



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ
FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

DETEKCE A LOKALIZACE DOPRAVNÍCH ZNAČEK

TRAFFIC SIGNS DETECTION AND LOCALISATION

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

ONDREJ KUDLÁČ

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. MARTIN VEĽAS

BRNO 2016

Vysoké učení technické v Brně - Fakulta informačních technologií

Ústav počítačové grafiky a multimédií

Akademický rok 2015/2016

Zadání bakalářské práce

Řešitel: **Kudláč Ondrej**

Obor: Informační technologie

Téma: **Detekce a lokalizace dopravních značek**
Traffic Signs Detection and Localisation

Kategorie: Zpracování obrazu

Pokyny:

1. Prostudujte základní metody zpracování obrazu a hloubkových dat. Zaměřte se na problematiku detekce objektů v prostředí, v kterém se pohybuje sensorický systém.
2. Získejte bližší pohled na techniky a existující řešení, které se v současnosti používají v oblasti detekce dopravních značek a fúzi sensorických dat.
3. Navrhněte jednoduchý systém, který je schopný detekovat a lokalizovat dopravní značky na základě aktuálních sensorických dat (2D, 3D, GPS, inerciální jednotka, ...).
4. Implementujte navržený systém s maximálním využitím existujících řešení.
5. Získejte testovací datovou sadu pro testování.
6. Navrhněte a realizujte experimenty s Vaší implementací. Zhodnoťte dosažené výsledky a možnosti budoucího vývoje.
7. Vytvořte stručný plakát, který prezentuje obsah vaší práce a dosažené výsledky.

Literatura:

- Dle pokynů vedoucího.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění prvních tří bodů zadání.

Podrobné závazné pokyny pro vypracování bakalářské práce naleznete na adrese <http://www.fit.vutbr.cz/info/szz/>

Technická zpráva bakalářské práce musí obsahovat formulaci cíle, charakteristiku současného stavu, teoretická a odborná východiska řešených problémů a specifikaci etap (20 až 30% celkového rozsahu technické zprávy).


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

Vedoucí: **Velás Martin, Ing., UPGM FIT VUT**

Datum zadání: 1. listopadu 2015

Datum odevzdání: 18. května 2016

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta informačních technologií
Ústav počítačové grafiky a multimédií
602 00 Brno, Božetěchova 2


doc. Dr. Ing. Jan Černocký
vedoucí ústavu

Abstrakt

Cielom tejto bakalárskej práce je navrhnuť jednoduchý systém pre detekciu a lokalizáciu dopravného značenia v obraze s využitím už existujúcich riešení. Detekcia značiek prebieha na základe ich tvarov a lokalizácia detekovaných objektov prostredníctvom dat z LIDARu. Vytvorené riešenie pozostáva z dvoch komponent: z detektora a lokalizátora pričom každá dokáže pracovať samostatne.

Abstract

This thesis aims to design the traffic signs detection and localization system using RGB image and 3D LiDAR data leveraging the the existing solutions. Traffic sign detection is based on the shape analysis. Then, the LIDAR data are used for the localization of previously detected signs. The created solution consists of two main components: the detector and locator, each able to operate independently.

Klíčové slová

detekcia, lokalizácia, dopravné značky, LIDAR

Keywords

detection, location, traffic signs, LIDAR

Citácia

KUDLÁČ, Ondrej. *Detekce a lokalizace dopravních značek*. Brno, 2016. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Velas Martin.

Detekce a lokalizace dopravních značek

Prehlásenie

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne pod vedením Ing. Martina Velasa. Uviedol som všetky literárne pramene a publikácie, z ktorých som čerpal.

.....
Ondrej Kudláč

18. mája 2016

Podakovanie

Chcel by som poďakovať svojmu vedúcemu práce, Ing. Martinovi Velasovi, za jeho ochotu, trpezlivosť a odbornú pomoc. Ďalej by som rád poďakoval svojmu spolubývajúcemu Bc. Viktorovi Dorotovičovi za jeho cenné rady a podporu.

© Ondrej Kudláč, 2016.

Táto práca vznikla ako školské dielo na FIT VUT v Brně. Práca je chránená autorským zákonom a jej využitie bez poskytnutia oprávnenia autorom je nezákonné, s výnimkou zákonne definovaných prípadov.

Obsah

1 Úvod	2
2 Detekcia dopravných značiek	3
2.1 Analýza dopravného značenia	3
2.2 Možnosti detekcie objektu v obraze	4
3 Lokalizácia dopravných značiek	7
3.1 Lokalizácia pomocou viacerých kamier	7
3.2 Lokalizácia pomocou LIDARu	9
3.3 Lokalizácia pomocou Kinectu	14
3.4 Lokalizácia pomocou Time-of-flight kamery	15
4 Návrh systému	16
4.1 Návrh systému pre detekciu	16
4.2 Návrh lokalizátora	16
5 Implementácia	21
5.1 Použité technológie	21
5.2 Detektor	22
5.3 Lokalizátor	22
6 Dosiahnuté výsledky	23
6.1 Vyhodnotenie lokalizátora	23
7 Záver	25
Literatúra	26
Prílohy	28
Zoznam príloh	29
A Preklad programu	30
B Obsah DVD	31
C Plagát	32

Kapitola 1

Úvod

Systémy na detekciu a lokalizáciu objektov v priestore sa stávajú v posledných rokoch súčasťou veľkého množstva zariadení od zabezpečovacích systémov v rôznych inštitúciách po rôzne systémy, ktorými sú vybavené dnešné automobily. Práve systém pre detekciu a lokalizáciu dopravného značenia má veľký potenciál v automobilovom priemysle. Stáva sa súčasťou systémov, ktoré upozorňujú vodiča napríklad na prekročenie rýchlosti, blížiaci sa koniec hlavnej cesty až po upozornenie na nesprávne parkovanie. Testujú sa prvé autonómne automobily a pomocou systémov na detekciu dopravného značenia môžu reagovať na zmeny, ktoré nastali v premávke a nemajú ich zanesené vo svojich mapách.

Systém pre detekciu a lokalizáciu dopravných značiek, ktorý je navrhnutý a implementovaný v tejto bakalárskej práci využíva pri detekcii toho, že značky majú pomerne jednoduché tvary. Lokalizácia detekovaných značiek je prevádzaná využitím LIDARu, ktorý je súčasťou veľkého počtu riešení autonómnych vozidiel a stáva sa dostupnejším širšej verejnosti.

Postupne v tejto práci bude rozobraná detekcia objektov v obraze s využitím kaskádového klasifikátora a detekcia na základe tvarov detekovaných objektov. Popísané budú zariadenia slúžiace na lokalizáciu aj s postupom ako pomocou nich objekty lokalizovať. Ďalej bude rozobratý návrh jednotlivých častí systému, spôsob implementácie, popísané a analyzované dosiahnuté výsledky spolu s hodnotením úspešnosti.

Kapitola 2

Detekcia dopravných značiek

Detekcia a rozpoznávanie rôznych objektov patrí k základným problémom, ktoré sa pokúša riešiť počítačová grafika. Využitie riešení je veľmi široké od detekcie vozidiel na železničných prejazdoch, zabezpečovanie bezpečnosti, monitorovania priestorov, zabezpečovania plynulosti dopravnej premávky až po poľnohospodárstvo.

V tejto kapitole sú popísané princípy detekcie dopravných značiek ale aj základné princípy a postupy, ktoré sú možné uplatniť na detekciu veľkého množstva iných objektov. Lokalizáciou v tejto kapitole rozumieme vyznačenie plochy a určenie súradníc kde sa detekovaný objekt nachádza a nie určenie jeho polohy v reálnom svete. Tým sa zaoberajú až kapitoly ďalšie.

2.1 Analýza dopravného značenia


Dopravné značenie slúži k riadeniu premávky a zvyšovania bezpečnosti a efektivity samotnej cestnej dopravy. Jeho formu určujú zákony jednotlivých krajín a preto sa dostalo do štádia, kedy rovnaké pravidlá v rôznych štátoch určuje iné označenie. Väčšinou je značenie podobných geometrických tvarov ale líši sa najmä vo farbe podkladu ale aj nápismi^{2.1}. Celosvetová zhoda nastala viacmenej len v čísliciach keď aj veľa ázijských krajín začalo používať arabské číslice. Pri detekcii tieto malé rozdiely nespôsobujú veľké problémy ale pri rozpoznaní jednotlivých značiek to spôsobuje problém.



Obr. 2.1: Zobrazenie značky "Stop daj prednosť v jazde"vo svete

Vlastnosť, ktorú má spoločné dopravné značenie vo všetkých krajinách je, že využíva rovnaké alebo veľmi podobné tvary dopravného značenia : kruh, obdĺžnik, trojuholník, osemuholník ^{2.2}. Táto vlastnosť zjednodušuje detekciu značenia oproti iným objektom, ktoré majú nepravidelný tvar. Spoločnou vlastnosťou, ktorá je identická po celom svete sú

farby použité na jednotlivých značkách. Používa sa len :červená, modrá, biela, žltá a zelená. Ako podklad sa používa biela a žltá. Na jednotlivých druhoch značiek sa nachádzajú len určité kombinácie týchto farieb a na niektorých len jedna z farieb (zelená pre diaľničné navádzače, modrá na informatívne značky ...).



Obr. 2.2: Tvary dopravného značenia

Okrem týchto rozdielov majú rôzne štáty aj ojedinelé zvláštnosti, ktoré komplikujú návrh detektoru, ktorý by zohľadňoval detekciu dopravného značenia celosvetovo.

2.2 Možnosti detekcie objektu v obraze

Pre detekciu rôznych objektov v obraze existuje veľké množstvo rôznych riešení. Pre každý druh objektov existuje iný druh detektora, ktorý dokáže dané objekty detekovať z väčšou úspešnosťou alebo veľkou rýchlosťou. Medzi najrozšírenejšie a najpoužiteľnejšie detektory patria tie, ktoré dokážu detekovať s veľkou úspešnosťou patria riešenia, ktoré využívajú kaskádový klasifikátor alebo vyhľadávajú objekty na základe geometrický tvarov. Pre zrýchlenie detekcie sa objekty popisujú pomocou rôznych príznakov. Tie obsahujú aj jednotlivé klasifikátory. Existuje veľké množstvo rôznych druhov príznakov. Ich dobrou kombináciou je možné výrazne zvýšiť úspešnosť detekcie.

2.2.1 Príznaky

Príznaky v kontexte detekcie objektov slúžia na popis objektov. Pomocou nich je možné natréňovať klasifikátor na správne detekovanie objektu. Počítajú sa aj pri následnej detekcii. Porovnávajú sa s natréňovaným klasifikátorom a podľa toho sa určuje, či sa jedná alebo nejedná o objekt, ktorý chceme detekovať. Dôvod pre zavedenie príznakov bol ,že dokážeme s nimi popísať väčšiu plochu a nemusíme spracovať opakovane každý pixel.

Haarove príznaky

Haarove príznaky sa počítajú na základe intenzity obrazu. Pre jednotlivé obdĺžnikové oblasti ich vypočítame odpočítaním hodnoty pixelov v bielej ploche od hodnoty pixelov v čiernej ploche 2.3. Každéj oblasti je pridelená váha v závislosti na farbe danej oblasti. Hodnota príznaku je vyjadrená vzorcom 2.1 [4]. Kde V_0 je váha bielej oblasti W a V_1 je váha čiernej oblasti B .

$$f(x) = V_0 * W + V_1 * B \quad (2.1)$$



Obr. 2.3: Typy Haarových príznakov


SURF príznaky

SURF (Speeded-Up Robust Features) je metóda popisujúca obrázok pomocou deskriptorov. Na hodnoty jednotlivých deskriptorov nemá vplyv ani zmena vzdialenosti kamery od objektu a ani rotácia. Okrem klasifikácie sa metóda používa aj pri rekonštrukcii 3D scény. Často sa kombinuje s inými algoritmi najmä na vyhľadávanie rohov. Metóda SURF vyhľadáva kľúčové body, okolo ktorých počíta deskriptory. Pri detekcii sa vyhľadávajú podobné alebo zhodné kľúčové body a porovnávajú sa jednotlivé deskriptory [5].

2.2.2 Detekcia objektov s využitím kaskádového klasifikátora

Klasifikácia rozdeľuje obrazové objekty do rôznych tried podľa predom definovaných pravidiel. V závislosti na metóde popisu objektu, ktorý chceme detekovať sa volí popis klasifikácie. Existujú 2 postupy klasifikácie. Pri kvantitatívnej klasifikácii sa pracuje s príznakmi, charakteristikami a parametrami požadovaných objektov. Pri štruktúrálnej klasifikácii sa pracuje navyše aj s popisom objektov. Popisujú sa pomocou primitív. Tieto triedy pracujú z vlastným slovníkom a gramatikou.

Kaskádový klasifikátor je tvorený celou radou slabých klasifikátorov a spolu tvoria jeden silný klasifikátor. Slabé klasifikátory sú tvorené malým množstvom príznakov alebo prahom. Jednotlivo majú slabé klasifikátory malú úspešnosť zrovnateľnú s náhodným výberom. Objekt, ktorý má byť detekovaný postupne prechádza radom slabých klasifikátorov a ak v niektorom nevyhoví je okamžite označený ako objekt nedetekovaný a pokračuje sa ďalším 2.4. Rýchlosť klasifikovania závisí od množstva použitých slabých klasifikátorov. Pri malom počte je detekcia rýchla ale s veľkým percentom falošných detekcií. Pri neúmerne veľkom počte slabých klasifikátorov sa znižuje percento falošných detekcií ale nie často nie sú detekované objekty, ktoré sú mierne zdeformované alebo ich niečo mierne prekrýva. Existuje viac druhov kaskádových klasifikátorov. Vstupom do kaskádových klasifikátorov je výrez z obrazu v ktorom má byť detekovaný objekt. Postupne sa do klasifikátora posiela celý obraz niekoľko krát rozrezaný na rôzne veľké výrezy.



Obr. 2.4: Princíp kaskádového klasifikátora

AdaBoost

Jedna z najznámejších metód tvoriaca kaskádový klasifikátor sa nazýva AdaBoost (Adaptive Boosting). Klasifikátor je tvorený lineárnou kombináciou slabých klasifikátorov [15]. Na vstupe do AdaBoostu je tréningová množina. Podmienkou pre vytvorenie jedného slabého klasifikátora je aby eliminoval aspoň 50 % podoblastí a určil ich ako pozadia. Ak nie je toto dosiahnuté generuje sa ďalší príznak a testuje sa ten až do vygenerovania príznaku, ktorý túto podmienku splní. Ak sa vygeneruje príznak spĺňajúci túto podmienku generuje sa ďalší klasifikátor. Existuje viac úprav AdaBoostu upravujúce najmä podmienky pre vytvorenie klasifikátora.

2.2.3 Detekcia objektov na základe tvaru

Pri objektoch, ktoré sa dajú ľahko popísať základnými geometrickými útvarmi okrem detekcie pomocou kaskádového klasifikátora pripadá v úvahu aj detekcia založená na tvare [6]. Pri detekcii dopravného značenia, ktoré je podobné až na pár výnimiek po celom svete a opísateľné základnými geometrickými tvarmi dosahuje detekcia na základe tvarov veľmi dobré výsledky.

Prvým ktorom princípu je detekcia hrán. Veľmi dobré výsledky dosahuje Harrisov detektor popísaný v kapitoly 3.1.2. Harrisov algoritmus dosahuje slabšie výsledky v RGB farebnom priestore a preto je potrebné pre väčšiu úspešnosť prevádzať obrázky z modelu RGB do šedo-tónového obrazu.

Jedná sa o obraz kedy je každý bod určený len jednou hodnotou. V RGB modeli je potrebné každý bod popisovať 3 hodnotami (červená, zelená, modrá). Prevod je jednoduchý a robí sa podľa vzorca 2.2. Výsledný bod so súradnicami x, y prevedení do stupňa šedi je označený ako $BodS_{xy}$ a jednotlivé zložky toho istého bodu v RGB modeli sú násobené váhami jednotlivých farieb. Jednotlivé farby majú odlišné váhy pretože aj ľudské oko vníma rozlične intenzívne rôzne farby.

$$BodS_{xy} = 0.299R_{xy} + 0.587G_{xy} + 0.114B_{xy} \quad (2.2)$$

Postup detekcie obrysov a geometrických útvarov opísal a použil vo svojej bakalárskej práci Jakub Sochor [14]. Pre detekciu obrysov použil algoritmus známy ako "border following" popísaný v publikácii Azriela Rosenfielda [12].

Postupne sa označujú jednotlivé body hodnotami podľa toho či sú hrana, označený obrys alebo ani jedno. Obrisy delí na vonkajšie a vnútorné. Algoritmus postupne prechádza obraz a hľadá bod, ktorý môže byť počiatočný bod obrysu. Tomuto obrysu je potom priradené kladné číslo. Následne sú tieto označené obrisy prechádzané algoritmom od počiatočného bodu dovtedy pokým nenarazí opäť na počiatočný bod. Po tomto je nutné už len obrisy extrahovať a zvoliť ich reprezentáciu.

Kapitola 3

Lokalizácia dopravných značiek

Táto kapitola popisuje lokalizáciu značiek detekovaných pomocou detektora. Lokalizáciu v tejto práci rozumieme ako priradenie detekovanému objektu polohu buď relatívnu oproti zariadeniu, ktoré značku detekuje alebo absolútnu od začiatku cesty prípadne priradenie GPS súradníc. V tejto kapitole sú popísané všeobecné princípy a možnosti lokalizácie rôznych objektov ohraničených v 2D výrezy. Pre lokalizáciu objektov v priestore existuje viacero funkčných riešení. Prvé sa vyvinuli z vojenskej vojenskej špionáže. Pre potreby počítačového videnia sa využívajú riešenia, ktoré patria do metódy diaľkového prieskumu Zeme. Diaľkový prieskum Zeme je veda získavať užitočné informácie o objektoch, plochách alebo iných javoch prostredníctvom dát meraných na zariadeniach, ktoré s týmito skúmanými objektami, plochami alebo javmi nie sú v priamom kontakte.[10]. V počítačovom videní sa najčastejšie používajú dáta z LIDARov, radarov, kamier a z rôznych zariadení používajúcich infračervené a ultrafialové žiarenie. V ďalších kapitolách sú popísané najčastejšie používané zariadenia a metódy využívajúce sa k lokalizácii objektu v priestore.

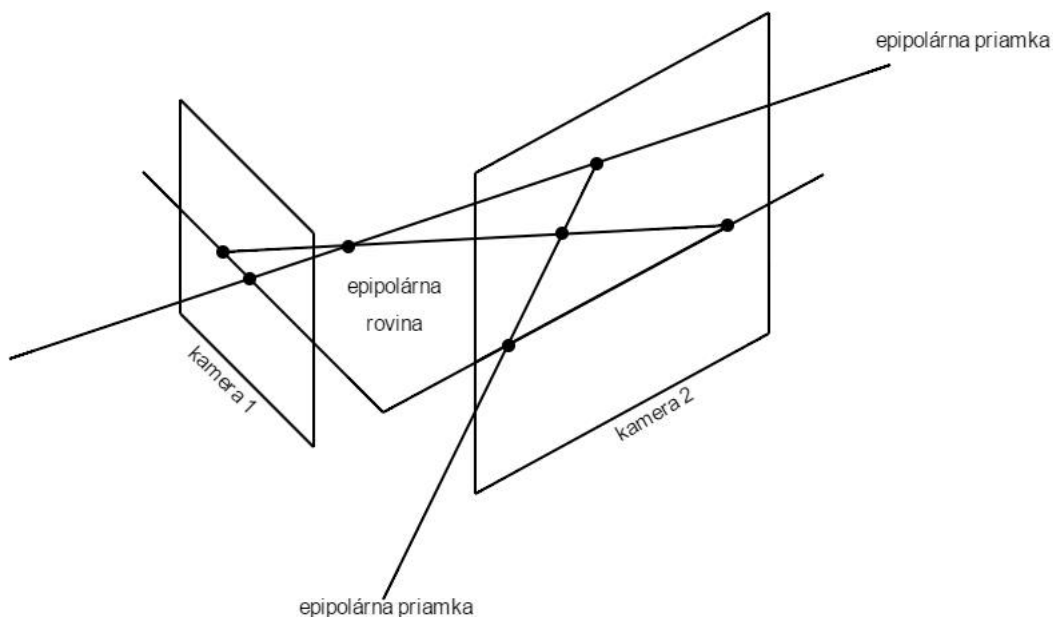
3.1 Lokalizácia pomocou viacerých kamier

Medzi klasické problémy, ktoré sa v počítačovom videní riešia patrí rekonštrukcia 3D scény z jej 2D snímok. Dvojicu takýchto obrazov snímaných pomocou kamier nazývame stereopár. Oproti jednej kamere má snímanie minimálne dvomi veľkú výhodu. Zatiaľ čo jednou kamerou sme schopný spracovať len scénu pozostávajúcu z roviny. Pri stereo páre je možné pomocou epipolárnej geometrie, ak premietacie roviny kamier neležia v jednej rovine, namapovať určitý bod v jednom snímku z jednej kamery na priamku v snímku druhej kamery, vyhľadať bodovú korešpondenciu a určiť polohu bodu.

3.1.1 Epipolárna geometria

Epipolárna geometria popisuje geometrické vlastnosti priesečníkov priemetní kamier zo zväzkom rovín, ktoré pretínajú priamku spájajúcu ohniská kamier. Je ju možné použiť len v prípade, keď neležia ich priemetne v jednej rovine. Tieto priamky sa nazývajú základné priamky. Sú nezávislé od umiestnenia objektov v scéne. Vplyv na nich majú len samotné parametre kamier a ich poloha. Epipól je miesto kde sa pretínajú obidvoch kamier. Epipolárna rovina je rovina cez ktorú prechádza základná priamka [8]. Epipolárna priamka je každá priamka, ktorá pretína epipolárnu rovinu a priemetnu kamery 3.1. Polohu kamier medzi sebou je možné popísať pomocou posunutí a otočení. Pri posune kamery ale zachovaním smeru, dochádza k rovnakej situácii ako pri posune celej scény jedným smerom

a statickou kamerou. Vtedy hovoríme o tom, že vektory posunutia všetkých bodov v scéne zachovávajú svoje hodnoty. Nimi určené priamky sa premietnu do roviny a pretnú sa v jednom bode. Tento bod sa nazýva bod splnutia.



Obr. 3.1: Epipolárna priamka a rovina

Bodová korešpondencia


Bodová korešpondencia je relácia, ktorá je podmnožina kartézskoho súčinu dvojdimenzi-onálnych súradníc, ktorá určuje dvojice bodov zodpovedajúce projekciám na priemetne rovnakého bodu scény v jednotlivých kamerách. Ak poznáme polohu kamier je možné z každej dvojice tejto relácie vypočítať pozíciu daného bodu v priestore.

3.1.2 Harrisov detektor

Bodovú korešpondenciu je potrebné vyhľadať. Body musia byť jednoznačne detekované v projekčných plochách všetkých kamier. Tieto body je možné vyhľadať pomocou Harrisovho detektora. Je nezávislý na rotácii. Ako jednoznačné body určuje rohy. Detektor spolieha na to, že v rohoch sa intenzita obrazu mení vo viacerých smeroch, preto skúma zmeny intenzity pri posune. Okolo rohových bodov sa pri posune ľubovoľným smerom intenzita obrazu mení. [3.2](#)

3.1.3 Lokalizácia detekovanej oblasti

V prípade, že sa rozhodneme použiť metódu viacerých kamier k lokalizácii detekovanej oblasti je potrebné aby bola oblasť detekovaná na viacerých kamerách. Pomocou Harrisovho detektora vyhľadáme v detekovanej oblasti bodovú korešpondenciu. V prípade, že poznáme polohu kamier, kde sa podarilo v detekovanej oblasti bodovú korešpondenciu nájsť pre určenie polohy oproti ľubovoľnej kamere použijeme vzťah [3.1](#) [\[11\]](#) .



Obr. 3.2: Nalezení rohu pomocou Harrisovho detektora

$$Point_{3D} = \begin{bmatrix} X/W & Y/W & Z/W \end{bmatrix} = \begin{bmatrix} X & Y & Z & W \end{bmatrix} = Q * \begin{bmatrix} x & y & disparita(x, y) & 1 \end{bmatrix} \quad (3.1)$$

Polohu bodu oproti kamere dostaneme vynásobením perspektívnej transformácie Q z maticou obsahujúcu súradnice x, y , ktoré značia polohu bodu v projekčnej ploche kamery. Disparita je rozdiel v zobrazení bodov na projekčnej ploche druhej kamery.

Toto zopakujeme nad všetkými korešpondenčnými bodmi v detekovanej oblasti a spriemerovaním ich súradníc dostaneme polohu oproti kamere.

3.2 Lokalizácia pomocou LIDARu

3.2.1 Popis LIDARu

Názov LIDAR je akronymom anglického "Light Detection And Ranging". Jedná sa o prístroj alebo technológiu k detekcii objektu a meraniu jeho vzdialenosti od zariadenia. Momentálne sa LIDAR využíva v širokej škále odvetí (astronómia, biológia, geodézia, geológia, automobilový priemysel, ...) a jeho potenciál nie je zďaleka naplno využitý. Zariadenie sa skladá zo zdroju laserového žiarenia, optickej sústavy, detektoru elektrotechnického žiarenia a veľmi presných hodín. U LIDARov, ktoré sú namontované na mobilných platformách bývajú súčasťou aj navigačné a polohové systémy. Najčastejšie sú to GPS a IMU jednotky. Výsledkom laserového skenovania je mračno bodov. Najčastejšie sa LIDAR používa k mapovaniu do digitálneho modelu povrchu alebo 3D modelu objektu.


3.2.2 Princíp LIDARu

Princíp fungovania LIDARu je veľmi jednoduchý. Zo zdroju laserového žiarenia, u výkonných zariadení pevno-látkový laser u menej výkonných diódový laser, je vysielaný smerom k objektu zväzok lúčov laserového žiarenia. Najčastejšie sa využíva spektrum 1064 - 1530 nm, pri meraní hĺbky vody 530nm. Od objektu sa žiarenie odrazí smerom k detektoru, ktorým je najčastejšie svetlocitlivá dióda spektrálne synchronizovaná na rovnakú vlnovú dĺžku ako je vysielané laserové žiarenie. Vysoká citlivosť diódy je podmienkou k presnému meraniu nakoľko energia svetla klesá z druhou mocninou vzdialenosti. Optická sústava zabezpečuje

koncentráciu žiarenia do veľmi úzkeho zväzku a spoluprácu medzi emitorm laserového žiarenia a detektorom. Súčasťou optickej sústavy je aj zrkadlo, ktoré zabezpečuje smerovanie laserového lúču pod inými uhlami. Zabezpečuje sa tým snímanie určitého priestoru bez potreby pootáčania celého zariadenia. Úlohou hodín je merať čas od vyslania paprsku po jeho detekciu na detektore. **3.3** Pomocou znalosti rýchlosti svetla je možné určiť vzdialenosť objektu a spolu so znalosťou smeru vysielaného lúču možno určiť polohu skenovaného objektu. Vzdialenosť objektu od LIDARu sa počíta podľa vzorca **3.2** kde l je vzdialenosť objektu, t je čas od vyslania laserového lúču po jeho detekciu na detektore v sekundách a c je rýchlosť svetla v sekundách. Výslednú hodnotu je potrebné vydeliť dvomi nakoľko svetlo žiadanú vzdialenosť prešlo aj naspäť od objektu do detektora.

$$l = (t * c) / 2 \quad (3.2)$$


Pri meraní môže dochádzať ku chybám, ktoré majú vplyv na presnosť merania vzdialenosti. Najčastejším zdrojom chýb je presnosť meraného času. U pulzných systémov musí byť pulz vyslaný v presne určený čas. Ak je generovaný oneskorene je výpočet chybný. Podobný problém je aj pri posune tvaru alebo zmenou frekvencie. V tomto prípade má problémy detektor z rozoznaním odrazeného signálu a nepresnosť v meraní. Odchýlku merania môže spôsobiť aj rôzna odrazivosť rôznych materiálov. Pri LIDARoch, ktorých súčasťou sú aj navigačné a polohové systémy je možnosť určiť priamo GPS súradnice objektu a nie len polohu oproti LIDARu.



Obr. 3.3: Zjednodušený princíp LIDARu

3.2.3 Lokalizácia objektu v obraze

Pre lokalizáciu objektu detekovaného vo výstupe z kamery je potrebné vyriešiť viacero problémov. Objekt detekovaný pomocou kamery je popísaný v 2-dimenzionálnom priestore súradnicami v jej výstupe. LIDAR pracuje v 3-dimenzionálnom a jeho adresovanie bodov je rozdielne ako má výstup z kamery. Preto je potrebné jednotlivé body, ktoré sú výstupom LIDARu naadresovať podľa výstupu z kamery. Ďalej je potrebné jednotlivé body pomocou projekcie previesť z 3D na 2D a určiť či sa nachádzajú v detekovanom priestore a až následne je možné objekt lokalizovať a priradiť objektu GPS súradnice alebo polohu od zariadenia. Jednotlivé kroky si rozoberieme v ďalších podkapitolách.



Obr. 3.4: Posun a rotácia v priestore

Priestorová transformácia súradníc

Priestorová transformácia je určená tromi súradnicami posunu a tromi uhlami natočenia. Posúva a otáča sa súradnicový systém LIDARu na súradnicový systém kamery. V obrázku 3.4 je zaznamenané posunutí a otočení súradnicového systému LIDARu k súradnicovému systému kamery. a_1 ukazuje posun v smere r , a_2 v smere s a a_3 v smere t . Okolo os je potrebné spraviť otočenie podľa x, y, z . Na poradí prevedenia jednotlivých úloh v priestorovej transformácii záleží [9].

Posunutie je určené vektorom posunutia 3.3 a transformačnou maticou 3.4. Pre posunutie bodu LIDARu so súradnicami (x, y, z) a vektora 3.3 dostaneme bod v súradnicovom systéme kamery 3.5.

$$v = (Tx, Ty, Tz) \quad (3.3)$$

$$Tr = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ Tx & Ty & Tz & 1 \end{bmatrix} \quad (3.4)$$


$$[x \ y \ z \ 1] * \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ Tx & Ty & Tz & 1 \end{bmatrix} = [x + Tx \ y + Ty \ z + Tz \ 1] \quad (3.5)$$

Pre otáčanie okolo jednotlivých súradnicových osí používame tiež transformačné matice. Pre každú os existuje jedna transformačná matica. Pre otočenie o uhol u 3.6.

$$Ax = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos u & \sin u & 0 \\ 0 & -\sin u & \cos u & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} Ay = \begin{bmatrix} \cos u & 0 & \sin u & 0 \\ 0 & 1 & 0 & 0 \\ -\sin u & 0 & \cos u & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} Az = \begin{bmatrix} \cos u & \sin u & 0 & 0 \\ -\sin u & \cos u & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.6)$$

Projekcia

Pod pojmom projekcia rozumieme zobrazovanie viacrozmerných objektov do priestorov s menej rozmermi. Pri lokalizácii objektu detekovaného z výstupu kamery potrebujeme použiť projekciu pre premietnutie mračna bodov z lidararu na rovinu 3.5 pre určenie, ktoré body sa nachádzajú v detekovanej ploche a zaujímajú nás ich vzdialenosti pre určenie polohy.



Obr. 3.5: Projekcia mračna bodov na výstup z kamery


Projekciu spravíme vynásobením 3D bodu projekčnou maticou 3.7.

$$P_{2D} = P_m * P_{3D} \quad (3.7)$$

Najjednoduchší spôsob ako spraviť projekciu je odignorovanie jednej súradnice. Takáto projekcia sa nazýva paralelná projekcia 3.6. Nezohľadňuje však skutočnosť, že vzdialenejšie objekty sa javia menšie a bližšie zasa väčšie. Paralelnú projekciu dostaneme vynásobením s nulovou z-kovou zložkou 3.8.

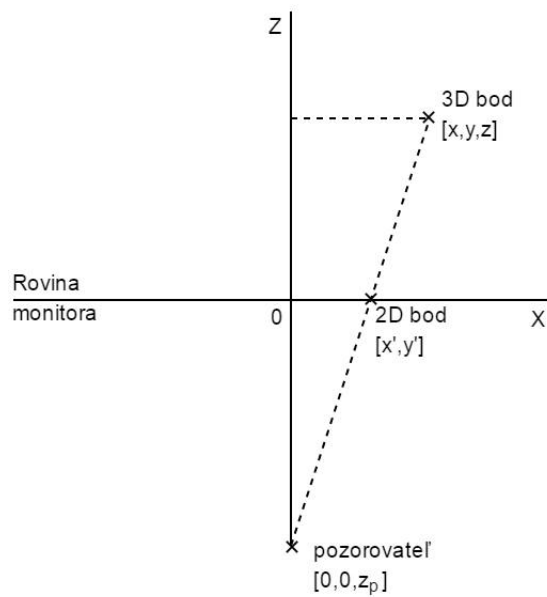
$$\begin{bmatrix} x_{2D} \\ y_{2D} \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} * \begin{bmatrix} x_{3d} \\ y_{3d} \\ z_{3d} \\ 1 \end{bmatrix} \quad (3.8)$$

Skreslenie, ktoré vzniká pri paralelnej projekcii rieši perspektívna projekcia. Perspektívna projekcia funguje podobne ako náš zrak. Objekty, ktoré sú bližšie vidíme väčšie ako objekty, ktoré sú ďalej. Pri perspektívnej projekcii sa premietajú jednotlivé body v priestore do roviny od pozorovateľa 3.7. Pre premietnutie bodu z priestoru do roviny používame nasledujúci vzorec 3.9 [9]. Kde d označuje vzdialenosť medzi pozorovateľom a projekčnou rovinou .



Obr. 3.6: Paralelná projekcia

$$\begin{bmatrix} dx_{2D} \\ dy_{2D} \\ 1 \end{bmatrix} = \begin{bmatrix} d & 0 & 0 & 0 \\ 0 & d & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} * \begin{bmatrix} x_{3d} \\ y_{3d} \\ z_{3d} \\ 1 \end{bmatrix} \quad (3.9)$$



Obr. 3.7: Perspektívna projekcia

Prevod LIDAR 3D bodu do roviny kamery


Pre prevod ľubovoľného bodu z mračna bodov do roviny kamery potrebujeme transformačnú maticu Tr pre posun a otočenie súradnicového systému do súradnicového systému kamery. Potrebná je aj projekčná matica Pm kamery v ktorej výstupe je detekovaná oblasť. Používame perspektívnu projekciu. Celý prevod priestorového bodu z LIDARu do umiestnenia v rovinnom zobrazení kamery podľa vzorca 3.10. Dôležité je poradie jednotlivých

operácii.

$$Point_{2D} = Pm * (Tr * Point_{3D}) \quad (3.10)$$

3.3 Lokalizácia pomocou Kinectu

Kinect je herný systém vyvinutí firmou Microsoft. Pôvodne slúžil ako rozšírenie pre domácu hernú konzolu Xbox. Umožňoval ju ovládať bez ovládača len pohybmi a rečou. Vďaka kombinácii zariadení, ktoré ho tvoria našiel využitie aj v počítačovej grafike. Kombinuje v sebe RGB kameru, hĺbkové čidlo, širokospektrálne mikrofóny a procesor pre beh riadiaceho softwaru.



Obr. 3.8: Kinect a jeho súčasti [2]

Súčasti kinectu :

1. Infračervená kamera a infračervený projektor
2. RGB kamera
3. Širokospektrálne mikrofóny rozmiestnené na dolnej hrane zariadenia
4. Motorizované naklonenie pre pohyb nahor a nadol


Senzor hĺbky sa skladá z dvoch komponentov a to zo infračerveného žiariča teda zdroja infračerveného svetla a infračerveného žiariča. Kinect vytvára hlbinnú mapu v ktorej každý pixel nesie informáciu o vzdialenosti objektu od senzoru. Z infračerveného žiariča je do priestoru premietané štruktúrované svetlo. Obrazce svetla sú rozdelené do skupín. Každá skupina má unikátny obrazec. Kinect pozná každú skupinu a svoju pozíciu. Po premietnutí do priestoru sa obrazce deformujú podľa tvarov predmetu. Žiarenie odrazené od predmetov v scéne sa detekuje na monochromatický CMOS senzor citlivý na infračervené pásmo. Hľadá známe obrazce a kontroluje pod akým uhlom sa vracajú. Z toho dokáže Kinect určiť v akej vzdialenosti sa predmet nachádza.

3.3.1 Použitie Kinectu pre lokalizáciu detekovaných oblastí

Použitie kinectu k lokalizácii detekovaných oblastí je značne obmedzené pre jeho nízke zorné uhle a pre malý dosah infračerveného žiariča (4m). Pre lokalizáciu detekovaných dopravných značiek je nevhodný hlavne pre nízky dosah. Táto hodnota sa vo výhľadnej dobe nezlepší nakoľko Kinect nie je primárne určený k tomuto ani podobnému účelu.

3.4 Lokalizácia pomocou Time-of-flight kamery

Time-of-flight (TOF) kamera pracuje na podobnom systéme ako LIDAR. Pracuje s rýchlosťou svetla a časom do detekovania odrazu. Narozdiel od LIDARu ale celú scénu zachytí na jeden impulz a neskenuje postupne bod po bode ako LIDAR. Jedná sa o relatívne novú technológiu, ktorá mohla vzniknúť až dosiahli bežné zariadenia vysokého výkonu. Dosah týchto kamier býva v radoch kilometroch. TOF kamery dokážu snímkovať scénu rýchlosťou až 100 snímok za sekundu. Najjednoduchšie TOF kamery využívajú svetelné pulzy. Na veľmi krátku dobu osvetlia celú scénu. Objektív kamery priamo odrazené svetlo a v závislosti na čase prijatia priraduje vzdialenosti. Skreslenie vzdialenosti nastáva pri viacnásobných odrazoch, kedy dôjde k neskoršiemu návratu odrazeného lúču.[13] Zlé výsledky kamera dostáva najmä pri zrkadlovom povrchu.



Obr. 3.9: Porovnanie jednotlivých technológií

3.4.1 Použitie TOF kamery pre lokalizáciu detekovaných oblastí

TOF kamera je použiteľná pre lokalizáciu detekovaných oblastí. Jedná sa však o pomerne novú a komplikovanú technológiu. Masovému rozšíreniu zatiaľ bráni predovšetkým cena zariadení.

Kapitola 4

Návrh systému

Systém pozostáva z dvoch jednotlivých komponent, ktoré pracujú samostatne a je ich možné pri zachovaní vstupu/výstupu zameniť za inú komponentu. Pri návrhu systému bolo prioritou jednoduchosť, rýchlosť a funkčnosť celého systému. Systém musí byť schopný detekovať dopravné značenie používané po celom svete. Z určených podmienok bolo vybrané vhodné riešenie z možností popísaných vyššie a so snahou ho z čo najväčšej časti pokryť už existujúcimi riešeniami.

4.1 Návrh systému pre detekciu

Pre detektor dopravných značiek v obraze bolo potrebné nájsť systém splňujúci podmienky vymedzené vyššie. Pre splnenie týchto podmienok som sa rozhodol použiť systém detekujúci objekty podľa ich tvarov. Použitie systému detekujúceho objekty pomocou kaskádového klasifikátora by bolo problémové hlavne z dôvodu potreby veľmi veľkej trénovacej množiny pre pokrytie tak veľkého počtu rôznych typov. Rôzne krajiny majú značky podobných tvarov ale nie farieb, orámovaní a použitého písma. Tieto vlastnosti by vyžadovali veľmi robustný klasifikátor zložený z príliš veľkého množstva slabých klasifikátorov a predĺženie času potrebného pre detekciu. V prípade použitia systému v automobiloch sa vyžaduje detekcia a lokalizácia v reálnom čase. Tieto podmienky spĺňa systém postavený na detekcii pomocou tvarov, ktoré dokážu pracovať v reálnom čase. Pre presnú identifikáciu značku bude potreba použiť klasifikátor ale v závislosti od tvaru značku sa jedná o výrazne menšiu množinu možností ako pri nešpecifikovaní tvaru. Niektoré druhy značiek sú dokonca aj medzinárodne identifikovateľné podľa tvaru.


4.1.1 Detektor na základe tvarov

Podmienky stanovené v kapitole vyššie plno spĺňa detektor, ktorý v rámci svojej bakalárskej práce[14] navrhol Jakub Sochor. Detektor detekuje značky v obraze pomocou ich tvarov. Generuje veľmi nízke percento falošných detekcií a má pomerne veľkú úspešnosť.

4.2 Návrh lokalizátora

Pre zloženie systému na lokalizáciu objektu detekovaného v detektore som porovnával vhodnosť jednotlivých riešení popísaných v kapitole 3.

Z už existujúcich riešení som sa rozhodol lokalizovať detekovaný objekt pomocou LIDARu. Celé zariadenie pre detekciu a lokalizáciu v automobile pozostáva z kamery, LIDARu



Obr. 4.1: Umiestnenie zariadení na aute použitom k vytvoreniu KITTY datasetu [3]

a GPS/IMU. Systém bol navrhnutý z ohľadom na budúce využitie datasetu KITTY, ktorý takéto riešenie využíva. [7].

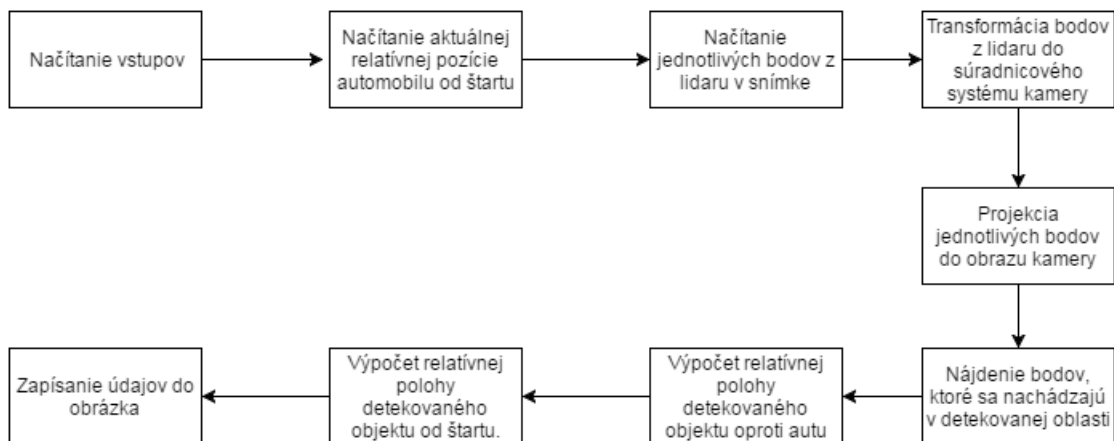
4.2.1 KITTY dataset

KITTY dataset bol vytvorený na Karlsruhe Institute of Technology, pomocou auta na ktorom boli jednotlivé zariadenia umiestnené vid'4.1.Zoznam použitých zariadení [3] :

- 1x interný navigačný systém: OXTS RT 3003
- 1x Lidar Velodyne : HDL-64E
- 2x Čiernobiela kamera : Point Grey Flea 2 (FL2-14S3M-C)
- 2x Farebná kamera: Point Grey Flea 2 (FL2-14S3C-C)

Dataset je zložený z 22 častí. Z toho 11 je určených pre tréning a 11 bez polohy pre vyhodnocovanie. Odometry Dataset je primárne určený pre tvorbu hĺbkových máp. Dataset sa skladá z :


- Obrázky v odtieňoch šedej
- RGB obrázky
- Snímkov z LIDARu
- Kalibračnými súbormi pre každú časť obsahujúcu projekčné matice jednotlivých kamier a transformačnú maticu pre transformáciu bodov zo súradnicového systému LIDARu do súradnicového systému kamery
- Súbormi určujúcimi relatívnu pozíciu auto voči štartu v metroch



Obr. 4.2: Beh programu

4.2.2 Časti lokalizátora


Lokalizátor sa skladá z viacerých častí, pre lokalizáciu objektu je potrebné spraviť viacero úkonov 4.2. Vstupom do programu je XML súbor s názvami snímok, na ktorých bola detekcia úspešná aj so súradnicami, kde sa daný objekt v snímku nachádza. Pre jednotlivé snímky sa načíta relatívna poloha vozidla voči štartu (tvar x, y, z v metroch), orientácia, kalibračný súbor s projekčnými a kalibračnými maticami a súbor obsahujúci mračno bodov nasnímané v čase tvorenia snímku. Následne sa jednotlivé body adresované súradnicovým systémom LIDARu pomocou transformačnej matice transformujú do súradnicového systému kamery podľa vzorca 3.5. Je potrebné spraviť aj otočenie súradníc pretože kamera a LIDAR používajú rozdielne orientácie ôs 4.3. Následne sa jednotlivé body premietnu do



Obr. 4.3: Orientácia súradnic jednotlivých zariadení [3]

scény kamery podľa vzorca pre projekciu. 3.9. Tak ako je vidieť na obrázky 4.4 tak mračno bodov nepokrylo dopravnú značku.

LIDAR HDL-64E má príliš malé zorné pole (2° hore a -24.8° dole [1]) a preto nepokryje značky, 4.6 ktoré sa nachádzajú vyššie ako LIDAR na aute. Takto vysoké značky je možné lokalizovať iba z veľkej vzdialenosti ale tam má problém z detekciou zasa detektor. Tento problém vid. obráok C je čiastočne možné odstrániť premietnutím predchádzajúceho snímku mračna bodov zosnímaného počas jazdy a premietnutím do snímky v aktuálnej polohe vid.



Obr. 4.4: Mračno bodov po projekcii do 2D



Obr. 4.5: Mračno bodov po projekcii po úprave algoritmu.


obrzok 4.5. Takýto bod dostaneme upravením vzorca 3.10 na 4.1

$$P_{2D} = P * (Tr((Ai^{-1} * B[i - x]) * P_{3D}[i - x])) \quad (4.1)$$

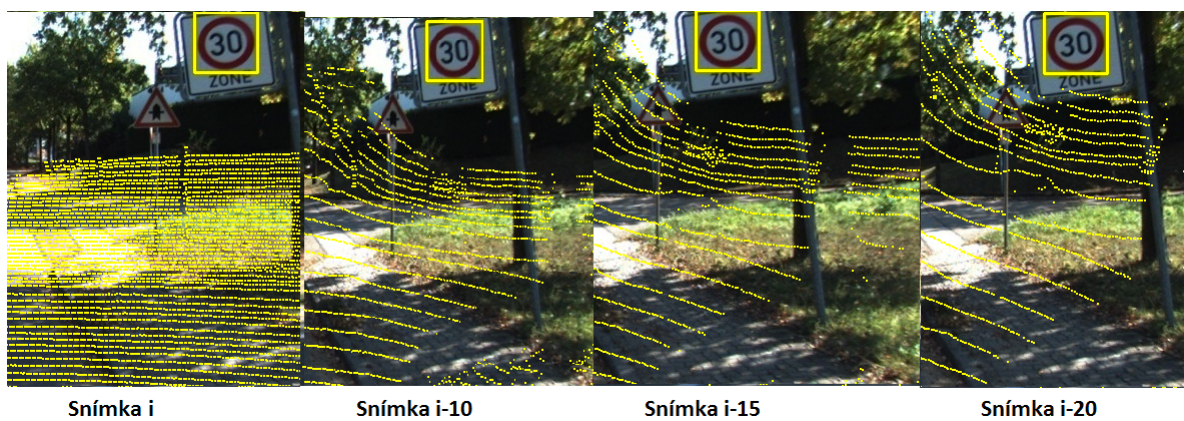
- $Point_{2D}$ - Výsledné súradnice premietnutého bodu.
- P - Projekčná matica
- Tr - Transformačná matica
- Ai^{-1} - inverzia aktuálnej polohy. Invertujeme pretože polohu budeme postupne odčítat.
- $B[i-x]$ - poloha v dobe tvorenia mračna bodov, ktoré projektujeme do snímku v polohe Ai
- $P_{3D}[i-x]$ - bod z mračna bodov v polohe $B[i-x]$.

Je potrebné obmedziť vracanie o veľký počet snímok dozadu z 2 dôvodov. Používaný typ LIDARu má veľmi obmedzený dosah (cca 60m) a ak sa v umiestnení pred tým nachádza nejaká prekážka, ktorá bráni priamemu výhľadu na značku tak bude detekovaná ona. Posledným krokom je vypočítať relatívnu polohu od štartu. Tú dostaneme dosadením do vzorca 4.2.

$$Poloha = PolohaAuta * PolohaZnacky \quad (4.2)$$



Obr. 4.6: LIDAR HDL-64E nedokáže pokryť na malú vzdialenosť objekt výrazne vyšší ako jeho umiestnenie.



Obr. 4.7: Mračno bodov pri projekci predchádzích snímok.

Kapitola 5

Implementácia

V tejto kapitole bude popísaný stručne spôsob ako je implementovaný systém navrhnutý v kapitole vyššie a aké technológie k tomu boli použité.

5.1 Použité technológie

Pre implementáciu som si zvolil jazyk C++ hlavne pre jeho rýchlosť a podporu veľkého množstva knižníc, ktoré výrazne uľahčovali naprogramovanie systému. Naprogramované boli v ňom aj všetky použité už naimplementované komponenty, ktoré som k zloženiu celého systému použil. Systém je implementovaný ako dva samostatné programy : detektor, lokalizátor. V ďalších podkapitolách sú uvedené knižnice, ktoré som použil aj z ich charakteristikou a popisom čo je využitím nich implementované.

5.1.1 OpenCV2

OpenCV je open source multiplatformná knižnica, v ktorej je implementovaných veľké množstvo algoritmov z oboru počítačového videnia. Je veľmi rozšírená a má okolo seba veľkú a aktívnu komunitu. Jej funkcie ju pre prácu z obrázkami ¹.

5.1.2 PCL

Point Cloud je open source knižnica napísaná v jazyku C++. Určená je pre prácu z mračien bodov ². Používam ju pre prácu a operácie nad mračnom bodov z LIDARu.

5.1.3 Eigen

Eigen je open source knižnica napísaná v jazyku C++. Je v nej naimplementovaný veľký počet algoritmov pre lineárnu algebru, geometrické transformácie, maticové a vektorové operácie ³. Využívam ju na všetky operácie s maticami, vektormi a transformácie.

5.1.4 But_velodyne

But velodyne je open source knižnica napísaná v jazyku C++. Určená je pre spracovanie mračien bodov ale implementované sú v nej aj funkcie pre parsovanie dát poskytnutých

¹<http://www.opencv.org>

²<http://www.pointclouds.org>

³<http://www.eigen.tuxfamily.org>

KITTY datasetom ⁴. Používam ju k spracovaniu vstupov z KITTY datasetu, predovšetkým na načítanie jednotlivých bodov z mračna bodov a parsovanie polôh a matic z poses a calib súborov.

5.1.5 TinyXML2

TinyXML2 je open source knižnica napísaná v jazyku C++ určená pre parsovanie a tvorbu XML dokumentov ⁵. Využívam ju na spracovanie XML dokumentu so snímkami z pozitívnu zhodou a polohou detekovaného objektu.

5.2 Detektor

Pre detekciu dopravných značiek som použil program Jakuba Sochora implementovaný v rámci jeho bakalárskej práce [14].

5.3 Lokalizátor

Lokalizátor implementovaný v rámci mojej bakalárskej práce umožňuje lokalizovať objekty, detekované na detektore. Parsuje XML súbor vo formáte ako je na výstupe poskytnutého detektora. Pre jednotlivé snímky s pozitívnym nálezom otvára a parsuje dáta z binárneho súboru na výstupe LIDARu, textových súborov s pozíciami a kalibračných s projekčnými a transformačnými maticami. Do obrázkov značí polohu auta voči štartu a v prípade lokalizácie detekovaného objektu aj jeho polohu.

Pre prácu s parametrami, jednotlivými podadresármi a informáciami o aktuálne rozpracovanom snímku som si definoval vlastné dátové typy.

⁴https://github.com/robofit/but_velodyne_lib

⁵<http://www.grinninglizard.com/tinyxml2/>

Kapitola 6

Dosiahnuté výsledky

V tejto kapitole zhodnotím dosiahnuté výsledky. Detektor dopravných značiek navrhnutý Jakubom Sochorom som nehodnotil nakoľko ho zhodnotil on už vo svojej bakalárskej práci. Pri vyhodnocovaní úspešnosti mnou implementovaného lokalizátora sa zameriam na počet úspešných lokalizácií a na ich správnosť. Analyzujem dosiahnuté výsledky a určím slabé miesta.

6.1 Vyhodnotenie lokalizátora

Vyhodnotenie úspešnosti lokalizátora rozdelím na 2 časti. V prvej časti budem porovnávať úspech/neúspech lokalizácie a v druhej správnosť/ nesprávnosť lokalizácie. Pre vyhodnotenie som používal 2 testovacie sady. Prvá sada sú detekované dopravné značenia pomocou detektora Jakuba Sochora. Druhá sada sú ručne vyznačené rôzne objekty nachádzajúce sa na snímkach. Snímky a aj ostatné dáta pochádzajú z KITTY datasetu.

6.1.1 Úspešnosť lokalizácie


V tejto časti porovnam úspešnosť lokalizácie len na základe úspechu/neúspechu lokalizácie pri obidvoch sadách. Porovnam aj úspešnosť pre algoritmus pred úpravou vracania sa v snímkach pri neúspešnej lokalizácii.

Tabuľka 6.1: Porovnanie úspešnosti lokalizácie

	Počet vzorkov	Úspešnosť bez vracania	Úspešnosť s vracaním
Sada so značkami	76	6,5%	34,2%
Vlastná sada	89	14.6%	39,2%

Podľa nameraných výsledkov zhrnutých v tabuľke 6.1 je vidieť výrazné zvýšenie úspešných lokalizácií objektov po naimplementovaní vracania v snímkach. Väčšia úspešnosť bez vracania v snímkach pri vlastnej sade je kvôli nižšiemu umiestneniu testovacích objektov. Objekty sa nedarilo lokalizovať ak sa nachádzali príliš vysoko alebo v kopci 6.1. Po úprave algoritmu pre vracanie sa v snímkach úspešnosť detekcie vzrástla takmer šesťnásobne.

Veľký rozdiel v úspešnosti rozdielnych verzii programu ukazuje, že výmenou typu LIDARu za model z väčším zorným uhlom by došlo k detekciám už pri prvom snímku a nebolo by potrebné sa v snímkach vracat späť. Prehľadávanie starších snímkov je časovo náročné. Zväčšením úspešnosti pri prvom nalezení by sa výrazne zvýšila rýchlosť lokalizácie.



Obr. 6.1: Mračno bodov pri umiestnení detekovaných objektov v kopci

6.1.2 Správnosť lokalizácie

Nakoľko neexistuje anotovaná sada sledujúca polohu objektov tak je správnosť lokalizácie určovaná len odhadom porovnaním s aktuálnou pozíciou vozidla. Jedná sa o kontroverznú a určite nie presnú metódu určenia, pretože správnosť polohy je posudzovaná subjektívne. Sledovať budem priradené adresy pri rovnakých testovacích sadoch ako v kapitole vyššie.

Tabuľka 6.2: Porovnanie správnosti lokalizácie

	Počet lokalizácií	Správnosť lokalizácie
Sada zo značkami	26	26,9%
Vlastná sada	35	22,8%

Správnosť lokalizácie vyhodnotená v tabuľke 6.2 jasne ukazuje, že vo veľa prípadoch je pridelená adresa zlá. Problém je najmä s x-ovou súradnicou. Často sa líši o veľmi veľké čísla. Analyzovaním jednotlivých prípadov sa mi nepodarilo príčinu zistiť. Niektoré menšie skreslenia mohli vzniknúť kvôli vráteniu o veľký počet snímok dozadu a detekovanie objektu, ktorý stál medzi autom a značkou. Namerané hodnoty môžu byť pri anotovanej sade namerané ešte nižšie.

Kapitola 7

Záver

V mojej práci som mal za cieľ navrhnuť a implementovať jednoduchý detektor a lokalizátor dopravných značiek. Toto sa podarilo splniť. Lokalizácia prebehne v približne 35% detekovaných objektoch. Nanešťastie sa mi nepodarilo dosiahnuť uspokojujúce percento korektných lokalizácií. Výsledný systém je navrhnutý a naimplementovaný tak aby sa dal použiť aj iný detektor alebo pri lokalizátore kvalitnejšia dátová sada nasnímaná najmä LIDARom s väčším zorným polom.

Behom vypracovania som si preštudoval rôzne možnosti detekcie a lokalizácie objektov v obraze. Tieto možnosti som aj popísal a zvažil výhodnosti implementácie rôznych možností. Výsledný systém je naimplementovaný spôsobom, ktorý reflektuje čo najväčšie splnenie jednotlivých požiadavkov. Počas návrhu a implementácie som experimentoval s dielčimi komponentami a výsledkom bolo vylepšenie lokalizátora a dosiahnutie takmer 6-násobne väčšej úspešnosti lokalizácie. Pre lepšie vyhodnotenie úspešnosti som si navrhol a vytvoril vlastnú testovaciu sadu.

Ďalšie možnosti pokračovania práce vidím najmä vo vylepšení presnosti a úspešnosti detekcie. Otestovať systém s viacerými druhmi detektorov nielen dopravného značenia ale aj nad výstupmi iných druhov LIDARov. Vhodné by bolo aj zaobstaráť jednotlivé zariadenia a pokúsiť sa vytvoriť vlastnú anotovanú sadu pre lepšie odladenie systému a vylepšenie úspešnosti.

Literatúra

- [1] *HDL-64E manual*. [Online; navštíveno 2.4.2016].
URL <http://www.velodynelidar.com/lidar/products/manual/HDL-64E%20Manual.pdf>
- [2] *Súčasťi senzora Kinect pre konzolu Xbox 360*. [Online; navštíveno 30.4.2016].
URL <https://support.xbox.com/sk-SK/xbox-360/accessories/kinect-sensor-components>
- [3] *The KITTI Vision Benchmark Sensors*. [Online; navštíveno 17.3.2016].
URL <http://www.cvlibs.net/datasets/kitti/setup.php>
- [4] Crow, F.: "Summed-area tables for texture mapping" in *Proceedings of SIGGRAPH*, 18(3):207-212. 1984.
- [5] Ess, G., Tuytelaars: *Speeded-Up Robust Features SURF*. [Online; navštíveno 12.3.2016].
URL ftp://ftp.vision.ee.ethz.ch/publications/articles/eth_biwi_00517.pdf
- [6] GARCIA-GARRIDO, M.-G., SOTELO: *An algorithm on multi-view adaboost*. Ieee, 2007, ISBN 1424400937.
- [7] Geiger, A.; Lenz, P.; Urtasun, R.: *Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite*. 2012.
- [8] Hartley, R.; Zissermans, A.: *Multiple View Geometry in Computer Vision*. Cambridge University Press, 2004, ISBN 0521540518.
- [9] Korbas, J.: *Lineárna algebra a geometria I*. UK Bratislava, 2003, ISBN 8022317063.
- [10] Lillesand, T.; Kiefer, R. W.: *Remote Sensing and Image Interpretation, 4th Edition*. Academia, 1999, ISBN 0471255157.
- [11] Morvan, Y.: *Acquisition, Compression and Rendering of Depth and Texture for Multi-View Video*. [Online; navštíveno 16.2.2016].
URL <http://www.epixea.com/research/multi-view-coding-thesis.html>
- [12] ROSENFELD, A.: "Connectivity in Digital Pictures" *Journal of the ACM ročník 17, č. 1, Január 1970: s. 146-160, ISSN 0004-5411*.
- [13] Sergi Foix, G. A.; Torras, C.: *Lock-in Time-of-Flight (ToF) Cameras: A Survey*. [Online; navštíveno 8.4.2016].

URL [http://www.iri.upc.edu/files/scidoc/1232-Lock-in-Time-of-Flight-\(ToF\)-Cameras:-A-Survey.pdf](http://www.iri.upc.edu/files/scidoc/1232-Lock-in-Time-of-Flight-(ToF)-Cameras:-A-Survey.pdf)

- [14] Sochor, J.: *Rychlá detekce dopravných značek v obraze*. 2012.
- [15] Zhijie Xu, S. S.: *An algorithm on multi-view adaboost*. Springer, 2010, ISBN 3-642-17536-8.

Prílohy

Zoznam príloh

A	Preklad programu	30
B	Obsah DVD	31
C	Plagát	32

Príloha A

Preklad programu

Pre správny preklad je pogramov je potrebné mať nainštalované knižnice:

1. OpenCV 2.3.1
2. Pcl 1.7.1
3. Eigen 3.2.6
4. Cmake 2.6

Popis použitia jednotlivých komponent je v súbore README alebo pomocou parametru -h
Preklad lokalizátora:

```
cd localizator
cmake .
make
```

Preklad detektora

```
cd sochor_detector
cmake .
make
```

Príloha B

Obsah DVD

K tejto práci je priložené DVD obsahujúce zdrojové kódy systému implementovaného v rámci tejto práce. Na DVD sú nasledujúce zložky:

1. Localizator V tejto zložke sa nachádzajú zdrojové kódy mnou implementovaného lokalizátora vrátane podporných knižnic a testovacích sád spolu s výsledkami
2. Sochor_detector V tejto zložke sa nachádzajú zdrojové kódy detektora implementovaného Jakubom Sochorom
3. Plagat V tejto zložke sa nachádza plagát vytvorení pre prezentáciu tejto práce
4. Bachelor V tejto zložke sa nachádzajú zdrojové texty tohto dokumentu a aj jeho verzia identická s odovzdanou do školského systému

Príloha C

Plagát

Detekce a lokalizace dopravních značek
Autor : Ondrej Kudláč Vedúci: Ing. Martin Veľas



Cieľ: Jednoduchý systém pre detekciu a lokalizáciu dopravných značiek

Detekcia: Detektor Jakuba Sochora na základe tvarov

Lokalizácia : Lokalizácia pomocí LIDARu

Uspešnosť : Uspešnosť 10%

