

Ing. Frederik Valocký

Autoreferát dizertačnej práce

**VIZUÁLNY LOKALIZAČNÝ SYSTÉM
PRE AUTONÓMNE VOZIDLÁ**

na získanie

akademickej hodnosti doktor (philosophiae doctor, PhD.)

v doktorandskom študijnom programe: Mechatronické systémy
v študijnom odbore Kybernetika
forma štúdia: Denná

Miesto a dátum: Bratislava, 22.7.2022

Dizertačná práca bola vypracovaná:**Na:**

Ústave automobilovej mechatroniky
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita v Bratislave
Ilkovičová 3, 812 19, Bratislava

Predkladateľ:

Ing. Frederik Valocký
Ústav automobilovej mechatroniky
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita v Bratislave
Ilkovičová 3, 812 19, Bratislava

Školiteľ:

doc. Ing. Oto Haffner, PhD.
Ústav automobilovej mechatroniky
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita v Bratislave
Ilkovičová 3, 812 19, Bratislava

Oponenti:

doc. Ing. Rastislav Pirník, PhD.
ŽILINSKÁ UNIVERZITA V ŽILINE
Fakulta elektrotechniky a informačných technológií,
Katedra riadiacich a informačných systémov
Žilinská univerzita
Univerzitná 8215/1, 010 26 Žilina

prof. Ing. Štefan Kozák, PhD
Fakulta informatiky
Paneurópska vysoká škola
Tematínska 10, 851 05 Bratislava



SLOVENSKÁ TECHNICKÁ
UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY
A INFORMATIKY

Autoreferát bol rozoslaný dňa:

Obhajoba dizertačnej práce sa bude konať dňa **o** **hod. na**
Fakulte elektrotechniky a informatiky STU v Bratislave, Ilkovičova 3, 812 19 Bratislava, v
miestnosti

Prof. Dr. Ing. Miloš Oravec
dekan fakulty
Fakulta elektrotechniky a informatiky
Slovenská technická univerzita v Bratislave

SÚHRN

SLOVENSKÁ TECHNICKÁ UNIVERZITA V BRATISLAVE
FAKULTA ELEKTROTECHNIKY A INFORMATIKY

Študijný program :	Mechatronicke systémy
Študijný odbor:	Kybernetika
Dizertačná práca:	Vizuálny lokalizačný systém pre autonómne vozidlá
Autor:	Ing. Frederik Valocký
Vedúci záverečnej práce:	doc. Ing. Oto Haffner, PhD.
Miesto a rok predloženia práce:	Bratislava 2022

Abstrakt:

Kľúčovou technológiou pre lokalizáciu autonómnych vozidiel sa často používa GPS GNSS (GPS, GLONASS, Galileo, Beidou) v kombinácii s IMU (Inertial Measuring Unit) a odometriou. GNSS môže poskytovať globálnu, vysoko presnú službu určovania polohy, ale v dôsledku orbitálnej chyby satelitu, chyby časovania s vplyvom chýb šírenia signálu a pod. V práci bude opísaný návrh riešenia, ktorý bude pozostávať z kamerového systému, ktorý kontinuálne bude snímať vozovku a jeho úlohou bude rozpoznáť značku - identifikátor umiestnený na vozovke. Následne zo získaných obrazových dát bude určená vzdialenosť medzi identifikátorom a kamerovým senzorom resp. vozidlom. Vďaka známej absolútnej polohe cestných identifikátorov je možné získať zvýšenú presnosť polohy vozidla aj pri zhoršených podmienkach pre prenos signálu z GNSS a korekciu integrovanej chyby z odometrie vozidla.

Kľúčové slová:

autonómne vozidlo, vizuálny systém, lokalizačný systém, kamerový systém, cestný identifikátor

ABSTRACT

SLOVAK UNIVERSITY OF TECHNOLOGY IN BRATISLAVA
FACULTY OF ELECTRICAL ENGINEERING AND INFORMATION
TECHNOLOGY

Study programme:

Mechatronic systems

Study field:

Cybernetics

Dissertation Thesis

Visual localization system for
autonomous vehicles

Author:

Ing. Frederik Valocký

Supervisor:

doc. Ing. Oto Haffner, PhD.

Place and year of submission:

Bratislava 2022

Abstract:

GPS GNSS (GPS, GLONASS, Galileo, Beidou) in combination with IMU (Inertial Measuring Unit) and odometry is often used as the key technology for the localization of autonomous vehicles. GNSS can provide a global, high-precision positioning service, but due to satellite orbital errors, timing errors with the influence of signal propagation errors, etc. The work will describe the proposed solution, which will consist of a camera system that will continuously scan the road and its task will be to recognize the mark - the identifier placed on the road. Subsequently, the distance between the identifier and the camera sensor or by vehicle. Thanks to the known absolute position of road identifiers, it is possible to obtain increased accuracy of the vehicle's position even in poor conditions for signal transmission from GNSS and correction of the integrated error from vehicle odometry.

Keywords:

autonomous vehicle, visual system, localization system, camera system, road identifier

OBSAH

ÚVOD.....	7
1 SÚČASNÝ STAV PROBLEMATIKY	9
2 DEFINÍCIA PROBLÉMU A CIELE DIZERTAČNEJ PRÁCE	14
3 NÁVRH A REALIZÁCIA MOBILNEJ TESTOVACEJ PLATFORMY ..	16
3.1 MOPASv1.....	16
3.2 MOPASv2.....	18
4 NÁVRH VIZUÁLNEHO SYSTÉMU S MOPASv1.....	21
4.1 IN-SIGHT EPLORER.....	21
4.2 KALIBRÁCIA VIZUÁLNEHO SYSTÉMU	21
4.3 MERANIA A EXPERIMENTY	23
4.4 VÝSLEDKY PREPOČTU PÍXELOV NA MILIMETRE.....	24
4.5 PRENOS DÁT Z KAMERY DO POČÍTAČA	24
4.6 POROVNANIE RÝCHLOSTÍ ROZPOZNÁVANIA ZÁKLADNÝCH GEOMETRICKÝCH ÚTVAROV	25
4.7 DIZAJN R-ID	27
5 NÁVRH A TESTOVANIE MODELU PRE ROZPOZNÁVANIA	
CESTNÉHO IDENTIFIKÁTORA	29
5.1 PRIEBEH A POSTUP TRÉNOVANIA	29
5.2 KALIBRÁCIA KAMERY	33
5.3 PRÍPRAVA POSTUPU MERANIA	34
6 EXPERIMENTÁLNE OVERENIE IMPLEMENTÁCIE NAVRHNUTEJ	
METÓDY ROZPOZNÁVANIA CESTNÉHO IDENTIFIKÁTORA	36
7 ZHODNOTENIE MERANÍ	40
ZÁVER.....	41
PUBLIKAČNÁ ČINNOSŤ AUTORA.....	44
ZOZNAM POUŽITEJ LITERATÚRY.....	47

Úvod

V posledných rokoch sme svedkami obrovského pokroku v oblastiach súvisiacich s umelou inteligenciou ako je strojové učenie, počítačové videnie a autonómne vozidlá. Výnimkou v pokroku nezostali ani osobné vozidlá, predovšetkým rodinné automobily, ktoré sú neodmysliteľnou súčasťou každodenného života v rozvinutých krajinách po celom svete. Mnoho výrobcov automobilov ponúka na trhu vozidlá, ktoré sú vybavené asistenčnými systémami pre uľahčenie jazdy vodičom. Počnúc automatickými parkovacími asistentami, ktoré využívajú ultrazvukové senzory na detekciu vhodného parkovacieho miesta, až po asistované zaparkovanie vozidla bez nutnosti zásahu vodiča. Vozidlá s adaptívnym tempomatom zase udržia vhodnú vzájomnú vzdialenosť medzi vozidlami v závislosti od rýchlosti vozidla idúcim pred ním a krízovo zabrzdíť aby sa predišlo vzájomnej kolízii. Kamerové systémy umožňujú udržať vozidlo v jazdnom pruhu, rozpoznať dopravné značky a semaforey či detegovať objekty a prekážky. Fúzia dát z týchto senzorov umožňuje priblížiť automobily k autonómnej jazde.

Medzi neodmysliteľnú súčasť moderného automobilu patrí aj navigácia vozidla. Aktuálnym štandardom výbavy je modul spolupracujúci s globálnym družicovým navigačným systémom (GNSS). Tento modul umožňuje určiť polohu vozidla, vďaka čomu sú tieto dáta využívané aj v úlohách navigácie. Kontinenty ako Ázia, Európa a Severná Amerika majú svoje vlastné navigačné systémy. Navstar GPS v Severnej Amerike, Galileo a Doris v Európe a BeiDou-3 spolu s Glonass v Ázii. Ďalším významným a rýchlo sa rozvíjajúcim systémom využívaným vo vozidlách je vizuálny systém. Vizuálne kamerové systémy sú do vozidiel inštalované z viacerých dôvodov. Tým hlavným je využitie tohto systému na rozpoznávanie objektov v kombinácii s počítačovým videním. Tento rozpoznávaný objekt môže reprezentovať iné vozidlo, dopravné značenie, chodca alebo cyklistu čakajúceho na prechode. Vizuálny systém je jedným z najvýznamnejších prvkov pre úlohy autonómneho riadenia a navigácie vozidla bez nutnosti zásahu či dokonca prítomnosti šoféra vo vozidle.

V tejto práci bude kamerový systém využitý primárne na zvýšenie presnosti lokalizácie autonómneho vozidla. Využívať sa bude elektrické vozidlo, ktoré je vyvíjané v rámci projektu APVV-17-0190 na Ústave automobilovej mechatroniky FEI STU. Pri určovaní polohy vozidla má najväčšiu váhu informačný údaj z GNSS modulu, ktorý je určený práve na lokalizáciu. Avšak nie všade je možné prijímať GNSS signál tak aby spĺňal podmienky pre dostatočne kvalitné určenie polohy. Medzi tieto miesta patria napríklad aj tunely, vysokohorské oblasti, kde pohoria blokujú signál z družice alebo aj kryté výrobné haly a parkovacie domy. V týchto miestach sa lokalizácia môže

spoliehať na iné princípy lokalizácie napr. odometriu, kde však vzniká riziko integrácie chyby a nepresnej lokalizácie vozidla. Tieto skutočnosti otvárajú priestor pre výskum a vývoj nových metód a systémov zameraných na zvýšenie presnosti lokalizácie vozidiel.

V práci bude opísaný kamerový systém, ktorý bude snímať značku, ktorá upresní polohu vozidla. Preto je nutné zaoberať sa aj návrhom tohto identifikátora aby bol čo najlepšie a najrýchlejšie rozpoznateľný. Návrh bude pozostávať s rôznych testov v závislosti od rotácie, tvaru a veľkosti možného identifikátora. Taktiež identifikátor alebo neskôr v práci nazývaný R-ID (Road-Identifier) musí byť čo najmenej možné zameniteľný s objektami a vzormi, ktoré sú už aktuálne na vozovke.

V prvej kapitole sa pojednáva o súčasnom stave problematiky, ktorý ponúka prehľad riešení zameraných na lokalizáciu mobilných robotických systémov a vozidiel. Spracované boli ako vedecké práce a články tak aj patentové spisy Európskej patentovej organizácie.

Druhá kapitola je venovaná definícii problému, ktorý vychádza z poznání uvedených v prvej, druhej a tretej kapitole. Po definícii problému vytyčujeme ciele dizertačnej práce.

Tretia až siedma kapitola je ťažiskom dizertačnej práce a opisuje výsledky dizertačnej práce. Tretia kapitola sa venuje návrhu a realizácii mobilnej testovacej platformy MOPAS. Kapitola štyri sa venuje návrhu vizuálneho systému s využitím mobilnej testovacej platformy MOPAS. Piata kapitola pojednáva o návrhu a testovaní modelu pre rozpoznávanie cestného identifikátora. V šiestej kapitole je predstavené experimentálne overenie implementácie navrhutej metódy rozpoznávania cestného identifikátora a v siedmej kapitole sú tieto merania diskutované.

V závere diskutujeme ďalšie možnosti rozvíjania danej problematiky a uvádzame význam výsledkov dizertačnej práce v príslušnom odbore.

1 Súčasný stav problematiky

Nasledujúca kapitola ponúka prehľad riešení zameraných na lokalizáciu mobilných robotických systémov a vozidiel. Zamerali sme sa na rešerš ako vedeckých prác a článkov tak aj patentových spisov Európskej patentovej organizácie. Mnohé vedecké práce sú zamerané na lokalizáciu mobilných robotických systémov. V týchto prácach možno nájsť mnohé podnetné postupy vhodné pre aplikáciu do autonómnych vozidiel. Pri skúmaní patentových spisov sme sa zamerali na metódy a spôsoby pre vizuálnu lokalizáciu autonómnych vozidiel a zvyšovania presnosti lokalizácie autonómnych vozidiel.

Príspevok [1] predstavuje systém referenčných značiek špeciálne vhodný na odhad polohy kamery v aplikáciách, ako je rozšírená realita a lokalizácia robotov. Autori najskôr navrhli algoritmus na generovanie konfigurovateľných slovníkov značiek (veľkosť a počet bitov) podľa kritéria maximalizácie vzdialenosti medzi značkami a počtu bitových prechodov. V tomto procese odvodili maximálnu teoretickú vzdialenosť medzi značkami, ktorú môžu mať slovníky štvorcových binárnych značiek. Po druhé, navrhli metódu pre automatickú detekciu značiek a opravu možných chýb. Po tretie, autori uvádzajú riešenie problému s oklúziou (prekrytím) v aplikáciách rozšírenej reality. Za týmto účelom sa kombinuje viac značiek s oklúznou maskou vypočítanou podľa farebnej segmentácie.

V článku [2] bol opísaný systém SLAM (Simultaneous localization and mapping), ktorý sa všeobecne používa pomocou prírodných orientačných bodov, ako sú kľúčové body alebo textúra, predstavuje však určité obmedzenia, napríklad potrebu dostatočne štruktúrovaného prostredia a vysoké výpočtové nároky. V niektorých prípadoch je lepšie obetovať flexibilitu týchto metód na zvýšenie rýchlosti a odolnosti pomocou umelých orientačných bodov.

Autori nadviazali na ich predchádzajúcu prácu [3], v ktorej navrhli off-line metódu na získanie mapy štvorcových planárnych markerov vo veľkých vnútorných prostrediach. Voľným rozmiestnením sady značiek vytlačených na kúsok papiera metóda odhaduje polohy značiek zo sady obrázkov za predpokladu, že v každom obraze sú viditeľné najmenej dve značky. Potom je možné vykonať lokalizáciu kamery v správnom meradle. Offline proces má však niekoľko obmedzení. Po prvé, chyby nemožno zistiť, kým sa nedokončí celý proces, napr. Nedostatočný počet značiek v scéne alebo značky, ktoré nie sú správne zaznamenané v etape snímania. Po druhé, metóda nie je prírastková, takže v prípade potreby rozšírenia mapy je potrebné celý proces opakovať od začiatku. Nakoniec túto metódu nemožno použiť v systémoch v

reálnom čase s obmedzenými výpočtovými prostriedkami, ako sú napríklad mobilní roboti alebo UAV (Unmanned aerial vehicle).

V článku [4] autori riešili problém s detekciou markerov. Jedná sa o časovo náročný proces, najmä ak narastá rozmer snímaného obrazu. Moderné vizuálne senzory sú schopné získavať obrazy s vysokým rozlíšením, ale systémy referenčných značiek nie sú prispôbené z hľadiska výpočtovej rýchlosti. Ich príspevok preto navrhuje viacúrovňovú stratégiu na urýchlenie detekcie markerov vo videosekvenciách „smart“, výberom najvhodnejšej škály na detekciu, identifikáciu a odhad rohu.

Autori v príspevku [5] riešia problém s nepresným čítaním štvorcových lokalizačných značiek a navrhuje metódu na dôkladnú detekciu tohto typu orientačných bodov za náročných obrazových podmienok prítomných v realistických scenároch. V článku je opísané, že v tomto probléme možno klasifikátor trénovať pomocou výlučne syntetických údajov, pričom vykazuje dobré výsledky v reálnych a náročných podmienkach. Autori testovali rôzne typy klasifikátorov, aby sa potvrdila platnosť ich návrhu (konkrétne Multilayer Perceptron (MLP), Convolutional Neural Network (CNN) a Support Vector Machine (SVM)), a boli vykonané štatistické analýzy za účelom dosiahnuť najlepší prístup k problému s čítaním značiek. Nakoniec boli získané klasifikátory porovnané so systémami referenčných značiek ArUco a AprilTags v náročných videosekvenciách.

V príspevku [6] skúmajú autori systém samo-lokalizácie mobilného robota založený na duálnych značkách, ktoré sú umiestnené na strope. Autori preskúmali možnosť realizácie lacného a jednoduchého navigačného systému založeného na pasívnych duálnych značkách, ktoré sú schopné viesť autonómneho mobilného robota po vopred určenej ceste. V ich článku sa prezentuje sa návrh značky založenej na tvare kruhu. Pomocou nízko nákladovej webovej kamery a vhodného algoritmu detekcie značiek sa určujú tri funkcie: poloha robota, nový smer pohybu a ID značky.

Autori v článku [7] predstavujú metódu lokalizácie mobilných robotov s využitím umelých značiek nasadených do prostredia. Špecialitou značiek je, že polohu a rotáciu kamery vo vzťahu k značke je možné určiť iba z jednej značky. Ďalej sú v článku popísané niektoré experimenty.

V článku [8] je predstavený ChromaTag, referenčný marker a detekčný algoritmus navrhnutý na použitie prevrátených farieb na obmedzenie a rýchle zamietnutie počiatočných nesprávnych detekcií v šedej farebnej škále odtieňov pre presnú lokalizáciu. Ukázali tiež, aký vplyv má veľkosť značky na presnosť detekcie smeru sledovania.

Autori v príspevku [9] predstavili schému vlastnej lokalizácie navigácie mobilných robotov v interiéroch založenú na spoľahlivom dizajne a rozpoznávaní umelých vizuálnych orientačných bodov. Každý orientačný bod je vzorovaný sadou čiernych a bielych sústredných krúžkov, ktoré spoľahlivo kódujú identitu orientačného bodu pod osvetlením prostredia. Mobilný robot v navigácii používa na snímanie orientačných bodov v prostredí palubnú kameru. Orientačné body v obraze sa detegujú a identifikujú pomocou algoritmu rozpoznávania dvoch vrstiev: Proces globálneho rozpoznávania spočiatku extrahuje kandidátske oblasti orientačných bodov na celý obraz a snaží sa identifikovať dostatok orientačných bodov; ak je to potrebné, proces miestneho rozpoznávania lokálne zvyšuje tie neidentifikované oblasti záujmu ovplyvnené osvetlením a neúplnosťou a znovu ich identifikuje. Rozpoznané orientačné body sa používajú na odhad polohy a orientácie palubnej kamery v prostredí na základe geometrického vzťahu medzi obrazom a snímkami prostredia.

Tento článok [10] si kladie za cieľ zvýšiť presnosť lokalizácie mobilného robota pomocou vizuálneho systému. Mobilný robot fotografuje prostredie obsahujúce umelé značky. Jednou z úloh bola aj tvorba značiek. Značky možno použiť v interiéri a sú umiestnené na strope, kde je malý počet ďalších rušivých prvkov. Sú navrhnuté tak, aby dokázali rozdeliť každú značku na dve časti - jedna je nemenná a druhá sa s každou značkou mení. To poskytuje ľahkú segmentáciu všetkých značiek a potom ich tiež ľahko rozlišuje. Lokalizácia je založená na zmenách uhla a polohy značiek v získaných obrázkoch. Posledná časť práce sa venuje implementácii vizuálneho systému a fúzii odometrie.

V štúdií [11] autori uviedli obrazový rámec lokalizácie 3D objektov na báze plochého povrchu. Pre lokalizáciu navrhli dve metódy detekcie objektov, ArPico a PicPose. ArPico deteguje a rozpoznáva zarámované obrázky tým, že ich prevádza do binárnych kódov značiek pre zhodu so známymi kódmi v knižnici. Potom pomocou rohových bodov na okraji obrázka identifikuje pózu fotoaparátu v 3D priestore. Metóda PicPose deteguje obrazový rovinný povrch objektu v zobrazení kamery a vytvára výstup pózy porovnaním bodových prvkov v zobrazení s bodmi na pôvodnom obrázku a vytvorením homografie na mapovanie skutočnej polohy objektu na 3D mapu reálneho sveta. Postavili autonómneho pohyblivého robota, ktorý sa dokáže lokalizovať pomocou svojej palubnej kamery a technológie PicPose.

V práci [12] autori predstavili rýchly a presný softvér založený na počítačovom videní určený na lokalizáciu viacerých robotov. Základnou súčasťou softvéru je nový a efektívny algoritmus na detekciu čiernobielych vzorov. Ich metóda je odolná voči rôznym svetelným podmienkam.

Príspevok [13] navrhuje spoľahlivý a priamy prístup k mobilným robotom (alebo pohybujúcim sa objektom všeobecne) k vnútornému sledovaniu, aby bolo možné vykonať predbežnú štúdiu ich dynamiky. Hlavnými vlastnosťami tohto prístupu je jeho minimálne a lacné nastavenie a užívateľsky prívetivá interpretácia údajov generovaných knižnicou ArUco. Použitím bežne dostupnej kamery, ako je napríklad smartphone alebo webová kamera, a aspoň jednej značky pre každý objekt, ktorý je potrebné sledovať, je možné odhadnúť polohu týchto značiek vzhľadom na referenciu vhodne umiestnenú v prostredí s cieľom dosiahnuť výsledky, ktoré sú ľahko interpretovateľné používateľom. Tento príspevok predstavuje jednoduché rozšírenie knižnice ArUco na generovanie takýchto užívateľsky prívetivých údajov a poskytuje analýzu výkonu tejto aplikácie so statickými a pohybujúcimi sa objektmi, pričom na zvýraznenie najpozoruhodnejšej črty tohto riešenia, ale tiež obmedzenia.

V dokumente [14] sú poskytnuté systémy a spôsoby na ovládanie vozidla. V jednom uskutočnení spôsob zahŕňa: prijímanie údajov o orientačnom bode získaných z obrazového snímača vozidla procesorom; fúzovanie údajov o orientačnom bode pomocou procesora s údajmi o polohe vozidla na vytvorenie fúzovaných údajov o jazdnom pruhu, pričom fúzovanie je založené na Kalmanovom filtri; získavanie, pomocou procesora, mapových údajov z mapy jazdných pruhov na základe údajov o polohe vozidla; selektívna aktualizácia mapy jazdných pruhov procesorom na základe zmeny údajov spojených jazdných pruhov z údajov mapy; a riadenie vozidla procesorom na základe aktualizovanej mapy jazdných pruhov.

Dokument [15] opisuje rôzne techniky na použitie v inerciálnom navigačnom systéme s podporou vizuálneho systému. 1. Inerciálny navigačný systém s podporou vizuálneho systému, ktorý obsahuje: obrazový zdroj, ktorý generuje obrazové dáta obsahujúce množstvo obrazov; a inerciálnu meraciu jednotku (IMU), ktorá vytvára údaje o inerciálnej meracej jednotke indikujúce pohyb vizuálne podporovaného inerciálneho navigačného systému, keď vizuálne asistovaný inerciálny navigačný systém generuje obraz, pričom obrazové údaje zachytávajú znaky externého kalibračného cieľa. Inerciálny navigačný systém s podporou videnia ďalej obsahuje jednotku spracovania vrátane odhadovača, pričom jednotka spracovania zahŕňa spracovanie údajov inerciálnej meracej jednotky a obrazových údajov na výpočet kalibračných parametrov pre inerciálny navigačný systém s podporou videnia pri výpočte náklonu a sklonu kalibračného cieľa, pričom kalibračné parametre definujú relatívne polohy a orientácie inerciálnej meracej jednotky a zdroja obrazu inerciálneho navigačného systému s podporou videnia.

Spôsob pre systém riadenia vozidiel s kamerou s perspektívnym videním generujúcou perspektívne obrazy vozidiel v smere premávky, vrátane vykonávania antiperspektívnej transformácie na perspektívnych obrazoch je prezentovaný v dokumente [16]. Metóda rozdeľuje každý antiperspektívny obraz na čiastkové obrazy pozdĺž jedného z radiálneho smeru a tangenciálneho smeru vzhľadom na smer dopravy a určí mierkový faktor pre každý čiastkový obrázok na základe merania mierky každého vozidla na viacerých pozíciách na jednom obrázku použitím metódy rámcového rozdielu. Následne sa vykonaná transformácia mierky pre každý čiastkový obrázok použitím zodpovedajúcich mierkových faktorov pre čiastkový obrázok. Kombináciou každého z mierkových transformovaných čiastkových obrázkov pre každé vozidlo do zodpovedajúcich vylepšených antiperspektívnych obrázkov je následne možné vykonať detekciu vozidla pre každé vozidlo na základe kombinácie vylepšených antiperspektívnych obrázkov, v ktorých je sledovanie vylepšené optimalizovaným rozsahom veľkosti detekčného boxu určeného vylepšenými antiperspektívnymi obrazmi. Potom je možné sledovať vozidlo pre každé vozidlo na základe kombinácie vylepšených antiperspektívnych obrazov, v ktorých je detekcia vylepšená s optimalizovaným rozsahom veľkosti detekčného boxu určeného vylepšenými antiperspektívnymi zobrazeniami.

Dokument [17] opisuje spôsob lokalizácie vozidla. Vozidlo senzoricky deteguje prvé okolité objekty. Lokalizácia vozidla je potom realizovaná zosúladením údajov senzoricky zistených prvých okolitých objektov s mapovými údajmi prvej digitálnej mapy. Ak toto zosúladenie nie je možné, vytvorí sa druhá digitálna mapa pre lokálne okolie a poloha vozidla sa určí použitím podľa druhej digitálnej mapy.

Vynález z dokumentu [18] sa týka druhu bezpilotnej automobilovej navigácie a zlepšenie presnosti určovania polohy zlučenej na základe GNSS a vizuálnej odometrie (VO). Kroky vizuálnej odometrie sú nasledovné: (1) detekcia jazdného pruhu na základe monokulárneho videnia; optimalizácia presnosti polohovania počítadla kilometrov pre monokulárne videnie; (3) korekcia presnosť polohovania integrovaného navigačného systému GNSS a vizuálnej odometrie. Predložený vynález zlepšuje vizuálnu odometriu pomocou čiary jazdného pruhu, potom sa zlúči s určovaním polohy GNSS, aby sa zlepšila spoľahlivosť systému určovania polohy vozidla. GNSS/VO má veľmi silnú doplnkovú charakteristiku, GNSS môže získať dlhodobu stabilnú výsledok určovania polohy a VO môže získať krátkodobé vysoko presné údaje polohy. Výpočet je filtrovaný rozdielom meraní polohy pomocou dvoch druhov snímačov.

2 Definícia problému a ciele dizertačnej práce

Kľúčovou technológiou pre lokalizáciu autonómnych vozidiel sa často používa GPS GNSS (GPS, GLONASS, Galileo, Beidou) v kombinácii s IMU (Inertial Measuring Unit) a odometriou. GNSS môže poskytovať globálnu, vysoko presnú službu určovania polohy, ale v dôsledku orbitálnej chyby satelitu, chyby časovania s vplyvom chýb šírenia signálu a pod. dokáže presnosť určovania polohy pomocou GNSS dosiahnuť iba úroveň 1 metra. Pre zlepšenie presnosti určovania polohy pre účely navigácie sa často do výpočtov integruje informácie o polohe z iných snímačov. Napríklad presné určenie polohy použitím INS je zaťažené integračnou chybou, ktorá s časom narastá a stáva sa tak nevhodné pre samostatné použitie v autonómnych vozidlách.

Novosť navrhutej metódy pre zvýšenie presnosti lokalizácie autonómneho vozidla bude spočívať je v použití monokulárnej kamery na vozidle pre snímánie polohy cestného identifikátora (R-ID) na dráhe pred vozidlom za účelom vyhodnotenia relatívnych súradníc R-ID ku vozidlu. R-ID má vopred známu, kalibrovanú polohu v globálnych súradniciach v globálnej mape uloženej v riadiacom počítači. Pomocou kamery a spracovania obrazu sa získajú presné globálne súradnice vozidla za pohybu. Tento originálny senzorický systém bude poskytovať globálnu polohu pre navigáciu autonómnych vozidiel vo vonkajšom aj vnútornom prostredí (outdoor + indoor). Na rozdiel od GNSS (GPS, Galileo,...) meria globálnu polohu aj v „satelitnom tieni“ budov, prístreškov alebo priamo v budovách. Navrhovaný spôsob zvýšenia presnosti lokalizácie pomocou kamerového systému je využiteľný pre všetky autonómne vozidlá a transportné systémy, ktoré potrebujú automatickú navigáciu a presné riadenie po určenej dráhe na cestách alebo obslužných plochách (logistické centrum, výrobný areál, rekreačný areál, letisko a pod.) alebo v budovách ako sú výrobné haly, sklady, hangár a pod.

Aktuálny rešerš ukázal, že nie sú realizované systémy, ktoré by dokázali lokalizovať vozidlo pomocou jedného kamerového snímača s vysokou presnosťou, resp. by umožňovali zvýšenie presnosti lokalizácie vozidla. Za vysokú presnosť sa v našom prípade považuje presnosť v rozsahu do 10 centimetrov. Zmyslom pridania vizuálneho systému je hlavne to, že GNSS pri bežnom pohybe vozidla nedokáže určovať polohu v desiatkach centimetrov. Staticky dokáže GNSS zamerať presnú polohu s presnosťou 2,5 cm (podľa našich meraní), avšak tento údaj je za ideálnych podmienok. Naš systém jednej kamery by mal byť určený do prostredí kde GNSS má veľmi výrazné odchýlky alebo stratu signálu.

Ciele práce možno zhrnúť do nasledovných bodov:

1. Návrh metódy spresnenia lokalizácie autonómneho vozidla
 - Návrh spôsobu lokalizácie vozidla na základe rozpoznávania cestného identifikátora s presne definovanou polohou s využitím vizuálneho systému
 - Návrh vhodnej cestnej značky (R-ID)
 - Návrh výpočtu vzdialenosti medzi vizuálnym senzorom a identifikátorom R-ID
 - Návrh rozpoznávania R-ID v reálnom čase pomocou moderných klasifikačných modelov
 - Návrh mobilnej testovacej platformy pre experimentálne overenie navrhnutých metód
2. Implementácia navrhnutých metód lokalizácie vozidla
 - Vytvorenie vlastného jedinečného datasetu obrázkov navrhnutého cestného identifikátora R-ID
 - Natrénovanie modelov pre konvolučnú neurónovú sieť a pre HAAR kaskádový kvalifikátor
 - Realizácia kalibračného postupu vizuálneho systému pre určenie vzájomnej polohy vozidla a cestného identifikátora.
 - Realizácia mobilnej testovacej platformy
3. Overenie
 - Experimentálne testovanie a overenie navrhutej metódy spresnenia lokalizácie vozidla na báze cestného identifikátora a vizuálneho
 - Vyhodnotenie dát z experimentálneho testovania

3 Návrh a realizácia mobilnej testovacej platformy

Inovačným cieľom dizertačnej práce bude navrhnuť a realizovať vizuálny lokalizačný systém pre autonómne vozidlo. V záujme vysokej spoľahlivosti a funkčnej bezpečnosti využívajú autonómne vozidlá viaceré - redundantné senzorické systémy za účelom vyhodnotenia polohy a orientácie vozidla. Inovatívny prístup predstavuje snímanie špeciálnych cestných značiek (cestné identifikátory – R-ID) umiestnených na predpokladanej dráhe, ktoré majú vopred určenú (presnú, kalibrovanú) globálnu polohu (GPS) vloženú do navigačnej mapy. Úlohou navrhovaného vizuálneho lokalizačného systému s kamerou umiestnenou na vozidle je snímať tieto cestné značky R-ID a pomocou metód strojového videnia určiť relatívnu polohu k tejto značke R-ID. Táto úloha je podporovaná z projektu APVV-17-0190: „Vývoj autonómneho vozidla na otvorenej platforme elektromobilu.“ Tento projekt predpokladá použitie štyroch fyzikálne nezávislých senzorických systémov pre lokalizáciu vozidla. Sú to prijímač GNSS (GPS, Galileo,...), odometria, IMU a navrhovaný vizuálny lokalizačný systém, ktoré sa navzájom dopĺňujú a zároveň sú redundantné. V rámci projektu bolo vyvíjané vozidlo určené najmä pre prevádzku a vo vonkajšom prostredí v uzavretých areáloch (letisko, výrobný podnik, logistické centrum, a pod.) ako súčasť „Automatického transportného systému“. Ide o cestné komunikácie, kde sa nenachádzajú jazdné pruhy a zároveň sa predpokladá funkčnosť senzorického systému aj v blízkosti budov a aj s plynulým prechodom do vnútra hospodárskych budov (kde GNSS nefunguje).

Pre návrh, prototypovanie a testovanie senzorických systémov pre autonómne vozidlo bolo vytvorená mobilná laboratórna testovacia platforma pod názvom *mobilná platforma pre autonómne a asistenčné senzorické systémy* (MOPAS) ktoré bolo iteračným postupom zdokonaľované.

3.1 MOPASv1

Prvé odborné skúsenosti s vizuálnou lokalizáciou boli získané experimentovaním s kamerou od výrobcu COGNEX (obr. 4.1), ktorá je primárne určená do priemyselných oblastí na kontrolu produktov a teda je stavaná na to aby údaje o meraní objektov pomocou tejto kamery boli čo najpresnejšie.

Monochromatická kamera COGNEX IS7802 má rozlíšenie 1600x1200 pixelov a počet snímok za sekundu je 53. Ako objektív bol použitý modul automatického zaostrovania s 8 mm objektívom (ISAF-7000-8 mm) a osvetlenie s bielym prstencom LED krytu na ochranu objektívu [19]. Ide o typ tzv. „smart“ kamery, ktorá má zabudovaný mikropočítač pre spracovanie obrazu.



Obr. 4.1 Kamera COGNEX IS-7802 [20]

Program In-Sight Explorer disponuje veľkou knižnicou systémových nástrojov s funkciami pre nájdenie natrénovaných obrazov a vzorov a pre inšpekciu geometrických objektov až po ich identifikáciu a meranie. Príkladom nástrojov sú PatMax, LineMaxTM, OCRMaxTM, IDMaxTM [21]

Keďže bolo potrebné testovať kameru nie len staticky ale aj v pohybe bolo nutné vytvoriť testovacie vozidlo, ktoré spĺňa požiadavky na rýchlosť, nosnosť a ďalšie požiadavky, ktoré simulujú reálne autonómne vozidlo, na ktoré bude systém nasadený.

Pre vytvorenie vozidla sme sa rozhodli použiť podvozok, riadiacu jednotku a elektromotor od výrobcu Traxxas. Konkrétne ide o model Traxxas BigFoot [22]. Konštrukcia modelu testovacieho vozidla je zostrojená z hliníkových profilov od značky MakerBeam. Tieto hliníkové profily majú šírku a výšku 15 mm a obsahujú drážky a na oboch koncoch profilu závit pre možnosti namontovania skrutiek a matiek o veľkosti M3. Prvotnou riadiacou jednotkou, ktorá mala nahradiť originálnu riadiacu jednotku bolo Raspberry Pi model 3B+. V hornej časti vozidla sa nachádzala kamera od spoločnosti COGNEX. Konkrétne išlo o model IS-7802, ktorý bol opísaný vyššie.



Obr. 4.2 Pohľad na MOPASv1 zhora

Ďalej je na vozidle mikrokontroler Arduino a prídavné dosky plošného spoja zabezpečujúce bezdrôtovú komunikáciu a prenos dát s ultrazvukového senzora v prednej časti vozidla do mikropočítača RaspberryPi. Najdôležitejšia je však kamera COGNEX, ktorá je umiestnená v hornej časti vozidla (Obr. 4.2).

3.2 MOPASv2

Po vykonaní prvotných testov boli zistené nevýhody vozidla MOPASv1. Medzi hlavné nevýhody patrila ťažký akumulátor s výstupným napätím 24V. Tento akumulátor napájala mikropočítač RaspberryPi a kameru COGNEX IS 7802.

Ďalšou nevýhodou bolo použitie kamery COGNEX IS 7802. Aj keď algoritmy používané vo firmvéri kamery sú veľmi presné a užitočné pre náš cieľ, jedná sa o uzavreté patentované metódy a teda užívateľovi nie je umožnené preprogramovať alebo inak modifikovať tieto metódy. Taktiež kamera mala len monochromatický snímač. Monochromatický snímač vo svojej podstate nie je problematický, keďže navrhnuté R-ID je čiernobiele, avšak ostatné objekty na vozovke môžu byť farebné čo môže spôsobiť komplikácie v prípadoch, kedy farebný predmet prekryva R-ID. Preto kamera COGNEX IS 7802 bola nahradená kamerou e-con FSCAM CU135 (Obr. 4.3).



Obr. 4.3 Kamera e-con FSCAM CU135


Kamera e-con FSCAM CU135 je zo skupiny USB UVC (USB Video Class) kamier s internou vyrovnávacou pamäťou, ktorá zaisťuje spoľahlivý prenos obrazu cez USB rozhranie. Kamery FrameSafe, obsahujúce patentovanú technológiu FloControl od spoločnosti econ, podporujú prenos snímok cez rozhranie USB UVC. FSCAM_CU135 má 2 Gb DDR3 SDRAM na ukladanie a prístup k snímkam pri veľmi vysokých rýchlostiach. Dokáže uložiť až päť 13 MP (4208 x 3120) nekomprimovaných

snímok bez ovplyvnenia streamovania z kamery. FSCAM_CU135 je 13,0 MP, farebná, USB 3.1 Gen 1 SuperSpeed kamera s konektorom typu C plug and play.

Nakoľko bola zmenená aj kamera a aj bola znížená hmotnosť vozidla rozhodli sme sa použiť ako riadiacu jednotku na spracovanie dát z kamery počítač so vstavaným akumulátorom, ktorý napája zároveň aj kameru. Taktiež bolo na platforme MOPASv2 pridaný senzor 2D LiDAR a GNSS anténa (Obr. 4.4). Na obrázku 4.5 môžete vidieť informácie o rozmeroch zorného poľa kamery.



Obr. 4.4 MOPASv2 (pohľad z boku)




Obr. 4.5 Informácie o rozmeroch zorného poľa z kamery na MOPASv2

4 Návrh vizuálneho systému s MOPASv1

Kamera COGNEX bola zvolená pre rýchle prototypovanie merania vzdialenosti vozidla od cestnej značky, pretože má veľmi kvalitný a široko použiteľný softvér s rýchlou podporou a priateľským konfiguračným prostredím In-Sight Explorer nainštalovaným na počítači, kde sa kamera ovláda.

4.1 In-Sight Explorer

Keďže ďalším predmetom výskumu je pripevnenie kamery na pohybujúce sa vozidlo, bol zostrojený držiak, kde bola kamera uchytená. Bol nasmerovaný pod uhlom 38° , aby zorné pole kamey umožnilo zachytiť a zmerať časť cesty (v našich experimentoch časť podlahy). Obrázok 5.1 je konštrukcia so vzdialenosťami dosahu kamery. Vzdialenosti boli merané od obrazového senzora.




Obr. 5.1 Schéma kamery COGNEX s držiakom

4.2 Kalibrácia vizuálneho systému

In-Sight Explorer ponúka možnosť kalibrovat' obraz pomocou kalibračných prvkov. Táto kalibrácia sa používa hlavne na prepočítanie obrazu tak, aby bol prezentovaný v kolmej projekcii vzhľadom na meraný objekt. To umožňuje previesť pixely na tzv. "Jednotky reálneho sveta" v mm.

Počas kalibrácie boli testované dva typy vzoriek. Oba majú vzdialenosť kalibračných bodov presne 10 mm. Prvým bol bodkovaný začiatočný smer osí x a y (obr. 5.2) a druhým bol šachovnicový vzor so začiatočnými smermi osí x a y (obr. 5.2).



Obr. 5.2 Bodkovaný kalibračný vzor (vľavo) a Šachovnicový kalibračný vzor (vpravo)

Testovaním sa zistilo, že je lepšie použiť šachovnicový vzor, pretože bodkovaný vzor nedokázal identifikovať osi x a y automaticky, ale iba manuálne, zachytil aj malé nečistoty na podlahe ako kalibračné body, čo spôsobilo veľmi nepresné výsledky. Je to pravdepodobne preto, že pri naklonení kamery pod uhlom sa body skresľujú natoľko, že sa nedajú identifikovať.

Po výbere správneho kalibračného obrazca sa začala kalibrácia, kde kamera zachytila 277 kalibračných bodov, ktoré program previedol z pixelov na vyššie spomínanú súradnicu “world-unit”. Príklad prevedených hodnôt je uvedený na obrázku 5.4. Počas kalibrácie sa vypočíta možná chybovosť v pixeloch, aby sa určilo, či je prevod spoľahlivý alebo nie. Pri hodnote medzi 0 a 0,5 pixelov je spoľahlivosť vynikajúca, naša kalibrácia mala priemernú hodnotu chyby 0,173 pixelov, čo je vynikajúca spoľahlivosť. Od 0,5 do 2 je spoľahlivosť okrajová, ďalej od 2 do 5 je slabá a nad 5 je nespoľahlivá. Prevody z pixelov na súradnice reálneho sveta je možné vidieť na Obr. .

Index	Row	Column	World X	World Y
0	487.5	954.8	-100.055	-60.076
1	487.3	940.1	-90.036	-60.024
2	487.1	925.3	-80.012	-60.035
3	486.8	910.5	-69.958	-60.088
4	486.6	895.7	-59.941	-60.121
5	486.4	880.9	-49.961	-60.112
6	486.2	866.2	-39.989	-60.128
7	486.0	851.4	-29.996	-60.206
8	485.8	836.6	-20.002	-60.273

Obr. 5:4 Prevody z pixelov na súradnice v svetových jednotkách

4.3 Merania a experimenty

Meranie vzdialenosti pomocou kamery COGNEX je založené na meraní pixelov medzi dvoma okrajmi objektu. V terminológii strojového videnia je okraj definovaný ako hrana (buď čiara, oblúk alebo kruh) medzi dvoma susednými skupinami pixelov s kontrastnými hodnotami v odtieňoch šedej. Nástroje In-Sight Edge Tools sa používajú na detekciu a spracovanie štatistik o nájdených hranách. Hrany môžu pozostávať z jednej hrany alebo z dvojice hrán, ktoré pozostávajú z dvoch prechodov z tmavej na svetlú alebo zo svetlej na tmavú, ako je znázornené vyššie. Pre presné meranie bol zvolený obdĺžnikový vzor so šírkou 48 cm a výškou 66 cm. vzor pozostával z 1 cm čiernych a bielych štvorcov. Tento vzor bol umiestnený pred kamerou tak, aby stred vzoru bol aj v strede naskenovaného obrazu. Spodná časť vzoru bola teda vzdialená 76 cm od snímачa a horná časť vzoru bola 142 cm od snímачa kamery. No, vo všetkých rohoch tohto vzoru boli 4 merania a počet opakovaných meraní bol 277. Testované bolo správne meranie vzdialenosti, ktorá bola určená na presných 130 mm. Postup merania bol nasledovný. Najprv bolo potrebné určiť okraje ohraničujúce 130 mm.

Na to bola použitá funkcia FindSegment v In-Sight Explorer. Táto funkcia označuje okraje a meria vzdialenosť medzi nimi v pixeloch. Hoci skutočná vzdialenosť bola 130 mm, rozdiely v pixeloch sú veľmi odlišné. Tento rozdiel je spôsobený skreslením v dôsledku naklonenia kamery. Zatiaľ čo bo spodná časť zachytená fotosnímачom je vzdialená 40 cm, teda vrchná časť je od snímачa vzdialená 230 cm. Pomocou Pytagorovej vety $a^2 + b^2 = c^2$, sa získajú aj vzdialenosti medzi senzorom a podlahou. Rozdiel medzi 130 mm v hornej časti vzoru a 130 mm v spodnej časti vzoru je v priemere 44,97 pixelov.

Tab. 1.: Počítané a merané vzdialenosti

Pozícia meraného objektu	Vzdialenosť	
	Vypočítaná [mm]	Namerané [pixel]
Vľavo Hore	129.831	149.079
Vľavo Dole	130.062	203.055
Vpravo Hore	129.988	148.1
Vpravo Dole	129.955	199.66
Priemerná chyba	0.041	

Preto bolo potrebné použiť kalibráciu, ktorá vyrovnala nasnímaný obraz, ako keby bola kamera kolmá na vzor. Potom boli použité konvertované jednotky z pixelov na „svetovú jednotku“ a výsledky môžete vidieť v tabuľke 1.

4.4 Výsledky prepočtu pixelov na milimetre

Po prepočte z pixelov musíme počítať vzdialenosť v milimetroch alebo nejakej spoľahlivej jednotke. Počítalo sa pomocou (5.1). Kde x_1 predstavuje súradnicu riadku koncovkej hrany a x_0 predstavuje súradnicu riadku začiatkovej hrany. Referenčná hodnota všetkých nameraných a spočítaných vzdialeností na rôznych miestach pred kamerou bola 130 mm. S týmto riešením problému s prevodom pixelov z rámu kamery na milimetre v reálnom svete získame presnosť s priemernou chybou 41 μm so vzdialenosťami od 110 cm do 163 cm medzi snímačom fotoaparátu a meraným objektom. Maximálna chyba z meraní bola nameraná v pravom dolnom rohu a rozdiel medzi x_1 a x_0 bol 757 μm .

$$|x_1| - |x_0| \quad (5.1)$$

4.5 Prenos dát z kamery do počítača

Keďže nami používaná kamera Cognex IS7802 podporuje aj FTP protokol, rozhodli sme sa na prenos dát použiť FTP server vytvorený na počítači s operačným systémom Windows 10.

4.5.1 Vytvorenie FTP server

Rozhodli sme sa vytvoriť FTP server na počítači, ktorý je v rovnakej sieti ako kamera. Windows 10 podporuje vytváranie používateľov a serverov na jednom počítači. V prvom rade je potrebné vytvoriť záložku, ktorá bude predstavovať úložný priestor pre dáta. Používatelia budú mať prístup k tejto karte, aby na ňu mohli zapisovať údaje. Ďalším krokom je vytvorenie účtu, ktorý bude mať práva na prístup k záložke. Tento účet predstavuje prihláseného užívateľa s užívateľským menom a heslom pre prístup na FTP server. V tomto nástroji je potrebné pridať svojho nového používateľa a pridať všetky práva (čítanie a zápis).

4.5.2 Konfigurácia FTP prenosu v kamere

Kamera je nakonfigurovaná v In-Sight Explorer, čo je softvér, ktorý kameru ovláda. V tomto softvéri sa nastavujú všetky parametre fotoaparátu a určuje aj to, ktorý obrázok sa má zachytiť a aké parametre uložiť a ďalej spracovať.

V prieskumníkovi prehľadov má používateľ dve možnosti zobrazenia prostredia. Prvým je „EasyBuilder“ a druhým „Spreadsheet“. Keď je funkcia WriteFTP alebo WriteImageFTP nakonfigurovaná, má formát zápisu uvedený vo vzorci 5.2.

WriteFTP(Udalosť, Názov hostiteľa, Používateľské meno, Heslo, Názov súboru, Formát údajov, Reťazec, Pripojiť) (5.2)

Na obrázku 5.5 môžete vidieť príklad, ako sú nami vybrané zapisované dáta len pre jeden typ testovacieho procesu z kamery do PC.

A_RectangleEB-m-mr-rdown-rup – Poznámkový blok				
Súbor Úpravy Formát Zobrazit Pomocník				
----- ľavý horný roh-----				
Pass: 1	Exe. Time: 190.041061	Angle: -2.448685	Scale: 87.356201	Score: 69.749092
Pass: 1	Exe. Time: 191.469070	Angle: -2.483627	Scale: 87.360008	Score: 69.714096
Pass: 1	Exe. Time: 188.499069	Angle: -2.469658	Scale: 87.357521	Score: 69.639526
Pass: 1	Exe. Time: 187.478073	Angle: -2.476646	Scale: 87.362930	Score: 69.787338
Pass: 1	Exe. Time: 188.416046	Angle: -2.462662	Scale: 87.370750	Score: 69.552650
Pass: 1	Exe. Time: 188.636047	Angle: -2.448685	Scale: 87.371605	Score: 69.609406


Obr. 5.5 Formát zápisu dát prijatých z kamery

4.6 Porovnanie rýchlostí rozpoznávania základných geometrických útvarov

Najprv bolo potrebné zistiť, ktorý geometrický útvar je najľahšie rozoznateľný. Počas testovania sa testovali 3 geometrické tvary, a to štvorec, kruh a trojuholník. Každý z týchto geometrických tvarov bol teda vytlačený s veľkosťou 15 cm a hrúbkou strany 1 cm. Tieto tvary boli pripevnené k pevnému povrchu, s ktorým sa pohyboval pred kamerou vo vzdialenosti 2,5 m. Účelom týchto testov bolo zistiť, ktorý odbor pozná najkratšie a tiež nájsť výhody a nevýhody použitia pre každý z obrazcov. Rozhodli sme sa vykonať 3 experimenty pre tieto obrazce. Prvý pokus bol zameraný na rozpoznávanie obrazcov v rôznych polohách pred kamerou. Tieto polohy boli rozložené v celom zornom poli kamery. Druhý pokus bol zameraný na percentuálne prekrytie vzoru, keď je obraz stále rozpoznávaný. 3. experiment bol navrhnutý tak, aby určil, ako čas rozpoznávania ovplyvní rotáciu vzoru pred kamerou. Tieto experimenty sú založené na parametroch, ktoré je možné nastaviť na fotoaparáte, ktorý používame. Medzi tieto parametre patrí napríklad skreslenie obrazu, ak objektív používa efekt rybieho oka. Na to bol zameraný aj prvý test. Ďalším parametrom je uhol rotácie obrazca, pod ktorým musí obrázok rozpoznať, a teda pre každý tvar je potrebné nastaviť uhol podľa strán geometrického útvaru.

4.6.1 Umiestnenie v pohľade kamery – rohy, stred

Pred kamerou boli merané polohy, kam sa budú predmety umiestňovať. Týchto možných polí objektov bolo 9. Môžete ich vidieť na obrázku 5.6.



Obr. 5.6 Rozmiestnenie objektov v zornom poli kamery [23]

V tomto teste je rozhodujúci čas, za ktorý bol obraz rozpoznaný a tiež o koľko bolo potrebné zvýšiť parameter zarovnania obrazu, aby bol rozpoznaný v rohoch šošoviek, kde je obraz skreslený. Vzorový obraz alebo teda natrénovaný obraz bol presne v strede a parametre sa ďalej upravovali tak, aby bol tento obraz rozpoznateľný pre ostatné časti obrazovky. Takto sme dosiahli presnosť, že na akomkoľvek mieste, kde kamera sníma obraz a tento obraz bude rozpoznaný. V tomto teste bolo vykonaných 100 samostatných meraní v každej polohe na 100 rôznych obrázkoch spolu, takže bolo 900 meraní, pre ktoré sme vypočítali priemerný čas rozpoznávania a zostavili graf, pri ktorom poloha trvala dlhšie a pri ktorom čas kratšie.

4.6.2 Percentuálne prekrytie vzoru

V druhom teste bolo nutné zistiť, koľko percent geometrických tvarov sa dá prekryť a napriek tomu ich fotoaparát dokáže rozpoznať. Tento test mal predpokladať, že tieto značky budú umiestnené na ceste. A tak hrozí, že sa môžu čiastočne poškodiť alebo zakryť či znečistiť. V tomto teste bol vzor kalibrovaný presne na stred kamery. Ostatné parametre ako rotácia či percentuálne zväčšenie či zmenšenie obrazu boli nastavené na nulu, aby bol čisto detekovateľný bez akýchkoľvek ďalších parametrov. Toto percento predstavuje premenná nazývaná skóre. Tento test bol vykonaný tak, že vzor so vzorom sa postupne prekryval z každého kardinálneho smeru a ich kombinácie, to znamená, že pre každý vzor bolo 8 testov, ktoré boli spriemerované a posledný údaj v premennom skóre bola najnižšia hodnota, pri ktorej fotoaparát dokáže rozpoznať vzor.

4.6.3 Rotácia vzoru pred kamerou

Ďalším testom bolo určiť čas potrebný na rozpoznanie vzoru, ak sa s ním otáča. Tento test mal určiť, ako uhol a rotácia vzoru ovplyvnia čas rozpoznávania. Tento test bol prevedený tak, že pre každý obrázok ste nastavili uhol potrebný na 100% rozpoznanie obrázka. Pre kruh to bolo 0° , pre obdĺžnik to bolo 90° a pre trojuholník to bolo 120° . Tieto nastavenia sa nastavujú v programe InSight Explorer, ktorý poskytuje ovládanie kamery. V tomto teste bolo použitých dvesto obrázkov pre každý vzor. Každý z týchto obrázkov bol iný a výstupom z rozpoznávania kamery bolo zistiť, ako kamerový systém vníma zmenu uhla pre ďalšie spracovanie obrazu.

Ako bolo zistené kamera absolútne nedokáže rozpoznať rotáciu vzoru. V tomto teste by sa mal graf otáčať tak, aby vytvoril sinusoidu v štvorci a trojuholníku a v kruhu bude rovný.

4.7 Dizajn R-ID

Po testoch sa rozhodlo použiť trojuholník ako najideálnejší tvar na rozpoznávanie navrhnutým vizuálnym systémom. Treba ho však ešte upraviť, aby mohol podávať informácie o rotácii vozidla. Treba myslieť aj na to, že tvar sa bude maľovať na cestu a teda podklad musí pozostávať z jedného kusu. Preto sme tvar upravili do podoby, ako je vidieť na obrázku 5.8.



Obr. 5.8 Reálny R-ID s výškou (vľavo) a s bočným rozmerom (vpravo)

4.7.1 Výsledky meraní

V tejto časti práce bol navrhnutý prototyp jednoduchého cestného identifikátora R-ID, ktorý sa bude ďalej testovať. Využili sme poznatky, ktoré boli merané pomocou kamery COGNEX is7802 kamery, kde sme v testoch zistili, že najnižší čas rozpoznávania je pri geometrickom tvare trojuholníka. V tabuľkách 2, 3 a 4 sú uvedené priemerné časy rozpoznávania z vykonaných meraní.

Tab. 2.: Priemerný čas rozpoznania vzoru pre všetky tri obrazce počas testovania prekrytia

Vzor	Priemerný čas rozpoznania obrazca [ms]
Kruh	72.715
Trojuholník	80.576
Štvorec	87.685

Tab. 3.: Priemerný čas rozpoznania vzoru pre všetky tri obrazce počas testovania rotácie

Vzor	Priemerný čas rozpoznania obrazca [ms]
Kruh	64.427
Trojuholník	138.068
Štvorec	122.263

Tab. 4.: Priemerný čas rozpoznania vzoru pre všetky tri obrazce v závislosti od umiestnenia v zornom poli kamery

Vzor	Priemerný čas rozpoznania obrazca [ms]				
	Horné Rohy	Dolné Rohy	Stred	Stred Vrch/Spodok	Stred Vľavo/Vpravo
Kruh	218.484	219.412	222.980	222.162	224.081
Trojuholník	53.982	51.203	34.406	32.413	39.191
Štvorec	188.914	240.710	78.712	78.252	76.750

Ako vidno z tabuliek, najväčšie rozdiely v rozpoznávaní boli namerané pri testoch, kedy boli maximálne požiadavky na rozpoznávanie, teda rozpoznať vzor v ktorejkoľvek časti naskenovaného obrazu. V ďalších testoch sa bude predpokladať nižší možný uhol. Pri testovaní prekrytia vzoru boli časy relatívne rovnaké, ale treba poznamenať, že pri rozpoznávaní prekrývajúcich sa vzorov bolo najlepšie percento pravouhlého trojuholníka 50,295 (to znamená, že 49,705 % obrazu môže byť zakrytých vzorom), 52,573, čo je prekrytie 47,827 % a so skóre štvorca 54,362 je prekrytie 45,638 %. Preto sme sa rozhodli použiť trojuholník ako R-ID.

5 Návrh a testovanie modelu pre rozpoznávanie cestného identifikátora


Nakoľko máme navrhnutý jednoduchý a jedinečný cestný identifikátor, je potrebné ho rozpoznať pomocou unikátneho modelu rozpoznávania. Po rozpoznaní je nutné zistiť aj polohu v rámci zachyteného obrazu. Prvým pokusom ako zistiť, kde v obraze sa nachádza cestný identifikátor bolo použitím HAAR kaskádového klasifikátora. Tento klasifikátor nám umožňuje rozpoznávať objekty v reálnom čase. Po rozpoznaní objektu je nutné určiť kde sa v obraze nachádza a pomocou nakalibrovanej kamery zmerať vzdialenosť medzi vozidlom a centroidom obrazca R-ID.

5.1 Pribeh a postup trénovania

Aby sme vedeli HAAR kaskádový klasifikátor vytvoriť a používať, je potrebné pripraviť vhodný dataset pozostávajúci zo snímkov obsahujúcich R-ID.

5.1.1 Vytvorenie datasetu

Na HAAR kaskádový klasifikátor je potrebné mať dataset, ktorý sa skladá z dvoch priečinkov. V jednom priečinku sú pozitívne snímky a v druhom priečinku sú negatívne snímky (obr. 6.1).



Obr. 6.1 Priečinky s pozitívnymi (napravo) a negatívnymi (naľavo) snímkami

Pri našom riešení bol zvolený postup použitím už orezaných snímkov. Museli sme teda navrhnuť systém, ktorý by nám dokázal prácu uľahčiť ako manuálne orezávať veľké množstvo obrázkov. Rozhodli sme sa preto použiť pre predprípravu dát konvolučnú neurónovú sieť. Vznikla tu otázka prečo nepoužiť konvolučnú neurónovú sieť rovno? Dôvodom bol nepostačujúci hardvér bez výkonnej grafickej karty a bolo potrebné zabezpečiť čo najväčší počet snímkov, ktoré dokážu byť rozpoznané v reálnom čase. Konvolučná neurónová sieť bola v tomto kroku použitá len na predprípravu dát. Jednalo sa o „mask_rcnn_R_50_FPN_3x“ od facebookresearch/detectron2 [24]. Postup

predprípravy pozostával z natočenia 5 minútových videí kamerou s rôznym podkladom, ktorá bola už namontovaná na testovacom vozidle MOPASv2. Na tomto videu sa po podlahe posúval R-ID vzor po celom zornom poli kamery. Následne bola vytvorená metóda v pythone, ktorá rozdelila video na snímky. Tento dataset bol ešte prefiltrovaný tak, že ak sa nachádzala snímka s veľmi podobným umiestnením R-ID vzoru v zornom poli kamery tak takáto snímka bola odstránená. V konečnom dôsledku sme dostali 200 snímkový dataset pre náš R-ID model.

5.1.2 Označovanie (labelovanie) datasetu


Labelovaním sa rozumie prideliť ku danému obrázku ohraničujúce obdĺžniky alebo rámčeky určujúce kde sa na obrázku nachádza požadovaný tvar, ktorý chceme trénovať. Keďže pre danú mask-RCNN, ktorú sme sa rozhodli použiť pre predlabelovanie, musí byť na vstup do trenovacieho algoritmu použitý iný formát ako pre HAAR kaskádový klasifikátor, a tak bolo nutné olabelovať dataset. Pre skript *R-ID_train.py* bolo potrebné na vstup dostať dataset v COCO formáte. Pre labelovanie datasetu sme sa rozhodli použiť voľne dostupný nástroj Label Studio. Najväčšou výhodou Label Studia je, že sa dá pustiť cez docker alebo cez „git“ repozitár.

V oboch prípadoch sa po nakonfigurovaní spustilo na localhost:8080 prostredie v ktorom bolo možné vytvoriť projekt, importovať do projektu súbory na labelovanie a následne napísať pomocou HTML jazyka nastavenia pre daný projekt. Tieto nastavenia je možné vidieť na obrázku 6.2. Labelovanie je na obrázku 6.3.

Projects / R-ID / Settings / Labeling Interface



Obr. 6.2 Nastavenia Label Studia



Obr. 6.3 Proces labelovania – zeleným obdĺžnikom označený R-ID

Po olabelovaní dát bolo potrebné rozdeliť dataset na tréningovú a validačnú sadu. Proces tréningovania v jednoduchosti pozostáva v tom, že na tréningových dátach sa trénujú váhy pre konkrétny model a na validačných dátach prebieha validácia, ktorá vyhodnotí dané váhy. V našom prípade sa tento parameter nazýva AP (average precision). Kým AP rastie tým sa model učí a vylepšuje váhy. Dalším dôležitým údajom je LR (learning rate). Tento zas udáva ako veľmi boli váhy zmenené. Pokiaľ je LR veľmi nízky, tak už sa váhy významne zlepšovať nebudú. Validácia prebiehala po každej 100 iterácii a tak sme vedeli určiť kedy bolo vhodné ukončiť tréningovanie.

5.1.3 Tréningovanie konvolučnej neurónovej siete

Po napísaní skriptu, ktorý má tréňovať neurónovú sieť sa pri spustení skriptu zadali potrebné parametre. Sú to názov datasetu, anotované súbory pre tréningovanie a validáciu, priečinok s obrázkami a konfiguračný súbor. Jednalo sa o „mask_rcnn_R_50_FPN_3x“, ku ktorej prislúcha aj konfiguračný súbor od facebookresearch / detectron2 [63]. Na nasledujúcich obrázkoch 6.4 a 6.5 môžete vidieť výpisy z terminálu počas procesu tréningovania.

```
[05/27 12:26:33 d2.evaluation.coco_evaluation]: Evaluation results for bbox:
| AP | AP50 | AP75 | APs | APm | APl |
|:-----|:-----|:-----|:-----|:-----|:-----|
| 57.684 | 100.000 | 44.551 | nan | 64.862 | 45.000 |
[05/27 12:26:33 d2.evaluation.coco_evaluation]: Some metrics cannot be computed and is shown as NaN.
[05/27 12:26:33 d2.engine.defaults]: Evaluation results for R-ID_ver2-val in csv format:
[05/27 12:26:33 d2.evaluation.testing]: cypypaste: Task: bbox
[05/27 12:26:33 d2.evaluation.testing]: cypypaste: AP,AP50,AP75,APs,APm,APl
[05/27 12:26:33 d2.evaluation.testing]: cypypaste: 57.6841,100.0000,44.5506,nan,64.8619,45.0000
```

Obr. 6.4 Prvých 100 iterácií

```
[05/27 14:20:28 d2.evaluation.coco_evaluation]: Evaluation results for bbox:
| AP | AP50 | AP75 | APs | APm | APl |
|:-----|:-----|:-----|:-----|:-----|:-----|
| 88.125 | 100.000 | 100.000 | nan | 91.485 | 82.500 |
[05/27 14:20:28 d2.evaluation.coco_evaluation]: Some metrics cannot be computed and is shown as NaN.
[05/27 14:20:28 d2.engine.defaults]: Evaluation results for R-ID_ver2-val in csv format:
[05/27 14:20:28 d2.evaluation.testing]: cypypaste: Task: bbox
[05/27 14:20:28 d2.evaluation.testing]: cypypaste: AP,AP50,AP75,APs,APm,APl
[05/27 14:20:28 d2.evaluation.testing]: cypypaste: 88.1246,100.0000,100.0000,nan,91.4851,82.5000
```

Obr. 6.5 Prvých 500 iterácií

Trénovanie prebehlo 2 krát a to prvýkrát takzvané „from scratch“ čomu by sa dalo rozumieť ako úplne od základu (začiatku). Druhé trénovanie bolo pustené už na predtrénovanom modeli. Predtrénovaný model („from scratch“) dosiahol priemernú presnosť AP 96,4% na validačnej sade. Druhý model dosiahol po 3099 iteráciách presnosť AP 98,2% na validačnej sade. Znamená to že 98,2 % obrázkov z validačnej sady dokázal rozpoznať presne tak ako boli olabelované. Po spustení skriptu *R-ID_finder.py*, ktorý už používal náš natrénovaný model sme dokázali orezať snímky z dvoch ďalších rozdielných videí. Videá sa líšili rozdielnym podkladom, (hnedé parkety, tmavosivé linoleum, sivý betón) a teda sa rozšíril náš dataset bez ďalšieho nutného prácneho a zdĺhavého labelovania. Po výstupe z daného skriptu sme teda dostali 1800 obrázkový dataset pre HAAR kaskádový klasifikátor. Pre porovnanie, na natrénovanie mask-RCNN bolo použitých 200 snímok.


5.1.4 Trénovanie HAAR

Na trénovanie HAAR kaskádového klasifikátora sme použili voľne dostupnú aplikáciu na trénovanie – Cascade Trainer GUI. V Samples Folder sa nachádza priečinok s rozdelením N a P, čiže negatívne snímky a pozitívne snímky. Následne si nastavíme počet tréovacích cyklov. Počet snímok koľko má ísť do jedného tréovacieho vlákna a ďalšie možné nastavenia. V našom prípade sme nastavili 20 cyklov po 300 snímkach v jednom vlákne. Po ukončení tréovania vypíše upozornenie s nápisom, že trénovanie bolo úspešné. Tým pádom máme natrénovaný HAAR kaskádový klasifikátor pre R-ID vzor.

5.2 Kalibrácia kamery

Pri použití jednej kamery bolo nutné navrhnuť spôsob prepočtu a konverzie pixelov na milimetre tak, aby algoritmus vedel určiť vzdialenosť na základe rozpoznaného R-ID. V prvom rade bol určený ako referenčný bod merania polohy centroid R-ID. Na tento bod sú aj kalibrované GNSS súradnice.

Spôsob prepočtu spočíva v kalibrácii obrazu zachytávaného kamerou pomocou šachovnicového vzoru. Na túto kalibráciu sa použili metódy z knižnice openCV. Na vstupe do tejto metódy vstupuje šachovnicový vzor kde metóda `findChessboardCorners` našla rohy šachovnicového vzoru. Pri testovaní boli použité dva typy. Prvý typ mal veľkosť strany štvorca 2 cm a druhý typ mal 5 cm (Obr. 6.6). Následne openCV metóda `cornerSubPix` nájde hrany kde sa mení čierna a biela farba na šachovnici. Následne máme potrebné dáta pre vstup do metódy `calibrateCamera`. Po týchto testoch sme sa rozhodli používať vzor s 5 cm hranami. Bolo to preto, že pri hornom kraji snímky už nedokázal presne detegovať hrany.



Obr. 6.6 Vzor s 5 cm šachovnicovým vzorom

Po tejto kalibrácii sme dostali údaj, ktorý nám presne určuje konverziu na centimetre. Aj keď konverzia udáva hodnoty na milimetre, počas kalibrácie bol použitý kalibračný vzor s veľkosťou strany 5 cm a teda najpresnejšie dokážeme odmerať vzdialenosť s presnosťou 5 cm. Na nasledujúcich obrázkach 6.7 je možné vidieť pohľad z hora. V zornom poli kamery je umiestnený R-ID. Akonáhle vizuálny systém rozpozná R-ID v zachytenej snímke tak sa začína prepočet.

Keďže po kalibrácii sú prepočítané pixely na milimetre je tak možné učiť kde sa nachádza poloha R-ID a tak isto prepočítať uhol a vzdialenosť medzi R-ID a kamerovým senzorom. Vo vzorci 6.1 je ukázané, že každý bod má x a y súradnice. Tieto súradnice sú buď v pixeloch alebo milimetroch. Po prepočte kalibrácie sú však všetky koordináty v centimetroch. Premenná Δx predstavuje vzdialenosť medzi kamerovým senzorom a centroidom R-ID označeným bodom C. Hodnotu Δx dostaneme pomocou vzorca 6.5.


$$BOD [X, Y] \quad (6.1)$$

$$\Delta x = x_{0R} + x \quad (6.2)$$

$$x_{0R} = \sqrt{x_0^2 + (A[Y])^2} \quad (6.3)$$

$$x_R = \sqrt{(C[Y] - A[Y])^2 + (C[X])^2} \quad (6.4)$$

$$\Delta x = \sqrt{x_0^2 + (A[Y])^2} + \sqrt{(C[Y] - A[Y])^2 + (C[X])^2} \quad (6.5)$$




Obr. 6.7 Pohľad z hora na umiestnenie kamery a zorné pole kamery

5.3 Príprava postupu merania

Meranie by malo spočívať v meraní vzdialenosti pomocou nami navrhnutého kamerového systému a presnosť merania by mal overiť LiDAR. Na toto meranie sa použil MOPASv2, ktorý už obsahuje aj LiDAR a aj kameru. Nakoľko LiDAR bol pripojený na Jetson Nano, ktorý aj spracovával dáta z LiDARu a kamerový senzor bol pripojený na počítač, ktorý zase spracovával dáta z kamery, bolo nutné vytvoriť spôsob, ktorým by sa dal synchronizovať čas merania. Rozhodli sme sa pripojiť počítač aj Jetson Nano na rovnakú Wi-Fi sieť a na počítači vytvoriť klienta a na Jetson Nano server a tak

zabezpečiť komunikáciu medzi zariadeniami a synchronizáciu času. Pre komunikáciu sa použila pythonovská knižnica *roslibpy*. Modul *roslibpy* bol nainštalovaný aj na Jetson Nano a použili sa metódy zabezpečujúce komunikáciu, kde Jetson Nano vystupoval ako server a počítač ako klient, dopytujúci sa na server s požiadavkou o aktuálny čas. Celý proces je možné vidieť na diagrame na obrázku 6.8.




Obr. 6.8 BPMN diagram procesu synchronizácie času

Ďalej je nutné rozložiť značky, ktorých poloha sa bude merať v určitej vzdialenosti. Značky je nutné umiestniť tak, aby počas jedného záberu bola v zornom poli kamery len jedna značka R-ID. Na konci priestoru s umiestnenými značkami je potrebné vytvoriť rovnú zástenu, od ktorej sa budú odrážať laserové lúče LiDARu.

Ak budú R-ID rozložené, treba si zvoliť referenčný bod z ktorého bude vozidlo štartovať. Ak máme presne definovaný úsek aj s rozmermi, na Jetson Nano sa spustí skript na meranie vzdialenosti LiDARu. LiDAR meria len vzdialenosť v uhle 0° čo znamená priamy smer vozidla. Ďalej tejto nameranej vzdialenosti priraduje časovú známku a ukladá do *.xls súboru. Následne sa pustí skript na počítači, ktorý má za úlohu rozpoznávať značku R-ID pomocou HAAR-ovho kaskádového klasifikátora a následne dopočítať jej presnú polohu. Akonáhle je detegovaná R-ID značka klient na počítači sa dopytuje na server na Jetson Nano od ktorého si vypýta informáciu o presnom aktuálnom čase a tento čas priradí značke R-ID. Výstup z tohto skriptu sa zapíše do *.txt súboru v nami predpísanom formáte. Následne z týchto údajov spravíme porovnanie na základe časových známok. Matematicky prepočítame vzdialenosť z LiDARu tak aby bol ekvivalentný meraniam z kamery. Po prepočítaní vynesieme údaje do grafu aby bolo znázornené aká bola odchýlka medzi LiDARom a kamerou.


6 Experimentálne overenie implementácie navrhutej metódy rozpoznávania cestného identifikátora

Podľa kapitoly „Merania pomocou HAAR Kaskadového klasifikátora + LiDAR“ sme si pripravili meranie. Vytlačili sme na A4 značky R-ID a pri tomto meraní boli použité tri značky. Referenčný bod bol vzdialený presne 8 metrov od zásteny. Znamená to, že samotný kamerový senzor a LiDAR boli umiestnené 800 cm od zásteny čiže LiDAR dokázala namerať maximálnu vzdialenosť 8 metrov. Od referenčného bodu boli umiestnené značky R-ID každých 220 cm. (obr. 7.1)




Obr. 7.1 Náčrt pripraveného merania

Po príprave prostredia sa na oboch zariadeniach spustili skripty a overila sa komunikácia medzi Jetsonom Nano a počítačom. Test spojenia spočíval v privedení vozidla do takej vzdialenosti, aby staticky rozpoznával R-ID. Akonáhle prvýkrát rozpoznal obrazec začali sa zapisovať správy do textového súboru aj s časovou známkou z Jetsonu Nano. Taktiež v konzole na počítači vypisovalo hlášku posielania správy so žiadosťou o čas. Po teste spojenia sa vozidlo vrátilo do referenčného bodu a začalo sa reálne meranie. Reálne meranie spočívalo v pohybe vozidla v priamom smere vpred a vzad. Rýchlosť vozidla sa s počtom testov zvyšovala. Kým na prvých meraniach kedy vozidlo išlo krokom približne 1.3 m/s, tak kamerový systém zachytával priemerne 20 snímok rozpoznaného R-ID na jedno R-ID, tak na posledných meraniach pri vysokej rýchlosti približne 7 m/s to bolo 3 až 5 snímok. Videá z príkladu merania je možné vidieť v prílohe A v priečinku videá pod názvom „*output_meranie_28*“ a „*output_meranie_13*“. Po dokončení merania sa údaje z počítača a LiDARu zlúčili sa do jedného *.xls súboru. V tomto súbore potom prebiehali prepočty a synchronizovanie podľa časových známok. Po prepočtoch sme dostali nasledovné výsledky zobrazené na obrázku 7.2.



Obr. 7.2 Graf výsledkov z LiDARu a Kamery

Ako môžeme vidieť na predošlom grafe (obr. 7.2), v meraní je značný časový posun medzi dátami z LiDARu a dátami z vizuálneho systému. Predmetom ďalšieho skúmania bolo teda zistiť, prečo tento časový posun vznikol. Dospeli sme k záveru, že synchronizácia a prenos dát cez Wi-Fi nie je dobrá voľba a preto sme vykonali test na dobu prenosu. Použitím softvérového nástroja Wireshark sme zmerali dobu prenosu od prvej správy z počítača, ktorá je posielaná na server až po prijatie správy s informáciou o čase z hodín v Jetsonu Nano. Tento čas nám priemerne vychádzal na jednu sekundu. Po aplikovaní časovej korekcie sme dostali nasledovné výsledky, ktoré je možné vidieť na Obr. 7.3.



Obr. 7.3 Graf výsledkov z LiDARu a Kamery po časovej korekcii

Tab. 11.: Výsledky s nameranými chybami z merania

Maximálna nameraná chyba v kladnej hodnote [mm]	158
Maximálna nameraná chyba v zápornej hodnote [mm]	121
Smerodajná odchýlka [mm]	54,1
Priemerná chyba [mm]	41,7
Počet vzoriek z kamery	147

Ako je možné vidieť v tabuľke 11 tak najväčšia nameraná chyba v kladnej hodnote (väčšia vzdialenosť ako skutočná) bola 158 mm a v zápornej hodnote (menšia vzdialenosť ako skutočná) bola 121 mm. Priemerná chyba bola v absolútnej hodnote čiže nehralo úlohu či bola chyba záporná alebo kladná a táto hodnota priemernej chyby bola 41,7 mm. Týmito pokusmi sme dokázali že je možné veľmi presne merať vzdialenosť pomocou jednej kamery. Príklady nameraných vzdialeností v statickom stave môžete vidieť na obrázku 7.4. Tieto merania boli overované laserovým meračom vzdialenosti. Príklady nameraných vzdialeností v pohybe môžete vidieť v prílohe A „./video/output_meranie_28.mp4v“.



Obr. 7.4 Príklad výsledku merania v statickom stave

7 Zhodnotenie meraní

Počas vypracovávaní dizertačnej práce bolo vykonaných viacero testov a meraní. Merania a testovania by sa mohli rozdeliť na dve hlavné kategórie. Do prvej kategórie spadajú testy a merania pomocou kamery COGNEX upevnenej na platforme MOPASv1. Do druhej kategórie sú primárne začlenené merania s kamerou e-con FSCAM CU135 umiestnenou na MOPASv2.

V prvej kategórii meraní prebehli merania na kamere so softvérom a metódami do ktorých sme nevedeli zasahovať. Aj preto sme týmto patentovaným softvérom od spoločnosti COGNEX testovali hlavne funkcionlitu a či vôbec bude možné nami navrhnuté riešenie funkčne realizovať. Zisťovali sme, či je možné pomocou kamery merať vzdialenosť, ďalej ako je možné merať vzdialenosť pomocou jedného kamerového senzoru aj keď kamera nie je určená na tento účel. Pri týchto meraniach bol navrhnutý postup kalibrácie, ktorá prekonvertuje pixely na milimetre. Tento test dopadol úspešne a kalibrácia kamery sa podarila s veľmi vysokou presnosťou ako je možné vidieť v kapitole 7.3 kedy priemerná chyba bola 0,041 mm. Keďže kalibračný vzor mal šírku jedného štvorca 10 mm, tieto výsledky považujeme za veľmi presné, nakoľko nemôžeme uviesť presnosť nižšiu ako veľkosť kalibračnej mriežky. Ďalším účelom merania pomocou kamery COGNEX bolo navrhnuť cestný identifikátor R-ID. Pre tento účel boli vybrané tri jednoduché útvary ako štvorec, kružnica a rovnostranný trojuholník. Na týchto útvaroch sa meral hlavne čas rozpoznania objektu a percentuálne skóre rozpoznaného objektu. Pri týchto útvaroch prebehli tri testovania a to test umiestnenia útvaru v celom zornom poli kamery, v druhom teste rotácia útvaru a v treťom testovaní sa meralo percentuálne prekrytie objektu. Po zvážení výsledkov sme sa rozhodli použiť pre návrh R-ID rovnostranný trojuholník.

V druhej kategórii meraní sa meralo s meracími zariadeniami umiestnenými na MOPASv2. V týchto testoch sa už používal nami navrhnutý a vyvinutý softvér a spúšťali sa nami napísané skripty na testovanie. Tieto testy najmä pri pohybe vozidla pri maximálnej rýchlosti 10 m/s a priemernej rýchlosti 4,2 m/s. Presnosť merania vzdialenosti sa skoro vôbec nelíšila, nevýhodou vyšších rýchlostí však bolo menej zachytených vzoriek na porovnanie s LiDARom. Po vytvorení a natrénovaní modelov sme rozpoznávali R-ID v zornom poli kamery a následne prepočítali vzdialenosť medzi kamerou a R-ID. Pri týchto testoch sme zistili, že pri použití kalibračnej mriežky 50 mm vieme dosiahnuť presnosť s priemernou chybou 41,7 mm, takže výsledky považujeme rovnako za veľmi presné, nakoľko nemôžeme tvrdiť presnosť nižšiu ako veľkosť kalibračnej mriežky. Najväčšia dosiahnutá chyba bola 158 mm.

Záver

Lokalizácia autonómnych vozidiel a iných mobilných mechatronických zariadení je aktuálne veľmi rozšírenou témou. Využitie takýchto zariadení má nesmierne veľkú škálu využitia. Či už sa môže jednať o sklady, výrobné haly, letiská alebo aj lokalizácie pre autonómne vozidlá v tuneloch, krytých parkoviskách a mnoho ďalších použití. O to unikátnejšie je použitie vizuálneho lokalizačného systému s použitím jedného kamerového snímača a cestného identifikátora R-ID. V súčasnom stave výstup z tejto práce dopĺňa a spresňuje aktuálne používané lokalizačné zariadenia.

V prvej kapitole je spravený stručný rešerš aktuálnych riešení s blízkou problematikou, avšak ani jedno z týchto riešení nijako nekonkuruje nášmu vizuálnemu lokalizačnému systému.

V kapitole dva bola sformulovaná definícia problému a predstavené ciele práce. Navrhnuť sa mala metóda spolu s implementáciou, kde koncept nami navrhnutého vizuálneho lokalizačného systému pozostáva z návrhu jednoduchého cestného identifikátora, algoritmu, ktorý rozpozná identifikátor a prepočíta aktuálnu vzdialenosť medzi identifikátorom a kamerovým snímačom.

Najväčší prínos v práci je popísaný v kapitolách tri až šesť. Kapitola tri opisuje návrh a zostrojenie testovacích vozidiel MOPASv1 a MOPASv2. Tieto vozidlá sú odlišné použitým hardvérom. MOPASv1 je pre nás uzavretý systém s vlastným programovacím prostredím a bol použitý výhradne na testovacie účely vývoja a overenia funkčnosti konceptu. MOPASv2 je založený čisto na voľne dostupnom softvéri. MOPASv2 obsahuje už aj komponenty ako sú 2D LiDAR a GNSS prijímač. Taktiež bolo toto vozidlo konštruované tak aby bolo schopné vykonávať merania ako v statickom stave tak aj v pohybe a simulovať tak reálne autonómne vozidlo. V kapitole štyri sú opísané prvé merania a testovania s vozidlom MOPASv1. Cieľom týchto testov bolo zistiť a navrhnuť ideálny jednoduchý cestný identifikátor. Testované boli tri jednoduché geometrické útvary a z nich sa mal vybrať najlepší pre vzor R-ID. Vybraté útvary podstúpili tri testy. Po týchto testoch sa navrhol jednoduchý R-ID s ktorým sa pracovalo aj po zvyšok práce a ďalších meraní. V kapitole pät sa rozhodlo používať MOPASv2 pre ktoré však bolo potrebné navrhnuť matematické operácie pre prepočet vzdialenosti, keďže toto vozidlo už používalo nami navrhnutý a naprogramovaný softvér založený na voľne dostupných riešeniach a nebolo možné použiť patentované metódy od firmy COGNEX.

V kapitole šesť sa používalo na merania vozidlo MOPASv2 už s nami implementovanými metódami. S vozidlom MOPASv2 prebehlo viacero testov

v statickom stave v interiéri. Ďalej prebehli testy s pohybujúcim sa vozidlom aj v interiéri so stabilnými svetelnými podmienkami a taktiež aj v exteriéri kde sa svetelné a poveternostné podmienky menili. Z týchto meraní sa zistilo že nami navrhnutý systém je v interiéri rozpoznávať a odmerať obrazce pri rýchlosti 5 m/s a v exteriéri bola táto rýchlosť nižšia. Slabšie výsledky exteriéri boli zapríčinené hlavne svetelným odrazom slnečného žiarenia do kamerového snímača a tak kamera nerozpoznala obrazec keďže bol preexponovaný. Tento problém by sa dal vyriešiť hardvérovým filtrom ktorý by sa namontoval pred objektív. Čo sa týka problému so striedavým a nadmerným osvetlením obrazca tento problém by vyriešila výroba R-ID z iného materiálu aký bol použitý pri testoch. Každopádne vozidlo v pohybe dokázalo zmerať vzdialenosť medzi R-ID a kamerovým snímačom s najväčšou dosiahnutou chybou 158 mm a priemernou chybou 41,7 cm. Tieto výsledky boli namerané v interiéri pri priemernej rýchlosti 4,2 m/s.

Kapitola sedem pojednáva o meraniach a testoch, ktoré boli vykonané počas dizertačného štúdia. V kapitole je zhrnutie meraní, ktoré sa delí na dva celky. Prvý obsahoval merania pomocou kamery COGNEX namontovanej na MOPASv1 a druhý pomocou kamery e-con FSCAM CU135 namontovanou na MOPASv2. V kapitole sú stručne popísané dosiahnuté výsledky zo všetkých dôležitých meraní.

Dizertačná práca prezentuje originálne riešenie, nakoľko podľa analýzu súčasného stavu problematiky nebola takáto metóda merania vzdialenosti a lokalizovania vozidla prezentovaná a implementovaná. Toto riešenie pokladáme za vedecký prínos práce k rozvoju vedného odboru a je v súlade s požiadavkami praxe. Implementácia metódy bude využiteľná aj v reálnom autonómnom vozidle, ktoré vyvíja ústav automobilovej mechatroniky na Fakulte elektroniky a informatiky. Inovativnosť prezentovaných výsledkov umocňuje aj fakt, že navrhnuté metódy, implementácie a výsledky tejto dizertačnej práce významnou mierou prispeli k návrhu nového technického riešenia plánovaného na patentovú ochranu (v čase písania tejto práce si Slovenská Technická Univerzita uplatnila právo na riešenie a teda podstupuje ďalšie kroky k podaniu patentovej prihlášky).

Prínosy práce

Za prínosy dizertačnej práce možno považovať

- Analýza oblastí lokalizačných systémov vo vozidlách, počítačového videnia a nových trendov pri používaní vizuálnych systémov na meranie vzdialenosti vozidiel
- Návrh metódy pre meranie vzdialenosti použitím unikátneho R-ID a použitím vizuálneho systému
- Návrh a realizácia vizuálneho systému pre meranie vzdialenosti a testovanie vizuálneho systému na viacerých R-ID so statickým vozidlom a vozidlom v pohybe
- Tvorba unikátnych datasetov pre R-ID a natrénovanie unikátnych modelov pre rozpoznávanie R-ID
- Implementácia navrhutej metódy merania vzdialenosti
- Experimentálne overenie implementácie navrhutej metódy rozpoznávania cestného identifikátora použitím vlastnej unikátnej mobilnej platformy

Publikačná činnosť autora

ADE Vedecké práce v ostatných zahraničných časopisoch

- ADE01 VALOCKÝ, Frederik - ORGOŇ, Miloš. Riešenie komunikácie autonómneho vozidla s jednotkou riadenia. In *Elektrorevue [elektronický zdroj]*. Vol. 21, No. 6 (2020), s. 166-170. ISSN 1213-1539.

AFC Publikované príspevky na zahraničných vedeckých konferenciách

- AFC01 GRNÁČ, Andrej - VALOCKÝ, Frederik - ORGOŇ, Miloš. Implementation of elliptic curve cryptography between autonomous vehicles and control center. In *Software Engineering and Algorithms : 10th Computer Science On-line Conference*. Vol. 1. Zlin, Czech Republic. April 29, 2021. Cham : Springer, 2021, S. 718-729. ISBN 978-3-030-77441-7. V databáze: DOI: 10.1007/978-3-030-77442-4_60 ; SCOPUS: 2-s2.0-85113407428.
- AFC02 VALOCKÝ, Frederik - DRAHOŠ, Peter - HAFFNER, Oto. Measure distance between camera and object using camera sensor. In *2020 Cybernetics & Informatics (K&I) [elektronický zdroj] : 30th International Conference*. Velké Karlovice, Czech Republic. January 29-February 1, 2020. 1. ed. Danvers : IEEE, 2020, [4] s. ISBN 978-1-7281-4381-1. V databáze: IEEE: 9039879 ; WOS: 000753938900031 ; SCOPUS: 2-s2.0-85083108676 ; DOI: 10.1109/KI48306.2020.9039879.

Ohlasy:

1. [3] Friendly, F., Harizahayu, H., Sembiring, R. W., & Br Sembiring, B. S. (2021). Measurement of Image Distance Using Only Camera On Object Detection OpenCV. INFOKUM, 10(1), 56-63.
 2. [1] KHACHUMOV, Mikhail - KHACHUMOV, Vyacheslav - ABRAMOV, Nikolay - FRALENKO, Vitaly. Range Measurement by Computer Vision Systems Based on Invariant Moments. In ICSEC 2021 25th International Computer Science and Engineering Conference, 2021-01-01, pp. 134-137., Registrované v: SCOPUS
 3. [3] Nuramin Fitri Aminuddin, Zarina Tukiran, Ariffuddin, Joret, Herdawatie Abdul Kadir. Speed Estimation of Moving Vehicle based on Input Images from a Smartphone Camera. In *Evolution in Electrical and Electronic Engineering* Vol. 2 No. 1 (2021) 177-185
- AFC03 VALOCKÝ, Frederik - DRAHOŠ, Peter - HAFFNER, Oto - KOZÁKOVÁ, Alena - ORGOŇ, Miloš. Design of a R-ID in order to determine the position of the vehicle. In *FedCSIS : Proceedings of the*

2020 federated conference on computer science and information systems. Sofia, Bulgaria. September 6-9, 2020. Piscataway : IEEE, 2020, S. 435-441. ISBN 978-83-955416-9-8. V databáze: DOI: 10.15439/2020F128 ; IEEE: 9222860 ; SCOPUS: 2-s2.0-85095795579.

- AFC04 VALOCKÝ, Frederik - PUCHALÍK, Martin - ORGOŇ, Miloš. Implementing asymmetric cryptography in high-speed data transmission over power line. In *UEMCON 2020 : 11th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference. October 28-31, 2020*. Danvers : IEEE, 2020, S. 850-855. ISBN 978-1-7281-9656-5. V databáze: IEEE: 9298107 ; WOS: 000652194300136 ; SCOPUS: 2-s2.0-85099752905.

AFD Publikované príspevky na domácich vedeckých konferenciách

- AFD01 VALOCKÝ, Frederik - ORGOŇ, Miloš - FUJDIK, Ina. Experimental autonomous car model with safety sensor in wireless network. In *PDeS 2019 : 16th IFAC conference on programmable devices and embedded systems. High Tatras, Slovakia. October 29-31, 2019*. 1. vyd. Laxenburg : IFAC, 2019, S. 92-97. ISSN 2405-8963. V databáze: DOI: 10.1016/j.ifacol.2019.12.739 ; WOS: 000507495200017 ; SCOPUS: 2-s2.0-85081557813.

Ohlasy:

1. [1] FU, Erkang - LI, Xi - YAO, Zhi - REN, Yuxin - WU, Yuanhao - FAN, Qiqi. Personnel emotion recognition model for Internet of vehicles security monitoring in community public space. In *EURASIP JOURNAL ON ADVANCES IN SIGNAL PROCESSING*, 2021, vol. 2021, no. 1, pp. ISSN 1687-6180., Registrované v: WOS, CC, SCOPUS

- AFD02 VALOCKÝ, Frederik - DRAHOŠ, Peter - HAFFNER, Oto - ORGOŇ, Miloš. Transfer data from camera required for autonomous driving via FTP. In *ELITECH'20 [elektronický zdroj] : 22nd Conference of doctoral students. Bratislava, Slovakia. May 27, 2020*. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2020, [4] s. ISBN 978-80-227-5001-1.
- AFD03 VALOCKÝ, Frederik - DRAHOŠ, Peter - HAFFNER, Oto. Methods of determining the position of the object in the field of view of the camera. In *ELITECH'21 [elektronický zdroj] : 23th Conference of Doctoral Students*,

May 26, 2021. 1. ed. Bratislava : Vydavateľstvo Spektrum STU, 2021, [6]
s. ISBN 978-80-227-5098-1.

Štatistika: kategória publikačnej činnosti

ADE	Vedecké práce v ostatných zahraničných časopisoch	1
AFC	Publikované príspevky na zahraničných vedeckých konferenciách	4
AFD	Publikované príspevky na domácich vedeckých konferenciách	3
Súčet		8

Štatistika: kategória ohlasov

1	Citácie v zahraničných publikáciách, registrované v citačných indexoch Web of Science a databáze SCOPUS	2
3	Citácie v zahraničných publikáciách neregistrované v citačných indexoch	2
Súčet		4

Zoznam použitej literatúry

- [1] S. Garrido-Jurado, R. Muñoz-Salinas, F. J. Madrid-Cuevas, and M. J. Marín-Jiménez, “Automatic generation and detection of highly reliable fiducial markers under occlusion,” *Pattern Recognit.*, vol. 47, no. 6, pp. 2280–2292, Jun. 2014, doi: 10.1016/j.patcog.2014.01.005.
- [2] R. Muñoz-Salinas, M. J. Marín-Jimenez, and R. Medina-Carnicer, “SPM-SLAM: Simultaneous localization and mapping with squared planar markers,” *Pattern Recognit.*, vol. 86, pp. 156–171, Feb. 2019, doi: 10.1016/j.patcog.2018.09.003.
- [3] R. Muñoz-Salinas, M. J. Marín-Jimenez, E. Yeguas-Bolivar, and R. Medina-Carnicer, “Mapping and localization from planar markers,” *Pattern Recognit.*, vol. 73, pp. 158–171, Jan. 2018, doi: 10.1016/j.patcog.2017.08.010.
- [4] F. J. Romero-Ramirez, R. Muñoz-Salinas, and R. Medina-Carnicer, “Speeded up detection of squared fiducial markers,” *Image Vis. Comput.*, vol. 76, pp. 38–47, Aug. 2018, doi: 10.1016/j.imavis.2018.05.004.
- [5] V. Mondéjar-Guerra, S. Garrido-Jurado, R. Muñoz-Salinas, M. J. Marín-Jiménez, and R. Medina-Carnicer, “Robust identification of fiducial markers in challenging conditions,” *Expert Syst. Appl.*, vol. 93, pp. 336–345, Mar. 2018, doi: 10.1016/j.eswa.2017.10.032.
- [6] A. Mutka, D. Miklic, I. Draganjac, and S. Bogdan, “A low cost vision based localization system using fiducial markers,” *IFAC Proc. Vol.*, vol. 41, no. 2, pp. 9528–9533, 2008, doi: 10.3182/20080706-5-kr-1001.01611.
- [7] A. Babinec, L. Jurišica, P. Hubinský, and F. Duchoň, “Visual localization of mobile robot using artificial markers,” in *Procedia Engineering*, 2014, vol. 96, pp. 1–9. doi: 10.1016/j.proeng.2014.12.091.
- [8] J. Degol, T. Bretl, and D. Hoiem, “ChromaTag: A Colored Marker and Fast Detection Algorithm,” in *Proceedings of the IEEE International Conference on Computer Vision*, Dec. 2017, vol. 2017-October, pp. 1481–1490. doi: 10.1109/ICCV.2017.164.
- [9] X. Zhong, Y. Zhou, and H. Liu, “Design and recognition of artificial landmarks for reliable indoor self-localization of mobile robots,” *Int. J. Adv. Robot. Syst.*, vol. 14, no. 1, Feb. 2017, doi: 10.1177/1729881417693489.
- [10] Z. Mikulová, F. Duchoň, M. Dekan, and A. Babinec, “Localization of mobile robot using visual system,” *Int. J. Adv. Robot. Syst.*, vol. 14, no. 5, pp. 1–11, Oct. 2017, doi: 10.1177/1729881417736085.
- [11] Y. Meng, K. J. Lin, B. L. Tsai, C. C. Chuang, Y. Cao, and B. Zhang, “Visual-based localization using pictorial planar objects in indoor environment,” *Appl. Sci.*, vol. 10, no. 23, pp. 1–24, Dec. 2020, doi: 10.3390/app10238583.
- [12] T. Krajník *et al.*, “A Practical Multirobot Localization System,” *J. Intell. Robot. Syst. Theory Appl.*, vol. 76, no. 3–4, pp. 539–562, Oct. 2014, doi: 10.1007/s10846-014-0041-x.
- [13] A. Botta and G. Quaglia, “Performance analysis of low-cost tracking system for mobile

robots,” *Machines*, vol. 8, no. 2, Jun. 2020, doi: 10.3390/MACHINES8020029.

- [14] L. A. Bush, M. Losh, B. N. Bacchus, and U. P. Mudalige, “Methods and systems for mapping and localization for a vehicle” [Online]. Available: <https://patentimages.storage.googleapis.com/e7/08/4e/ecfc523d7cbb57/US20200318974A1.pdf>
- [15] S. I. Rumeliotis, “Extrinsic parameter calibration of a vision-aided internal navigation system” [Online]. Available: <https://patentimages.storage.googleapis.com/0b/70/07/24be9d807f0da7/WO2014130854A1.pdf>
- [16] H. Li, Z. Bin LEI, Y. Liu, M. Y. CHIU, and K. Wu, “Vehicle detection, tracking and localization based on enhanced anti-perspective transformation” [Online]. Available: <https://patents.google.com/patent/US9928426B1/en?q=US9928426B1>
- [17] H. Mielenz and R. Jan, “Method for locating a vehicle” [Online]. Available: <https://patents.google.com/patent/US10691963B2/en?q=US10691963B2>
- [18] 曾庆喜, 冯玉鹏, 周倪青, 邓书朝, and 李中兵, “A kind of pilotless automobile navigation and positioning accuracy antidote merged based on GNSS and visual odometry”, [Online]. Available: <https://patents.google.com/patent/CN107229063A/en?q=CN107229063A>
- [19] COGNEX, “In-Sight 7000 Series Vision System.” <https://www.cognex.com/downloads/literaturemain?event=b9f50403-7f83-4bed-8d45-9ead201143b2>
- [20] COGNEX, “SISTEMAS DE VISIÓN IN-SIGHT 7000.” <https://www.cognex.com/es-es/products/machine-vision/2d-machine-vision-systems/in-sight-7000-series>
- [21] COGNEX, “PC-based vision software for the most challenging 2D and 3D vision applications.” <https://www.cognex.com/products/machine-vision/vision-software/visionpro-software>
- [22] Traxxas, “Traxxas BigFoot”, [Online]. Available: <https://traxxas.com/products/models/electric/bigfoot-classic>
- [23] F. Valocky, P. Drahos, O. Haffner, A. Kozakova, and M. Orgon, “Design of a R-ID in order to determine the position of the vehicle,” 2020. doi: 10.15439/2020F128.
- [24] Facebook, “Detectron 2,” 2021. <https://github.com/facebookresearch/Detectron>