotlivých značek. Posledním krokem detekce je proložení segmentu plochou, které má dva významy. Za prvé je díky němu možné odfiltrovat šum a za druhé jsou pomocí výsledné plochy eliminovány všechny značky, jejichž směr neodpovídá směru jízdy auta. Chen a kol. (2009) také poukazují na jeden důležitý faktor detekce, a to předpoklad, že barva na značce není opotřebená. Na degradaci barvy značení poukazují také González-Jorge a kol. (2011).

Jiný přístup k detekci dopravního značení používají Golovinskiy, Kim a Funkhouser (2009). Ve svém článku popisují systém sloužící k označení jednotlivých bodů v mračnu bodů. Každý bod je označen buď jako náležející k pozadí nebo jako bod na konkrétním typu objektu. Jedním z typů objektů jsou i dopravní značky. Jejich přístup spočívá ve čtyřech krocích: nalezení potenciální oblasti výskytu ob-



Obrázek 10: Výsledek detekce dopravní značky znázorněný v georeferencovaném obrazu (Chen a kol., 2009).

jektů, segmentace objektů od pozadí, získání rysů objektů a klasifikace objektů do jednotlivých skupin.

González-Jorge a kol. (2011) se zabývají hodnocením stavu dopravního značení. Hodnocení spočívá ve zjištění náklonu dopravní značky a dále pak ke zjištění hladkosti povrchu značky. Náklon dopravní značky je zkoumán pomocí rozdílu mezi úhlem vozovky a úhlem, pod kterým je značka nakloněna. Zjišťování hladkosti povrchu je provedeno pomocí proložení dopravní značky plochou a zkoumání odchylky bodů od této plochy. Pomocí této metody je možné zjistit ohnutí povrchu dopravní značky.


4.1.4 Vodorovné dopravní značení

Detekce a identifikace vodorovného značení je v dnešní době velice populární vědeckou oblastí, a to především díky vývoji samonaváděcích automobilů. Tyto automobily by měly být (a v mnoha případech již jsou) schopny se samy pohybovat po vozovce. Nejdříve je nutné si definovat, co je myšleno pod termínem vodorovné dopravní značení. Jedná se různé symboly pomáhající řidičům a chodcům při orientaci na pozemních komunikacích. Patří sem například souvislé a přerušované čáry, šipky, přechody pro chodce a další. Je velice důležité říci, že na vytvoření vodorovného značení, stejně tak jako svislého dopravního značení, je použita speciální barva, díky které má značení větší odrazivost. Zásady pro vodorovné dopravní značení na



Obrázek 11: Různá poškození dopravních značek (González-Jorge a kol., 2011).

pozemních komunikacích je možné nalézt v dokumentu vydaném ministerstvem dopravy (Zásady pro vodorovné dopravní značení na pozemních komunikacích, 2011).



Obrázek 12: Příklad vodorovného dopravního značení: vlevo plné a přerušované čáry, vpravo šipky (Zásady pro vodorovné dopravní značení na pozemních komunikacích, 2011).

V dostupných zdrojích je možné nalézt značné množství různých metod umožňujících jak detekci, tak identifikaci vodorovného značení. Pro potřeby této práce je nutné tyto metody rozdělit do několika kategorií a definovat, kterou kategorií se bude tato rešerše zabývat. Základní rozdělení dostupných metod je možné provést podle zdrojových dat. Hillel a kol. (2014) rozdělují zdroje dat používané pro detekci vodorovného značení na 3 kategorie:

- **Obrazová data** – obrazová data jsou nejpoužívanějším zdrojem dat. Hlavním důvodem je nízká cena kamer. Dalším důvodem je podobnost kamer s lidským

okem. Vodorovné značení je uzpůsobeno pro lidské oko, proto je použití obrazových dat logickým krokem.

- LIDAR – druhým zdrojem dat jsou data z LIDARu, tedy mračna bodů. Výhodou mračen bodů je možnost detekce značení i za velmi špatného počasí nebo ve špatných světelných podmínkách. Další výhodou je schopnost LIDARu zaznamenat i další informace o jednotlivých bodech, jako například sílu odrazivosti. Využití mračen bodů pro detekci značení bylo hodně využíváno týmy při DARPA výzvě (viz kapitola 4.4).
- Stereo obrazy – stereo obrazy jsou obrazy pořízené dvěma a více kamerami. Tyto kamery se dívají do jednoho bodu a je díky nim možné pořádit mračna bodů podobně jako s využitím LIDARu. Nevýhodou ovšem je nízká přesnost pořízených mračen.

Dalším možným rozdělením je pak rozdělení na reálné a offline metody. Reálné metodami jsou myšleny metody, které detekují a identifikují vodorovné značení přímo ve chvíli, kdy automobil projíždí danou oblastí. Naopak offline metody analyzují oblast až dodatečně.

Reálné metody pro detekci linie našly velké uplatnění především v systémech pro detekci opuštění jízdního pruhu (Lane Departure Warning – LDW). Tyto systémy mají za úkol upozornit řidiče, pokud automobil vyjede z jízdního pruhu, popřípadě i sami zareagovat a korigovat dráhu automobilu.

Tato práce se zabývá získáváním informací z laserového skenování, a proto se literární rešerše nebude detekcí z obrazových dat zabývat. Dalším zaměřením práce je pak offline zpracování dat, ovšem pro lepší přehlednost je dobré se věnovat i reálným metodám.


Bisheng a kol. (2012) se věnují detekci přerušovaných čar v mračnu bodů. V prvním kroku autoři převedou mračno bodů na georeferencovaný obraz, ve kterém pak pomocí výškových filtrů izolují body náležející k vozovce a kousek nad ní. V druhém kroku je takovýto obraz filtrován podle síly odrazivosti jednotlivých bodů. Jak již bylo řečeno, vodorovné dopravní značení je malováno speciální barvou s vyšší odrazivostí. V posledním kroku pak autoři využívají sémantické znalosti o dopravním značení k jejich detekci a identifikaci. Autoři specifikují dvě možné uspořádání přerušované čáry, a to za sebou a vedle sebe.

Stejně jako Bisheng a kol. (2012) i Guan a kol. (2013) využívají Houghovu transformaci pro detekci vodorovného značení. Jejich postup je závislý na vytvoření tří 2D georeferencovaných obrazů pomocí metody IDW³. Tyto obrazy jsou: výškový obraz, obraz hustoty bodů a obraz odrazivosti. Výškový obraz je určen k filtrování bodů ležících na vozovce (barva pixelu reprezentuje množství bodů ve větší výšce). Obraz hustoty bodů slouží k filtrování pixelů s velkou hustotou bodů (postaveno na předpokladu, že čím je bod blíže k automobilu se skenerem, tím je větší hustota bodů). Poslední, obraz odrazivosti, je použit k filtrování bodů podle jejich odrazi-

³Inverse Distance Weighting

vosti. Ve výsledném obrazu jsou pak pomocí Houghovy transformace a Cannyho hranového detektoru hledána lineární vodorovná značení.

Chen a kol. (2009) také využívají vyšší odrazivosti vodorovného značení. Jimi navržený systém je schopen rozeznat dva typy dopravního značení, a to plnou a přerušovanou čaru. Po odfiltrování přebytečných bodů převedou mračno bodů na 2D obrazy, které dále zpracovávají pomocí běžných metod na zpracování obrazu. V dalším kroku pomocí Houghovy transformace hledají linie představující jednotlivé čáry. Jak poukazují, nevýhodou Houghovy transformace je nutnost zadání počtu čar k nalezení. Proto definují velké číslo, díky kterému ovšem získají mnoho špatně identifikovaných čar. Tyto čáry je nutné dále filtrovat pomocí znalosti dráhy vozu a geometrických vlastností čar. V posledním kroku pak vytvoří bounding box⁴ kolem každé čáry a zkoumají rozmístění bodů podle křivky proložené bounding boxem. V tomto kroku je čára identifikována jako plná nebo přerušovaná.



Obrázek 13: Vlevo hledání čar pomocí Houghovy transformace, vpravo vyfiltrované čáry podle dráhy automobilu a geometrických vlastností čar (Chen a kol., 2009).

Velice jednoduchý přístup k detekci značení popisují Smadja, Ninot a Gavrilovic (2010). Jejich přístup spočívá pouze ve filtrování mračna bodů podle odrazivosti. Tento přístup je ovšem závislý na dokonalé identifikaci bodů na vozovce. Jak ovšem upozorňují, i takto jednoduchý proces může být narušen díky postupně se zhoršující kvalitě vodorovného značení.

Odrazivost je využita i v systému popsaném v Thuy a León (2010). Základem je filtrování bodů pomocí odrazivosti a následné převedení bodů do 2D obrazu. V dalších krocích je pak možné použít běžné metody zpracování obrazu, jako například Cannyho hranový detektor. Výsledkem Cannyho hranového detektoru je binární obraz, který dále zpracovávají (bílémi pixely je znázorněno značení). Jejich přístup je založen na dvou obdélnících, které posouvají v obrazu. Základním předpokladem je, že značení je většinou ve středu vozovky a proto se obdélníky začínají posouvat od

⁴Bounding box je nejmenší možný obdélník, který obsahuje všechny vstupní body.

středu ke krajům obrazu. Pokud je v obdélníku nalezen určitý počet bílých pixelů, jsou tyto body označeny jako potenciální značení. V posledním kroku je pak potenciální čára sledována buď pomocí metody minimálních čtverců, nebo pomocí Kalmanova filtru. Dalším příkladem detekce vodorovného dopravního značení je systém navržený pro DARPA výzvu (Kammel a Pitzer, 2008). Tento systém opět využívá odrazivost bodů a zároveň při detekci a identifikaci značení zjišťuje odchylku mezi detekovaným značením a značením v mapových podkladech.

Schindler, Maier a Janda (2012) navrhli systém pro tvorbu přesných digitálních map. Jejich systém se soustředí především na plné a přerušované čáry. Ve svém článku se zabývají reprezentací čar. Podle nich je nejjednodušší reprezentací polygon. Jak ovšem poukazují, polygon není schopen reprezentovat zakřivenost značení. Proto navrhuje další typ reprezentace, a to pomocí oblouků. Jejich přístup spočívá v proložení značení křivkou.

V praxi nejsou výjimečné ani metody, které využívají k detekci značení jak obrazová data, tak mračna bodů. Huang a kol. (2009) popisují metodu, která v první fázi detekuje všechno vodorovné dopravní značení v obrazových datech. Tato detekce ovšem produkuje mnoho špatně určených značení, proto jsou použita mračna bodů k odstranění jejich části. V posledním kroku pak detekují čáru procházející středem jakéhokoliv detekovaného vodorovného značení (především plných a přerušovaných čar). Další příklad kombinace mračna bodů a obrazových dat je možné nalézt v Li a kol. (2014a).

Li a kol. (2014b) popisují automatickou detekci vodorovného značení pomocí filtrování odrazivosti ve spojení s prahováním pomocí vzdálenosti. Jak poukazují, při detekci vodorovného značení je nutné kromě samotné hodnoty odrazivosti počítat i s tím, že na tuto hodnotu má vliv vzdálenost bodu od skeneru a dále úhel, pod kterým byl bod pořízen. Na potřebu normalizace odrazivosti poukazují i Thuy a León (2010) a Guan a kol. (2014).

4.1.5 Ostatní objekty

Kromě výše zmíněných objektů je možné detekovat i řadu dalších. V této kapitole budou popsány další, nejběžněji detekované objekty v mračnec bodů, a to budovy a stromy (resp. lesy).

Budovy

Detekce a identifikace budov, resp. fasád v mračnu bodů je jednou z nejběžnějších úloh při zpracování mračna bodů. Detekce fasád je základním krokem při 3D rekonstrukci měst (Arachchige a Maas, 2012). Většina metod pro detekci fasád má jako primární krok detekci ploch. Tato detekce je většinou prováděna pomocí metody RANSEC. Jak ukazují Hammoudi, Dornaika a Paparoditis (2009) detekci fasád je možné použít i pro další účely, jako například generování plánů budov. Ve svém článku se zabývají automatickým generováním polygonů reprezentující podstavy budov z dat pořízených pomocí mobilního mapování. Další přístup pro detekci fasád je

popsán v Arachchige a Maas (2012). Autoři poukazují na další důležitou podmínku detekce fasád, a to odstranění bodů na zemi. Jejich přístup spočívá v odstranění bodů na zemi a následném hledání ploch v mračnu bodů (opět pomocí metody RAN-SEC). Součástí detekce fasád může být i detekce oken. Mesolongitis a Stamos (2012) popisují metodu detekující okna v obydlených oblastech. Jejich metoda funguje na předpokladu, že okna jsou uspořádána v pravidelných strukturách.



Obrázek 14: Výsledek detekce fasád (Hammoudi, Dornaika a Paparoditis, 2009).


Stromy a lesy

Dalšími, v praxi detekovanými objekty, jsou stromy, potažmo i lesy. Jak poukazují Monnier, Vallet a Soheilian (2012) detekce stromů má několik využití:

- Realistická rekonstrukce stromů pro přesnou vizualizaci měst. Detekcí stromů je možné nejen realisticky vizualizovat města, ale je možné i částečně odstranit problém okluze, který stromy způsobují například na budovách.
- Automatická navigace robotů. Detekcí stromů je možné zpřesnit automatický pohyb robota ve scéně.
- Plánování měst a inventarizace majetku.

Existuje mnoho metod pro detekci stromů, ovšem lze je rozdělit do dvou kategorií:

- Detekce kmenů stromů (Király a Brolly, 2007).
- Detekce stromů pomocí zkoumání geometrických vlastností okolí jednotlivých bodů (Monnier, Vallet a Soheilian, 2012).



Obrázek 15: Výsledek detekce individuálních stromů v mračnu bodů (Monnier, Vallet a Soheilian, 2012).


Detekce lesů v mračnu bodů má velký potenciál pro jejich efektivní správu. Uvedme si dva příklady. Peterson a kol. (2005) popisují využití LIDARu pro předpověď chování ohně v lese. Upozorňují na fakt, že díky LIDARu je možné získat charakteristiky potřebné k modelování chování ohně při požáru. Dalším příkladem je inventarizace lesů. Holmgren a Jonsson (2004) popisují mapování 50 km² lesa ve Švédsku. Díky tomuto mapování je možné určit průměrnou výšku stromů, průměrný obvod kmenů a další charakteristiky.

4.2 Generování digitálního výškového modelu

Jednou z oblastí, kde mračna bodů nacházejí značné uplatnění, je generování digitálního výškového modelu. Digitální výškový model představuje reprezentaci povrchu určitého území. Tato reprezentace je vyjádřena pomocí nadmořské výšky. Pro vyjádření digitálního výškového modelu se nejvíce používají TIN modely, tedy vyjádření modelu pomocí trojúhelníkové sítě (Bandara a kol., 2011). S termínem digitální výškový model velice souvisí dva další termíny, a to digitální model terénu a digitální model povrchu. Digitální model povrchu (Digital Surface Model) představuje obraz povrchu země se vším, co na něm je, tedy například i koruny stromů. Naopak digitální model terénu (Digital Terrain Model) reprezentuje pouze povrch, tedy pouze terén. Digitální výškový model je nejčastěji generován z dat pořízených pomocí leteckého mapování (Li, Zhu a Gold, 2004).

Vygenerovaný digitální model terénu má řadu použití. Covasianu a kol. (2007) se zabývají využitím digitálního modelu terénu pro analýzu území ohroženého povodněmi. Díky DTM je možné předpovědět chování vody při povodni. Werbrouck a kol. (2011) navrhuje využití DTM pro analýzu historie daného území. Jejich pří-

stup spočívá v generování velmi přesného DTM bez jakýchkoliv umělých objektů. Tento DTM je pak porovnán s historickými mapami.



Obrázek 16: Příklad digitálního výškového modelu (TanDEM-X Global Digital Elevation Model, 2014).

4.3 Pasportizace

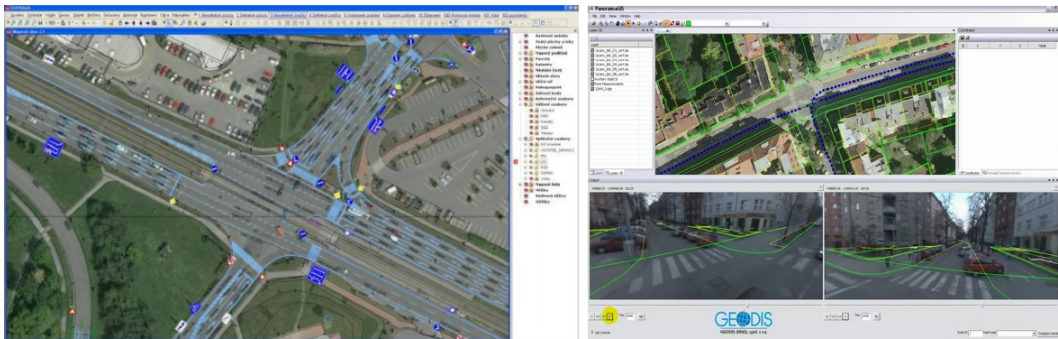
Proces pasportizace, čili proces sběru informací a tvorba pasportů, je jednou ze základních činností při správě majetku. Pro majitele i správce nemovitosti je to jeden z důležitých nástrojů při získávání informací o nemovitosti při řešení údržby, obnovy, modernizace nebo při získávání informací o vybavení a výměrách a jiných technickoekonomických parametrech (Beránková, 2013).

Z výše uvedeného vyplývá, že pasportizace je proces získávání informací o nemovitém majetku. Existuje mnoho způsobů získávání těchto informací a také mnoho různých typů majetku, o kterých se informace shromažďují. Mračna bodů jsou běžně využívány pro pasportizaci majetku na nebo v okolí silnic. Takové pasporty se vytvářejí především dvěma různými způsoby: manuálně v terénu a manuálně v kanceláři. V terénu probíhá měření pomocí zařízení s GPS. V kanceláři pak pomocí specializovaných softwarů. Uvedme dva příklady, PanoramaGIS⁵ a DOPRAVA⁶. Oba dva programy fungují na principu zobrazení snímané oblasti expertnímu personálu. Tento personál pak vytváří pasporty. Výstupem těchto programů je pak například

⁵<http://sluzby.geodis.cz/technologie/panoramagis>

⁶http://okas.cz/userfiles/reference_pdf/text_9.pdf

seznam všech dopravních značek v požadované oblasti. Tento seznam je možné exportovat do standardních formátů používaných v GIS (např. ESRI Shapefile).



Obrázek 17: Programy DOPRAVA (vlevo) a PanoramaGIS (vpravo).

4.4 Asistenční systémy pro vozidla

Jedním z možných využití mračky bodů jsou i tzv. autonomní automobily. V roce 2004 začala první DARPA výzva. DARPA výzva byla vyhlášena Ministerstvem obrany Spojených států amerických. Hlavním cílem výzvy bylo vyvinout autonomní roboty, kteří budou schopní se sami pohybovat v podmínkách, které jsou pro člověka moc nebezpečné. Hlavní cenou v této výzvě byl jeden milión dolarů. V roce 2004 vyjelo prvních 15 automobilů. Jejich úkolem bylo projet 228 kilometrů dlouhou pouštní trasu. Na první pokus se ovšem nepovedlo nikomu zadanou trasu projet. V roce 2005 se konal druhý ročník, ve kterém ze 195 týmů trasou projelo pět, a vítězný tým ze Stanfordu si odnesl cenu ve výši dva miliony dolarů. Třetí ročník se konal v roce 2007. Tento ročník byl ovšem zaměřený na navigování v obydlených oblastech (The DARPA Grand Challenge: Ten Years Later, 2014).

Důvodem, proč DARPA výzva souvisí s mračkou bodů je fakt, že většina týmů využívala pro navigaci v terénu 3D skenery a tedy i mračka bodů (Hillel a kol., 2014). Využití 3D skenerů přineslo značnou přidanou hodnotu. 3D skenery byly využívány pro detekci vodorovného dopravního značení (viz kapitola 4.1.4) nebo například pro detekci překážek v cestě. Jak uvádí Hillel a kol. (2014) týmy při detekci vodorovného značení využívali LIDAR také pro identifikaci objektů zakrývajících dopravní značení a detekci vozovky resp. okrajů vozovky.

4.5 3D rekonstrukce


Jednou z největších výzev v počítačovém vidění a počítačové grafice je konstrukce a reprezentace realistického virtuálního 3D prostředí v počítači. Vytvoření 3D rekonstrukce velké scenerie (jako je muzeum, historická památka nebo ulice města) bylo a je tradičně velmi nákladné, časově náročné a vyžaduje expertní personál při



Obrázek 18: Modifikovaný Ford F-250. Jeden z finalistů ve výzvě z roku 2007 (Pandey, McBride a Eustice, 2010).

jeho tvorbě. Při 3D rekonstrukci jsou hojně používána právě mračna bodů. Slouží totiž jako základ pro vytvoření 3D povrchů.

Nejjednodušším příkladem 3D rekonstrukce z mračna bodů je rekonstrukce střech. Pro tuto rekonstrukci se používají mračna bodů pořízená z leteckého mapování. Vosselman a Dijkman (2001) popisují nejběžnější verzi 3D rekonstrukce obydlených oblastí. Tato 3D rekonstrukce spočívá v identifikaci bodů ležících na střeše, detekci hran na střechách a následnou rekonstrukcí budov z nich.




Obrázek 19: Vlevo: Výsledek detekce ploch na střechách. Vpravo: Výsledný 3D model (Vosselman a Dijkman, 2001).

Nejobtížnější částí tohoto procesu je určení správné topologie střechy. Hlavní výzvou jsou pak komplexní střechy. Další příklady rekonstrukce budov ze střech je možné nalézt v Dorninger a Nothegger (2007).

Pro 3D rekonstrukci je ovšem možné použít i data pořízená pomocí mobilního mapování (El Meouche a kol., 2013).

Zhou a Neumann (2012) posouvají problematiku rekonstrukce o krok dále. Prezentují systém určený pro rekonstrukci právě obytných oblastí. Na vstupu jejich systému je mračno bodů pořízené pomocí leteckého snímkování. Výstupem je pak komplexní scéna obsahující kromě budov i stromy a zemi. Další příklad rekonstrukce budov je možné nalézt v Kai a Ming-ju (2014). Autoři se soustředí na nepravidelné budovy (konkrétně na klášter Jinshan v Číně).

Jednou z oblastí používající mračna bodů pro rekonstrukci je i rekonstrukce historických památek. Díky této rekonstrukci je možné velice přesně dokumentovat historickou památku. Příkladem může být rekonstrukce skalního města Petra v Jordánsku (Alshawabkeh, 2005).



Obrázek 20: Vlevo: 3D model skalního města vytvořený pomocí 5-ti skenů. Vpravo: 360-ti stupňové skenování vnitřních prostor (Alshawabkeh, 2005).

Další příklad rekonstrukce historických památek je možné nalézt v Remondino a kol. (2009). Ve svém článku popisují důvody pro rekonstrukci historických památek:

- Dokumentování historických budov a objektů pro pozdější obnovení v případě požáru, zemětřesení, povodně nebo jiné katastrofy.
- Vytvoření výukových materiálů pro studenty historie a kultury.
- Zobrazení scén z pohledů, které nejsou díky velikosti či přístupnosti dostupné.

- Rekonstrukce budov nebo objektů, které již neexistují, nebo jsou výrazně poškozeny.
- Interakce s objekty bez nebezpečí jejich poškození.
- Poskytnutí virtuálních prohlídek měst nebo například muzeí.

Společným rysem většiny metod a přístupů pro rekonstrukci je využití jak mračen bodů, tak i obrazových dat. Obrazová data jsou ve většině případů používána pro otexturování výsledných modelů. Remondino a kol. (2009) navrhuje zajímavou kombinaci obrazových dat a mračen bodů při rekonstrukci. Pomocí obrazových dat je provedena hrubá rekonstrukce venkovních prostor (s využitím *Image-based rendering* metod). Pro rekonstrukci detailů jsou pak použity právě mračna bodů, která nabízejí mnohem větší přesnost.



Obrázek 21: Výsledek rekonstrukce systémem 3D-Arch (Remondino a kol., 2009).

5 Zpracování mračna bodů

V této kapitole jsou popsány čtyři základní kategorie operací, které bývají běžně prováděny nad mračny bodů. Těmito kategoriemi jsou: registrace, segmentace, vzorkování, filtrace. Tyto kategorie operací budou využívány v další části práce při zpracování mračen bodů.

5.1 Registrace

Registrace je proces nalezení společného souřadného systému pro více jednotlivých množin pořízených dat. Jakékoliv použité zařízení nám vždy v konkrétním okamžiku vrátí pouze mračno bodů z jednoho úhlu, tedy z jednoho konkrétního pohledu. Pracovat pouze s jedním mračnem bodů je velice vzácné a je možné pouze u velice jednoduchých objektů. Ve většině případů je nutné najít společné vlastnosti pro jednotlivá mračna bodů a tím je spojit dohromady tak, aby vytvořily podrobnější obraz scény (Bernardini a Rushmeier, 2002).


V high-end systémech je registrace řešena přesným sledováním pozice skeneru, např. jeho propojením se zařízením pro měření pozice a orientace senzoru. V méně nákladných zařízeních může být registrace řešena několika jinými způsoby, např.:

- Použitím otočného stolu pro skenování povrchu konkrétního objektu (Bernardini a Rushmeier, 2002).
- Využitím lidské pracovní síly v podobě technika určujícího např. tři a více stejných bodů v jednotlivých částech dat (Mure-Duboids a Hugli, 2008).
- Nalezení shodných rysů (features) ve všech mračnách bodů (Jaw a Chuang, 2008).
- Využití informace o barvě pro nalezení shody mezi mračny bodů (Sinha, 2002).

Silva, Bellon a Boyer (2004) rozdělují přístupy k registraci do dvou kategorií: prostá registrace a jemná registrace. V prosté registraci je cílem nalezení závislosti mezi mračny bodů bez jakékoliv předchozí znalosti vztahů mezi nimi. Bez znalosti předchozí transformace je nutné spoléhat na další vlastnosti obsažené v mračnách bodů: hrany, linie, plochy, křivky, zahnutí, orientace povrchu a další.

Naopak jemná registrace spoléhá na předchozí znalost transformace mezi mračny bodů. Typickým příkladem této kategorie je *Iterative Closest Points* algoritmus. (Basl a kol., 1992). Algoritmus ICP začíná se dvěma mračny bodů a přibližným odhadem transformace mezi nimi. Algoritmus následně iterativně zlepšuje tuto transformaci za použití nalezení shodných rysů v obou mračnách bodů. Zároveň také nalezne nejlepší rotaci a translaci, která minimalizuje chybu ve vzdálenosti mezi jednotlivými body (Mitra a kol., 2004).

Mitra a kol. (2004) poukazuje na to, že i přes velké množství výzkumu v oblasti registrace, právě chyba ve vzdálenosti je ve většině případů opomíjena. V Silva, Bellon a Boyer (2004) a Bernardini a Rushmeier (2002) je popsáno mnoho variací ICP algoritmu, které se snaží odstranit jeho nedostatky.



Obrázek 22: Příklad registračního algoritmu. Navázání částečného skenu na originál (Mitra a kol., 2004).

5.2 Segmentace

Segmentace je proces rozdělení bodů do skupin na základě podobných nebo shodných vlastností. Tyto body následně vytvoří menší mračna bodů vytvořené z původního. Takto vytvořené segmenty mračen bodů musí být smysluplné tak, aby označovaly vždy konkrétní objekty (např. stromy) nebo části objektů (např. části budov) (Ning a kol., 2009).

Rabbani a kol. (2006) rozdělují segmentační algoritmy do tří kategorií:

- Segmentace podle hran – algoritmy pro segmentaci podle hran mají dva základní kroky, a to detekce hran, které ohraničují různé oblasti a následné seskupení bodů patřících do této oblasti. Hrany jsou detekovány na základě změny ve vlastnostech částí obrazu, jako například v normálech povrchů, zahnutí povrchů a dalších.
- Segmentace podle povrchů – tento způsob segmentace využívá základních vlastností povrchů a na základě shody těchto vlastností sjednocuje jednotlivé části dat. Jak Rabbani a kol. (2006) poukazují, tyto metody jsou méně náchylné k šumu v datech a mají proto mnohdy lepší výsledky než metody segmentace podle hran.
- Segmentace pomocí skenovacích linek – třetí kategorie segmentace se používá především pro data získaná z velké vzdálenosti a segmentuje mračno tak, že každá řada v mračnu bodů je považována za skenovací linku. U této skenovací linky se určí vlastnosti jednotlivých částí a ty se pak dále seskupují dohromady.

Existuje mnoho přístupů k segmentaci a mnohdy jsou definovány výsledným použitím segmentovaných dat. Například Lerma a Biosca (2005) se zabývají segmentací architektonických dat. Jimi navrhovaná segmentace probíhá ve třech krocích. V prvním kroku jsou data rozdělena do několika kategorií podle typu povrchů. Jejich algoritmus definuje maximálně čtyři typy povrchů: rovinný, hladký, zvlněný a vysoce zvlněný. V druhém kroku se pak zaměřují pouze na body, které patří k rovinným povrchům. Cílem je separovat body na rovinných površích do různých tříd. Každou

třídou je pak skupina rovin se stejným sklonem. Jinými slovy každá třída definuje skupinu paralelních rovin, které se liší pouze ve vzdálenosti od cíle. V posledním kroku jsou pak body ve třídách rozděleny do několika paralelních rovin. Nevýhodou algoritmu je jeho omezené použití, hodí se především pro objekty složené převážně z rovných povrchů.


Ning a kol. (2009) navrhují metodu segmentace na základě normálových vektorů. Segmentace je pak použita pro zlepšení identifikace architektonických tvarů v mračnu bodů. Jejich metoda pracuje ve čtyřech krocích. V prvním kroku vypočítají normály. V druhém kroku se provede hrubá segmentace, na jejímž základě se provede identifikace základních objektů ve scéně (např. stromů). Posledním krokem je pak přesnější segmentace konkrétních částí objektů.

5.2.1 Segmentace pomocí Euklidovské vzdálenosti

V této práci bude využita především segmentace na základě Euklidovské vzdálenosti (Rusu, 2009). Tato segmentace pracuje na principu rozdělení bodů podle vzdálenosti mezi nimi. Pokud je vzdálenost mezi dvěma body větší než daný práh, tyto body patří do rozdílných segmentů. Tento princip segmentace má ovšem jednu nevýhodu. Je nutné počítat vzdálenost mezi všemi body v mračnu bodů. Proto je nutné segmentaci optimalizovat. Toho je docíleno s využitím KD-Tree. KD-Tree je generalizací binárního prohlédávacího stromu, který ukládá body v k -rozměrného prostoru (PCL – Euclidean Cluster Extraction, 2014).

Pseudokód 1 Implementace segmentace pomocí Euklidovské vzdálenosti

- 1: Pro vstupní mračno bodů P je vytvořena KD-Tree reprezentace
 - 2: Je vytvořen prázdný seznam všech segmentů C a fronta bodů,
 - 3: které mají být zařazeny do segmentů Q
 - 4: **for** každý bod z P **do**
 - 5: Bod je zařazen do fronty Q
 - 6: **for** každý bod z fronty Q **do**
 - 7: Najdi množinu sousedních bodů, které jsou v kouli
 - 8: o poloměru menším, než je práh vzdálenosti
 - 9: Zařaď do fronty Q každý sousední bod, který dosud nebyl zpracován
 - 10: **end for**
 - 11: Jakmile jsou zpracovány všechny body ve frontě Q , zařaď frontu
 - 12: do seznamu segmentů C
 - 13: **end for**
 - 14: Algoritmus končí ve chvíli, kdy je každý bod ze vstupního mračna bodů
 - 15: zařazen do seznamu segmentů C .
-



Obrázek 23: Příklad segmentace pomocí Euklidovské vzdálenosti.

5.2.2 Region Growing segmentace

Region Growing algoritmus je jedním z běžně používaných segmentačních algoritmů ve zpracování obrazu. Algoritmus má za cíl zjistit, jestli pixel náleží ke konkrétní oblasti. Základem tohoto algoritmu je určení počátečního bodu (seed point). Od tohoto bodu jsou prohledávány sousední pixely, a pokud odpovídají daným pravidlům, jsou zařazeny do stejné oblasti. Nevýhodou tohoto algoritmu je právě potřeba určení počátečního bodu (Russ, 2011). Ovšem velkou výhodou tohoto algoritmu je možnost stanovit si vlastní pravidla pro segmentaci. Díky tomu je tento princip hojně využíván i u mračen bodů.

Tento algoritmus má velice jednoduchý princip (PCL – Region Growing segmentation, 2014):

Příklad využití Region Growing algoritmu je možné nalézt v Zhan a kol. (2009). Jejich algoritmus segmentuje obarvené mračno bodů na základě podobnosti barev.

5.3 Vzorkování (zjednodušení)

V praxi se běžně setkáváme s mračny bodů mnoha velikostí. Velikost může být od několika tisíc bodů až po několik stovek milionů bodů. V prvním případě je možné nad mračnem bodů provádět jakékoliv operace; je-li ovšem množství bodů velké, jakékoliv zpracování zabere mnoho času. Proto je v řadě případů nutné zmenšit množství bodů.

Existuje mnoho způsobů jak zjednodušit mračno bodů. Du, Yin a Kong (2007) zmiňují tři, a to: vzorkování, iterativní zjednodušení a shlukování. Hlavní myšlenkou vzorkování je výpočet nového mračna bodů založeného na tom původním. Iterativní

Pseudokód 2 Popis principu Region Growing algoritmu

```

1: while Seznam bodů  $A$  není prázdný do
2:   Najdi první nezpracovaný bod odpovídající pravidlu
3:   Založ novou oblast a vlož do ní nalezený bod
4:   for Každý bod v seznamu bodů  $A$  do
5:     if bod je v seznamu  $A$  a odpovídá daným pravidlům then
6:       Zařaď bod do aktuální oblasti
7:       Vyřaď bod ze seznamu  $A$ 
8:     end if
9:   end for
10:  Vlož novou oblast do seznamu oblastí
11: end while

```


zjednodušení vybírá dvojice bodů, které následně kolabuje do jednoho. Tento proces probíhá v mnoha iteracích, dokud nedojde k požadovanému zjednodušení. Shlukování rozděluje mračno bodů do více menších a sjednocuje body v konkrétních částech. Pauly, Gross, Kobbelt (2002) ještě přidávají čtvrtý způsob. Tento způsob je založen na zjednodušení mračna bodů na základě povrchu. V první fázi se vytvoří povrch z daných bodů. Cílem je pak nalezení nového povrchu, který je co nejbližší tomu starému a zároveň splňuje podmínku menšího množství bodů, než měl původní. Toto množství bodů je dopředu dané. Také ale poukazují, že při výběru správného způsobu velice záleží na výsledném použití.

Z výše uvedeného je zřejmé, že existují dvě hlavní kategorie metod, a to metody zjednodušující přímo mračna bodů a metody zjednodušující mračno bodů na základě zjednodušení povrchu. Metody v druhé kategorii mají velkou nevýhodu, a tou je potřeba prvotního vytvoření povrchu. To může mít za následek zvýšení náročnosti na výpočetní výkon a hodí se tedy jen pro mračna bodů s menším počtem bodů. Jedním z problémů při zjednodušování, na který poukazují Du, Yin a Kong (2007), je náročnost na operační paměť. Většina algoritmů neustále udržuje v paměti kromě nových, zjednodušených dat i ty původní. Proto navrhují algoritmus, který tento problém odstraňuje.

Dalším, hojně využívaným způsobem zjednodušení 3D mračna bodů, je převod do 2D, ve většině případů převod na 2D obraz. Díky tomuto převodu je možné razantně snížit počet bodů. Dalším důvodem této operace je možnost následného použití standardních metod pro zpracování obrazu. Převod do 2D je použit například v Bisheng a kol. (2012).

Jimi popsaná metoda spočívá ve vytvoření bounding boxu kolem mračna bodů (bounding box je vytvořen pomocí znalosti levého dolního a pravého horního rohu mračna bodů). Následně vypočítají šířku (W) a výšku (H) výsledného obrazu. Šířka a výška jsou vypočítány pomocí rovnic:

$$W = \frac{X_{\max} - X_{\min}}{GSD} \quad (1)$$



Obrázek 24: Příklad segmentace. Zleva: Zdrojové mračno bodů, běžná segmentace, segmentace detailů scény, výsledná segmentace (Zhan a kol., 2009).

$$H = \frac{Y_{\max} - Y_{\min}}{GSD} \quad (2)$$


X_{\min} , Y_{\min} , X_{\max} a Y_{\max} jsou souřadnice rohů bounding boxu. GSD (Ground Sample Distance) je hodnota prostorového rozlišení. Jakmile je šířka a výška obrazu vypočítána, je každý bod v mračna bodů zařazen do konkrétního pixelu v obraze.

5.4 Odstranění šumu

Odstranění šumu je běžnou operací při zpracování mračna bodů. Šumem máme na mysli body, které se nenacházejí na povrchu skenovaného objektu. Jsou to tedy body, které chceme z mračna bodů odstranit. Tyto body se také nazývají „outliers“. Odstranění těchto bodů není jednoduchý proces, protože je nutné brát v úvahu mnoho faktorů a vlastností mračna bodů. Jsou jimi například geometrické nesrovnalosti způsobené překrytím různých částí objektů, žádná předchozí znalost rozmístění jednotlivých bodů, existence šumu v datech, různé hustoty jednotlivých částí mračna bodů a další (Sotoodeh, 2006).

Metody pro odstranění šumu v datech je možné rozdělit do dvou kategorií: odstranění šumu přímo z mračna bodů a odstranění šumu vyhlazením povrchu objektů. Příkladem první kategorie je například algoritmus implementovaný v PCL (Removing outliers using a StatisticalOutlierRemoval filter, 2014). Tento algoritmus statisticky analyzuje okolí každého bodu a vymaže ty body, které nesplňují požadovaná kritéria. Jejich algoritmus je založený na výpočtu rozmístění bodů v závislosti na

vzdálenosti k jeho sousedům. Pro každý bod je spočítán průměr vzdáleností k jeho sousedům. Předpokládají, že výsledné rozdělení je Gaussovské s průměrem a standardní odchylkou a tím pádem jsou všechny body, které leží mimo interval definovaný globálním průměrem a směrodatnou odchylkou považovány za šum a odstraněny (obr. 25).



Obrázek 25: Příklad odstranění šumu implementovaný v *PCL* (Removing outliers using a *StatisticalOutlierRemoval* filter, 2014).

Metody v druhé kategorii fungují na principu zjemnění a vyhlazení povrchu a tím odstraní šum v datech. Odstranění šumu v této kategorii metod je tedy mnohdy spojené s vytvářením povrchu (resp. 3D modelu). Nejjednodušší metodou pro vyhlazení povrchu je Laplacianovo vyhlazení (Bray, 2004), které funguje pouze na principu zprůměrování hodnot sousedních bodů a tím zjištění nové polohy bodu v polygonové síti. Jednou z velice populárních metod využívaných jak při rekonstrukci povrchu, tak při jeho vyhlazení, je Moving Least Squares. Tato metoda je použita například v Mederos, Velho a de Figueiredo (2003a).

6 Metodika vývoje a testování metod

V předchozích kapitolách byla popsána mračna bodů, způsoby jejich zpracování a dále pak různé přístupy k detekci čtyř typů objektů: bodů na zemi, sloupovitých objektů a svislého a vodorovného dopravního značení. Prvním krokem postupu musí být jasné definování informací, které je možné získat z mračna bodů o těchto objektech. V rámci zasazení této problematiky do kontextu obecné detekce objektů budou porovnány informace, které je možné získat buď z mračna bodů, nebo ze standardních obrazových dat. Rozvedeny budou především tři poslední typy objektů (viz podkapitola 6.1).

Důvodem porovnání s obrazovými daty je fakt, že v praxi používaná záznamová zařízení pořizují jak mračna bodů, tak i obrazová data (viz kapitola 2.2.2).

Cílem práce je navržení nových metod pro detekci objektů v mračnech bodů. V následujících kapitolách jsou popsány čtyři nové metody pro detekci objektů v mračnech bodů. U každé této metody je popsáno:

- zhodnocení současných metod detekce objektu,
- důvod vytvoření metody,
- princip fungování metody,
- otestování metody na reálných datech,
- shrnutí funkcionality metody.

Především testování metody na reálných datech je velice důležitou částí celého procesu vývoje. V podkapitole 6.2 je popsán způsob vyhodnocení úspěšnosti jednotlivých metod. Tři metody budou hodnoceny na základě jednoho způsobu, čtvrtá pak jiným.

V poslední části této kapitoly budou popsány dostupné vzorky mračen bodů. Veškeré testování metod bude prováděno na těchto vzorcích.

6.1 Možné získané informace

Jednotlivé informace budou vycházet z rešerše v kapitole 4.1 a budou se vztahovat ke třem typům objektů: sloupovité objekty, dopravní značení, vodorovné značení. Výsledky této kapitoly publikovali Landa a Procházka (2014).

6.1.1 Sloupovité objekty

Jedinou informací, kterou je možné přesně získat z obrazových dat je barva sloupu. Toto je ovšem informace, která není v praxi žádána a pro její získání je nutné objekt najít. Proto jsou na detekci a identifikaci sloupovitých objektů používány výhradně mračna bodů.

Z mračna bodů lze získat především:

- výšku sloupovitého objektu,
- průměr sloupovitého objektu,
- pozici základny objektu,
- typ sloupovitého objektu.

V praxi nejvíce žádanou informací je pozice základny objektu. Další obvyklou informací je pak výška, díky které je možné i částečně určit typ objektu (sloup, lampa atd.). Průměr sloupovitého objektu je také možné využít pro určení typu, ovšem tato informace je velice těžko získatelná. Je to především z důvodu umístění mnoha jiných objektů na sloupy (např. reklamy nebo dopravní značení).

6.1.2 Svislé dopravní značení

U svislého dopravního značení se v praxi eviduje mnoho různých informací, ovšem tou nejdůležitější je, o jakou značku se jedná. Tato informace je v praxi při hledání značek nejžádanější. Tuto informaci je možné získat pouze z obrazových dat. Z mračna bodů by bylo možné identifikovat pouze značky, které mají jedinečný tvar. Právě z toho důvodu většina systémů pro detekci značek využívá standardní videokamery a ne 3D skenery. Z obrazových dat je pak možné ještě získat informaci o opotřebení barvy značky a to díky analýze intenzity barvy na značce.

Mezi informace, které je možné o dopravním značení získat z mračna bodů patří především:


- pozice značky,
- opotřebení barvy na značce,
- poškození tvaru značky,
- přesná pozice sloupu, na kterém je značka připevněna.

Klíčovou informací získávanou z mračna bodů je pozice značky. Pozice značky je reprezentována středem značky. Tuto informaci lze s dobrou přesností získat pouze z mračna bodů. Z obrazových dat je možné ji získat, ale s velice malou přesností (desítky centimetrů). S pozicí značky souvisí i pozice sloupu, ke kterému je značka připevněna. Tato pozice je reprezentována místem, kde je sloup zapuštěn do země. I tuto informaci by bylo extrémně náročné získat z obrazových dat.

Další dvě informace, které je možné získat z mračna bodů, je opotřebení barvy na značce a poškození tvaru značky. Opotřebení barvy je možné zjistit pomocí zjišťování intenzity a množství bodů na značce. U nové značky bude množství bodů větší, než u staré a poškozené. O zjišťování poškození tvaru značky je možné nalézt více v González-Jorge a kol. (2011).

Z předchozího textu tedy vyplývá, že obrazová data je nejlepší použít v případě, že chceme identifikovat dopravní značení. Pokud ovšem chceme značku pouze detekovat (tedy určit její pozici) je nejlepší použít mračno bodů. Mračno bodů má také

jednu velkou výhodu. Je možné jej použít, i když bylo pořízeno při špatném počasí, nebo obecně při špatných světelných podmínkách (snímání ráno nebo večer, kdy je slunce pod malým úhlem a značnou část značek tedy neosvítí). Právě omezená doba snímání je obecně při pořizování obrazových dat ve viditelném spektru problém (viz obr. 26).



Obrázek 26: Srovnání viditelnosti dopravního značení při špatném počasí z obrazových dat (vlevo) a mračna bodů (vpravo).

6.1.3 Vodorovné značení

Vzhledem k tomu, že detekce a identifikace vodorovného značení je v praxi nejvíce používána pro automatické řízení vozidla je ve většině případů použita obyčejná kamera. Tou nejdůležitější informací extrahovanou z obrazových dat bývá typ čáry (přerušovaná a plná), dále pak navigační šipky a v neposlední řadě také přechody pro chodce. Z obrazových dat je možné získat následující informace o značení:

- barva značení,
- tvar značení,
- typ značení,
- pozice značení.

Získání barvy značení je možné pouze z obrazových dat. Ve většině případů je na značení použita bílá barva, ovšem není výjimkou i jiná, především žlutá. Získání tvaru značení je použito především u identifikace šipek a přerušovaných čar. Díky získání tvaru je možné použít různé techniky pro porovnání tvaru proti šabloně (např. *Template Matching*). Poslední a nejdůležitější informací je typ značení. Zjišťuje se, o jaký typ čáry se jedná, jaký je typ šipky, jestli se ve scéně nachází přechod pro chodce apod. I z obrazových dat je možné získat pozici značení, ovšem takto získaná pozice nebude mít příliš velkou přesnost.

Z mračna bodů je možné získat následující informace:

- tvar značení,
- pozice značení,
- typ značení.

Určení typu a tvaru značení z mračna bodů mnohdy probíhá stejně jako u obrazových dat (především u reálných metod). U vodorovného značení se mračno bodů používá především pro zjištění přesné pozice vodorovného značení.

6.2 Způsob hodnocení úspěšnosti metod

Metoda pro detekci bodů na vozovce bude hodnocena dvěma způsoby. Prvním způsobem je vizuální zhodnocení úspěšnosti metody při různých nastaveních. Druhým způsobem je pak především zhodnocení časové náročnosti metody na různých vzorcích mračen bodů.

Zbylé tři metody ovšem budou hodnoceny podle jiných kritérií, a to konkrétně podle ukazatelů přesnosti, úplnosti a kvality (Boyko a Funkhouser (2011), Kučerová (2011), Bruckhaus (2014)).

Při hodnocení pomocí přesnosti, úplnosti a kvality je nutné definovat kategorie hodnot:

- Správně určený objekt (True Positive, TP) – správně určená hodnota (správně detekovaný objekt v mračnu bodů).
- Špatně určený objekt (False Positive, FP) – špatná hodnota určená jako správná (detekovaný objekt špatně označený jako hledaný objekt).
- Nesprávně vynechaný objekt (False Negative, FN) – správná hodnota určená jako špatná (detekovaný objekt špatně označený jako nehledaný objekt).

Nyní se podívejme na výpočet jednotlivých ukazatelů. Všechny ukazatele se v praxi vyjadřují v procentech.

Ukazatel přesnosti

Ukazatel přesnosti představuje poměr mezi počtem správně nalezených objektů k celkovému počtu nalezených objektů.

$$p = \frac{TP}{TP + FP} \quad (3)$$

Ukazatel úplnosti

Ukazatel úplnosti představuje poměr mezi počtem správně nalezených objektů a celkovým počtem správných objektů v daném vzorku.

$$r = \frac{TP}{TP + FN} \quad (4)$$

Ukazatel kvality

Ukazatel kvality představuje poměr mezi počtem správně nalezených objektů a součtem počtu správných objektů v daném vzorku s počtem detekovaných objektů špatně označených jako správné objekty.

$$q = \frac{TP}{TP + FP + FN} \quad (5)$$

6.3 Testovaná mračna bodů


Pro potřeby této práce jsou k dispozici dva testovací vzorky mračen bodů. Oba vzorky jsou pořízeny pomocí mobilního mapování, ovšem liší se jak v hustotě bodů, tak v oblasti, kterou pokrývají. Oba dva vzorky byly zapůjčeny firmou Geodis a.s. a jsou uloženy ve formátu LAS.

Prvním vzorkem (obr. 27) jsou mračna bodů ve vysokém rozlišení skeneru pokrývající více jak 2 km silnice uprostřed města Brna. Naskenovaná oblast se nachází v okolí Mendlova náměstí a je uložena ve 20 souborech obsahujících více jak 150 milionů bodů.



Obrázek 27: Náhled prvního vzorku mračna bodů (vlevo mapa, vpravo kompletní mračno bodů).

Druhý vzorek (obr. 28) mračen bodů je v mnohem nižším rozlišení a pokrývá mnohem větší oblast, a to konkrétně více jak 17 km silnice. Tato mračna bodů jsou uložena ve třech souborech a obsahují téměř 90 milionů bodů.



Obrázek 28: Náhled druhého vzorku mračen bodů (vlevo mapa, vpravo kompletní mračno bodů).

Oba dva vzorky se velice liší ve své hustotě bodů. Protože je u laserového skenování těžké určit přesnou hustotu bodů (z důvodu úpravy mračen bodů před uložením do LAS) byl pro měření hustoty vybrán jeden bod, který je společný pro oba vzorky. Kolem tohoto bodu (nacházejícího se uprostřed silnice) byl vytvořen kruh o polooměru 2 m a v něm změřen počet bodů. V prvním vzorku se nacházelo 17 496 bodů a v druhém 2 645 bodů. Z toho plyne, že první vzorek má více jak 6× větší hustotu. Kompletní srovnání obou vzorků je uvedeno tabulce 2.

Tabulka 2: Srovnání dvou testovaných vzorků mračen bodů.

	Vzorek 1	Vzorek 2
Počet bodů	150 913 399	89 999 997
Hustota bodů	2 645	17 496
Přibližná délka trasy (km)	2	17

U každého bodu v obou mračnách bodů jsou evidované následující údaje:

- x souřadnice – x souřadnice v Křovákovi,
- y souřadnice – y souřadnice bodu v Křovákovi,
- z souřadnice – nadmořská výška (v m n. m.),
- odrazivost – odrazivost bodu. Reflexní materiály mají větší intenzitu (např. dopravní značky),
- klasifikace – každý bod má klasifikaci 0 nebo 7, kde 7 je klasifikován bod nad a pod dráhou automobilu,
- počet návratů – počet pulsů, které se po vyslání vrátily z konkrétního bodu,

- snímaný úhel – úhel, pod kterým byl vyslán laserový paprsek ze skeneru.

Všechny testy byly prováděny na počítači MacBook Air, Intel i5 1.7 GHz, 4 GB RAM, s SSD diskem bez použití více vláknové optimalizace.

Pro potřeby testování byla vytvořena aplikace testující všechny v práci prezentované metody. Tato aplikace byla vytvořena s využitím knihoven:

- PCL⁷ – Point Cloud Library je v dnešní době nejpoužívanější open source knihovnou pro práci s mračny bodů. Umožňuje mračna bodů nejen ukládat a číst z nich, ale obsahuje i mnoho algoritmů pro práci s nimi. Jmenujme například segmentační algoritmy, algoritmy pro filtrování, algoritmy pro rekonstrukci povrchu, vizualizaci a další. Značnou výhodou je velká komunita stojící za vývojem a správou a zároveň velmi kvalitní dokumentace.
- OpenCV⁸ – OpenCV je nejpoužívanější open source knihovnou pro zpracování obrazu. Knihovna nabízí velké množství algoritmů používaných při zpracování obrazu, od hranových detektorů po algoritmy využívající neuronové sítě.
- libLAS⁹ – libLAS je open source knihovna pro načítání a ukládání LAS souborů. Knihovna umožňuje použít programovací jazyk C++, C# nebo Python.
- Shapelib¹⁰ – ShapeLib je open source knihovna napsaná v programovacím jazyce C umožňuje číst a ukládat soubory od firmy ESRI Shapefile. Shapefile je v praxi často používán pro ukládání prostorových dat.

⁷<http://pointclouds.org/>

⁸<http://opencv.org/>

⁹<http://www.liblas.org/>

¹⁰<http://shapelib.maptools.org/>

7 Algoritmus pro identifikaci bodů na zemi

V této kapitole bude popsán algoritmus pro identifikaci bodů nacházejících se na zemi. Tento algoritmus neidentifikuje přímo body na vozovce, ale snaží se izolovat nejnižše položené body v mračnu bodů. Identifikace bodů nacházejících se na zemi je nepostradatelnou částí dalších metod popsaných v této práci.

Jak vyplývá z kapitoly 4.1.1, existuje několik algoritmů pro identifikaci bodů země. Nejjednodušší verzí algoritmu je izolace bodů pomocí jejich nadmořské výšky. V praxi to pak znamená izolaci např. 10 % nejnižších bodů. Tento přístup lze ovšem efektivně použít pouze pro rovinné úseky. Toto je velká nevýhoda tohoto přístupu a důvod, proč se používá pouze výjimečně a pouze u měření pořízených na rovném terénu.

Další variantou jsou metody pro identifikaci přímo vozovky, například identifikace pomocí patníků. Tento postup ovšem předpokládá, že budou všude ve snímané oblasti obrubníky. Pokud ovšem v nějaké oblasti nebudou, tak nedojde k identifikaci vozovky. Dále je u této metody nutnost dostatečného rozlišení senzoru. Jako další možnost se jeví algoritmy využívající vlastností vozovky. Tyto algoritmy mají ovšem mnoho předpokladů a opět se hodí především na rovné úseky. Pokud sloučíme všechny tyto požadavky, tak zjistíme, že univerzální algoritmus pro identifikaci vozovky je velice těžko implementovatelný pro reálné použití na velmi odlišných mračnech bodů v různých terénech.

Požadavky na mračna bodů jsou:

- Co nejvíce vodorovný povrch země.
- V oblasti jsou nutné chodníky, resp. obrubníky, ideálně s horizontálním značením u nich.
- Velké rozlišení skeneru, díky němuž je možné detekovat rozdíl mezi vozovkou a chodníkem.

Pokud tedy není některý z těchto požadavků splněný, není možné použít některou z metod popsaných v kapitole 4.1.1.

Pro potřeby této práce bylo nutné vytvořit algoritmus, který je univerzální a který bude pracovat ve všech podmínkách. Zároveň s tím není nutné, aby byly identifikovány přesně body vozovky, ale je nutné identifikovat, a v některých případech odstranit, všechny nejnižše položené body (v určité toleranci). Z těchto důvodů vznikl níže uvedený algoritmus. Algoritmus pro identifikaci bodů na zemi publikovali Landa, Procházka a Štastný (2013).

7.1 Popis algoritmu pro identifikaci bodů na zemi

Algoritmus pro identifikaci bodů na zemi pracuje na principu identifikace určitého procenta nejnižších bodů, ovšem dynamicky se přizpůsobuje povrchu země a je proto schopen identifikovat body i v členitém terénu (např. na kopci).

Pseudokód 3 Algoritmu pro odstranění země

```

1: Vytvoření bounding boxu
2: Rozdělení bounding boxu do  $n$  menších bloků
3: for každý blok do
4:   Výpočet maximální a minimální výšky v bloku
5:   Výpočet koeficientu pro odstranění země ( $C_{HE}$ )
6:   if nadm. výška bodu je  $\leq C_{HE}$  then
7:     Označit bod jako bod na zemi
8:   else
9:     Označit bod jako bod nad zemí
10:  end if
11: end for

```

Pro potřebu algoritmu byl vytvořen vzorec pro výpočet koeficientu pro odstranění země:

$$C_{HE} = \min_l H + \Delta H \left(1 - \frac{\max_g H - \max_l H}{\Delta H} \right) + C_E \quad (6)$$


kde:

$\min_l H$ je minimální nadmořská výška v bloku,
 $\max_l H$ je maximální nadmořská výška v bloku,
 $\max_g H$ je maximální nadmořská výška celého mračnu bodů,
 ΔH je rozdíl mezi minimální a maximální nadmořskou výškou celého mračna bodů,
 C_E je výškový koeficient.

Výškový koeficient je možné nastavit na jakékoliv číslo od 0 do 1 (např. 0,01 představuje přibližně 0,5 m nad zemí). Algoritmus pracuje na principu rozdělení mračna bodů do n sloupců. V každém sloupci jsou pak izolovány nejnižší body identifikované pomocí výše zmíněného vzorce. Díky tomu je možné identifikovat body i v mračnu bodů, které bylo pořízeno na nerovném terénu. V následující kapitole je otestováno, jak se algoritmus chová na různých mračnech bodů.

7.2 Testování algoritmu

Testování algoritmu bylo provedeno na obou dvou vzorcích mračen bodů. Algoritmus byl testován ve dvou hlediscích. Prvním je, jak se chová při různých nastaveních parametrů a při různých velikostech mračen bodů. Druhým kritériem je vizuální hledisko a to konkrétně vizuální zhodnocení celého mračna bodů, ve kterém jsou barevně odděleny body, které algoritmus identifikoval jako body nacházející se na zemi.



Obrázek 29: Rozdělení vstupního mračna bodů do n bloků.

7.2.1 Testování na prvním vzorku mračen bodů

U prvního vzorku byl algoritmus testován nejdříve na částech a následně na celém mračnu bodů. V tabulce 3 jsou znázorněny výsledky měření na prvním vzorku mračen bodů.

Z měření jasně vyplývá, že s rostoucím počtem bloků (a s rostoucím počtem bodů) roste i množství času potřebného pro identifikaci bodů na zemi. Měřené hodnoty počtu bloků v jednom směru (n) byly stanoveny experimentálně. Pro univerzálnost algoritmu není doporučeno snižovat hodnotu n pod 20. Pokud dojde ke snížení pod 20, může dojít k vynechání značné části mračna bodů v hodně členitém terénu. Experimentováním bylo také zjištěno, že pro testovaná mračna bodů je ideální hodnota $n = 50$. Při této velikosti dojde ke korektnímu identifikování bodů na zemi a zároveň je doba výpočtu udržena v rozumné míře.

Největší časovou zátěží na algoritmus je rozdělení původního mračna bodů do n bloků. Tato operace zabírá přibližně 99 % veškerého času. I z tohoto důvodu je algoritmus testován při konstantní velikosti výškového koeficientu. Jeho změnu je možné zhodnotit především vizuálně.

Algoritmus byl dále testován na celém vzorku mračen bodů (150 mil. bodů). Při ideálním nastavení $n = 50$ byla délka zpracování 24 minut a 14 vteřin. Další výsledky testování jsou zaznamenány v tabulce 4.

Na obrázku 30 je znázorněno vizuální testování. Na obrázku je vidět, že při nízkém počtu bloků dojde k vynechání velké části vozovky. Stejně tak je patrné, že existuje minimální změna v počtu detekovaných bodů při hodnotě $n = 50$ a 100.

Tabulka 3: Výsledky testování algoritmu na několika souborech z prvního vzorku mračen bodů.

ID mračna bodů	Počet bloků v jednom směru (n)	Výškový koeficient	Celkový počet bodů	Počet bodů na zemi	Čas výpočtu (v sek.)	
1	20	0,01	2 580 808	1 308 476	3	
	50			1 394 426	26	
	100			1 445 879	94	
2	20		2 419 989		1 202 970	3
	50				1 334 949	24
	100				1 367 936	92
3	20		1 478 228		618 891	2
	50				686 463	14
	100				776 005	52
4	20		7 623 968		3 545 657	11
	50				4 082 894	67
	100				4 166 367	268
5	20		11 075 785		8 188 951	21
	50				8 420 206	100
	100				8 453 547	845
6	20		17 707 429		10 868 232	33
	50				12 122 860	162
	100				12 536 323	637


Pomocí vizuální kontroly je možné říci, že při nastavení výškového koeficientu na hodnotu 0,01 dojde k identifikaci bodů přibližně 0,5 m nad zemí. Při hodnotě 0,1 už jsou to více jak 3 m. Znázorněné mračno bodů představuje největší převýšení v měřeném mračnu bodů, a to konkrétně 7 m.

7.2.2 Testování na druhém vzorku mračen bodů

U druhého vzorku mračen bodů byl algoritmus otestován jen na části a to z důvodů stejných charakteristik dalších dvou mračen bodů. U druhého vzorku bylo zjištěno, že algoritmus se nehodí pro mračna bodů pokrývající velkou oblast. Zatímco u prvního vzorku pokrývají jednotlivé soubory oblasti v metrech čtverečních, u druhého jsou to stovky metrů. Pro takovou oblast by bylo nutné nastavit parametr n na hodnotu 1000 a více. Při prvních testech trvala identifikace více jak 14 hodin. Proto bylo nutné

Tabulka 4: Výsledky testování algoritmu na celém prvním vzorku mračen bodů.

ID mračna bodů	Počet bloků v jednom směru (n)	Výškový koeficient	Celkový počet bodů	Počet bodů na zemi	Čas výpočtu (v sek.)
Všechny	20	0,01	150 913 399	91 884 402	296
	50			98 036 301	1454
	100			99 769 069	5581

Obrázek 30: Vlevo nahoře – $n = 10$, VK = 0,01, vpravo nahoře $n = 50$, VK = 0,01, vlevo dole – $n = 100$, VK = 0,01, vpravo dole $n = 50$, VK = 0,1.

toto mračno bodů rozdělit na menší části a až na nich poté provádět identifikaci bodů na zemi.

Pomocí experimentů bylo zjištěno ideální nastavení algoritmu na $n = 200$ při prvotním rozdělení mračna bodů na 100 menších částí. Délka výpočtu pak byla přibližně 58 minut a vizuální výsledky byly srovnatelné s prvním vzorkem mračen bodů (viz obr. 30).

Právě testování druhého vzorku jasně ukázalo potřebu kalibrace algoritmu pro konkrétní mračno bodů.

7.3 Shrnutí

V této kapitole je popsán algoritmus pro identifikaci bodů na zemi. Výsledkem tohoto algoritmu je množina nejnižše položených bodů v mračnu bodů. Motivací

pro vytvoření algoritmu byla neuniverzálnost mnoha běžně používaných algoritmů. Je nutné uvést, že se nejedná o algoritmus pro identifikaci bodů na vozovce.

Algoritmus funguje na principu rozdělení mračna bodů do menších bloků a identifikace nejnižších bodů v každém bloku. Při testování bylo zjištěno, že s přibývajícím množstvím bloků roste čas potřebný pro zpracování.

Výhodou tohoto algoritmu je jeho rychlost a především pak univerzálnost. Algoritmus se dynamicky přizpůsobuje povrchu země a je proto použitelný pro jakékoliv převýšení. Je určen především pro situace, při nichž není nutné izolovat přímo body na vozovce, ale je potřeba s velkou přesností izolovat body nacházející se do určité výšky nad terénem. Algoritmus se hodí především pro rozlohou menší mračna bodů. Velká mračna bodů je nutné nejdříve rozdělit (jak ukázaly testy na druhém vzorku).

Právě schopnost přizpůsobit se terénu a izolovat nejnižší body i v kopcovitém terénu je velkou výhodou oproti konkurenčním algoritmům. Většina ostatních algoritmů se soustřeďuje na identifikaci bodů na vozovce, popřípadě identifikace nejnižších bodů pomocí detekce plochu. Tento přístup se ovšem absolutně nehodí pro města, kde je okolí silnice velice členité. Mnou navržený přístup je schopen velice spolehlivě izolovat nejnižší body v mračnu bodů bez toho, aby bylo nutné poskytovat jakékoliv dodatečné informace o mračnu bodů. Toto ho činí velice univerzálním oproti jiným přístupům.

Nevýhodou vytvořeného algoritmu je ale nemožnost použití na velké území. Při velké oblasti je nutné mračno rozdělit a na těchto nově vzniklých částech použít algoritmus. U velkých oblastí je čas potřebný pro zpracování neúnosně velký.

Z testování algoritmu jasně vyplývá, že algoritmus je nutné kalibrovat pro konkrétní typ mračna bodů, který je dán typem skeneru a způsobem pořízení. To ovšem není velkou nevýhodou, protože společnosti obvykle mají pouze jeden nebo dva typy mračen bodů.

8 Detekce pozice sloupovitých objektů v mračnech bodů

V této kapitole je popsán postup pro detekci sloupovitých objektů v mračnech bodů. Jak je uvedeno v kapitole 4.1.2, sloupovitým objektem je objekt, jehož body jsou uspořádány ve válcovitém tvaru směřující svisle vzhůru. Takovýto objekt ovšem musí splňovat i další kritéria, např. minimální výšku. Tato kapitola se zabývá pouze detekcí takovýchto objektů, ale ne jejich identifikací. Nejdříve je popsána motivace pro vytvoření nové metody, dále je tato metoda dopodrobna popsána a nakonec i otestována na prvním vzorku mračnech bodů. Díky nízké hustotě bodů není možné metodu použít u druhého vzorku mračna bodů.

Požadovanou informací, kterou je potřeba získat, je poloha bodu, kde se sloup střetává se zemí, tedy poloha podstavy sloupu.

U detekce sloupovitých objektů je nutné počítat s mnoha překážkami. Tou hlavní je zastínění částí sloupů. K tomu dochází především díky stromům, které se nacházejí v jejich blízkosti. Díky stromům může dojít nejen k vynechání objektu při detekci, ale i ke špatné identifikaci stromu jako sloupu. Dalšími překážkami jsou také například auta zaparkovaná v blízkosti sloupů, nebo sloupy nacházející se v blízkosti budov.

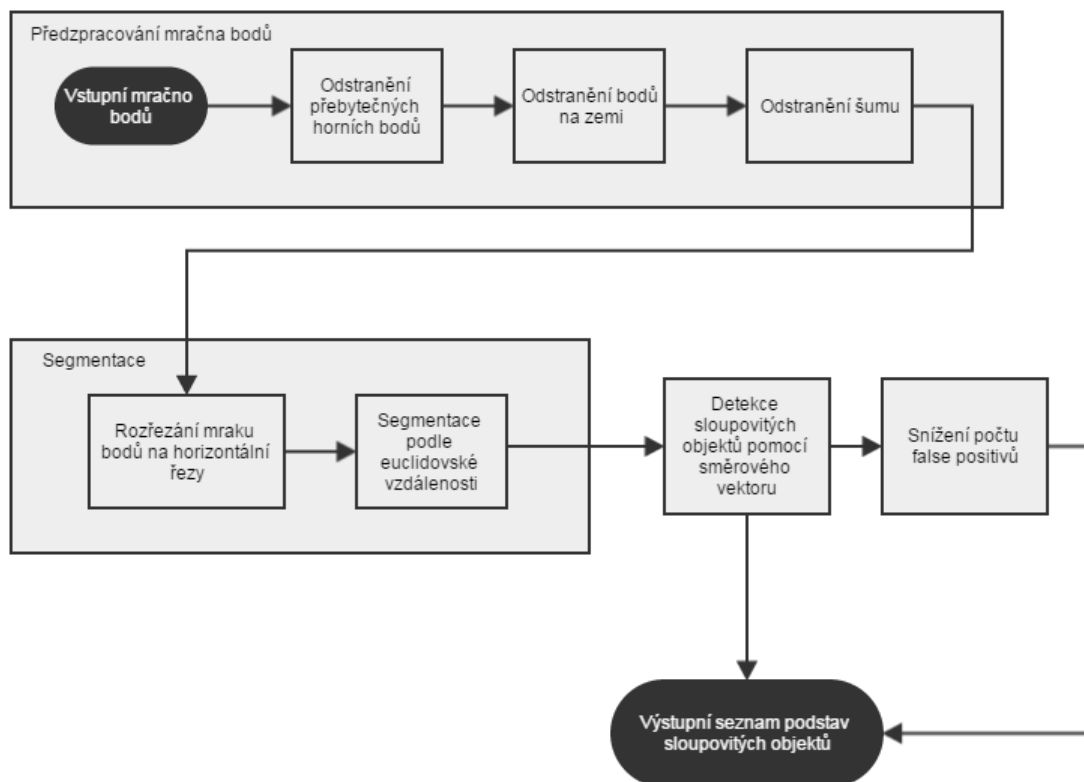
Obecně v praxi používané metody pro detekci sloupovitých objektů jsou popsány v kapitole 4.1.2. Jedním ze základních předpokladů většiny přístupů je dokonalá segmentace vstupního mračna bodů. Díky ní je pak možné pracovat s každým segmentem samostatně. Ve všech článcích zmíněných v kapitole 4.1.2 je tato segmentace možná a není příliš náročná. Ovšem v mračnech bodů testovaných v této práci má tato segmentace velkou překážku, a to je trolejbusové vedení. Toto vedení spojuje mnoho sloupů v testovaném mračnu bodů a velice stěžuje segmentaci. Z tohoto důvodu bylo nutné vytvořit metodu, která nebude potřebovat prvotní segmentaci. Níže popsaná metoda je z části založena na metodě popsané v Lehtomäki a kol. (2010), ovšem v mnoha ohledech se liší. Části této metody jsou publikovány v Landa, Procházka a Štastný (2013).

8.1 Popis metody pro detekci pozice sloupovitých objektů

Proces detekce sloupovitých objektů je rozdělen do čtyř částí. První částí je předzpracování mračna bodů. Druhou je segmentace. Třetí částí je detekce sloupovitých struktur pomocí směrového vektoru, po níž následuje filtrování špatně označených sloupovitých objektů. Filtrování špatně označených sloupovitých objektů je volitelnou operací a jak vyplývá z dalšího textu je pouze na potenciálním uživateli, zda ji použije.

8.1.1 Předzpracování mračna bodů

Prvním krokem je předzpracování mračna bodů. Předzpracování slouží k omezení počtu bodů v mračnu, na němž budou následně prováděny další výpočty. Nejdříve




Obrázek 31: Metoda pro detekci pozice sloupovitých objektů.

jsou odstraněny přebytečné horní body a body nacházející se na zemi. Na oba tyto kroky je použita metoda popsaná v předchozí kapitole. Přebytečné horní body jsou odstraněny na základě předpokladu, že sloupy mají určitou maximální výšku (12 metrů). Každý další bod nad touto výškou je tedy nadbytečnou informací. Jak vyplývá z obr. 30, pokud je výškový koeficient nastaven na vysokou hodnotu (např. 0,5) nejsou v mračnu bodů izolovány pouze body v blízkosti země, ale i všechny body do určité výšky nad ní. Prvním krokem je tedy izolace bodů pouze do určité výšky nad zemí, z nichž jsou následně odstraněny body nacházející se ve velké blízkosti země. Posledním krokem předzpracování je odstranění šumu. Díky tomu dojde k odstranění bodů, které by mohli narušovat další krok, kterým je segmentace.

8.1.2 Segmentace

Jak již bylo řečeno, není možné použít standardně používanou segmentaci pracující na principu spojení sousedních bodů v určité vzdálenosti (kapitola 4.1.2). Lehtomäki a kol. (2010) ve svém článku používají rozdělení mračna bodů do jednotlivých skenovacích linií a následně práce s nimi. V našem případě je ovšem na vstupu neseřazené mračno bodů a není proto možné tento přístup použít. Bude tedy použit přístup rozřezání mračna bodů na n horizontálních řezů a zpracování každého zvlášť. Počet horizontálních řezů byl určen experimentálně a stanoven na 40. Po rozřezání mrač-



Obrázek 32: Vstupní mračno bodů (vlevo) a mračno po předzpracování.

na bodů na jednotlivé horizontální řezy následuje segmentace pomocí Euklidovské vzdálenosti. Tato segmentace má následující pravidla:

- minimální počet bodů v segmentu je 30,
- maximální počet bodů v segmentu je 10 000,
- maximální vzdálenost mezi dvěma body je 30 cm.

Výsledkem segmentace je seznam bodů, kde u každého bodu jsou evidovány následující informace:

- x souřadnice centroidu mračna bodů,
- y souřadnice centroidu mračna bodů,
- z souřadnice centroidu mračna bodů,
- největší vzdálenost mezi centroidem a jakýmkoliv bodem v segmentu.

Všechny tyto informace jsou následně použity při dalších výpočtech.

8.1.3 Detekce sloupovitých objektů pomocí směrového vektoru

Výsledkem předchozího kroku je seznam bodů s několika informacemi (viz předchozí kapitola). Dalším krokem je uspořádání těchto bodů do sloupovitých struktur. Toto uspořádání je vytvořeno pomocí Region Growing algoritmu (viz kapitola 5.2.2). Pseudokód 4 popisuje zmíněnou detekci.

V pseudokódu 4 (viz str. 66) jsou důležité především dvě části, a to pravidla pro zařazení bodu do segmentu a pravidla pro zařazení segmentu do seznamu sloupovitých objektů.

Pravidla pro zařazení bodu do segmentu:

- Směrový úhel γ , tedy odchylka směrového vektoru od kladné souřadnicové osy z , je menší než 20 stupňů.
- Bod má větší nadmořskou výšku než poslední bod v novém segmentu.
- Rozdíl nadmořské výšky posledního bodu segmentu a nového bodu je menší než 2 m a větší než 10 cm.

Pseudokód 4 Detekce sloupovitých objektů pomocí směrového vektoru

```


1: Seřazení bodů podle z souřadnice
2: for každý bod v seznamu bodů do
3:   if bod ještě nebyl zpracován then
4:     Vytvoř nový segment
5:     Vlož aktuální bod do nového segmentu
6:     for každý bod v seznamu bodů do
7:       if ještě nebyl zpracován a odpovídá pravidlům pro bod then
8:         Zařaď bod na konec nového segmentu
9:         Označ bod jako zpracovaný
10:      end if
11:    end for
12:    if segment odpovídá pravidlům pro segment then
13:      zařaď segment do seznamu sloupovitých objektů
14:    end if
15:  end if
16: end for

```

- Vzdálenost centroidu k nejbližšímu bodu je menší než 1 m.

Pravidla pro zařazení segmentu do seznamu sloupovitých objektů:

- počet bodů v jednom segmentu je větší než 4,
- rozdíl výšky mezi nejvyšším a nejnižším bodem v segmentu jsou 4 m.



Obrázek 33: Detekce sloupovitých objektů pomocí směrového vektoru (ve 2D).

Proces je vizuálně znázorněn na obr. 33 a pro zjednodušení je celý proces převeden do 2D. Červenou barvou jsou označeny body segmentů, které nesplňují kritéria

a zelenou barvou jsou označeny body segmentů kritéria splňující. V levé části obrázku jsou vidět čtyři segmenty, které jsou tvořeny jedním bodem. Pro tyto segmenty nebylo možné najít další body, se kterými by byly spárovány. Uprostřed je segment, jehož všechny body odpovídají pravidlům a zároveň jim odpovídá on sám. Napravo je pak segment, jehož body sice odpovídají pravidlům, ovšem on sám již ne.

Posledním krokem je určení požadované informace, tedy poloha bodu kde se sloup střetává se zemí. Pro určení této polohy není možné použít nejnižší body v jednotlivých segmentech, protože v mnoha případech tyto body neleží na zemi. Naopak mnoho těchto bodů je jeden i dva metry nad zemí (z důvodů např. zaparkovaného automobilu vedle sloupu). Je proto nutné tento bod získat z kombinací x a y souřadnice centroidu segmentu a nalezením nejnižšího bodu v blízkosti tohoto centroidu.

Hledání polohy bodu probíhá způsobem, který popisuje pseudokód 5. Hledání začíná na poloměru 0,2 m od vypočteného centroidu. Pokud v tomto poloměru není nalezen žádný bod, poloměr je zvýšen o 0,1 m. Hledání pokračuje, dokud není nalezen alespoň jeden bod.

Pseudokód 5 Nalezení pozice podstavu detekovaného sloupovitého objektu.

```

1: for každý segment v seznamu segmentů do
2:   Vypočti  $x$  a  $y$  souřadnice centroidu bodů v segmentu
3:   Testovací poloměr = 0,2
4:   Nejnižší nadmořská výška = 10000
5:   while nejnižší nadmořská výška == 10000 do
6:     for každý segment v seznamu segmentů do
7:       if bod je v testovaném poloměru od centroidu
8:         &&  $z$  souřadnice < nejnižší nadmořská výška then
9:           nejnižší nadmořská výška =  $Z$  souřadnice
10:        end if
11:     end for
12:     Testovací poloměr += 0,1
13:   end while
14: end for

```

8.1.4 Algoritmus pro snížení počtu špatně určených sloupovitých objektů

Tento algoritmus vychází z algoritmu publikovaném Landou, Procházkou a Štastným (2013). U sloupovitých objektů je předpoklad, že jednotlivé body tvořící segmenty mají minimální odchylku od osy sloupu. Naopak segmenty stromu mají velkou odchylku, i třeba tím, že kmen není vodorovný, ale roste pod určitým úhlem. Dalším předpokladem je, že pokud se tato odchylka vyskytne, jsou body vychýleny pouze v jednom směru. Příkladem může být velké dopravní značení umístěné na sloupu veřejného osvětlení. V mnoha případech je toto značení připevněno krajem ke sloupu a ne uprostřed. V tomto okamžiku dojde k vychýlení bodu pouze jedním směrem (viz obr. 34).



Obrázek 34: Příklad velkého dopravního značení umístěného na sloupu veřejného osvětlení.

Algoritmus vychází z výpočtu rozptylu jednotlivých bodů segmentu od mediánu. Rozptyl je spočítán jak pro osu x , tak pro osu y . Pokud jedna z těchto odchylek přesáhne daný práh, je segment vyřazen ze seznamu sloupovitých objektů.

Výsledek detekce je znázorněn na obrázku 35. Pro potřeby vizualizace je do obrázku k výsledným segmentům přidána i země.


8.2 Výsledky a testování

Testování bylo prováděno ve dvou fázích. V první fázi byla metoda testována bez algoritmu pro snížení počtu špatně určených sloupovitých objektů (viz kapitola 8.1.4) a v druhé s tímto algoritmem. Testování bylo prováděno vizuálně za pomoci vizualizace mračna bodů. Celkem se v mračnu bodů pokrývající sledovanou oblast nacházelo 187 sloupovitých objektů, mezi něž patří sloupy veřejného osvětlení, reklamní sloupy a sloupy sloužící pro uchycení trolejového vedení.

Celkový čas potřebný k nalezení všech sloupovitých objektů v prvním vzorku mračen bodů byl přibližně 4 hodiny.

Podívejme se nyní na rozvržení jednotlivých hodnot do kategorií uvedených v kapitole 6.2.

Bez použití algoritmu pro snížení počtu špatně určených sloupovitých objektů bylo v mračnech bodů správně detekováno 178 ze 187 sloupů. Pouze devět sloupů algoritmus minul. Tyto sloupy jsou zařazeny do kategorie nesprávně vynechaných



Obrázek 35: Výsledek metody pro detekci sloupovitých objektů.

Tabulka 5: Výsledky testování metody bez použití algoritmu pro snížení počtu špatně určených sloupovitých objektů.

Správně určený objekt	178
Špatně určený objekt	51
Nesprávně vynechaný objekt	9

objektů. Jednalo se především o sloupy, které se nacházejí v bezprostřední blízkosti stromů nebo budov. Dvěma nesprávně vynechanými objekty byly sloupy, na nichž se nachází velké množství jiných objektů (reklamní plocha, reklamní cedule, značky atp.).

V mračném bodu bylo 51 špatně určených sloupovitých objektů, z toho většinu tvoří stromy. Hlavní problém byl v horní části ulice Úvoz, kde se nachází malý lesík. A právě takto velké množství špatně určených sloupovitých objektů bylo důvodem aplikace algoritmu pro snížení jejich počtu.

V druhé fázi bylo tedy mračno bodů testováno s aktivním algoritmem pro snížení počtu špatně určených sloupovitých objektů. Díky tomuto algoritmu bylo možné snížit počet špatně určených sloupovitých objektů na více jak polovinu, ovšem zvýšil se počet nesprávně vynechaných objektů, protože 14 sloupovitých objektů nesplnilo kritéria tohoto algoritmu.

Tabulka 6: Výsledky testování metody bez použití algoritmu pro snížení počtu špatně určených sloupovitých objektů.

Správně určený objekt	164
Špatně určený objekt	23
Nesprávně vynechaný objekt	23

Podívejme se nyní na jednotlivé ukazatele úspěšnosti metody. Z tabulky 7 jasně vyplývá, že metoda má větší přesnost s použitým algoritmem pro snížení počtu špatně určených sloupovitých objektů. S tímto algoritmem se ovšem zvýšil počet nesprávně vynechaných objektů, tedy sloupovitých objektů, které nebyly detekovány. Dalo by se říci, že bez použití algoritmu byla metoda úspěšnější v počtu nalezených sloupovitých objektů, ovšem ne tak kvalitní.

Tabulka 7: Hodnoty ukazatelů úspěšnosti metody

Ukazatel	Bez algoritmu pro snížení počtu špatně určených sloupovitých objektů	S algoritmem pro snížení počtu špatně určených sloupovitých objektů
Přesnosti	77,7 %	87,7 %
Úplnosti	95,1 %	87,7 %
Kvality	74,8 %	78,1 %

8.3 Shrnutí

Výše prezentovaná metoda funguje na principu rozřezání mračna bodů na horizontální řezy a následném zpracování těchto řezů. Každý řez je rozsegmentován a o každém segmentu je uchována informace o poloze centroidu segmentu a vzdálenost k nejvzdálenějšímu bodu segmentu od centroidu. Díky těmto informacím je pak možné s pomocí směrových vektorů detekovat vertikální struktury v mračnu bodů. Při prvním testování metody byla zjištěna úplnost 95,19 %, ovšem tato úplnost je za cenu velkého množství špatně určených sloupovitých objektů. Většinou se jednalo o stromy. Z tohoto důvodu byl do metody přidán algoritmus na jejich eliminaci. Díky němu se podařilo snížit počet špatně určených sloupovitých objektů na více jak polovinu při zachování velké úplnosti detekce (87,70 %). Je ovšem na zvážení, jestli je nutné tento algoritmus použít. Velké množství špatně určených sloupovitých objektů je možné eliminovat v následném postprocesingu odborným personálem. Mnoho špatně určených sloupovitých objektů se totiž jasně nachází v oblastech, ve kterých je výskyt sloupů velice nepravděpodobný. Na obrázku 61 (příloha B) je znázorněn import výsledků do programu ArcMap. Zároveň je do programu přidána ortofotomapa. Díky tomu je možné během pár minut eliminovat 43 špatně určených sloupovitých objektů. Na obrázku je znázorněna eliminace 21 špatně určených sloupovitých objektů.

Značnou výhodou metody oproti konkurenčním metodám je fakt, že nepotřebuje prvotní segmentaci. Prvotní segmentace, a tím získání individuálních sloupů, je použita ve většině nalezených metodách. V mém případě ovšem nebylo možné tuto segmentaci provést. Proto metoda nejdříve mračno bodů rozřeže a až následně provádí segmentaci. Další výhodou metody je možnost práce i nad neseřazeným

mračnem bodů. Z toho plyne, že vstupem metody může být pouze mračno bodů, nic víc. Toto je výhodou oproti metodě popsané v Lehtomäki a kol. (2010).

9 Detekce pozice svislého dopravního značení

V této kapitole bude popsána metoda pro detekci svislého dopravního značení v mračnu bodů. Metoda je zaměřena pouze na detekci pozice značky, protože jak vyplývá z kapitoly 4.1.3, mračno bodů nelze použít na identifikaci. V první části je popsána přímo metoda pro detekci dopravního značení. Druhá část kapitoly se zabývá implementací této metody a posledním testováním metody.

Z mračna bodů budou odvozeny dva údaje o dopravní značce. První je střed značky. Druhým je bod, kde se sloup, na kterém je značka připevněna, střetne se zemí.

V kapitole 4.1.3 jsou popsány nejběžnější přístupy k detekci dopravních značek. Tyto metody mají jeden společný krok, a to filtrování mračna bodů na základě odrazivosti bodů. Jak již bylo zmíněno v kapitole 4.1.3, značky jsou natřeny speciální, vysoce odrazivou barvou díky které je možné je jednodušeji detekovat v mračnech bodů. Další běžnou operací je proložení dopravní značky plochou. Tento postup se ale hodí pouze na jednoduché značky, ovšem v městech je mnohdy poskládáno několik značek nad sebou. Například metoda zmíněná v Chen a kol. (2009) je určena především na detekci značek, které jsou rovné a zároveň ve směru jízdy. Pro pasportizaci je ovšem užitečné detekovat jak samostatné značky, tak skupiny značek položené nad sebou. Zároveň je užitečné detekovat i značky otočené nejen po směru jízdy.

Metoda pro detekci vodorovného značení je publikována v Landa a Procházka (2014).

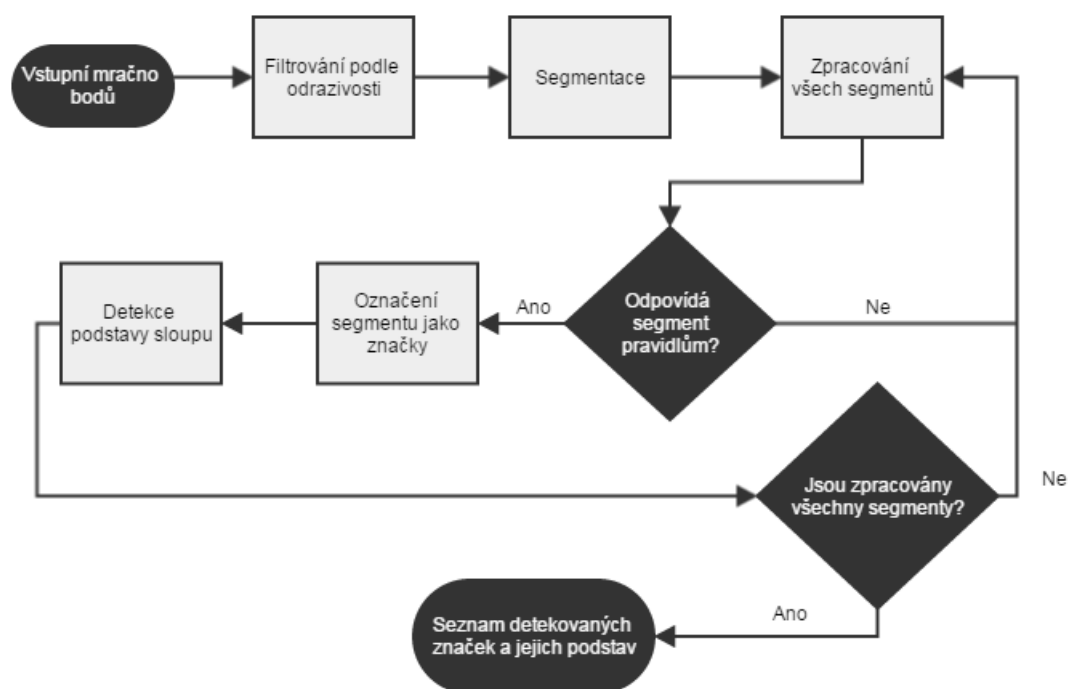
9.1 Metoda pro detekci dopravního značení

Detekce dopravního značení může být prováděna pouze na mračnech bodů z prvního vzorku. Pouze tyto mračna bodů poskytují dostatečné rozlišení pro detekci značení.

Prvním krokem metody je filtrování podle odrazivosti. Hodnoty pro filtrování byly zjištěny na základě experimentu a jsou konkrétní pro daný typ mračna bodů. V případě testovaného mračna bodů je to 4000 a více. Tímto krokem je ovšem získáno nejen dopravní značení, ale i mnoho jiných objektů, jako například reklamní cedule, části domů, části vozovky, státní poznávací značky automobilů a další. Mračno před a po filtrování podle odrazivosti je možné vidět na obrázku 37.


Dalším krokem je segmentace. Pro segmentaci je použita metoda segmentace podle Euklidovské vzdálenosti. Pokud nejsou jakékoliv dva body od sebe vzdálené více jak 0,5 m, jsou považovány za jeden segment. Díky segmentaci je mračno bodů rozděleno do jednotlivých částí, které je možné dále samostatně zpracovávat.

Aby bylo možné, alespoň s rozumnou přesností, detekovat dopravní značení, je nutné stanovit pravidla, které musí segment splňovat, aby byl označen jako dopravní značka. Následuje výčet těchto pravidel a popis segmentů, které jsou díky konkrétnímu pravidlu odstraněny.



Obrázek 36: Schéma metody pro detekci pozice svislého dopravního značení.


1. **Segment musí mít minimálně 70 a maximálně 150 000 bodů.** Požadavek na minimální počet bodů je dán rozlišením skeneru. Tímto pravidlem jsou odstraněny velice malé segmenty. Tyto segmenty mohou být dopravním značením, které bylo ve velké vzdálenosti od skeneru. Toto značení ovšem pokrývá pouze velice malou část případů. Zbytek jsou drobné segmenty například na fasádách domů. Požadavek na maximální velikost segmentu je dán charakteristikou vozovky a chodníků. Na nich se také vyskytují body, které mají velkou intenzitu.



Obrázek 37: Vstupní mračno bodů (vlevo) se zvýrazněnou odrazivostí (barevná škála od zelené po červenou). Mračno bodů po filtraci podle odrazivosti.

2. **Centroid segmentu, tedy jeho středový bod, musí být minimálně 1,5 m nad zemí.** Toto pravidlo vyřazuje všechno dočasné značení, státní poznávací značky automobilů a další segmenty, které nejsou dostatečně vysoko na to, aby mohly být považovány za dopravní značku.
3. **Výška segmentu (tedy rozdíl mezi jeho nejnižším a nejvyšším bodem) je minimálně 0,4 m.** Díky tomuto pravidlu jsou odstraněny segmenty, které splňují všechny přechozí, ale jsou příliš ploché.

Příklady segmentů, které byly na základě pravidel vymazány, jsou vidět na obrázku 38.



Obrázek 38: Příklady segmentů, které nespĺnily pravidla (modrá barva). Vpravo dole reklamní cedule, nahoře uprostřed SPZ zaparkovaných aut.

Všechny segmenty, které odpovídají těmto pravidlům, jsou automaticky označeny jako dopravní značení.

Dalším krokem je nalezení pozice podstavy sloupu, ke kterému je značka připevněna. Jedná se v podstatě o nalezení nejnižšího bodu sloupu. Je ovšem nutné zdůraznit, že některé značky sloupy nemají. Tyto značky mohou být připevněny například ke stěně domu (viz obr. 39).

Nalezení podstavy sloupu probíhá v následujících krocích:

1. Nalezení nejnižšího bodu značení. Tento bod splňuje dvě pravidla: má nejnižší hodnotu souřadnice z a zároveň je jeho vzdálenost maximálně 10 cm od středového bodu segmentu. Tato vzdálenost je počítána pouze v souřadnicích x a y .
2. Nalezení všech bodů v původním mračnu bodů, které jsou v okruhu 70 cm od nejnižšího bodu značení z předchozího kroku. V případě, že je výškový rozdíl



Obrázek 39: Příklady nejběžnějších typů podstav dopravních značek.

Zdroj fotografií: Google Street View.

mezi novým a starým bodem větší jak 20 cm a vzdálenost mezi těmito body (opět na ose x a y) je menší jak 1 m je tento bod označen jako nejnižší bod a v hledání se pokračuje stejným způsobem.

3. Jakmile je nalezen nejnižší bod, který nesplňuje pravidla z bodu 2, je hledání ukončeno. Hledání je tedy ukončeno ve chvíli, kdy je další nalezený bod součástí země. V tomto bodě se směr bodů mění z vertikálního na horizontální.

9.2 Výsledky a testování

Úspěšnost metody byla testována vizuálně. Výsledná mračna bodů jednotlivých značek byly porovnány s fotografiemi pořízenými z projíždějícího automobilu, popřípadě z Google StreetView.

Podívejme se nyní na rozvržení jednotlivých hodnot do kategorií uvedených v kapitole 6.2. V mračnech bodů a fotografiích bylo identifikováno celkem 86 dopravních značek. V tabulce 8 jsou uvedeny výsledky testování.

Z celkového počtu 86 značek bylo korektně detekováno 80 značek. V tabulce 9 jsou uvedeny hodnoty jednotlivých ukazatelů úspěšnosti metody. Z hodnot ukazatelů vyplývá, že metoda je hodně přesná a úplná. Oba dva ukazatele přesahují 90 %, což je velice dobrý výsledek. I ukazatel kvality s hodnotou 86 % ukazuje na poměrně kvalitní metodu. Nicméně je důležité zmínit, že do tohoto počtu patří i vícenásobné

Tabulka 8: Výsledky testování metody pro detekci svislého dopravního značení.

Správně určený objekt	80
Špatně určený objekt	7
Nesprávně vynechaný objekt	6

značky, tedy značky, které jsou nad sebou. Toto uspořádání značek je velice běžné, ovšem nemá jasně stanovená pravidla. Proto je vícenásobná značka identifikována jako jedna a musí být dále rozdělena při dalším zpracování. Bylo by možné se pokusit tyto značky rozdělit, ovšem při takto velkém množství kombinací je efektivnější nechat rozdělení na odborném personálu. Velké značky je možné označit příznakem, který navrhne jejich ověření odborným personálem.

Tabulka 9: Hodnoty ukazatelů úspěšnosti metody pro detekci dopravních značek

Ukazatel	Hodnota
Přesnosti	91,2 %
Úplnosti	93,0 %
Kvality	86,0 %



Obrázek 40: Příklad vícenásobné značky v mračnu bodů (vlevo) a ve fotografii (vpravo).

Z celkového počtu 87 segmentů označených jako dopravní značení jich pouze sedm bylo špatně určených (tedy pouze 8 %). Hlavním důvodem pro špatné určení jsou reklamní cedule. Z celkových sedmi jich právě pět bylo reklamní cedulí. Bohužel tomuto špatnému detekování se nelze vyhnout, protože některé společnosti používají, stejně jako u dopravního značení, vysoce reflexivní barvu.

Jedním špatně určeným značením byla část sloupu a posledním, ze sedmi špatně určených značení bylo zrcadlo. Zrcadlo je sice určitou součástí dopravního značení, ale pro potřeby této práce ho budeme považovat za špatně určené značení. Ve snímané scéně se nacházelo několik zrcadel, ovšem pouze jedno bylo detekováno. Je to

způsobeno jeho malou vzdáleností od skeneru. Všechna ostatní zrcadla byla dále od skeneru a nesplňovala pravidlo minima bodů.

Z celkových 86 dopravních značek, které se nacházely ve snímané scéně nebylo detekováno pouze šest, což ukazuje na 93 % úplnost. Z celkového počtu šesti vynechaných značení byly tři způsobeny malým počtem bodů na značce. Z tohoto důvodu tyto segmenty neprošly pravidlem pro minimální počet bodů. Toto nesprávné vynechání může být způsobeno buď velkou vzdáleností značek od skeneru, nebo, a to spíše, degradací barvy na nich. Vzhledem k velké úspěšnosti metody je i toto možné považovat za další indikátor, který je možné evidovat. Pokud není značka identifikována, je možné, že u ní došlo k velké degradaci barvy.

Velice zajímavé pak byly další 3 vynechané značky. Jednalo se totiž o označení zastávek.



Obrázek 41: Příklady správně určených značek (levý sloupec), špatně určených značek (prostřední sloupec) a nesprávně vyřazených značek (pravý sloupec).

9.3 Spojení detekce značek s detekcí sloupovitých objektů

V kapitole 8 je představena detekce sloupovitých objektů. Tuto detekci je možné spojit s detekcí dopravních značek, protože na mnoho sloupů je dopravní značka připevněna. U značek je určení pozice podstavy sloupu, na němž je připevněna, problémové, protože značka nemusí být ke sloupu připevněna v jejím středu. Ovšem naopak určení pozice sloupovitého objektu je díky velké přesnosti a úspěšnosti mnohem jednodušší. Proto je dobré tyto metody spojit dohromady.

U sloupovitého objektu je vždy evidována pozice podstavy tohoto sloupu. U dopravní značky pak pozice podstavy sloupu a střed značky. Srovnání metod bylo provedeno pomocí zjišťování vzdálenosti mezi středem značky a podstavou sloupu. Vzdálenost byla počítána ve 2D.

Porovnáním detekce značek a sloupů bylo nalezeno 34 značek, v jejichž nejbližším okolí (poloměr 30 cm) se nachází i podstava sloupovitého objektu. Ve dvou případech z 34 značka nemá nalezenou podstavu. Průměrná vzdálenost ve 3D mezi odpovídající podstavou sloupu a původně detekovanou pozicí podstavy značky je 30 cm.

Díky spojení těchto dvou metody je tedy možné zpřesnit určení pozice podstavy značky a tím optimalizovat detekci značek, resp. jejich podstav.

9.4 Shrnutí

V té kapitole byla prezentována metoda pro detekci pozice svislého dopravního značení. Metoda funguje na principu izolace dopravního značení pomocí odrazivosti bodů na nich. Značky jsou natírány speciální barvou, která má větší odrazivost než jiné materiály. Metoda dále filtruje takto izolované značky podle tří pravidel. Tyto pravidla jasně charakterizují potenciální značku. Na testovaném mračnu bodů má metoda 93 % úplnost a 86 % kvalitu což ukazuje na její velkou úspěšnost. Jako hlavní důvody nesprávného vynechání značení z detekce se ukázal malý počet bodů s velkou odrazivostí na značce a dále pak metoda hůře detekovala značky označující zastávku veřejné dopravy. Hlavním důvodem pro špatně určené značení byly reklamní cedule. Některé reklamní cedule bylo možné vyfiltrovat, například díky jejich nízké poloze nad zemí. Dalším důvodem pro špatně určené značení bylo zrcadlo.

Výhodou metody je její rychlost. Nad testovaným vzorkem bodů trvala detekce 893 sekund, tedy necelých 15 minut. Díky tomu by bylo možné metodu použít přímo při pořizování dat.

Jak se později ukázalo, je možné spojit metodu pro detekci dopravního značení s metodou pro detekci sloupovitých objektů. Metoda pro detekci sloupovitých objektů má větší přesnost určení pozice podstavy sloupu než metoda pro detekci značení. U 34 detekovaných značek byl v jejich nejbližším okolí nalezen i sloupovitý objekt. V několika případech byla dokonce 2D pozice sloupu a značky stejná.

Oproti konkurenčním metodám má metoda výhodu ve své univerzálnosti. Metoda pracuje s neseřazeným mračnem bodů a nepotřebuje ke své činnosti další informace, jako například dráhu automobilu. Díky tomu je schopna detekovat všechny značky, a ne jen například ty nacházející se ve směru jízdy automobilu.

Je nutné opět upozornit, že tato metoda slouží pouze pro detekci pozice značky. Ovšem díky této detekci je možné velice zjednodušit pozdější identifikaci typu značky, a to dvěma způsoby:

- Pokud jsou značky identifikovány odborným personálem, je možné zvýraznit na pozice většiny značek a tím urychlit práci.
- Pokud jsou značky identifikovány pomocí zpracování obrazu, je možné spojením pozice a georeferencovaných obrazů určit ROI¹¹, ve kterém se značka nachází. Určení ROI velice zjednodušuje identifikaci pomocí zpracování obrazu.

¹¹Region of Interest – oblast zájmu

10 Detekce pozice, identifikace typu a rekonstrukce tvaru vodorovného značení

Identifikace vodorovného značení je velice důležitou částí pasportizace majetku. Existující metody identifikace jsou popsány v kapitole 4.1.4. Následující část práce se zabývá popisem vlastní metody pro detekci, identifikaci a rekonstrukci vodorovného značení. Celý proces je rozdělen do tří částí:

- Detekce pozice potenciálního značení.
- Identifikace typu značení.
- Rekonstrukce tvaru značení.

Tato práce se soustředí pouze na detekci, identifikaci a rekonstrukci plných a přerušovaných čar. Výsledkem všech třech částí jsou pak tři standardní soubory ve formátu ESRI Shapefile. V prvním jsou uloženy všechny detekované čáry. V druhém je uloženo vodorovné značení, tedy čára s atributem buď plné čáry, nebo přerušované. Posledním je pak polygonový Shapefile obsahující rekonstruované značení. Hlavní požadovanou informací je tedy série polygonů reprezentující vodorovné čáry na vozovce. Tyto polygony jsou v praxi používány pro výpočet množství barvy, která je potřeba pro jejich natření. Důvodem uložení do ESRI Shapefile je zpřístupnění výsledků metody i pro běžné uživatele. Mračno bodů je např. pro běžného úředníka na úřadě v podstatě nepoužitelné, ovšem ESRI Shapefile je běžně používaným formátem.

10.1 Shrnutí současných metod pro detekci a identifikaci vodorovného značení

Všechny metody (kapitola 4.1.4) pro detekci nebo identifikaci vodorovného dopravního značení využívají odrazivosti značení. Díky odrazivosti je možné z velké části omezit množství bodů, které jsou dále zpracovávány. Další společnou vlastností všech metod je potřeba dobré identifikace bodů na vozovce, popřípadě minimálně identifikace bodů nacházejících se na zemi.

Další věcí, kterou mají metody společnou, je využívání sémantických znalostí o dopravním značení. Jedná se především o znalost rozmístění přerušovaných čar. Přerušované čáry mají přesně daná pravidla pro jejich rozmístění. Jsou sice různé varianty nakreslení čar, ovšem vždy je možné počítat s minimální a maximální délkou přerušované čáry a minimální a maximální velikostí rozestupu mezi jednotlivými čarami. Posledním společným rysem je převod mračna bodů na 2D obraz. Výhodou tohoto převodu je možnost následného využití běžných metod při zpracování obrazu.

Mnoho metod se soustřeďuje hlavně na přerušované čáry (Bisheng a kol., 2012), protože jejich detekce a identifikace je nejjednodušší.

Jedním ze společných rysů mnoha metod je také testování především na rovných, nebo jen lehce zakřivených úsecích (např. Chen a kol. (2009) nebo Thuy a León (2010)).

10.2 Motivace pro vytvoření metody

Jak již bylo řečeno v úvodu, požadavkem na výstup z metody je získání polygonů reprezentujících čáru na vozovce (buď plnou, nebo přerušovanou). Z tohoto důvodu je tedy nutné nejdříve nalézt způsob, kterým bude tento obalový polygon vytvořen, respektive způsob, jakým bude reprezentována čára na vozovce. Jednou z nejběžnějších reprezentací používanou v praxi je bounding box (resp. rotovaný bounding box). Jedná se o nejmenší možný obdélník, který obaluje jednotlivé body reprezentující značení. Tato reprezentace se ovšem hodí pouze pro přerušované čáry, které leží samostatně a především pak na rovném úseku silnice. Jakmile množina bodů nesplňuje tyto podmínky, není bounding box vhodnou reprezentací. Další možnou reprezentací čáry jsou konvexní a konkávní obálky (Moreira a Santos, 2007).

Konvexní a konkávní obálky (viz obr. 47, s. 85) představují mnohem lepší reprezentaci než bounding box, ovšem (stejně jako u bounding boxu) je jejich nevýhodou náchylnost k šumu v původních datech. Pokud se totiž v původních datech nachází bod nebo body mimo požadované dopravní značení (šum), tento bod nebo body jsou použity při výpočtu obálky a mohou výrazně zkreslit výslednou obálku. Další možnou reprezentací jsou křivky (Schindler, Maier a Janda, 2012). Křivky ovšem nepokrývají případy, kdy se vodorovné značení kříží nebo dotýká. A právě křížení a dotýkání značení se snaží pokrýt metoda popsaná v této kapitole.



Obrázek 42: Vlevo: přerušovaná a plná čára.
Vpravo: příklad dotýkajících se a křížících se čar.

Žádná z metod popsaných v kapitole 4.1.4 se nezabývá křížením značení. Křížení čar je běžným jevem především v městech, a pokud chceme efektivně reprezentovat značení, je nutné se zabývat i jeho křížením. Podívejme se nyní na jeden příklad. Na obrázku 42 je znázorněna situace, kdy dochází ke křížení a dotýkání se čar. V tomto okamžiku je nutné nalézt reprezentaci, která splňuje dva základní požadavky:

1. Je s její pomocí možné určit o jaký typ čáry se jedná (plná, přerušovaná).
2. Je díky ní možné rekonstruovat tvar značení (tzn. vytvořit obalový polygon).

Pro potřeby této práce byla jako reprezentace značení zvolena kostra. Kostry jsou běžně používány ve zpracování obrazu. Jejich použití je od reprezentace těles (Bucksch, Lindenbergh a Menenti, 2009) až po reprezentaci lidského těla ve 3D (Dimitrios a kol., 2011). Postup vytvoření kostry značení a výhody a nevýhody této reprezentace jsou popsány v následujícím textu.



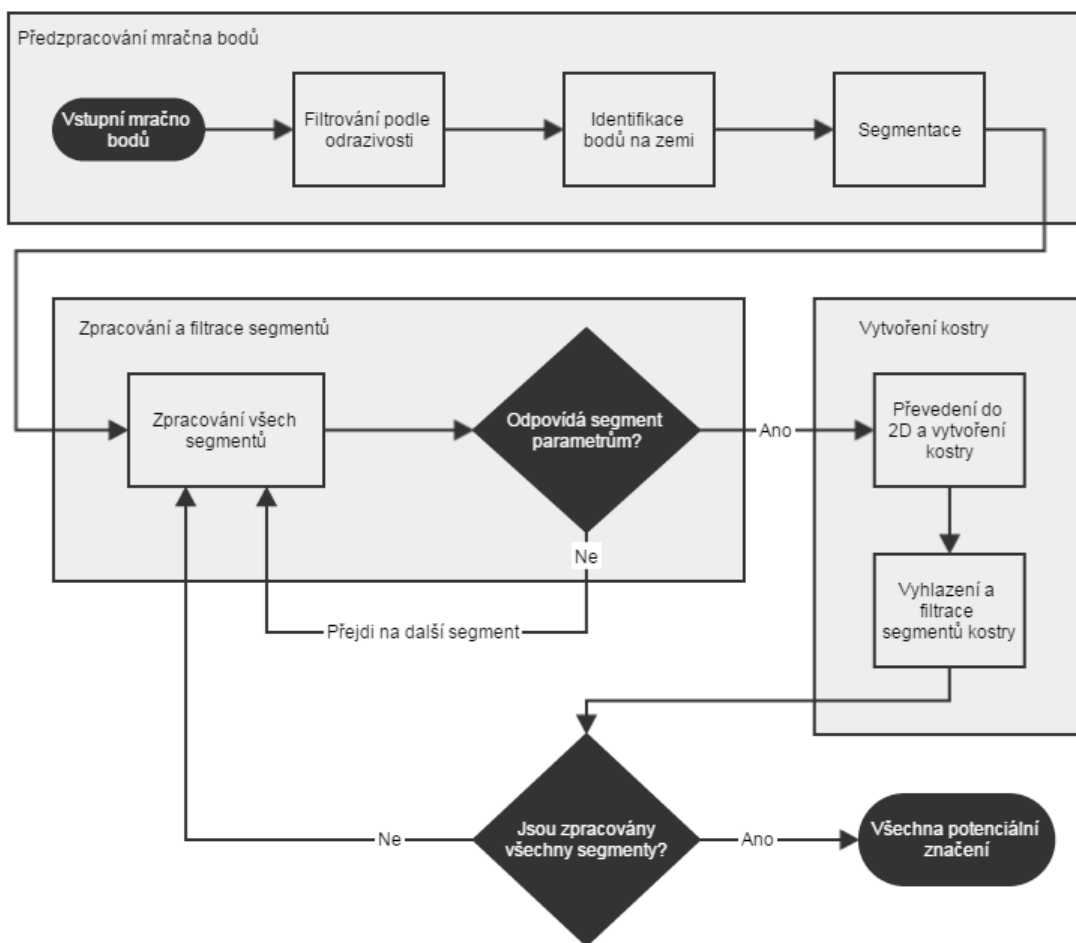
Obrázek 43: Příklad tvorby kostry z mračna bodů (Cao a kol., 2010).

10.3 Detekce potenciálního značení

Prvním krokem celého procesu je detekce potenciálního značení. V tomto kroku dojde k detekci objektů na vozovce a jejich postupnému filtrování tak, aby bylo možné je identifikovat jako dopravní značení. Celý proces detekce je znázorněn na obrázku 44 a je popsán v následujících podkapitolách.

10.3.1 Předzpracování mračna bodů


Vstupem předzpracování je vždy mračno bodů. Prvním krokem je filtrování jednotlivých bodů podle odrazivosti. U značení (jak vodorovného, tak svislého) lze využít toho, že je u nich použita speciální barva, která má větší odrazivost. Díky tomu je možné vyfiltrout velké množství bodů a zůstanou pouze ty, které odpovídají hraničním hodnotám, které si zvolíme. Přesné určení hodnoty odrazivosti je nutné zjistit pomocí experimentů, protože se mohou lišit u různých zařízeních. Například u prvního vzorku mračna bodů jsou hraniční hodnoty v rozmezí 3100 až 3900. V tomto rozmezí pak získáme značení plus různé body na chodnících, popřípadě na budovách.



Obrázek 44: Proces detekce potenciálního dopravního značení.

Dalším krokem je pak identifikace bodů na zemi. Algoritmus pro identifikaci bodů na zemi je popsán v kapitole 7. Identifikace je provedena až po filtrování podle odrazivosti z důvodů snížení počtu vstupních bodů a tím pádem urychlení celého procesu identifikace bodů na zemi. Posledním krokem je pak segmentace. Segmentace slouží pro rozdělení zpracovaného mračna bodů do jednotlivých částí. Segmentace je provedena na základě Euklidovské vzdálenosti bodů. V případě, že mají body nějakou minimální vzdálenost mezi sebou, jsou považovány za body jednoho segmentu.

Výsledkem této části je tedy segmentované mračno bodů, kde každý segment představuje potenciální značení. Je ovšem nutné říci, že výsledkem segmentace jsou i segmenty, které nepředstavují značení. Nejběžněji se jedná o části budov, chodníků a další.



Obrázek 45: Výsledek segmentace. Vstupní mračno bodů (vlevo) a mračno bodů po segmentaci (vpravo).

10.3.2 Zpracování a filtrace segmentů

V této části dochází postupně ke zpracování všech segmentů a vyřazení většiny těch, které nepředstavují vodorovné značení. Každý segment je testován podle následujících kritérií:

- minimální počet bodů je větší než prahová hodnota,
- maximální počet bodů je menší než prahová hodnota,
- minimální velikost obalového obdélníku v jednom směru x nebo y je větší než prahová hodnota,
- minimálně n procent bodů leží v rovině.

První dvě kritéria jsou již součástí segmentace. Třetí kritérium je zavedeno pro odfiltrování malých segmentů, které ovšem splní první dvě kritéria. Poslední kritérium předpokládá, že vodorovné značení neobsahuje body, které neleží v rovině. Problémem tohoto určení je ovšem to, že značení se nemusí nacházet vždy na rovném úseku (např. skenování v kopcovitém terénu). Nejpoužívanější metodou pro odhalení rovin v mračnu bodů je RANSEC. Tato metoda umožňuje proložit mračno bodů plochou a zároveň zjistit počet bodů, které se na ploše nacházejí. Není ovšem možné proložit celý segment značení, protože (především v kopcovitém terénu a u plných čar) by výsledkem bylo, že body reprezentující značení se nenacházejí v jedné rovině.

Z tohoto důvodu je ověření bodů, jestli jsou v rovině, provedeno pomocí algoritmu popsaném pseudokódem 6.

Díky tomuto postupu je možné eliminovat segmenty, které nejsou na vozovce, nebo nejsou chodníky (např. stěny budov). Pro testovaná mračna bodů byla prahová hodnota zvolena na 95 %.

10.3.3 Vytvoření koster značení


Poslední částí detekce značení je vytvoření koster z jednotlivých segmentů. Kostru z mračna bodů je možné vytvořit dvěma způsoby: vytvoření kostry přímo z mračna

Pseudokód 6 Algoritmus pro proložení množiny bodů plochou

```

1: for každý segment v seznamu segmentů do
2:   while všechny body nejsou zpracovány do
3:     Vyber první bod segmentu a najdi všechny
4:     jeho sousedy v okruhu  $n$  metrů
5:     Prolož tyto body plochou a ulož body nacházející se
6:     na ploše (v určité toleranci)
7:     Vyber další dosud nezpracovaný bod a opakuj celý proces
8:   end while
9:   if procentní počet bodů v rovině je větší než práh then
10:    Označ segment jako potenciální vodorovné značení
11:   end if
12: end for

```




Obrázek 46: Ukázka segmentů, které prošly (modrá barva) a které neprošly (růžová barva) ověřením na body v rovině.

bodů, nebo převedením mračna bodů do 2D obrazu a následné vytvoření kostry. Pro potřeby této práce byl zvolen druhý způsob, díky kterému je možné použít běžné používané metody pro zpracování obrazu. O vytvoření kostry přímo z mračna bodů je možné nalézt více v Huang a kol. (2013) nebo Cao a kol. (2010).

Prvním krokem vytvoření kostry je převedení bodů do 2D. Každý bod je převeden ze souřadného systému S-JTSK do lokálního souřadného systému. Převod do lokálního souřadného systému je použit pro zjednodušení následujících operací.

Druhým krokem je pak samotné vytvoření kostry. Pro vytvoření kostry objektu je nutné nejdříve získat samotný objekt. Díky předchozím krokům je získán pouze seznam bodů reprezentující potenciální značení. Z tohoto seznamu bodů je nutné vytvořit objekt, který je reprezentuje. V předchozím textu byly zmíněny dvě možnosti vytvoření objektu a to pomocí bounding boxu nebo konkávní obálky. Nevýhody bounding boxu již byly zmíněny a jasně z nich vyplývá, že ho v tomto případě není možné použít. Proto byla zvolena konkávní obálka.

Obrázek 47 demonstruje problém vytvoření konkávní obálky. U jejího vytvoření je problém s určením, která obálka je tou správnou. Na místo konkávní obálky se



Obrázek 47: Obrázek různých verzí konkávní obálky (Alpha Shapes and Concave Hulls, 2011).

proto mnohdy používá tzv. alfa tvar (alfa tvar). Alfa tvar byl prvně definován pány Edelsbrunnerem, Kirkpatrickem a Seidelem (1983). Prvním krokem vytvoření alfa tvaru je Delaunayova triangulace díky které vznikne tzv. TIN model, tedy sít trojúhelníků, spojující jednotlivé body. Z těchto trojúhelníků je nutné odstranit ty, které nesplňují určitá pravidla nebo pravidlo. Právě v tomto tkví výhoda alfa tvaru. Je možné si totiž stanovit pravidlo, které musí trojúhelník splňovat. Pro potřeby práce bylo stanoveno pravidlo:

Obvod trojúhelníku je minimálně dvakrát větší než medián obvodů všech trojúhelníků.

Po odstranění nepotřebných trojúhelníků následuje extrahování pouze okrajových hran trojúhelníků. Okrajová hrana je hranou, která se v seznamu trojúhelníků vyskytuje pouze jednou. Výsledkem je 2D obraz objektu reprezentujícího vstupní množinu bodů (viz obr. 48).



Obrázek 48: Dvojice výsledků vytvoření konkávní obálky (vstupní mračno bodů a vytvořená obálka).

Třetím a posledním krokem je převedení tvaru na kostru. Nejprve je nutné navrhnout definici kostry.


Definice 1 *Kostra je tvořena dvourozměrným seznamem segmentů. Každý segment je tvořen minimálně dvěma body. Každý bod v segmentu se v kostře vyskytuje minimálně jednou. Pokud je bod v kostře více jak dvakrát, je považován za křížovatku.*

Vytvoření kostry je pak provedeno ve třech krocích:

- Ředění bodů (thinning) pomocí Guo-Hall algoritmu (Guo a Hall, 1989).
- Extrakce koster a jejich segmentů z 2D obrazu.
- Vyhlazení a filtrace segmentů.

Ředění bodů

Ředění je operací běžně používanou právě pro získání kostry. Obvykle je vstupem i výstupem této operace binární obraz. Díky ředění je tedy možné získat velice zjednodušenou reprezentaci obrazu, která je ovšem topograficky stejná jako původní obraz. Pro ředění bodů byl zvolen Guo-Hall algoritmus (Guo a Hall, 1989).



Obrázek 49: Výsledky použití algoritmu pro ředění.

Extrakce kostry z 2D obrazu

Výstupem ředění je tedy množina pixelů, které reprezentují kostru obrazu. Aby bylo možné s kostrou dále pracovat, je nutné převést jednotlivé pixely do reprezentace kostry určené v definici 1. Pro převedení pixelů na kostru byla vytvořena rekurzivní podoba Region Growing algoritmu (pseudokód 7).

Nejdříve je nalezen první bod v obraze. Nad tímto bodem je zavolána funkce *RegionGrowingLineSegmentation*. Tato funkce má jako vstup binární obraz, počáteční bod a výslednou strukturu bodů. Při každém průchodu je prohledáno okolí (8 okolních pixelů) počátečního bodu. Pokud v jeho okolí není žádný jiný bod, je ukončeno prohledávání a kostra je označena za konečnou. Pokud je v jeho okolí jeden dříve nezpracovaný bod, je bod zařazen do struktury bodů a nalezený bod se stává počátečním.

Pokud je ovšem nalezeno bodů více, pak každý z těchto bodů se stává počátečním a je nad každým z nich opět zavolána funkce *RegionGrowingLineSegmentation*.

Pseudokód 7 Algoritmus pro převod řaděného obrazu na kostru

```

1: function REGIONGROWINGLINESEGMENTATION(rahovaný obraz, počáteční
   bod, výstupní seznam koster)
2:   Vytvoření nové struktury pro uložení kostry
3:   Uložení počátečního bodu jako aktuálního
4:   while !konec do
5:     prohledání sousedních bílých pixelů
6:     if počet sousedů == 0 then
7:       Uložení aktuálního bodu do segmentu
8:       Uložení segmentu do kostry
9:       konec ← true
10:    else if počet sousedů == 1 then
11:      Aktuálním bodem se stává souseď
12:      Prohledávání pokračuje
13:    else
14:      Pro každého souseda je volána funkce
15:        RegionGrowingLineSegmentation
16:    end if
17:  end while
18: end function

```


Vyhlazení a filtrace segmentů

Posledním krokem je vyhlazení a filtrace segmentů. Vyhlazením segmentů je myšleno snížení počtu bodů v segmentu. Výstupem předchozí části je seznam bodů, který by byl ovšem v praxi velice náročný na jakékoliv zpracování. Proto je nutné ho zjednodušit. Pro zjednodušení linií se často používá Rames-Douglas-Paucker algoritmus (Rames (1972), Douglas a Peucker (1973)). Tento algoritmus umožňuje zjednodušit sérii bodů pomocí hledání nejkratší vzdálenosti od bodu k linii spojující body, z nichž jeden je vždy před a druhý po zpracovávaném bodu.

V takto zjednodušené kostře jsou následně eliminovány všechny segmenty, které nejsou uprostřed kostry a jejichž délka je menší než daný práh.

10.3.4 Zhodnocení detekce potenciálního značení

V předchozím textu je popsána detekce potenciálního dopravního značení. Takto detekované značení je následně převedeno na kostrovou reprezentaci. Převedení na kostrovou reprezentaci má dvě výhody. První výhodou je zpřesnění segmentace. Problémem prvotní segmentace je šum. Díky němu může být více značení vedle sebe označeno jako jedno značení. Ten problém je částečně odstraněn při převodu bodů do binárního obrazu. Při extrakci alfa tvaru jsou mnohdy odstraněny i trojúhelníky spojující jednotlivé segmenty. Druhou výhodou je pak snadnější zpracování značení.



Obrázek 50: Vstupní obraz, výstup po ředění a výsledná kostra.

Jakékoliv následující operace už neprobíhají nad několika desítkami tisíc bodů, ale nad jednotkami nebo desítkami bodů.



Obrázek 51: Výsledek vytvoření koster z mračna bodů zobrazený nad ortofotomapou.

10.4 Identifikace značení

Výsledkem předchozí fáze detekce pozice potenciálního značení je seznam detekovaných koster. Každá kostra je definována dvojrozměrnou maticí bodů. Kromě bodů je u kostry evidováno několik dalších informací:

- počet křižovatek,
- délka kostry,
- úhel kostry k osám (x a y),
- úhel první a poslední části kostry – tento údaj se vypočítává pouze u koster složených z více jak dvou bodů ale bez jakékoliv křižovatky.


Tyto informace jsou automaticky vypočítány a využívány dále pro identifikaci značení.

Před samotným popisem metody pro identifikaci značení je důležité si definovat jasné hranice pro identifikaci. Díky velké složitosti a obrovskému množství různých kombinací se tato práce omezí na identifikaci jen části vodorovného značení, a to na identifikaci přerušované a plné čáry. Dalším omezením je pak struktura a délka čáry. Plná čára musí mít délku minimálně 10 m a přerušovaná minimálně 6 m. U přerušované je pak další omezení na minimální počet 6 bodů (v praxi to znamená, že je tvořena minimálně třemi přerušovanými čarami).

Identifikace plných a přerušovaných čar je docílena obměnou Region Growing algoritmu. V prvním kroku jsou vyfiltrovány všechny kostry, které mají více jak 3 křižovatky. Tímto krokem jsou odstraněny kostry moc složité na zpracování a dále pak velké množství šumu (tedy koster, které nejsou vodorovným značením). Následující kroky popisují identifikaci značení:

1. Najdi první nezpracovanou kostru, která nemá žádnou křižovatku.
2. Pokud je délka kostry větší než 4 m, označ ji jako novou plnou čáru. Pokud je délka kostry mezi 0,9 m a 4 m, označ ji jako novou přerušovanou čáru.
3. V cyklu projdi všechny kostry.
4. Pokud je novou čarou přerušovaná čára, najdi kostru nebo segment kostry, který má délku 0,9 až 4 m, jeho nejbližší bod je vzdálen maximálně 5 m a úhel mezi posledním segmentem přerušované čáry a čarou vzniklou propojením krajního bodu nové čáry a testované kostry je menší než 10 stupňů.
 - a) Pokud je novou čarou plná čára, postup je stejný, ale mění se kritéria na délku segmentu nad 4 m a maximální vzdálenost nejbližšího bodu na 1 m.
 - b) Pokud je nalezena nová kostra, nebo její segment, jsou všechny body kostry nebo segmentu zařazeny do nové čáry a proces pokračuje od bodu 4.
 - c) Pokud není nalezena další kostra nebo její segment pro zařazení, je nová čára označena jako konečná a není již dále zpracovávána.
5. Pokud byla čára označena jako konečná, vrať se k bodu 1, dokud nebudou zpracovány všechny kostry.
6. Eliminuj všechny čáry, které nesplňují výše uvedená kritéria.

Algoritmus tedy funguje na principu výběru jedné kostry a následného připojování dalších koster. Tyto kostry jsou přidávány na základě podmínek daných vyhláškou (Zásady pro vodorovné dopravní značení na pozemních komunikacích, 2011) a zá-



Obrázek 52: Princip fungování identifikace čar. Nejdříve je zvolena jedna čára a od jednoho jejího bodu jsou vyslány nové čáry (červené). Je nalezena ta čára, která má nejmenší úhel a vzdálenost (modrá). Čára, ke které je napojena, je přidána do výsledné přerušované čáry (zelená).

roven určených experimenty. Klíčovou výhodou tohoto postupu je, že k identifikaci značení není potřeba další dodatečná informace (např. o dráze automobilu).

10.5 Rekonstrukce tvaru značení


Poslední částí celé metody je rekonstrukce tvaru značení. Vstupem rekonstrukce je seznam koster, které byly zahrnuty do čar v identifikační části metody. Výstupem je pak seznam obalových polygonů reprezentujících značení. Jak vyplývá z definice 1 každý bod je v kostře minimálně jednou. Z toho plyne, že u každého bodu můžeme evidovat jeho násobnost. Násobnost znamená, kolikrát se daný bod vyskytuje v kostře. Jestliže má bod násobnost rovnu 1, tak se jedná o okrajový bod. Jestliže je násobnost bodu 2, jedná se o vnitřní bod. Jakákoliv kostra může a nemusí mít vnitřní bod. Jestliže je násobnost větší než 2, jedná se o křižovatku. Pro potřeby této práce se budeme soustředit na rekonstrukci koster, jejichž žádný bod nemá násobnost větší než 4. Pokud je násobnost větší než 4, jedná se o složitější kostru (došlo by ke křížení 3 a více čar) a takové kostry můžeme eliminovat, protože se u značení zřídkakdy vyskytují. Stejně jak v předchozích částech je výsledkem rekonstrukce standardní ESRI Shapefile.

Rekonstrukce čar bude popsána na příkladu tří běžně se vyskytujících koster vytvořených ze značení. První kostra je složená ze dvou bodů o násobnosti 1. Tato kostra reprezentuje standardní přerušovanou čáru. Druhý případ je kostra tvořená dvěma krajními body a n vnitřními. Taková kostra typicky reprezentuje plnou čáru. Posledním případem je kostra, kde dojde ke křížení značení, tedy kostra s jedním nebo více body o násobnosti rovné třem.

Tato metoda byla vyvinuta ve spolupráci s Davidem Procházkou¹² a Janou Procházkovou¹³.

Rekonstrukce přerušované čáry

V případě přerušované čáry je nejčastější kostra, která se skládá ze dvou bodů o násobnosti 1. Jak je vidět na obrázku 53. Prvním krokem je vytvoření kolmé úsečky v bodě P . Tato úsečka má délku $2d$, kde d je požadovaná vzdálenost obalového polygonu od kostry. Stejný postup je pak opakován i v bodě Q . Následně jsou okrajové body nově vzniklých úseček seřazeny. Tyto body tvoří požadovaný obalový polygon (znázorněný zelenou barvou).



Obrázek 53: Proces rekonstrukce přerušované čáry. Zelenou barvou je znázorněn výsledný polygon.

Rekonstrukce plné čáry

Rekonstrukce plné čáry, tedy čáry reprezentované kosterou o dvou krajních bodech a n vnitřních, vychází z principu pro rekonstrukci přerušované čáry. Prvním krokem je opět vytvoření kolmých úseček pro první segment kostry (mezi body P a Q). Dalším krokem je vytvoření kolmých úseček pro segment kostry přímo navazující na první (body Q a R). Díky tomuto propojení vzniknou nové body reprezentující části obalového polygonu pro dva po sobě jdoucí segmenty.


Dalším krokem je nalezení bodů mezi těmito segmenty. Tyto body jsou vždy dva. Je důležité říci, že je vždy nejdříve hledán ten bod, který se nachází na straně úhlu menšího než 180° (bod Q_A). Tento bod vznikne průnikem přímk procházejících nově vzniklými body prvního a druhého segmentu (obrázek 54b).

¹²Ing. David Procházka, Ph.D., Ústav informatiky, Provozně ekonomická fakulta, Mendelova univerzita v Brně

¹³Mgr. Jana Procházková, Ph.D., Ústav matematiky, Fakulta strojního inženýrství, VUT v Brně

Jakmile je určen první bod, je možné určit i protilehlý bod. Tento bod je určen protažením úsečky mezi body Q a Q_A do bodu Q_B . Vzdálenosti mezi body Q a Q_A a Q a Q_B jsou stejné (obrázek 54c).

Posledním krokem je pak seřazení všech bodů. Seřazením bodů vznikne seznam bodů reprezentující obalový polygon (obrázek 54d).



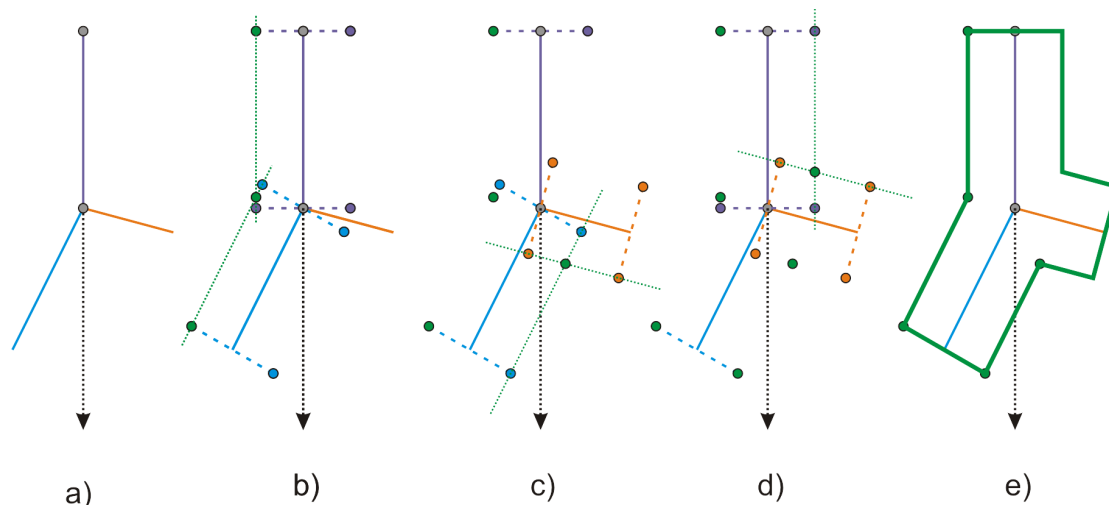
Obrázek 54: Proces rekonstrukce plné čáry: a) Vstupní polygon a vynesení úseček, b) vytvoření prvního průsečíkového bodu polygonu, c) dopočítání druhého průsečíkového bodu, d) výsledný polygon (zelenou barvou).

Rekonstrukce křížení čar

Posledním příkladem je rekonstrukce kostry obsahující bod s násobností 3. Stejně jako předchozí část navazovala na rekonstrukci přerušované čáry, i tento problém navazuje na svého předchůdce. Z toho plyne, že budou vždy rekonstruovány dva na sebe navazující segmenty. Jak je ovšem patrné, problémem je určení posloupnosti segmentů. Tato posloupnost je určena pomocí prodloužení prvního segmentu dopředu (obrázek 55, písm. a). Následně jsou spočítány úhly, pod kterými se další segmenty nachází vzhledem k prodlouženému segmentu. Díky tomuto postupu jsou jednotlivé segmenty seřazeny a následně jsou rekonstruovány vždy dva po sobě jdoucí (obrázek 55, písm. b–e). Princip rekonstrukce bodu s násobností 3 je pak možné rozšířit i na body s násobností 4 a více.

10.6 Výsledky a testování

Testování metody je rozděleno na tři části. V první části bude testována detekce potenciálního značení, v druhé identifikace značení a v třetí jeho rekonstrukce.



Obrázek 55: Proces rekonstrukce značení v případě křížení čar: a) prodloužení prvního segmentu, b) až d) nalezení bodů polygonu, e) výsledný polygon (zelenou barvou).

10.6.1 Testování detekce pozice potenciálního značení na prvním vzorku mračen bodů

Metoda byla nejdříve testována na prvním vzorku (150 mil. bodů). Detekce potenciálního značení byla testována v několika fázích. V první fázi jsou všechny kostry rozděleny do několika kategorií podle svých vlastností. Pomocí rozdělení je následně možné kostry dále filtrovat a tím zdokonalit výsledek detekce. Výsledkem metody pro detekci je celkem 1050 koster. Tyto kostry je možné rozdělit do těchto kategorií (včetně jejich počtů):

- Kostry bez křížovatky (873).
- Kostry s jednou nebo více křížovatkami (177).
- Kostry bez křížovatky o délce menší než 90 cm (229).
- Kostry bez křížovatky o délce větší než 90 cm a menší než 400 cm (524).
- Kostry bez křížovatky delší než 4 m (110).
- Kostry bez křížovatky delší než 10 m (10).

Nyní se podíváme na výsledky prvního testování. V první fázi byl testován pouze počet správně určených značení (správně detekované vodorovné dopravní značení) a počet vynechaných značení (dopravní značení, které nebylo detekováno). Tyto hodnoty jsou dále rozděleny na přerušované čáry, plné čáry a ostatní značení. Špatně určená značení (všechny kostry, které nejsou vodorovným značením, ale byly detekovány) jsou evidovány jako celek, protože je není možné efektivně rozdělit. Výsledky testování jsou uvedeny v tabulce 10.

Z tabulky 10 vyplývá, že detekce má poměrně velkou úspěšnost. Žádná z plných čar nebyla v detekci vynechána a pouze 32 segmentů přerušovaných čar nebylo detekováno. Po výpočtu ukazatele úplnosti se dostaneme na hodnotu 92 % u přerušované

Tabulka 10: Výsledky první fáze testování detekce potenciálního značení.

	Správně určený objekt	Nesprávně vynechaný objekt
Plná čára	22	0
Přerušovaná čára	371	32
Ostatní značení	253	×

čáry a dokonce na 100 % u plné čáry. Pod ostatním značením jsou především kostry reprezentující přechody pro chodce. Je ovšem nutné uvést, že přes velkou úplnost je v detekovaných kostrách poměrně velký počet špatně určených značení, a to 404. Z toho plyne, že ukazatel přesnosti je 61,5 %, což není mnoho. Také je nutné uvést, že některé čáry (jak plné tak přerušované) jsou reprezentované kostrami, které mají křižovatky.

Hlavním důvodem pro vynechání některých značení je především opotřebením barvy a zakrytí značení automobily. Většina vynechaného značení je v okolí křižovatek, kde v době pořízení dat byl rušný provoz a proto docházelo k zakrytí některého značení. Většinu špatně označeného značení pak představují kostry nacházející se mimo vozovku. Nyní se podívejme na způsoby, jak je možné u detekce snížit počet špatně označených značení.

Prvním krokem je odstranění všech koster, které nemají žádnou křižovatku a jejichž délka je menší než 90 cm. Díky tomuto filtrování je celkový počet vytvořených koster omezen na 821. Zároveň s tím se nezměnil počet detekovaného vodorovného značení.

Dalším filtrem bude filtr na počet křižovatek. Mnoho koster má velké množství křižovatek, což ukazuje na složitější značení. Proto odfiltrujeme všechny, které mají čtyři a více křižovatek. Tento krok má jednu velkou výhodu, a to zjednodušení výpočtů při identifikaci, protože jsou odstraněny velmi složité segmenty. Ovšem má i jednu velkou nevýhodu, a to omezení počtu detekovaných plných a přerušovaných čar. Počet plných čar se snížil o 7 a počet přerušovaných čar se snížil o 3. U přerušované čáry je tento počet minimální, ovšem u plných čar tvoří skoro třetinu. Výsledkem filtrování je snížení vstupního počtu koster pro identifikaci na 781.

10.6.2 Testování identifikace plných a přerušovaných čar

Výsledkem metody pro identifikaci typu značení je standardní ESRI Shapefile (SHP) obsahující seznam linií. U každé linie je atribut typ, určující o jaký typ čáry se jedná (plná nebo přerušovaná). Důvodem pro výstup ve formátu SHP je možnost dále s ním pracovat v balíku ArcMap, který je běžným programem používaným pro prostorová data.

Je nutné uvést, že identifikační část je velice závislá na detekční části, protože pro identifikaci jsou použity pouze kostry. Všechny články v kapitole 4.1.4 se soustředí především na rovné úseky silnic, nebo na úseky bez křižovatek. Z tohoto důvodu bude testování identifikace rozděleno na dvě části, a to na testování rovného úseku

a testování na úseku s křižovatkami. Rovným úsekem je ulice Úvoz v městě Brně. Dalším důvodem rozdělení je fakt, že pouze rovný úsek je společný pro první a druhý vzorek mračen bodů.

Na rovném úseku se nachází 5 plných čar a 5 přerušovaných čar, které vyhovují podmínkám uvedených v kapitole 10.4. Na obrázku 56 je znázorněno porovnání vstupních dat vytvořených z ortofotomapy a výsledkem identifikačního algoritmu.



Obrázek 56: Porovnání identifikace čar na rovném úseku (dole) s daty vytvořenými v programu ArcMap (nahore). Modrou čarou jsou znázorněny přerušované a červenou plné čáry.

Jak je z obrázku zřejmé, jediným rozdílem je délka jedné z přerušovaných čar. Tato čára je na svém začátku i konci kratší. V těchto oblastech ovšem nebylo detekováno žádné potenciální značení a proto je čára kratší.

Další fází je testování na úseku s křižovatkami. V tomto úseku se nachází 9 plných a 19 přerušovaných čar. Na tomto úseku je výsledek identifikace mnohem horší. Hlavními důvody jsou:

- Velké množství křížení čar.
- Rušnější provoz – řidiči mnohdy s auty přejížděli z pruhu do pruhu, což rušilo pořízení mračen bodů.

Z celkového počtu 19 přerušovaných čar bylo úplně, nebo částečně identifikováno 15 čar. Problém ovšem nastal u plných čar, kde byly částečně identifikovány pouze 4 čáry. Je také nutné uvést, že v identifikaci se vyskytly i kostry chybně identifikované jako vodorovné dopravní značení. Celkem byly tři. Výsledek identifikace je znázorněn na obrázku 57.

10.6.3 Testování rekonstrukce tvaru vodorovného značení

Jak již bylo řečeno, výsledkem identifikace je seznam čar, kde u každé je uveden její typ (přerušovaná, plná). Zároveň s tím je ale evidován i seznam koster, které



Obrázek 57: Porovnání identifikace čar na úseku s křižovatkami (vpravo) s daty vytvořenými v programu ArcMap (vlevo). Modrou čarou jsou znázorněny přerušované a červenou plné čáry.


jsou součástí identifikované čáry. A právě tyto kostry jsou vstupem pro rekonstrukci značení. Každá kostra je poslána do algoritmu pro rekonstrukci koster a výstupem je seznam bodů definující obalový polygon. Tento seznam je pak převeden na polygony a uložen do standardního Shapefile, aby s ním bylo možné pracovat v aplikaci ArcMap. Jako vstupní vzdálenost rekonstrukce polygonu byla zvolena vzdálenost 10 cm, čímž pádem bude mít obalový polygon značení šířku 20 cm. Tato vzdálenost je variabilní a je možné ji nastavit i na jinou hodnotu.

Podívejme se nyní na porovnání rekonstrukce s ortofotomapou¹⁴. Je nutné říci, že ortofotomapa byla pořízena jindy, než vstupní mračna bodů a proto nemusí pozice značení přesně sedět. Jak je vidět na obrázku 58 výsledkem rekonstrukce značení jsou obalové polygony jasně reprezentující vodorovné dopravní značení. Zároveň je na obrázku vidět i případ, kdy došlo ke zkřížení značení. Toto zkřížení je také zrekonstruováno.

10.6.4 Porovnání detekce a identifikace na prvním a druhém vzorku mračen bodů

Veškeré dosavadní testování metody bylo prováděno na prvním vzorku mračen bodů. V případě detekce dopravních značek a sloupovitých objektů byla hustota bodů v druhém vzorku příliš nízká na to, aby bylo možné tyto metody použít. U metody pro detekci a identifikaci vodorovného dopravního značení je možné toto srovnání částečně provést. Slovo částečně je zde uvedeno úmyslně. Nízká hustota bodů v druhém vzorku neumožňuje dosáhnout stejných výsledků jako u prvního vzorku. Jak je uvedeno v kapitole 6.3, jedinou společnou částí obou vzorků je relativně rovný úsek na ulici Úvoz.

¹⁴Zdroj ortofotomapy: http://geoportál.cuzk.cz/WMS_ORTOFOTO_PUB/WMSservice.aspx



Obrázek 58: Výsledek rekonstrukce vodorovného dopravního značení. Červenou barvou jsou znázorněny vytvořené obalové polygony.

Podívejme se nejdříve na detekci značení. Testování detekce na prvním vzorku je popsáno v kapitole 10.6.1. Pro potřeby testování jsou z detekce vyřazeny všechny kostry, které mají více jak 6 křižovatek. V tabulce 11 je uvedeno srovnání detekce na prvním a druhém vzorku se skutečným stavem na silnici.

Z tabulky 11 vyplývá, že u prvního vzorku bylo celkově detekováno více potenciálního značení. Zároveň s tím je zřejmé, že detekce přerušovaných čar je několikanásobně lepší u prvního vzorku. Hlavním důvodem je nízký počet bodů s vyšší odrazivostí u přerušovaných čar. U druhého vzorku dále nebyly detekovány dvě plné čáry. Posledním důležitým prvkem je detekce ostatního značení. Ve společné oblasti se jedná o šipky. V prvním vzorku bylo detekováno 5 z 6 šipek, ovšem ve druhém žádná.

Tabulka 11: Srovnání detekce potenciálního značení na prvním a druhém vzorku.

	První vzorek	Druhý vzorek	Skutečnost
Plné čáry	5	3	5
Přerušované čáry	53	16	59
Ostatní značení	5	0	6
Špatně určené značení	53	33	×
Celkový počet detekovaného značení	116	52	70

Nyní se podívejme na porovnání identifikace. Porovnání identifikace bude provedeno vizuálně. Na obr. 59 je znázorněn výsledek identifikace jak pro první vzorek, tak i pro druhý. Z celkového počtu 5 plných čar bylo v prvním vzorku identifikováno všech 5, ale v druhém vzorku byly identifikovány pouze 3. V oblasti se dále nachází 5 přerušovaných čar. V prvním vzorku bylo identifikováno všech 5 přerušovaných čar, ovšem v druhém pouze 2.

Při porovnání detekce a identifikace v prvním a druhém vzorku je zřejmé, že mnohem lepšího výsledku je docíleno u prvního vzorku. Tento výsledek je ovšem pochopitelný vzhledem k mnohem nižší hustotě bodů u druhého vzorku.



Obrázek 59: Srovnání identifikace plných a přerušovaných čar na prvním vzorku (uprostřed) a druhém vzorku (dole) se skutečností (nahore).

10.6.5 Časová náročnost metody

Podívejme se nyní na časovou náročnost celého procesu detekce, identifikace a rekonstrukce značení. Fáze detekce je rozdělena na tři části a to: předzpracování, segmentace a vytvoření kostry. U těchto třech částí byl měřen čas potřebný pro jejich ukončení. Aby bylo měření více vypovídající, proběhlo na čtyřech různých mračnecích bodů z prvního vzorku. Výsledky jsou zachyceny v tabulce 12.

Tabulka 12: Časová náročnost detekce potenciálního značení (čas je uvedený v sek).

	Mračno 1	Mračno 2	Mračno 3	Mračno 4
Počet bodů	2 580 808	7 623 968	15 652 299	17 707 429
Předzpracování	2	11	10	20
Segmentace	1	7	14	305
Vytvoření kostry	4	15	65	498
Celkem	7	33	89	823

Jak vyplývá z tabulky, časová náročnost metody se odvíjí především od velikosti mračna bodů, ovšem není to striktně dané. Porovnáme-li výsledky u mračna bodů 3 a 4 uvidíme, že tato mračna se velikostně razantně neliší, ale detekce na čtvrtém mračnu bodů trvala skoro 10× déle. Je to způsobeno především komplexností dat po předzpracování. Pokud je výsledkem předzpracování a následné segmentace velké množství potenciálního značení, trvá i vytvoření koster déle.

Délka trvání identifikace je velice závislá na komplexnosti vstupních koster. Čím komplexnější (větší počet křížovatek) kostry, tím delší bude čas zpracování. Je to dáno množstvím segmentů, které kostry mají. U testovacích dat byla délka 379 vteřin, tedy něco nad 6 minut.

Nejméně náročnou částí je proces rekonstrukce. Délka trvání rekonstrukce je v jednotkách sekund. Je to způsobeno především menším množstvím dat a použitím pouze relativně jednoduchých matematických vzorců.

10.7 Shrnutí

V této kapitole byla popsána metoda pro rekonstrukci tvaru vodorovného dopravního značení. Tato metoda se skládá ze tří částí, a to detekce pozice potenciálního značení, identifikace jeho typu a rekonstrukce tvaru.

Základem metody je nalezení vhodné reprezentace pro vodorovné značení. Většina metod pro detekci pozice dopravního značení se soustředí na přerušované čáry, které reprezentuje nejmenším možným obdélníkem. Tato reprezentace se ovšem nehodí pro plné čáry a dokonce ani pro přerušované čáry na zakřivených úsecích vozovky. V kapitole je jako vhodná reprezentace zvolena a popsána kostra. Díky kostře je možné reprezentovat plné i přerušované čáry a dále pak i případy, kdy dojde ke křížení čar.

Základem metody je detekce pozice potenciálního značení. K detekci pozice je použita zvýšená odrazivost barvy značení. Díky zvýšené odrazivosti je možné eliminovat velkou část mračna bodů, které nerepresentují značení. Následně je provedena segmentace a další zpracování jednotlivých segmentů. Po odfiltrování nepotřebných segmentů je mračno bodů převedeno na 2D reprezentaci značení (tzv. alfa tvar). Alfa tvar je následně převeden na kostru. Kostra je tvořena dvourozměrným seznamem segmentů. Každý segment je tvořen minimálně dvěma body, přičemž každý bod se v kostře vyskytuje minimálně jednou. Pokud je bod v kostře více než dvakrát, je považován za křižovatku.

Další částí metody je identifikace typu značení. Metoda se soustřeďuje na identifikaci plné a přerušované čáry. Identifikace typu značení pracuje na principu Region Growing algoritmu. Ze seznamu koster je vybrána jedna, která reprezentuje počáteční bod hledání. K ní jsou přidávány další, splňující určitá pravidla (počet bodů, úhel čáry spojující kostry a další). Výsledkem identifikační části je seznam čar, ve kterém má každá čára přiřazen typ (plná, přerušovaná).

Poslední částí metody je rekonstrukce tvaru. Rekonstrukce tvaru je provedena na principu vynášení tečen v jednotlivých bodech kostry. Tyto tečny slouží jako základ k dalšímu zpracování. Výsledkem metody je polygon reprezentující tvar značení.

Metoda byla testována na reálných mračnech bodů (na obou dvou vzorcích). Z testování vyplývá, že metoda je velice závislá na prvotním procesu detekce pozice. Výsledkem detekce pozice je poměrně velké množství koster, které nejsou dopravním značením. Je ale nutné uvést, že tyto segmenty jsou velice dobře eliminovány v procesu identifikace typu značení. Počáteční proces detekce pozice je pak hodně závislý na vstupních datech. Zde se ukázal problém především se značením, které bylo v době pořízení překryto automobily. Dalším problémem vstupních mračen bodů je pak větší vzdálenost od skeneru nebo degradace barvy značení.

Z výsledků testování, především pak z podkapitoly 10.6.4 vyplývá, že metoda je určena především pro úseky, kde nedochází k velkému křížení. Pokud dochází k velkému křížení je jakákoliv detekce a identifikace velice problémová. Další věcí, která se ukázala při testování, je možnost použití i v úsecích, kde dochází k velkému zakřivení vozovky. Výhodou reprezentace pomocí koster je totiž schopnost reprezentovat i přerušované čáry, které jsou ale zakřivené díky zakřivení vozovky.

Klíčovým přínosem oproti konkurenčním metodám je reprezentace značení pomocí koster. Díky kostrám je možné rekonstruovat i plné čáry, což se v praxi příliš neprovádí. Většina metod se soustřeďuje pouze na přerušované čáry. V Chen a kol. (2009) je zmíněna i identifikace plných čar. Tento přístup je ale možné použít pouze u plných čar na rovném úseku. U reprezentace pomocí koster toto omezení není.

Dalším přínosem metody je algoritmus pro rekonstrukci tvaru koster. Ve většině případů se značení reprezentuje pomocí bounding boxu. Tato reprezentace má ovšem pouze omezená použití (pouze přerušované čáry).

11 Diskuse

Automatizovaná evidence majetku je předpokladem jeho efektivní správy. Díky automatizaci je možné získávat potřebné informace v mnohem kratším čase a především pak levněji. Je nutné ovšem říci, že plně automatizovaná evidence je otázkou budoucnosti. I přes velké množství metod je stále nutné využít expertního personálu. Podívejme se nyní na jednotlivé metody popsané v práci a zhodnotme jejich přínos pro praxi, stupeň jejich přispění k automatizované evidenci majetku a jejich další rozvoj.

Algoritmus pro identifikaci bodů na zemi

Klíčovým přínosem algoritmu pro identifikaci bodů na zemi je jeho obecnost. Díky jednoduchému principu je možné ho použít pro jakýkoliv druh mračna bodů. Jeho velkou výhodou je možnost nastavit si výšku, do které budou body izolovány. Díky tomu je možné metodu použít vždy, kdy je potřeba izolovat nejnižší body v mračnu bodů.

Tento algoritmus se ukázal jako ideální pro ostatní metody zmíněné v práci, a to především díky jeho spolehlivosti. Je samozřejmé, že mnohem výhodnější by bylo (například pro metodu pro vodorovné značení) použít existující metodu pro detekci bodů přímo na vozovce. Ovšem tato metoda by musela mít stoprocentní přesnost, protože jinak by byl extrémně zkomplikován celý detekční proces.

Dalším přínosem algoritmu může být jeho použití jako základu metod pro detekci například bodů na vozovce. Díky algoritmu je totiž možné razantně omezit množství dat, které bude zpracováno a tím zjednodušit potenciální metodě její práci.

Metoda pro detekci pozice sloupovitých objektů

Klíčovým přínosem této metody je možnost určení přesné pozice sloupovitého objektu. Tento údaj je pak možné využít například pro:

- Identifikaci bodů patřících k sloupovitému objektu a díky tomu i identifikaci typu sloupovitého objektu.
- Rekonstrukci sloupovitého objektu, tedy vytvoření 3D modelu sloupovitého objektu.
- Evidenci stavu sloupovitého objektu. Díky znalosti bodů objektu je, při velké hustotě bodů, možné zjistit poškození sloupovitého objektu.

Značnou výhodou metody je to, že nepotřebuje prvotní segmentaci, jak je tomu obvyklé u ostatních metod. Prvotní segmentací je myšleno získání jednotlivých segmentů reprezentujících sloupy. Díky tomu je možné ji použít v oblastech, kde tato segmentace není možná nebo je velice náročná.

Nevýhodou metody je poměrně velké množství špatně určených sloupovitých objektů. Ty je ovšem možné odstranit v následném postprocesingu.

Dalším možným budoucím rozvinutím metody je rozhodně rekonstrukce sloupovitého objektu. Díky rekonstrukci by bylo možné přesně znázornit sloupovitý objekt včetně všech jiných objektů, které jsou k němu připevněny.

Metoda pro detekci pozice svislého dopravního značení

Největším přínosem této metody je úspora času potřebného pro vyhledání dopravní značky. Jde především o snížení času, který expertní personál potřebuje k nalezení značky v panoramatickém snímku.

Dalším přínosem metody je její značná rychlost. Detekce značek nad prvním vzorkem trvala přibližně 14 minut (na běžném notebooku), z čehož plyne, že tato metoda je dostatečně rychlá, aby ji bylo možné využít přímo při pořizování dat. Díky tomu je tak možné mít výsledek již ve chvíli, kdy se automobil vrátí ze sběru dat z terénu.

Další přínos spočívá v možnosti kombinace metody s obrazovými daty. V případě dostupnosti georeferencovaných obrazů je možné s velkou přesností určit ROI (Region Of Interest), ve kterém se dopravní značka nachází. Díky poměrně vysoké úplnosti metody (93 %) je možné určit ROI pro většinu dopravních značek ve snímané scéně. Na tento ROI je pak možné použít metody pro identifikaci dopravního značení v obrazových datech. Díky získání ROI je možné snížit náročnost a zvýšit přesnost těchto metod.

Dalším vývojem metody tedy bude její kombinace s obrazovými daty. Díky velké úplnosti je zde značný potenciál pro téměř automatizovanou metodu pro evidenci svislého dopravního značení.

Metoda pro detekci pozice, identifikaci typu a rekonstrukci tvaru vodorovného značení

Hlavním přínosem metody je nalezení vhodné reprezentace značení. Tato reprezentace musí nejen znázorňovat značení, ale musí umožnit následnou identifikaci a rekonstrukci. Touto reprezentací jsou kostry. Kostry umožňují nejen přesně reprezentovat značení, ale jsou i základem pro jeho rekonstrukci. Výhodou koster je, že umožňují reprezentovat nejen jednoduchá značení, ale i složitější značení, především pak případy, kdy dojde ke křížení značení.

Dalším přínosem metody je definování principu identifikace značení. Tento princip je možné použít i pro jiné reprezentace, ovšem hodí se nejlépe pro kostry.

Posledním, ale neméně důležitým přínosem, je metoda pro rekonstrukci koster. Tuto metodu je možné použít nejen pro rekonstrukci vodorovného značení, ale koster obecně.

Zásadní výhodou metody je univerzálnost zvolené reprezentace. Díky kostrám je možné v budoucnu identifikovat i jiné typy vodorovného značení, a nikoliv jen plně a přerušované čáry. Jedná se především o přechody a šipky.

Stejně tak jako u svislého dopravního značení, i zde je značný potenciál v kombinaci s obrazovými daty. Díky kombinaci je možné zlepšit detekci a identifikaci

značení tím, že značení nebude hledáno pouze v mračnu bodů, ale i v obrazových datech. Výsledkem pak bude sjednocení těchto detekcí.

Budoucí vývoj metody bude směřovat především na detekci a identifikaci i jiného dopravního značení než jsou plné a přerušované čáry a dále pak na kombinaci metody s obrazovými daty. V předchozím textu byly zmíněny výhody metody, ovšem je nutné uvést i nevýhody. Tou největší je závislost identifikační části na správném vytvoření koster. Další vývoj by měl proto také směřovat ke zlepšení detekční části metody.

Díky zvolené reprezentaci je možné v budoucnu prozkoumat i potenciál identifikace značení pomocí struktury kostry. Tento způsob identifikace by se hodil především pro složitější značení.

11.1 Ekonomické zhodnocení

Je velice obtížné nějakým způsobem přesně kvantifikovat ekonomický přínos práce. Podívejme se proto na situaci, kdy by metody navržené v práci byly implementovány v praxi. Největší přínos metod je pro firmu zabývající se pasportizací majetku. V takové firmě expertní personál sedí u počítače a „klikáním“ v panoramatických fotografiích nebo leteckých snímcích vytváří požadovaná geodata. Tento proces je samozřejmě velice náročný a to jak časově, tak i finančně. Pro firmu by metody navržené v práci byly přínosné následujícím způsobem:

- Metoda pro detekci pozice sloupovitých objektů – díky metodě je možné detekovat velké množství sloupovitých objektů a výsledek předat expertnímu personálu. Ten by měl už pouze za úkol doplnit ke každému objektu jeho atributy, jako typ, stupeň poškození a další. Výhodou je tedy úspora času, který musí personál strávit hledáním sloupovitých objektů v panoramatických snímcích.
- Metoda pro detekci pozice svislého dopravního značení – jak již bylo zmíněno, díky metodě je možné s velkou přesností určit pozici svislého dopravního značení. Díky němu je pak možné udělat ROI v georeferencovaném obraze. Expertní personál by pak v době zpracování měl obdélníky zvýrazněnou oblast, ve které se značení nachází. Jeho úkolem by bylo tedy pouze identifikovat typ značení, popřípadě mu přiřadit další požadované údaje.
- Metoda pro detekci pozice, identifikaci typu a rekonstrukci tvaru vodorovného značení – díky metodě je možné vytvořit polygony reprezentující vodorovné dopravní značení (plné a přerušované čáry). Takto vytvořené polygony mohou sloužit jako základ pro expertní personál, který by mohl pouze doplnit polygony, které chybí, popřípadě upravit polygony vytvořené metodou.

Značný přínos metod vidím především v možnosti práce v noci, resp. na pozadí. Je tedy možné metody spustit přes noc a následující den si již výsledky převezme expertní personál, který s nimi bude dále pracovat. Takovým způsobem bude na práci využít i čas, ve kterém expertní personál pracovat nemůže.

Přínos metod vidím také ve schopnosti metod pokrýt velká území. Především metoda pro rekonstrukci vodorovného dopravního značení se ukázala ideální pro oblasti, jako jsou dálnice nebo rychlostní komunikace.

Přínos práce pro firmu zabývající se pasportizací majetku pak vidím také v podkapitole 6.1. V podkapitole je uvedeno, jaké informace je možné získat o objektech z mračen bodů i z obrazových dat.

11.2 Budoucnost využití mračna bodů pro orgány státní správy a samosprávy

Jak již bylo řečeno, v práci jsou popsány metody pro získávání geodat, např. informace o dopravním značení. Tyto informace jsou ve většině případů využívány orgány státní správy a samosprávy, které shromažďují velké množství různých geodat a je nutné nalézt způsob, jakým může docházet k jejich efektivní správě a především výměně, ať už na státní, nebo i mezinárodní úrovni.

A právě takový způsob již existuje v podobě směrnice INSPIRE. INSPIRE – **IN**frastructure for **SP**atial **IN**fo**R**mation in **E**urope je iniciativou Evropské komise. Stejnomená směrnice Evropské komise a Rady si klade za cíl vytvořit evropský legislativní rámec potřebný k vybudování evropské infrastruktury prostorových informací. Stanovuje obecná pravidla pro založení evropské infrastruktury prostorových dat, zejména k podpoře environmentálních politik a politik, které životní prostředí ovlivňují. Hlavním cílem INSPIRE je poskytnout větší množství kvalitních a standardizovaných prostorových informací pro vytváření a uplatňování politik Společenství na všech úrovních členských států.

Základní principy INSPIRE:

- Data sbírána a vytvářena jednou a spravována na takové úrovni, kde se tomu tak děje nejefektivněji.
- Možnost kombinovat prostorová data z různých zdrojů a sdílet je mezi mnoha uživateli a aplikacemi.
- Prostorová data vytvářena na jedné úrovni státní správy a sdílena jejími dalšími úrovněmi.
- Prostorová data dostupná za podmínek, které nebudou omezovat jejich rozsáhlé využití.
- Snadnější vyhledávání dostupných prostorových dat, vyhodnocení vhodnosti jejich využití pro daný účel a zpřístupnění informace, za jakých podmínek je možné tato data využít (O INSPIRE, 2014).

Je nutné si uvědomit, že směrnice INSPIRE se týká především výměny prostorových dat na úrovni státu. Jedná se tedy o oblasti s velkou rozlohou. Díky leteckému mapování je možné takto velkou oblast pokrýt a zároveň z dat z mapování získat potřebné informace.

Uvedme si dva příklady možného využití mračna bodů pro INSPIRE. V kapitole 4.1.5 jsou uvedeny příklady detekce a inventarizace lesů (Peterson a kol. (2005), Holmgren a Jonsson (2004)).

Dalším příkladem může být zkoumání potenciálu střech pro umístění solárních panelů. Výzkumný tým z univerzity v Lisabonu se zabývá zjištěním množství energie, kterou by bylo možné vyprodukovat, pokud by byly solární panely umístěny na nejlepších možných místech (Santos a kol., 2011). Tato problematika samozřejmě velice souvisí s rekonstrukcí střech popsané v kapitole 4.1.5.

12 Závěr

První část této práce se zabývá teoretickým úvodem k mračnu bodů. Je v ní popsáno mračno bodů, způsoby jeho pořízení a uložení. Stěžejní částí práce je kapitola 4. V této kapitole jsou popsány současné metody používané pro detekci různých objektů v mračnech bodů. Zároveň s tím jsou v kapitole popsány další způsoby využití mračna bodů.

Hlavním cílem práce bylo vytvoření nových metod pro automatizovanou detekci objektů v mračnech bodů. Tento cíl se podařilo splnit. V práci jsou popsány nové metody pro detekci objektů v mračnech bodů.

V kapitole 7 je popsán algoritmus pro identifikaci bodů nacházejících se na zemi. Tento algoritmus je schopen izolovat nejnižše položené body ve vstupním mračnu bodů. Výhodou tohoto algoritmu je jeho schopnost přizpůsobit se terénu a tím izolovat nejnižší body v mračnu bodů. Tento algoritmus se stal jedním ze základních algoritmů používaných v dalších metodách popsaných v práci (např. metoda pro detekci sloupovitých objektů). Další výhodou algoritmu je jeho obecnost. Algoritmus ke své činnosti potřebuje pouze vstupní mračno bodů.

Kapitola 8 se zabývá detekcí sloupovitých objektů. Sloupovitým objektem je objekt, jehož body jsou uspořádány ve vertikálním směru. V kapitole je popsána nová metoda, jejíž hlavní předností je možnost její aplikace i na mračna bodů, v nichž by byla velice problémová úvodní segmentace. Metoda funguje na principu rozdělení mračna bodů na n horizontálních řezů. Nad každým řezem je provedena segmentace pomocí Euklidovské vzdálenosti. Díky segmentaci jsou vytvořeny struktury definující jednotlivé segmenty. Posledním krokem je detekce sloupovitých struktur pomocí směrového vektoru. Jak se ukázalo při testování, metoda má značnou úplnost, ovšem ve výsledcích se objevuje mnoho špatně určených sloupovitých objektů. Z tohoto důvodu byl navržen a implementován algoritmus pro jejich snížení. Jak je ukázáno na konci kapitoly, velkou část špatně určených sloupovitých objektů je možné odstranit v dalším zpracování dat expertním personálem (např. v programu ArcMap).

Další metodou popsanou v práci je metoda pro detekci svislého dopravního značení. Tato metoda je schopna s velkou přesností (91,2 %) a úplností (93 %) detekovat pozici dopravní značky v mračnu bodů. Výhodou metody je právě její přesnost a spolehlivost. Velkým přínosem metody je její rychlost. Nad prvním vzorkem dat (přibližně 2 km silnice uprostřed města) trvala detekce přibližně 15 minut. Tato metoda má použití především jako podpůrný element při evidenci dopravního značení. S její pomocí je možné s velkou přesností určit ROI v obrazových datech. Díky tomu je možné velice usnadnit práci expertnímu personálu který eviduje dopravní značení.

Poslední metodou popsanou v práci je metoda pro detekci, identifikaci a rekonstrukci vodorovného dopravního značení. Tato metoda se soustředí na plnou a přerušovanou čáru. Nejdůležitější částí a zároveň hlavním přínosem metody je nalezení vhodné reprezentace značení. Jako reprezentace byla zvolena kostra. Díky kostrám je možné velice kvalitně reprezentovat jak plnou tak přerušovanou čáru. Zároveň s tím je možné reprezentovat i případy, kdy dochází ke křížení značení.

Metoda je rozdělena do tří částí. První částí je detekce pozice potenciálního značení. Výsledkem detekce je seznam koster představující potenciální značení. Druhou částí je identifikace plných a přerušovaných čar. V této fázi jsou procházeny všechny kostry a nacházeny struktury splňující pravidla pro plné a přerušované čáry. Poslední částí je rekonstrukce tvaru značení. Rekonstrukce tvaru značení spočívá ve vytvoření obalového polygonu kolem kostry. V práci je prezentována nová metoda pro rekonstrukci koster. Metoda je sice určena pro rekonstrukci tvaru značení, ale je možné ji použít kdekoliv, kde je potřeba rekonstruovat kostru. Jak ukázalo testování metody, metoda se hodí především pro úseky s menším počtem čar, kde nedochází k velkému křížení. Z toho tedy vyplývá, že ideálním místem pro použití jsou např. dálnice nebo okresní silnice. Zde nabízí metoda značné využití, protože je díky ní možné velice zautomatizovat celý proces evidence značení.

Jeden z klíčových přínosů práce je také podkapitola 6.1. V této podkapitole jsou určeny informace, které je možné získat z mračna bodů. Tyto informace jsou dány do souvislosti s obrazovými daty. Tato kapitola může sloužit jako zdroj informací pro manažery firem, kteří se rozhodují, zda využít mračna bodů v rámci firemních procesů.

Celá práce má pak ještě další potenciální přínos, a sice pro 3D rekonstrukci měst. Při tvorbě realistické 3D rekonstrukce mohou být jednotlivé objekty v mračna bodů nahrazeny 3D modely z databáze modelů. Uvedme si příklad na sloupovitých objektech. Místo toho, aby byly sloupy rekonstruovány přímo ze vstupních dat je možné jejich body izolovat (díky metodě popsané v práci) a místo nich vložit 3D model. Takovým způsobem je možné izolovat i další objekty a také je nahradit 3D modely. Výsledná rekonstrukce pak bude působit mnohem lepším vizuálním dojmem než kdyby byla prováděna celá ze vstupního mračna bodů.

Značný potenciál pro budoucí rozvoj metod vidím především v propojení s obrazovými (nebo i jinými) daty. Práce je zaměřena na práci s mračny bodů. Z tohoto důvodu byla v metodách použita výhradně mračna bodů. Ovšem metody je možné rozšířit tak, aby pracovaly i s obrazovými daty. Příkladem jsou především metody pro dopravní značení. U svislého dopravního značení je to určení ROI v obraze. Nad tímto ROI je pak možné provést identifikaci dopravní značky. Díky propojení je tedy možné více automatizovat celý proces. Expertní personál by pak měl pouze kontrolní funkci. U vodorovného dopravního značení je potenciál propojení především ve zlepšení přesnosti metody. Díky ní je možné provést kontrolu správnosti detekce a také zlepšit samotnou detekci pomocí prolnutí dvou zdrojů.

13 Literatura

- Alpha Shapes and Concave Hulls*. [online]. 2011 [cit. 1. 3. 2014] Dostupné z: <http://alastaira.wordpress.com/2011/03/22/alpha-shapes-and-concave-hulls/>.
- ALSHAWABKEH, Y. Using Terrestrial Laser Scanning for the 3D Reconstruction of Petra/Jordan. *Photogrammetric Week 05*, 2005, 39–47.
- ARACHCHIGE, N. H., MAAS, H. G Automatic Building Facade Detection in Mobile Laser Scanner point Clouds. *DGPF Tagungsband 21*, 2012, 8 stran.
- BANDARA, K. R. M. U. a kol. Automated Generation of Digital Terrain Model using Point Clouds of Digital Surface Model in Forest Area. *Remote Sensing in Natural and Cultural Heritage*. 2011, 3(5), 845–858.
- BASL, P. J., MCKAY, N. D. A method for registration of 3-D shapes. *Pattern analysis and Machine Intelligence*. 1992, 2, 239–256.
- BELTON, D., BAE, K-H. Automating Post-processing of Terrestrial Laser Scanning Point Clouds for Road Feature Surveys. *Proceedings of the ISPRS Commission V Mid-Term Symposium on Close Range Image Measurement Techniques*, 2010, XXXVIII, 74–79.
- BENTLEY INNOVATION *Point Cloud Ground Detection*. [online]. 2013 [cit. 16. 1. 2014] Dostupné z: http://communities.bentley.com/communities/other_communities/bentley_innovation/b/weblog/archive/2013/05/31/point-cloud-ground-detection.aspx.
- BERÁNKOVÁ, E. *Pasportizace a pasporty při správě majetku*. [online]. 2013. [cit. 22. 2. 2014]. Dostupné z: <http://www.tzb-info.cz/udrzba-budov/10595-pasportizace-a-pasporty-pri-sprave-majetku>.
- BERNARDINI, F., RUSHMEER, H. The 3D Model Acquisition Pipeline. *Computer Graphics Forum 2002*. 2002, 21, 149–172.
- BISHENG, Y. a kol. Automated Extraction of Road Markings from Mobile Lidar Point Clouds. *Photogrammetric Engineering and Remote Sensing*. 2012, 78(4), 331–338. ISSN 0099-1112.
- BOYKO, A., FUNKHOUSER, T. Extracting roads from dense point clouds in large scale urban environment. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011.
- BRAY, N. *Notes on Mesh Smoothing*. [online]. 2004. [cit. 7. 3. 2014]. Dostupné z: <http://www.ann.jussieu.fr/~frey/papers/meshing/Bray%20N.,%20Notes%20on%20mesh%20smoothing.pdf>.
- BRUCKHAUS, T. *How Are Precision and Recall Calculated?* [online] [cit. 4. 4. 2014] Dostupné z: <http://www.kdnuggets.com/faq/precision-recall.html>.

- BUCKSCH, A., LINDENBERGH, R.C., MENENTI, M. SkelTre – fast skeletonisation for imperfect point cloud data of botanic trees. *EG 3DOR'09 Proceedings of the 2nd Eurographics conference on 3D Object Retrieval*. 2009, 13–20. ISBN 978-3-905674-16-3.
- CABO, C. a kol. An algorithm for automatic detection of pole-like street furniture objects from Mobile Laser Scanner point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 87, 47–56.
- CAO, J. a kol. Point Cloud Skeletons via Laplacian-Based Contraction. *Shape Modeling International Conference (SMI)*, 2010, 187–197. ISBN 978-1-4244-7259-8.
- COVASNIANU, A. a kol. Digital Terrain Model by airborne LIDAR technique: an essential tool for hydrologic risks assessment, *Journal of Optoelectronics and Advanced Materials*. 2007, 9(11), 3529–3532.
- CUARTERO, A. a kol. Error Analysis of Terrestrial Laser Scanning Data by Means of Spherical Statistics and 3D Graphs. *Sensors 2010*, 2010, 10, 10128–10145.
- DIMITRIOS, S. A. a kol. Evaluating a dancer's performance using kinect-based skeleton tracking. *MM'11 Proceedings of the 19th ACM international conference on Multimedia*, 2011, 659–662. ISBN 978-1-4503-0616-4.
- DORNINGER, P., NOTHEGGER, C. 3D Segmentation of Unstructured Point Clouds for Building Modelling. *PIA07 - Photogrammetric Image Analysis*, 2007, 191–196.
- DOUGLAS, D., PEUCKER, T. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *The Canadian Cartographer*, 1973, 112–122.
- DU, X., YIN, B., KONG, D. Adaptive Out-of-Core Simplification of Large Point Clouds. *Multimedia and Expo, 2007 IEEE International Conference*, 2007, 1439–1442. ISBN 1-4244-1016-9.
- EDELSBRUNNER, H., KIRKPATRICK, D., SEIDEL, R. On the shape of a set of points in the plane. *Information Theory*, 1983, 29(4), 551–559. ISSN 0018-9448.
- EL MEUCHE R. a kol. Automatic Reconstruction of 3D Building Models from Terrestrial Laser Scanner Data. *ISPRS Annals of the Photogrammetry. Remote Sensing and Spatial Information Sciences*, 2013, II-4/W1, 7–12.
- GOLOVINSKIY, A., KIM, V. G., FUNKHOUSER, T. Shape-based Recognition of 3D Point Clouds in Urban Environment. *International Conference on Computer Vision (ICCV)*. 2009, 2154–2161.

- GONZÁLEZ-JORGE, H. a kol. Geometric Evaluation Of Road Signs Using Radiometric Information From Laser Scanning Data. *Proceedings of the 28th ISARC*, 2011, 1007–1012.
- GUAN, H. a kol. Rapid Update of Road Surface Databases Using Mobile Lidar: Road Markings. *IEEE Proceedings on International Conference on Geo-Information Technologies for Natural Disaster Management*. 2013, 124–129.
- GUAN, H. a kol. Using mobile laser scanning data for automated extraction of road Markings. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2014, 87, 93–107.
- GUO, Z., HALL, R. W. Parallel thinning with two-subiteration algorithms. *Communications of the ACM*. 1989, 32(3), 359–373.
- HAMMOUDI, K., DORNAIKA. F., PAPARODITIS, N. Extracting building footprints from 3D point clouds using terrestrial Laser scanning at street level. *IAPRS*. 2009, XXXVIII(3/W4), 65–70.
- HILLEL, A. B. a kol. Recent progress in road and lane detection: a survey. *Machine Vision and Applications*. 2014, 25(3), 727–745. ISSN 0932-8092.
- HLÁSNÝ, T. *Geografické informačné systémy priestorové analýzy*. 1. vyd. Banská Bystrica: Čižmarová-Partner, 2007. 160 s. ISBN 978-80-8093-029-5.
- HÖFLE, B. Glacier surface segmentation using airborne laser scanning point cloud and intensity data. *ISPRS Workshop on Laser Scanning 2007 and SilviLaser 2007*. 2007, XXXVI, 195–200.
- HOLMGREN, J., JONSSON, T. Large Scale Airborne Laser Scanning of Forest Resources in Sweden. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2004, XXXVI(8/W2), 157–160.
- HRUBÝ, M. *Geografické Informační Systémy (GIS) Studijní opora* [online]. 2006. [cit. 3. 3. 2014]. Dostupné z: <http://perchta.fit.vutbr.cz/vyuka-gis/uploads/1/GIS-final2.pdf>.
- HUANG, A. S. a kol. Finding multiple lanes in urban road networks with vision and lidar. *Intelligent Vehicles Symposium*. 2009, 4, 246–251. ISBN 978-1-4673-2119-8.
- HUANG, H. a kol. L1-Medial Skeleton of Point Cloud. *ACM Transactions on Graphics*. 2013, 32(4), 64. ISSN 0730-0301.
- CHEN, X. a kol. Next generation map making: geo-referenced ground-level LIDAR point clouds for automatic retro-reflective road feature extraction. *Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, 2009, 488–491. ISBN 978-1-60558-649-6.

- CHEN, T. a kol. Gaussian-Process-Based Real-Time Ground Segmentation for Autonomous Land Vehicles. *Journal of Intelligent & Robotic Systems*. 2013, 1–20. ISSN 0921-0296.
- IBRAHIM, S., LICHTI, D. Curb-Based Street Floor Extraction from Mobile Terrestrial Lidar Point Cloud. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2012, XXXIX-B5.
- ISHIKAWA, K. a kol. Recognition of Road Objects from 3D Mobile Mapping Data. *International Journal of CAD/CAM*. 2013, 13(2), 41–48.
- JAW, J. J., CHUANG, T. Y. Feature-based registration of terrestrial lidar point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2008, XXXVII(B3b), 303–308.
- KADOBAYASHIA, R. a kol. Comparison and evaluation of laser scanning and photogrammetry and their combined use for digital recording of cultural heritage. *XXth ISPRS Congress: Proceedings of Commission V*. 2004, 401–406.
- KAI, Z., MING-JU, L. 3D Reconstruction of Irregular Buildings and Buddha Statues. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2014, II(4), 91–94.
- KAMMEL, S., PITZER, B. Lidar-based lane marker detection and mapping. *Intelligent Vehicles Symposium*. 2008, 1137–1142. ISBN 978-1-4244-2569-3.
- KIRÁLY, G., BROLLY, G. Tree Height Estimation Methods For Terrestrial Laser Scanning In A Forest Reserve. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2007, 3(3/W52), 211–215.
- KUČEROVÁ, H. *Kvantitativní metody zkoumání dokumentové komunikace* [online]. 2011. [cit. 27. 6. 2014] Dostupné z: <http://info.sks.cz/users/ku/ZIZ/kvant.htm>.
- LANDA, J., PROCHÁZKA, D. Automatic Road Inventory Using LiDAR. *17th International Conference Enterprise and Competitive Environment 2014*. 2014, 12, 363–370.
- LANDA, J., PROCHÁZKA, D., ŠŤASTNÝ, J. Point cloud processing for smart systems. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*. 2013, 01/2013, 2415–2421.
- LAS Specification - Version 1.3* [online]. 2010 [cit. 8. 8. 2014]. Dostupné z: http://www.asprs.org/a/society/committees/standards/LAS_1_3_r11.pdf.
- LEHTOMÄKI, M. a kol. Detection of Vertical Pole-Like Objects in a Road Environment Using Vehicle-Based Laser Scanning Data. *Remote Sensing*. 2010, 641–664. ISSN 2072–4292.

- LERMA, J. L., BIOSCA, J. M. Segmentation and filtering of laser scanner data for cultural heritage. *CIPA 2005 XX International Symposium*. 2005, 896–901.
- LI, D., OUDE ELBERINK, S. Optimizing detection of road furniture (pole-like object) in Mobile Laser Scanner data. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2013, II-5/W2, 163–168.
- LI, M., LI, Q. Real-time Road Detection in 3D Point Clouds using Four Directions Scan Line Gradient Criterion. *Future*. 2009, 5.
- LI, Q. a kol. A Sensor-Fusion Drivable-Region and Lane-Detection System for Autonomous Vehicle Navigation in Challenging Road Scenarios. *Vehicular Technology*. 2014a, 63(2), 540–555. ISSN 0018-9545.
- LI, Q. a kol. Automated road markings extraction from mobile laser scanning data. *Vehicular Technology*. 2014b, 63(2), 540–555. ISSN 0018-9545.
- LI, Z., ZHU, CH., GOLD, CH. *Digital Terrain Modeling: Principles and Methodology*. Florida: CRC Press, 2004. 323 s. ISBN 978-0415324625.
- LIBERGE, S. a kol. Extraction of Vertical Posts in 3D Laser Point Clouds Acquired in Dense Urban Areas by a Mobile Mapping System. *IAPRS*. 2010, XXXVIII(3B), 126–130.
- LONGLEY, P. A. a kol. *Geographic Information Systems and Science*. 1. vyd. England: John Wiley & Sons, 2001. 454 s. ISBN 0-471-89275-0.
- MEDEROS, B., VELHO, L., DE FIGUEIREDO, L. H. Point Cloud Denoising. *Proceeding of SIAM Conference on Geometric Design and Computing*. 2003a.
- MEDEROS, B., VELHO, L., DE FIGUEIREDO, L. H. *Moving Least Squares Multiresolution Surface Approximation* [online] 2003b [cit. 18. 7. 2014] Dostupné na webu: <http://w3.impa.br/~boris/sib2003.html>.
- MECHELKE, K., KERSTEN, T. P., LINDSTAEDT, M. Comparative investigation into the accuracy behaviour of the new generation of terrestrial laser scanning systems. *Optical 3-D Measurement Techniques VIII*. 2007, 1, 319–327.
- MESOLONGITIS, A., STAMOS, I. Detection of windows in point clouds of urban scenes. *Computer Vision and Pattern Recognition Workshops (CVPRW)*. 2012, 17–24. ISBN 978-1-4673-1610-1.
- MITRA, N. J. a kol. Registration of Point Cloud Data from a Geometric Optimization Perspective. *Eurographics Symposium on Geometry Processing*. 2004, 22–31. ISBN 3-905673-13-4.
- MONNIER, F., VALLET, B., SOHEILIAN, B. Trees Detection from Laser Point Clouds Acquired in Dense Urban Areas by a Mobile Mapping System. *ISPRS*

- Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2012, I-3, 246–250.
- MOOSMANN, F., PINK, O., STILLER, C. Segmentation of 3D lidar data in non-flat urban environments using a local convexity criterion. *Intelligent Vehicles Symposium*. 2009, 215–220, ISSN 1931-0587.
- MOREIRA, A., SANTOS, M. Y. Concave hull: a k-nearest neighbours approach for the computation of the region occupied by a set of points. *International Conference on Computer Graphics Theory and Applications*. 2007, 61–68. ISBN 978-972-8865-71-9.
- MURE-DUBOIDS, J., HUGLI, H. Fusion of Time of Flight Camera Point Clouds. *Workshop on Multi-camera and Multi-modal Sensor Fusion Algorithms and Applications*. 2008.
- NEBIKER, S., BLEISCH, S., CHRISTEN, M. Rich point clouds in virtual globes – A new paradigm in city modeling?. 2010. *Computers, Environment and Urban Systems*. 2010, 34(6), 508–517.
- NING, X. a kol. Segmentation of architecture shape information from 3D point cloud. *VRCAI '09 Proceedings of the 8th International Conference on Virtual Reality Continuum and its Applications in Industry*. 2009, 127–132. ISBN 978-1-60558-912-1.
- O INSPIRE* [online] [cit. 8. 8. 2014]. Dostupné z: <http://inspire.gov.cz/o-inspire>.
- PANDEY, G., MCBRIDE, J. R., EUSTICE, R. M. *Ford Campus Vision and Lidar Data Set* [online]. 2010. [cit. 10. 8. 2014]. Dostupné z: <http://robots.engin.umich.edu/publications/gpandey-2010b.pdf>.
- PARMERTER, B. *GIS Data Structure* [online]. 2007 [cit. 5. 11. 2013]. Dostupné z: <http://ocw.tufts.edu/data/54/676127.pdf>.
- PAULY, M., GROSS, M., KOBEL, L. P. Efficient simplification of point-sampled surfaces. 2002. *VIS'02 Proceedings of the conference on Visualization*. 2005, 163–170, ISBN 0-7803-7498-3.
- PCD file format* [online] [cit. 6. 6. 2014]. Dostupné z: http://pointclouds.org/documentation/tutorials/pcd_file_format.php.
- PCL – Euclidean Cluster Extraction* [online] [cit. 6. 6. 2014]. Dostupné z: http://pointclouds.org/documentation/tutorials/cluster_extraction.php#cluster-extraction.
- PCL – Region Growing segmentation* [online] [cit. 6. 6. 2014]. Dostupné z: http://pointclouds.org/documentation/tutorials/region_growing_segmentation.php.


- PETERSON, B. a kol. Use of LIDAR for Forest Inventory and Forest Management Application. *Proceedings of the seventh annual forest inventory and analysis symposium*. 2005, 193–202.
- PLY Files—an ASCII Polygon Format* [online] [cit. 2. 2. 2014]. Dostupné z: <http://people.sc.fsu.edu/~jburkardt/data/ply/ply.html>.
- PU, S. a kol. Recognizing basic structures from mobile laser scanning data for road inventory studies. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2011, 66(6), 528–539.
- RABBANI, T. a kol. Segmentation of point clouds using smoothness constraint. *ISPRS Commission V Symposium Image Engineering and Vision Metrology*. 2006, 248–253.
- RAMES, U. An iterative procedure for the polygonal approximation of plane curves. 1972. *Computer Graphics and Image Processing*. 1972, 1(3), 244–256.
- REMONDINO, F., a kol. 3D-ARCH 2009: „3D Virtual Reconstruction and Visualization of Complex Architectures“. *ISPRS Archives*. 2009, XXXVIII-5/W1.
- Removing outliers using a StatisticalOutlierRemoval filter* [online]. [cit. 21. 4. 2013]. Dostupné z: http://pointclouds.org/documentation/tutorials/statistical_outlier.php.
- RUSS, J. C. *The Image Processing Handbook*. 6. vyd., 2011, USA: CRC Press, 885 s., ISBN 9781439840450.
- RUSU, R. B. *Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments*. 2009. Disertační práce..
- SANTOS, T. a kol. Solar Potential Analysis in Lisbon Using LiDAR Data. *31st EARSeL Symposium and 35th General Assembly 2011*. 2011, 13–19.
- SCHINDLER, A., MAIER, G., JANDA, F. Generation of high precision digital maps using circular arc splines. *Intelligent Vehicles Symposium (IV)*. 2012, 246–251, ISBN 978-1-4673-2119-8.
- SILVA, L., BELLON, O. R. P., BOYER, K. L. Robust Range Image Registration Using Genetic Algorithms And The Surface Interpenetration Measure. 1. vyd. USA: World Scientific, 2004. 164 s. ISBN 978-9812561084.
- SINHA, T. K. *Surface registration using textured point clouds and mutual information*. 2002. Thesis. Vanderbilt University.
- SMADJA, L., NINOT, J., GAVRILOVIC, T. Road extraction and environment interpretation from Lidar sensors. *IAPRS*. 2010, XXXVIII(3A), 281–286.

- SOLBERG, S., NÆSSET, E., BOLLANDSÅS, O. M. Single-tree segmentation using airborne laser scanner data in a structurally heterogeneous spruce forest. *Photogrammetric Engineering & Remote Sensing*. 2006, 72, 1369–1378.
- SOTOODEH, S. Outlier detection in laser scanner point clouds. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2006, XXXVI-5, 297–302.
- Souřadnicové systémy* [online] [cit. 8. 9. 2014]. Dostupné z: [http://geoportal.cuzk.cz/\(S\(tnd3wkbqspw31m2fm0sl5kk2\)\)/Default.aspx?mode=TextMeta&side=sit.trans&text=souradsystemy](http://geoportal.cuzk.cz/(S(tnd3wkbqspw31m2fm0sl5kk2))/Default.aspx?mode=TextMeta&side=sit.trans&text=souradsystemy).
- SUÁREZA, J. C. Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry. *Computers & Geosciences*. 2005, 31(2), 253–262.
- TAMÁS, L. *Data acquisition and integration, Airborne laser scanning* [online]. 2010a [cit. 9. 9. 2014]. Dostupné z: http://www.tankonyvtar.hu/hu/tartalom/tamop425/0027_DAI4/ch01s02.html.
- TAMÁS, L. *Data acquisition and integration, Mobile laser scanning* [online]. 2010b [cit. 9. 9. 2014]. Dostupné z: http://www.tankonyvtar.hu/hu/tartalom/tamop425/0027_DAI4/ch01s04.html.
- TAMÁS, L. *Data acquisition and integration, Terrestrial laser scanning* [online]. 2010c [cit. 9. 9. 2014]. Dostupné z: http://www.tankonyvtar.hu/hu/tartalom/tamop425/0027_DAI4/ch01s03.html.
- TanDEM-X Global Digital Elevation Model* [online]. 2014 [cit. 21. 9. 2014]. Dostupné z: <http://www.geo-airbusds.com/sg/3264-tandem-x-global-dem>.
- The DARPA Grand Challenge: Ten Years Later* [online]. 2014 [cit. 23. 8. 2014]. Dostupné z: <http://www.darpa.mil/NewsEvents/Releases/2014/03/13.aspx>.
- THUY, M., LEÓN, F. Lane Detection and Tracking Based on Lidar Data. *Metrology and Measurement Systems*. 2010, 17(3), 311–321, ISSN 0860-8229.
- TOTH, C., PASKAA, E., BRZEZINSKA, D. Using Road Pavement Markings As Ground Control For Lidar Data. *International Society for Photogrammetry and Remote Sensing*. 2008, XXXVII, 189–196, ISSN 1682–1750.
- TUČEK, J. *Geografické informační systémy - Principy a praxe*. 1. vyd. Praha: Computer Press, 1998. 424 s. ISBN 80-7226-091-X.
- VOSSelman, G., DIJKMAN, S. 3D Building Model Reconstruction from Point Clouds and Ground Plans. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 2001, 34(3/W4), 37–44.

- WERBROUCK, I. a kol. Digital Elevation Model generation for historical landscape analysis based on LiDAR data, a case study in Flanders (Belgium). *Expert Systems with Applications*. 2011, 38(7), 8178–8185.
- Week 5: Monitoring Invasive Species* [online]. 2014 [cit. 23. 8. 2014]. Dostupné z: http://serc.carleton.edu/eyesinthesky2/week5/intro_gis.html.
- What is LIDAR?* [online] [cit. 18. 7. 2014] Dostupné na webu: <http://oceanservice.noaa.gov/facts/lidar.html>.
- YO, Z. a kol. Automatic object segmentation from large scale 3D urban point clouds through manifold embedded mode seeking. *Proceedings of the 19th ACM international conference on Multimedia*. 2011, 1297–1300. ISBN 978-1-4503-0616-4.
- YOKOYAMA, H. a kol. Detection and Classification of Pole-like Objects from Mobile Laser Scanning Data of Urban Environments. *International Journal of CAD/CAM*. 2013, 13(2), 31–40.
- Zásady pro vodorovné dopravní značení na pozemních komunikacích*. 2011. Ministerstvo dopravy, Technické podmínky, Dodatek č. 1 k II. vydání.
- ZHAN, Q. a kol. Color-based segmentation of point clouds. *Laserscanning09*. 2009, XXXVIII, 248–252.
- ZHOU, Q., NEUMANN, U. Modeling Residential Urban Areas from Dense Aerial LiDAR Point Clouds. *First International Conference, CVM 2012*. 2012, 91–98. ISBN 978-3-642-34262-2.

Přílohy

A Rozřezání mračna bodů na 40 horizontálních řezů



Obrázek 60: Rozřezání předpracovaného mračna bodů na 40 horizontálních řezů. Jednotlivé řezy jsou zvýrazněny barevně.

B Výsledek detekce pozice sloupovitých objektů importovaný do programu ArcMap



Obrázek 61: Výsledek detekce pozice sloupovitých objektů importovaný do programu ArcMap. Žlutou barvou jsou znázorněny správně určené sloupy, červenou eliminované špatně určené sloupovité objekty.