

INOVATIVNO RJEŠENJE ZA ORIJENTACIJU VOZILA U PROSTORU

Kattae, Yakub

Undergraduate thesis / Završni rad

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Karlovac University of Applied Sciences / Veleučilište u Karlovcu**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:128:404236>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-12-27**



VELEUČILIŠTE U KARLOVCU
Karlovac University of Applied Sciences

Repository / Repozitorij:

[Repository of Karlovac University of Applied Sciences - Institutional Repository](#)



zir.nsk.hr



DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

VELEUČILIŠTE U KARLOVCU
STROJARSKI ODJEL
STRUČNI STUDIJ MEHATRONIKE

YAKUB KATTAE

INOVATIVNO RJEŠENJE ZA ORIJENTACIJU VOZILA U PROSTORU

ZAVRŠNI RAD

KARLOVAC, 2023.

KARLOVAC UNIVERSITY OF APPLIED SCIENCES
MECHANICAL ENGINEERING DEPARTMENT
PROFESSIONAL UNDERGRADUATE STUDY OF MECHATRONICS

YAKUB KATTAE

INNOVATIVE SOLUTION FOR VEHICLE ORIENTATION IN SPACE

FINAL PAPER

KARLOVAC, 2023.

VELEUČILIŠTE U KARLOVCU
STROJARSKI ODJEL
STRUČNI STUDIJ MEHATRONIKE

YAKUB KATTAE

INOVATIVNO RJEŠENJE ZA ORIJENTACIJU VOZILA U PROSTORU

ZAVRŠNI RAD

Mentor: dr. sc. V. Tudić, prof. struč. stud.

KARLOVAC, 2023.

PREDGOVOR

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu. Zahvaljujem se mentoru dr. sc. Vladimiru Tudiću, prof. struč. stud. na stručnoj pomoći i savjetima pri izradi ovog rada. Posebne zahvale upućujem svojim roditeljima, koji su mi, uz ostatak obitelji, bili najveća podrška i motivacija tijekom studiranja.

SAŽETAK

Tema završnog rada je Inovativno rješenje za orijentaciju vozila u prostoru. Za predmet izučavanja odabrano je autonomno vozilo, kao aktualna tema današnje autoindustrije. U radu su opisane relevantne informacije i činjenice koje su bitne za razumijevanje funkcioniranja autonomnih vozila. Najprije smo se pozabavili definiranjem navedenog vozila, potom analizom funkcije i načinom rada bitnih dijelova vozila, te principom funkcioniranja cjelokupnog sustava za orijentaciju vozila. Kako se radi o veoma složenim i sofisticiranim komponentama, odlučili smo se svaku pojedinačno opisati u sažetoj formi koja je primjerena ovom radu. U drugom dijelu rada opisana je jedna od inovativnih metoda o kojoj će u nastavku biti riječi. Nakon toga smo razradili prikaz suprotstavljenih tehnologija i razilaženja u pogledu rješenja u samoj autoindustriji. Odluka o odabiru upravo ove teme za završni rad leži u činjenici da je autonomno vozilo izazov suvremenog doba i novina koja se postavlja pred nove tehnologije koje su još u fazi razvijanja. U drugom dijelu rada opisana je jedna od inovativnih metoda o kojoj će u nastavku biti riječi.

SUMMARY

The topic of the final paper is Innovative solution for vehicle orientation in space. An autonomous vehicle was chosen as the subject of study, as a current topic in today's auto industry. The paper describes relevant information and facts that are essential for understanding the functioning of autonomous vehicles. First, we start with the definition of the mentioned vehicle, then with the analysis of the function and mode of operation of the essential parts of the vehicle, and the principle of functioning of the entire vehicle orientation system. As these are very complex and sophisticated components, we decided to describe each one individually in a concise form that is appropriate for this paper. In the second part of the work, one of the innovative methods is described, which will be discussed below. After that, we worked on a presentation of competing technologies and differences in terms of solutions in the auto industry itself. The decision to choose this topic for the final paper lies in the fact that the autonomous vehicle is a challenge of the modern era and a novelty that is set in front of a new technologies that are still in the development phase. In the second part of the work, one of the innovative methods is described, which will be discussed below.

SADRŽAJ

1. UVOD	1
2. TEORETSKI DIO	2
2.1.1 Autonomno vozilo definicija.....	2
2.1.2 Razvoj autonomnih vozila.....	2
2.1.3 Faze razvoja autonomnih vozila.....	3
2.1.4 Razine automatizacije.....	3
2.1.5 Princip rada autonomnih vozila.....	5
2.1.6 Upravljački sustavi autonomnih vozila	5
2.1.7 Osjetila autonomnih vozila.....	6
2.2.1 LIDAR.....	8
2.2.2 Važnost LIDAR tehnologije u AV	8
2.2.3 Kako LIDAR radi u AV?	9
2.2.4 Kako automobili koriste LIDAR da "vide" što je oko njih?.....	11
2.3 Radar	13
2.4 Ultrazvučni senzor.....	15
2.5 Karta visoke razlučivosti (HD).....	16
2.6 HD karte i visoko automatizirana vožnja	16
2.6.1 Slojevi HD mapiranja.....	17
2.7 Problematika autonomnih vozila.....	18
3 PRAKTIČNI DIO	20
3.1 UVODNA RIJEČ	20
3.2 PROTOTIP I DIZAJN SENZORA	20
3.3 UMJERAVANJE I OBRADA SLIKA	23
3.4 Rekonstrukcija panoramskog pogleda.....	25
3.5 Umjeravanje senzora za stereo vid.....	26
3.6 Mjerenje dubine iz stereo uređaja.....	28
3.7 REZULTAT	29
4. ZAKLJUČAK	33
Literatura	34

POPIS SLIKA

Slika 1. Predodžba faze razvoja autonomnih vozila kroz povijesti. Izvor [1].	3
https://www.caranddriver.com/news/a15343941/future-past-self-driving-cars-have-actually-been-around-for-a-while/	
Slika 2. Predodžba razine automatizacije autonomnih vozila kroz povijesti. Izvor [2].	5
https://www.europarl.europa.eu/news/hr/headlines/economy/20190110STO23102/automatizirana-vozila-u-eu-u-od-znanstvene-fantastike-do-realnosti	
Slika 3. Predodžba osjetila vozila [3].	7
https://autoedu.info/autoelektronika/senzori/	
Slika 4. Predodžba kretanja vozila u aktivnom stanju, gdje svi senzori pokrivaju vozilo sa svih strana. Svaki senzor radi pojedinačno u suradnji sa ostalim senzorima. Osjetila su specijalizirana i imaju karakteristično područje djelovanja. Svi senzori dijele isti cilj - detektiranje prepreka i izbjegavanje pogreške odnosno sudara. Izvor [4].	7
https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775	
Slika 5. Predodžba opisanog senzora za mapiranje terena (lidar), poznate tvrtke Velodyne, koja izrađuje veoma kvalitetne lidare. Izvor [5].	8
https://www.businesswire.com/news/home/20210414005619/en/Velodyne-Showcases-Advanced-Lidar-Solutions-at-Auto-Shanghai-2021	
Slika 6. Predodžba položaja lidara na vozilu. Izvor [6].	9
https://blog.lidarnews.com/fully-autonomous-cruise-av-has-5-lidar-sensors/	
Slika 7. Predodžba opisa rada lidara. Izvor [7].	10
https://www.researchgate.net/figure/LiDAR-sensor-mounted-on-an-AV-samples-points-from-the-ROI-and-generates-a-point-cloud_fig3_351298741	
Slika 8. Predodžba koordinatnog sustava lidara. Izvor [8].	10
https://www.researchgate.net/figure/Conversion-relationship-between-lidar-coordinates-and-image-coordinates-a-shows-an_fig2_347674995	
Slika 9. Predodžba detekcije terena i objekata lidarom. Izvor [9].	10
https://www.researchgate.net/figure/The-final-objects-detection-results-from-the-original-point-cloud-are-marked-with-blue_fig4_347674995	
Slika 10. Predodžba načina rada lidara. Izvor [10].	11
https://intertechdevelopment.com/2020/autonomous-vehicles-av-lidar-technology/	
Slika 11 (e, f). Predodžba okoline detektirana lidarom. Izvor [11].	12
https://www.researchgate.net/figure/Visualization-results-under-typical-cases-a-shows-the-detection-result-of-objects-in_fig5_347674995	
Slika 12. Predodžba okoline detektirana lidarom. Izvor [12].	12
https://www.wevolver.com/article/new.attack.on.autonomous.vehicle.sensors.create.fake.obstacles	
Slika 13. Predodžba okoline detektirana lidarom. Izvor [13].	13
https://www.theautochannel.com/news/2020/11/06/898857-its-america-webinar-showcases-how-lidar-based-solutions-can-increase.html	
Slika 14. Predodžba mogućeg položaja lidara. Izvor [14].	13
https://driving.ca/car-culture/auto-tech/what-is-lidar-and-how-is-it-used-in-cars	

Slika 15. Predodžba prikaza mogućih izvedbi radara u kratkom, srednjem i dugom dometu. Izvor [15].	14
https://i0.wp.com/semiengineering.com/wp-content/uploads/2017/11/Fig2.png?ssl=1	
Slika 16. Predodžba načina funkcioniranja ultrazvučnoga senzora. Izvor [16].	16
https://medium.com/@BabakShah/ultrasonic-sensors-in-self-driving-cars-d28b63be676f	
Slika 17. Predodžba budućnosti autonomnih vozila. Izvor [17].	19
https://www.tportal.hr/tehnoclanak/plase-li-autonomna-vozila-osiguravatelje-evo-sto-kazu-u-hrvatskoj-20170830	
Slika 18 a, b. Predodžba strukture kamere, vid kamere u praksi. Izvor [18].	21
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 19 a. Predodžba prototipa katadioptriske kamere i tipične web kamere. Izvor [19].	21
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 19 b. Predodžba mobilnog robota s opisanim sustavom. Izvor [20].	22
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 20. Predodžba geometrije modela katadioptriske kamere. Izvor [21].	24
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 21. Predodžba geometrijske rekonstrukcije panoramskih slika. Izvor [22].	25
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 22. Predodžba primjera panoramskih pogleda: dobiveni korištenjem postupaka (a) i rekonstruirani navedenom metodom (b). Izvor [23].	26
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 23. Predodžba geometrije hibridnog senzora vidnog polja s virtualnom kamerom. Izvor [24].	27
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 24. Predodžba rezultata spajanja katadioptriske i tipične web kamere. Primjeri slika za jedan od skupova objekata: iz perspektive kamera (a), od svesmjerne kamere (b) i rekonstruirana panoramska slika (c). Izvor [25].	29
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 25. Predodžba primjera rezultata za isti skup objekata: odgovarajući SIFT značajke (a) i rijetke 3D točke izmjerene na sceni (b). Izvor [26].	30
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 26. Predodžba Performansi detektora-deskriptora u rijetkom stereo-u. Izvor [27].	30
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 27. Predodžba podudaranja pomoću SIFT (a), SURF (b) i ORB (c) detektori i deskriptori na mjestu događaja br. 3. Izvor [28].	31
http://srv.uib.es/public/MFI2016/papers/0093.pdf	
Slika 28. Predodžba Tablice 1. Izvor [29].	32
http://srv.uib.es/public/MFI2016/papers/0093.pdf	

1. UVOD

Težnjom za boljim načinom života i zahvaljujući konstantnom razvoju znanosti, čovjeku je omogućeno da kontinuirano unapređuje svoje izume, pa tako i automobile. Kako je čovjek u svojoj prirodi sklon greškama, jedan od ciljeva autoindustrije je razvoj autonomnih vozila, kojim će biti povećana sigurnost u prometu, kojima će se težiti smanjenju saobraćajnih nesreća, te omogućiti komforniji i sigurniji oblik transporta. Kada govorimo o komociji bitno je istaći i uštedu vremena porošenog svakodnevnim prijevozom ili putovanjima...

Sve navedeno ne bi bilo moguće bez instrumenata za orijentaciju vozila, gdje se omogućava vozilu da „vidi“ detalje prostora oko sebe: predvidi opasnosti, spriječi nesreću, te da se dalje nesmetano kreće sigurno do odredišta bez ljudske intervencije. U ovom radu ćemo prikazati i detaljno objasniti bitnije elemente koji omogućavaju orijentaciju, te će se u praktičnom dijelu prikazati jedno od inovativnih rješenja inspiriranog perifernim vidom.

2. TEORETSKI DIO

2.1.1 Autonomno vozilo definicija

U službenom listu Europske unije od 27. studenoga 2019., objavljena je Uredba 2019/2144 Parlamenta i Vijeća EU u kojoj se nalazi slijedeća definicija za automatizirano vozilo i potpuno autonomno vozilo:

“Automatizirano vozilo znači motorno vozilo konstruirano i izrađeno kako bi se kretalo autonomno tijekom određenog razdoblja bez stalnog nadzora vozača, ali u odnosu na koje se intervencija vozača ipak očekuje ili je potrebna” i “potpuno automatizirano vozilo znači motorno vozilo koje je konstruirano i izrađeno kako bi se kretalo autonomno bez ikakva nadzora vozača” (Santai, 2021.). Autonomno vozilo (AV) ima mogućnost osjetiti svoju okolinu, vidjeti je i upravljati automobilom bez čovjekove pomoći, kontrole pa čak i prisustva. Slobodan je ići svugdje gdje ide i „obični“ automobil, raditi sve samostalno (Santai, 2021.). Glavna karakteristika AV je na softverskim sustavima i njihovim mogućnostima, a ne na podvozju i motoru, budući da oni pokreću vozilo i podložni su reprogramiranju, uređivanju, ažuriranju što dovodi do napretka strojnog učenje i poboljšanja samog vozila (Santai, 2021.). Kako još uvijek postoje tehnološke prepreke za postizanje potpune autonomnosti vozila, uobičajeno je govoriti o stupnjevima autonomnosti vozila. Evolucija razvoja autonomnih vozila odvija se u fazama, slično kao i kod razvoja automobila, koji je počeo od prvih sporih, parnih pogona, do automobila na benzinski pogon pa do današnjih, potpuno električnih vozila (Marina Pavlič 2021.).


2.1.2 Razvoj autonomnih vozila

Ideja autonomnih vozila započela je kada je Nikola Tesla 1898. godine bežično upravljao svojim primjerkom robota. Početkom 1925 inženjer Francis Houdina izradio je radiom kontrolirano vozilo Houdina Radio Control kojim je upravljao iz pratećeg automobila. U Japanu je 1977. uspješno kontrolirano upravljačem, mjenjačem i kočnicama pomoću računalnih naredbi baziranim na procjeni slikovnih sekvenci u realnom vremenu dobivenih kamerom. Daljnji napredak napravljen je na vozilu Mercedes S klasa (W140) koje je bilo opremljeno četirima crno-bijelim video-kamerama, milimetarskim radarom i osam mikroprocesora za prepoznavanje objekata i autonomno upravljanje. Tada su demonstrirane mogućnosti poput promjene staze i automatskog prestizanja drugih automobila (Santai, 2021.).

2.1.3 Faze razvoja autonomnih vozila

Sadašnji i budući razvoj autonomnih vozila može se opisati u tri faze:

1. Mješovita vozila - potpuno autonomna vozila i vozila kojima upravljaju vozači dijele cestu. Sva vozila imaju namjenskog vozača koji može preuzeti ručno upravljanje.
2. Mješovita vozila i vozila bez vozača - Veći postotak potpuno autonomnih vozila nego u prvoj fazi. Vozila mogu putovati bez vozača.
3. Sva vozila na cesti su potpuno autonomna - isključena su vozila s ručnim upravljanjem (Santai, 2021.).



Slika 1. Predodžba faze razvoja autonomnih vozila kroz povijesti. Izvor [1].

2.1.4 Razine automatizacije

Prema Pavlič (2021.) razlikuju se prema tome je li za uočavanje okoline, upravljanje kontrolama i globalni nadzor svih vozačkih zadataka odgovoran vozač ili vozilo. Ovisno o okolnostima u kojima je potrebna posebna raspodjela razine odgovornosti, definirane su sljedeće razine autonomnosti vozila:

Nulta razina (no automation) – manualna vožnja u kojoj automatizirani sustav izdaje upozorenja i može trenutačno djelovati, ako je to potrebno


Prva razina (hands on) – sustav pomoći omogućuje vozilu upravljanje ili ubrzavanje i kočenje, ali uz nadzor vozača. Primjer takvih sustava su tempomat i sustav za održavanje u traci

Druga razina (hands off) – vozilo obavlja prva dva zadatka vožnje iz prethodnih razina, a vozač je i dalje odgovoran za nadgledanje vožnje, i mora biti spreman intervenirati u bilo kojem trenutku, ako automatizirani sustav ne reagira pravilno

Treća razina (eyes off) – vozač može sigurno skrenuti pozornost sa zadataka vožnje jer vozilo upravlja svojom putanjom, ali samo kod dobro referencirane putanje, i zbog toga vozač i dalje mora biti spreman za intervenciju

Četvrta razina (mind off) – nikada ne zahtijeva pozornost vozača, a autonomna vožnja podržana je samo u ograničenim područjima, ili u posebnim okolnostima, a izvan tih područja vozilo mora samo prekinuti autonomnu vožnju. Zadaće vozila uključuju operativne (upravljanje, usporavanje, kočenje, ubrzanje i nadzor) i taktičke aspekte (promjena kolničke trake, skretanje, poštivanje prometnih znakova i reakcija na incidentne situacija).

Peta razina (steering wheel optional) – ne zahtijeva prisutnost vozača. Zadaće vozila uključuju operativne (upravljanje, usporavanje, kočenje, ubrzanje i nadzor) i taktičke aspekte (promjena kolničke trake, skretanje, poštivanje prometnih znakova, reakcija na incidentne situacija itd.). Kod pete razine, koja se još naziva i razinom potpune automatizacije, vozač mora samo odrediti odredište i točke zaustavljanja na putu, bez obzira na složenost scenarija (Pavlič, 2021.).



Slika 2. Predodžba razine automatizacije autonomnih vozila kroz povijesti. Izvor [2].

2.1.5 Princip rada autonomnih vozila

Autonomna vozila rade uz pomoć senzora, složenih algoritama, sustava strojnog učenja, procesora, kamera koji su raspoređeni na različitim dijelovima vozila, na osnovu kojih stvaraju i održavaju kartu svog okruženje (Santai, 2021.).

2.1.6 Upravljački sustavi autonomnih vozila

Autonomna vozila temelje se na naprednim sensorima, koji prikupljaju informacije o okolini, na dubokim višeslojnim neuronskim mrežama i dubokom učenju (engl. Deep Learning), koji se koriste za raspoznavanje prometnica, vozila, objekata i osoba, iz podataka prikupljenih od senzora, te za upravljanje vozilom (Pavlić, 2021.).

Skupovi senzora na autonomnim vozilima (kamere, lidari, radari...) nadopunjuju jedni druge i nadoknađuju sve slabosti bilo kojeg korištenog senzora. Iako su robotski sustavi, u koje se ubrajaju i autonomna vozila, vrlo uspješni u prikupljanju podataka o okolini, razumijevanje tih podataka ostaje vjerojatno najteži dio razvoja iznimno pouzdanog autonomnog vozila. Temelj većine robotskih sustava, pa tako i autonomnih vozila, zasniva se na načelu "osjeti – planiraj – djeluj" pa tako vozilo najprije skupom


senzorskih sustava kojima je opremljeno, prikuplja podatke o vanjskom svijetu i vlastitoj okolini. Nakon toga, naprednim algoritmima obrađuje prikupljene podatke, i prema tome izrađuje planove o odlukama koje treba donijeti. Na temelju izrađenog plana djelovanja, plan se pretvara u djelotvorne naredbe za upravljački sustav vozila. Navedene naredbe mogu biti vezane za upravljač, kočnice, tempomat ili sličan sustav, a istodobno se može izvršavati više petlji u “osjeti – planiraj – djeluj” principu. Jedna petlja može pokrenuti ubrzanje ili kočenje u nuždi, dok se druga petlja izvodi rjeđe, a planira i izvršava složenije zadatke, kao što je promjena trake kolnika (Pavlič, 2021.).

Postoje i ekstremno kratke aktivnosti planiranja, poput incidentnih situacija, kada prikupljeni podaci iz senzora ukažu da je prepreka na maloj udaljenosti ispred vozila. U tom trenutku, automatski se mora pokrenuti kočenje u nuždi. U takvim kritičnim situacijama planiranje u petlji iz načela “osjeti – planiraj – djeluj” pretvara se u načelo “osjeti – djeluj”. U ovom slučaju podaci iz senzora izravno pokreću naredbe za djelovanje automobila. Incidentne situacije, poput reakcije na iznenadne pojave pješaka na kolniku, spadaju među najveće izazove koji se pojavljuju ispred autonomnih vozila. Izvrsna percepcija okoline koju senzori detektiraju i iz nje prikupljaju podatke, uz sofisticirane algoritme umjetne inteligencije koja ih tumači, dopuštaju autonomnim vozilima kvalitetno planiranje i visoku pouzdanost vožnje (Pavlič, 2021.).

Sama ideja razvoja autonomnih vozila temelji se na činjenicama da se takva vozila nikad ne umaraju, kako njihovi algoritmi planiranja mogu izabrati optimalno ponašanje u prometu, i njihovo izvršavanje može biti brzo i besprijekorno, jer im se ni u jednoj situaciji ne povećava vrijeme reagiranja, niti mogu pogriješiti u izvršavanju naredbe kao vozač. Ljudski vid prikuplja sve podatke koje autonomnom vozilu pružaju skupovi senzora. Ljudske kognitivne sposobnosti značajno nadilaze sposobnosti autonomnih vozila. Ljudi također puno bolje tumače i razumijevaju dobivene vizualne informacije. Pa ipak, ljudski vid i percepcija vizualnih informacija mogu biti ograničeni u određenim situacijama, poput nepovoljnih vanjskih uvjeta, umora, neuroloških problema, ili pod utjecajem različitih opijata (Pavlič, 2021.).


2.1.7 Osjetila autonomnih vozila

U ovom poglavlju prikazat će se razni sustavi koji omogućavaju samostalan rad autonomnih vozila, koji predstavljaju imitaciju ljudskih osjetila.



Slika 3. Predodžba osjetila vozila [3]

Na sljedećoj slici, prikazani su mnogobrojni senzori jednog autonomnog vozila.



Slika 4. Predodžba kretanja vozila u aktivnom stanju, gdje svi senzori pokrivaju vozilo sa svih strana. Svaki senzor radi pojedinačno u suradnji sa ostalim sensorima. Osjetila su specijalizirana i imaju karakteristično područje djelovanja. Svi senzori dijele isti cilj - detektiranje prepreka i izbjegavanje pogreške odnosno sudara. Izvor [4].

2.2.1 LIDAR

Cijev koja se brzo okreće postavljena na krov je LIDAR jedinica. Njegova uloga je mjerenje udaljenosti objekata u odnosu na položaj automobila u 3D-u (Port, 2022.).

LIDAR je skraćenica za detekciju i domet svjetlosti i smatra se najnovijom tehnologijom mapiranja. Kako tehnologija postaje sve profinjenija, LIDAR otkriva više mogućnosti primjene u inženjerstvu. To uključuje ključnu ulogu u razvoju AV. Većina LIDAR sustava sastoji se od četiri komponente koje rade zajedno kako bi dale rezultate:

1. Laser: sažima svjetlosne impulse sve dok ne udari u objekt i reflektira se natrag u LIDAR sustav.
2. Prijemnik: hvata laserske točke koje pingaju natrag u sustav.
3. Skener: grupira primljene laserske točke u "oblak točaka" kako bi stvorio 3D model objekata u svojoj okolini.
4. Globalni sustav pozicioniranja (GPS): bilježi precizne koordinate lokacije skeniranih 3D objekata u odnosu na položaj LIDAR senzora (Port, 2022.).



Slika 5. Predodžba opisanog senzora za mapiranje terena (lidar), poznate tvrtke Velodyne, koja izrađuje veoma kvalitetne lidare. Izvor [5].

2.2.2 Važnost LIDAR tehnologije u AV

Tehnologija LIDAR omogućuje AV donošenje proračunatih odluka svojom sposobnošću otkrivanja objekata u neposrednoj okolini. Može se smatrati "skupom očiju" vozila i najvažnijom komponentom u pretvaranju AV u stvarnost. Proizvođači automobila koriste


ovu tehnologiju dok se natječu u razvoju sigurnih AV. LIDAR sustavi mogu vidjeti stvari koje nadilaze ljudske sposobnosti. LIDAR je tehnologija preciznosti u prikupljanju podataka i izračunavanju točnih udaljenosti, koja promiče sigurnost AV (Port, 2022.).




Slika 6. Predodžba položaja lidara na vozilu. Izvor [6].

2.2.3 Kako LIDAR radi u AV?


LIDAR omogućuje vozilu da vidi kamo ide. LIDAR sustav radi mjerenjem udaljenosti objekata u odnosu na položaj AV kako bi se stvorila 3D replika okoline. Integrirani računalni sustav mjeri vrijeme između početnih laserskih impulsa i prijemnika koristeći brzinu svjetlosti za izračunavanje udaljenosti koju je svjetlost prešla. LiDAR svake sekunde emitira i izračunava podatke iz 100.000 laserskih impulsa. Koristi te podatkovne točke za formiranje oblaka točaka i stvaranje 3D modela objekata u svojoj okolini. Nakon što LiDAR vidi objekte, on ih identificira (tj. vozila, pješake) i predviđa njihovo ponašanje kako bi odredio reakciju vozila (Port, 2022.).



Slika 7. Predodžba opisa rada lidara. Izvor [7].




Slika 8. Predodžba koordinatnog sustava lidara. Izvor [8].




Slika 9. Predodžba detekcije terena i objekata lidarom. Izvor [9].

2.2.4 Kako automobili koriste LIDAR da "vide" što je oko njih?


Poznavanje udaljenosti između dva objekta ne odnosi se samo na mjerenje udaljenosti od točke do točke, već i kuta LIDAR jedinice i kuta pod kojim je puls ispaljen. Često nisu potpuno glatke kada je automobil u pokretu, ljulja se s jedne strane na drugu. Laserski impuls ispaljen vodoravno s vrha automobila možda neće biti vodoravan u odnosu na cestu. Uzimanje ovoga u obzir je od iznimne važnosti pri mjerenju okoline automobila. Mala promjena kuta mogla bi značiti razliku između sudara ili zaustavljanja dva automobila u vremenu, jer mijenja vrijeme putovanja svjetlosti između dvije točke. Praćenje ovih promjena kuta i unošenje tih podataka u računalo, uloga je onoga što se naziva inercijalna mjerna jedinica. Ova jedinica, laserska jedinica i računalo rade zajedno kako bi pratili udaljenost tisuća točaka svake sekunde oko cijelog vozila. To pomaže u izradi digitalne slike koja automobilu omogućuje da 'vidi' što je oko njega, a radi u mrklom mraku (Port, 2022.).



Slika 10. Predodžba načina rada lidara. Izvor [10].




(e)




(f)

Slika 11 (e, f). Predodžba okoline detektirana lidarom. Izvor [11].



Slika 12. Predodžba okoline detektirana lidarom. Izvor [12].



Slika 13. Predodžba okoline detektirana lidarom. Izvor [13].




Slika 14. Predodžba mogućeg položaja lidara. Izvor [14].

2.3 Radar

Neki automobili i kamioni opremljeni su sensorima kretanja koji detektiraju udaljenost između vozila i bilo kojeg vozila ili velikih predmeta ispred vozila. Ove senzore koriste prilagodljivi tempomat i/ili sustavi za izbjegavanje sudara. Većina postojećih senzora kretanja koristi radar od 76,5 GHz, ali koriste se i druge frekvencije (npr. 24 GHz, 35 GHz i 79 GHz). Neki sustavi koriste infracrvene senzore umjesto (ili uz) RADAR senzore (Brain, 2000.).

RADAR and the Autonomous Vehicle



Slika 15. Predodžba prikaza mogućih izvedbi radara u kratkom, srednjem i dugom dometu. Izvor [15].

Postoje dvije osnovne metode mjerenja udaljenosti pomoću radara. Prva je poznata kao metoda izravne propagacije i mjeri kašnjenje povezano s prijamom reflektiranog signala koje se može povezati s udaljenošću reflektirajućeg objekta kao funkcijom brzine svjetlosti i perioda ili bolje rečeno vremenskog kašnjenja u prijenos i prijem valova. Druga metoda poznata je kao metoda neizravne propagacije ili metoda frekvencijski moduliranog kontinuiranog vala (FMCW). Za neizravno širenje, modulirana frekvencija se šalje i prima, razlika u frekvenciji može se koristiti za izravno određivanje udaljenosti kao i relativne brzine objekta (Brain, 2000.).

Radarski signali vrlo su dobri u otkrivanju objekata koji snažno reflektiraju elektromagnetsko zračenje (npr. metalni predmeti). Budući da rade na valnim duljinama reda veličine nekoliko milimetara, automobilske radarske sustave prilično su dobri u otkrivanju objekata koji su nekoliko centimetara ili veći. Također su dobri u gledanju kroz (tj. ignoriranju objekata koji su mali u odnosu na valnu duljinu (npr. kapljice vode u magli) (Brain, 2000.).

Radarski senzori sastavni su dio naprednih sustava za pomoć vozaču (ADAS) u modernim automobilima. Dok su radarski senzori posebno vitalni za autonomna vozila, oni također poboljšavaju značajke sigurnosti i udobnosti za vozače. Radarski senzori za automobile obično se koriste za otkrivanje mrtvog kuta (BSD), pomoć pri promjeni trake (LCA), ublažavanje sudara (CM), pomoć pri parkiranju (PA) i značajke upozorenja na križni promet straga (RCTA). Infineon nudi širok izbor automobilske radarske senzora uključujući radarske senzore kratkog, srednjeg i dugog dometa (Brain, 2000.).

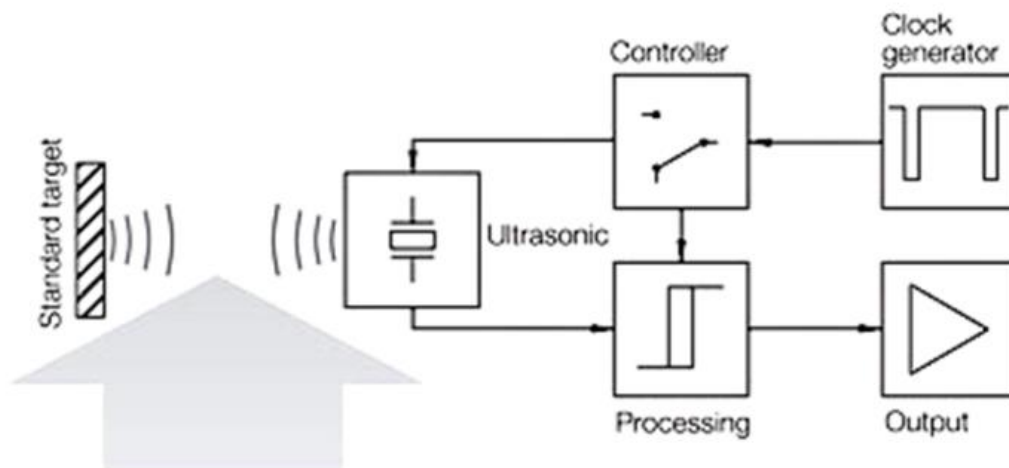
2.4 Ultrazvučni senzor

Sonar je kratica za zvučnu navigaciju i određivanje udaljenosti. Koristi se u vozilima kao podrška vozačima u njihovim zadacima vožnje poput parkiranja i otkrivanja prepreka u blizini (Shahian, 2019.).

Ultrazvučni senzori šalju kratke ultrazvučne impulse koji se odbijaju od prepreka. Echo signali se zatim primaju i obrađuju. Unutar plastičnog kućišta ultrazvučnog senzora nalaze se glavne komponente, ultrazvučni pretvornik. Sastoji se od aluminijske posude s dijafragmom koja sadrži piezokeramički element). Senzor prima digitalni prijenosni signal od ECU-a. To uzrokuje da aluminijska dijafragma oscilira pravokutnim valovima oko 300 μ sec s rezonantnom frekvencijom od oko 48 kHz što rezultira emisijom ultrazvučnih impulsa. Dijafragma se tada opušta oko 900 μ sec (tijekom kojih nije moguć prijem) prima reflektirani zvuk od prepreke i vibrira. Ove vibracije emitira piezokeramički element kao analogne signale, zatim se pojačavaju i pretvaraju u digitalni signal (Shahian, 2019.).

Ultrazvučni senzor dostupan je u tri mehanički kompatibilne varijante senzora:

1. Raspon detekcije: maks. 2,5 m, min. 15 cm; prisutnost predmeta 6 cm
2. Raspon detekcije: max. 4,5 m, min. 15 cm; prisutnost predmeta 3 cm
3. Raspon detekcije: maks. 5,5 m, min. 15 cm; prisutnost predmeta 3 cm. Postoje različite vrste radara na temelju dometa i kuta snopa. Ultrazvučni senzori u samovozećim automobilima obično imaju širok horizontalni raspon senzora (min. 15 cm do maks. 2–6 m, ovisno o vrsti senzora) i uzak vertikalni raspon senzora kako bi se izbjegle refleksije od zemlje (Shahian, 2019.).



Slika 16. Predodžba načina funkcioniranja ultrazvučnog senzora. Izvor [16].

2.5 Karta visoke razlučivosti (HD)

Visoko automatizirana i autonomna vozila zahtijevaju karte visoke preciznosti s točnošću do centimetra za lokalizaciju i predznanje za sustave kao što su percepcija, navigacija i kontrola. Karte visoke rezolucije, s detaljnom geometrijom i semantičkim informacijama o okolišu, omogućuju visoko automatiziranu vožnju. Mogu se smatrati još jednim sensorom autonomnim vozilima (AV) budući da pomažu u donošenju odluka i smanjuju nepredvidivost (Jain i sur., 2021.).

Ovaj rad duboko se bavi potrebom za kartama visoke razlučivosti (HD), načinom na koji one pomažu u visoko automatiziranoj vožnji te njihovom trenutnom primjenjivošću i budućim opsegom (Jain i sur., 2021.).

2.6 HD karte i visoko automatizirana vožnja

Razine autonomije u vozilima kategorizirane su prema SAE1 od razine 0, što je bez automatizacije, do razine 5, koja je potpuno autonomna. Karte visoke preciznosti preduvjet su za razinu 3 i više, što su visoke razine automatizacije s progresivnim smanjenjem ljudske ovisnosti (Jain i sur., 2021.). HD karte sadrže važne dijelove informacija poput osnovnog geometrijskog profila ceste uključujući zakrivljenost, nagib, širinu trake, broj traka po smjeru, između ostalog. Ove informacije se nadopunjuju osnovnim donošenjem odluka koje su ljudskim bićima "prirodne". Na primjer, ako se netko nalazi u krajnjoj desnoj traci dok skreće desno, a zatim nakon skretanja, vozilo obično ostaje u krajnjoj desnoj traci. Ove informacije su "kodirane" u HD kartama kao "povezanost traka". Granice traka, središte traka, cestovne barijere, zaustavne trake,

rubnjaci, odnosi prinosa na raskrižjima (znakovi za zaustavljanje i odstupanje) sve je to "poznato" HD kartama (Jain i sur., 2021.).

2.6.1 Slojevi HD mapiranja

Različiti pružatelji govore o različitom broju slojeva u HD karti, ali svi sugeriraju da se razina inteligencije (npr. analitika iza informacija pohranjenih u sloju) povećava od osnovnog sloja. Osim toga, što je veća razina autonomije vozila, veći je broj slojeva koji se koriste (Jain i sur., 2021.).

Na primjer, vozilo L1 ili L2 koristilo bi najniži sloj (s referencom na mape tehnologije Here2) i donja 3 sloja (karte Lyft LEVEL53), a tako korištena karta naziva se ADAS karta. L3 i više razine autonomije koriste sva 3 sloja Here tehnoloških karata i svih 5 slojeva LEVEL5 karata te su HD karte. HERE HD karte su logično strukturirane u 3 sloja - model ceste, HD model trake i HD model lokalizacije. Sloj modela ceste sadrži topologiju ceste, geometriju središnje linije ceste i attribute razine ceste. Sloj HD Lane Model uključuje podatke o topologiji trake i attribute na razini trake. Sloj HD lokalizacijskog modela uključuje različite značajke za podršku strategijama lokalizacije. Inteligentni slojevi nalaze se na vrhu HD karte. Na primjer, sloj aktivnosti je dinamički sloj koji bilježi kratkoročne promjene na cestovnoj mreži. Najviši sloj je analitički sloj, koji opisuje kako ljudska bića voze bilo koju dionicu ceste (Jain i sur., 2021.).

Pet slojeva Lyft mapa su Osnovna karta, Geometrijska karta, Semantički sloj karte, Prijašnji sloj karte i sloj znanja u stvarnom vremenu. Osnovna karta u kombinaciji sa slojem geometrijske karte i semantičkim slojem karte LEVEL5 karata prenosi statičke informacije. Statički sloj nalikuje komercijalnim kartama kojima danas pristupamo na našim mobilnim telefonima s više detalja o značajkama, trakama i informacijama o infrastrukturi vožnje. Dinamički sloj ili prethodni sloj karte pokriva privremene promjene statičkog sloja, kao što su zone nesreća, dionice izgradnje cesta ili održavanja te također podaci o ljudskom ponašanju. Podaci kao što su vremenski, statistički, probabilistički, analitički ulazi u kartu koji su zlato za autonomno vozilo, također su dio HD karata budući da dodaju ukupnim mogućnostima predviđanja AV-a (Jain i sur., 2021.). Vizualna percepcija za autonomna vozila koji koriste sustav više kamera: umjeravanje, mapiranje, lokalizacija i detekcija prepreka. Kamere su prirodan izbor kao primarni senzor za autonomna vozila budući da su oznake voznih traka, prometni znakovi, semafori i druga navigacijska pomagala dizajnirani za ljudski vizualni sustav. U isto vrijeme, kamere pružaju podatke za širok raspon zadataka koje zahtijevaju

autonomna vozila, uključujući 3D mapiranje, vizualnu lokalizaciju i 3D otkrivanje prepreka tijekom rada u unutarnjim i vanjskim okruženjima. Za potpunu autonomiju važno je da automobil može uočiti objekte oko sebe. To se može postići korištenjem sustava s više kamera koji pokriva cijelo vidno polje od 360° oko automobila. Kamere sa širokim vidnim poljem, mogu se koristiti za smanjenje broja potrebnih kamera, a time i ukupne cijene sustava (Häne i sur., 2017.). Umjeravanje je bitan preduvjet za korištenje sustava s više kamera u autonomnoj vožnji. Projekcija točke 3D scene na točku slike zahtijeva poznavanje i unutarnjih i vanjskih parametara za sustav s više kamera uz pozu vozila (Häne i sur., 2017.). Neprecizna umjeravanja utječu na sve dijelove cjevovoda vizualne percepcije, što dovodi do netočnih rezultata mapiranja, lokalizacije i otkrivanja prepreka. Nadalje, promjene okoliša, habanje i vibracije uzrokuju polagano odstupanje umjeravanja parametara od njihovih stvarnih vrijednosti tijekom vremena. Algoritmi temeljeni na više kamera osjetljivi su na takve pogreške, pa su potrebna česta ponovna umjeravanja. Stoga su se razvile metode automatskog umjeravanja za automobilski sustav s više kamera, koji je sposoban procijeniti točne parametre umjeravanja (Häne i sur., 2017.). Odabrani sustav kamera sadrži četiri kamere koje su montirane na automobil tako da imaju minimalno preklapanje što omogućuje pokrivenost od 360 stupnjeva. Iako bi bili mogući složeniji sustavi s dvoglednim parovima, koristi samo mali broj kamera kako bi troškovi i složenost bili niski. Korištenje više kamera dovelo bi do gušćeg očitavanja okoliša, ali bi također povećalo složenost i cijenu sustava. Mnogi se zadaci potrebni za aplikacije autonomnih vozila pri malim brzinama mogu implementirati pomoću takve postavke kamere (Häne i sur. 2017.).

2.7 Problematika autonomnih vozila

Prednost autonomnih vozila, uvjeravaju nas njihovi zagovornici, bit će između ostalog i u tome što mogu spasiti živote tako što će za upravljačem nepouzdana i nepredvidljiva ljudska bića zamijeniti precizna i pametna računala. Iako taj argument (još) nije u potpunosti utemeljen u stvarnim dostignućima robotike i umjetne inteligencije, pitanje koje plaši skeptike i užasava zaposlenike u osiguravajućim kućama glasi: kako zaštititi vozače i druge sudionike u prometu u prijelaznom razdoblju? (Miroslav Wranka, 2017).



Slika 17. Predodžba budućnosti autonomnih vozila. Izvor [17].

Autonomna vozila su veoma korisna i olakšavaju ljudski život, ali postavlja se pitanje da li će u bliskoj budućnosti postojati potpuno autonomno vozilo, koje će funkcionirati bez ljudske pomoći i bez grešaka. Odgovor na to pitanje ostaje da se vidi. Dio smo suvremenog društva, koje karakterizira brz tehnološki napredak i brze promjene. U tim promjenama bitno je ne zanemariti neke osnovne ljudske humane principe od kojih se mnogi sukobljavaju sa idejama i vizijama potpune robotizacije stvarnosti. Ne treba izgubiti iz vida osnovnu svrhu tehnologije (olakšati čovjeku) i ne treba dopustiti da tehnologija naštetiti samom čovjeku i njegovom humanom karakteru i moralu. Ako je uz pomoć autonomnog vozila moguće pratiti kretanje ljudi, ako će biti podložni hakerskim napadima, ako će olakšati kriminalcima posao prevoženja nedozvoljene robe – u tom slučaju otvaramo nove izazove kako se nositi sa nus-pojavama novog proizvoda autoindustrije. Autonomna vozila najveću primjenu nalaze u vojne svrhe, gdje se bitka zapravo vodi između vještine inženjera suprotstavljenih strana, gdje cijenu plaćaju upravo ljudi svojim životima. S druge strane autonomna vozila su oblikovana da olakšavaju čovjeku, jer ljudski napor preuzima robot i obavlja za njega rad.

3 PRAKTIČNI DIO

U ovom dijelu rada govorit će se o katadioptričkoj kameri u kombinaciji s tipičnom web kamerom, kao biološka inspiracija perifernog vida kod životinja. U nastavku će se detaljno razraditi to inovativno rješenje.

3.1 UVODNA RIJEČ

Danas kamere čine veoma kompaktan i jeftin eksteroceptivni senzori za mobilne robote. Kamere, koje oponašaju ljudski vid, daju oko 90% izvora informacija iz okoline. Što je s ostalih 10% informacija oko nas, koje mogu uzrokovati velike štete samom robotu i njegovoj okolini?


Ovdje smo spojili katadioptriske kamere zajedno sa klasičnom kamerom, što daje veoma zanimljivo inovativno rješenje.

Najprije krećemo iz same definicije. Što je to katadioptriska kamera, kako funkcionira?

Sama ideja katadioptriske kamere inspirirana je perifernim vidom. Ideja je dobila veliku pozornost u mobilnoj robotici, gdje sama kamera, koja se do tada koristila, iako daje bogat opis okoline, ima dovoljno ograničenja, a gdje primjenu nalaze katadioptriske kamere. Jedna kamera daje informacije o smjeru bez indikacija dometa do objekata unutar ograničenog vidnog polja pogleda. Uvođenjem katadioptriske kamere situacija se mijenja.

3.2 PROTOTIP I DIZAJN SENZORA

Tipičan primjer katadioptriske kamere prikazan je na slikama a i b. Radi se zapravo o veoma jednostavnom sustavu, koji se sastoji od kamere, koja je postavljena vertikalno prema gore postavljenoj, profiliranoj paraboličnoj leći, odnosno ogledalu. Kamera ima široki kut gledanja odnosno kut od 360°.




Slika 18 a, b. Predodžba strukture kamere, vid kamere u praksi. Izvor [18].

Prototip našeg senzora (slika a) koristi katadioptričku kameru sa zrcalom i tipičnu web kameru. Višesmjerni dio pruža periferni vid, dajući robotu mogućnost otkrivanja zanimljivih objekata ili događaja na širokom polju u stvarnom vremenu. Prednja kamera omogućuje robotu fokusiranje uskovidnog polja na otkrivene objekte .



Slika 19 a. Predodžba prototipa katadioptričke kamere i tipične web kamere. Izvor [19].

Obrada slika dobivenih u stvarnom vremenu iz ovih kamera osigurava jednodimenzionalno računalo Nvidia Jetson TK-1. Zahvaljujući korištenju ovog energetski učinkovitog i kompaktnog, ali snažnog računala s GPGPU - jedinica za grafičku obradu (General Purpose Graphics Processing Unit) uspjeli smo dizajnirati potpuno integriranu senzorsku jedinicu, koja ne samo da ispravlja geometriju višesmjernih slika i raspakira ih u stvarnom vremenu, već također implementira mjerenja udaljenosti. Sve je to ugrađeno u senzor, što omogućuje korištenje naš sustav vizije na malim i/ili ograničenim resursima mobilnih robota.



Slika 19 b. Predodžba mobilnog robota s opisanim sustavom. Izvor [20].

Hibridni senzor vidnog polja sastoji se od dva karakteristična dijela : svesmjerna kamera i perspektivna kamera kojom upravlja jednodlačno računalo Jetson TK-1. Višesmjerni dio kombinira kameru, a dio koji gleda prema gore i profilirano zrcalo smješteno je neposredno iznad nje. Mi smo odabrali hiperbolično zrcalo, koje omogućuje postizanje jednostavno i učinkovito svojstvo gledišta. Hiperbolički profil dan

$$y = \sqrt{7295.64 \left(\frac{x^2}{810.63} + 1 \right)}$$

je jednadžbom:

Može se proizvesti po prihvatljivoj cijeni od aluminijske ploče. Ogledalo promjera 50 mm drži se za prozirnu akrilnu cijev, iznad objektiva kamere. Višesmjerni dio koristi kameru E-Cam130 CUTK1 s CSI-2 MIPI sučeljem. Ova kamera je specijalizirana za ploču Jetson TK-1 i može slati visoku rezoluciju slika izravno u GPGPU memoriju. E-Cam130 CUTK1, opremljen je sa See3CAM CU130 lećama od 58° kuta gledanja, može raditi s rezolucijom do 4224×3156, ali odabrali smo 1920×1080 rezoluciju slike kako bismo postigli brzinu od 30 FPS. Perspektivni dio senzora koristi montiranu kameru na aluminijsku ploču, na gornjem kraju akrilne cijevi, točno iznad središta hiperboličkog zrcala. Da bi senzor bio jeftin, korištena je tipična Logitech 500 web kamera, koja se drži na kraju 3d isprintane plastične cijevi. Rezolucija ove kamere je 1280×1024, a sučelje je USB 2.0. Obje kamere su spojene na računalo Nvidia Jetson TK1, koji koristi sustav na čipu Tegra K1 dizajniran s četiri jezgre ARM Cortex-A15 2,3 GHz i 192852MHz grafičke jezgre u Kepler arhitekturi. Jetson TK-1 pokreće prilagođeni Linux 4 Tegra i podržava CUDA (Compute Unified Device Architecture) proračune. Svi zadaci obrade slike su

zatvoreni u obliku kapsule u jednopločnom računalu senzora, koji doseže 300 GFLOP/s u načinu rada s jednom preciznošću, dok troši samo 14 W snage (CPU i GPGPU).


3.3 UMJERAVANJE I OBRADA SLIKA

Umjeravanje standardne, perspektivne kamere može se postići jednostavnom primjenom jednog od dostupnih Matlab-a toolboxa ili korištenjem procedura iz OpenCV biblioteke. Iz literature su poznati i postupci umjeravanja za višesmjernne kamere, ali oni se često fokusiraju na određene vrste fotoaparata, koje zahtijevaju precizno poznavanje parametara zrcala ili dodatnu opremu za izvođenje umjeravanja.

Mogu se koristiti i postojeći alati za izračunavanje ekstrinzičnih parametara stereo para. Nažalost, standardni postupak za stereo umjeravanje ne može se primijeniti na naš hibridni senzor zbog geometrije izobličenja u višesmjernim slikama, koje se moraju ukloniti prije izdvajanja bilo kakvih metričkih informacija iz ove slike. Stoga predlažemo jednostavnu, ali učinkovitu shemu umjeravanja, koja iskorištava postojeće alate za umjeravanje perspektivne i katadioptriske kamere i zahtijeva samo prikupljanje slika jednostavnog uzorka umjeravanja, koji se nalazi na različite pozicije. Najprije je potrebno umjeravanje sustava kamera-zrcalo, da bi se moglo odrediti parametre matematičkog modela koji opisuje formiranje slike u katadioptričkom senzoru. Koristimo model koji je uveo Scaramuzza, prikazan na sljedećoj slici, a opisan je jednačbom:

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \begin{bmatrix} u \\ v \\ f(u, v) \end{bmatrix} = \begin{bmatrix} u \\ v \\ f(\rho) \end{bmatrix}$$

gdje su (u, v) koordinate projekcije točka p na idealiziranu (neiskrivljenu) sliku formiranu na ravninu okomitu na os zrcala, x, y i z definiraju vektor označavajući sliku ove točke na zrcalu,



Slika 20. Predodžba geometrije modela katadioptriske kamere. Izvor [21].

dok ρ je udaljenost projicirane točke p' od središta idealizirane slike. U našem modelu preslikavanje udaljenosti treba identificirati funkciju $z = f(\rho)$, što se pretpostavlja da će biti zadana polinomom 4. reda $z = a_0 + a_1\rho + a_2\rho^2 + a_3\rho^3 + a_4\rho^4$. Određen je i najbolji poredak polinoma uklapanjem iterativnih polinoma rastućeg reda i uočavanje grešaka reprojeckije. Vektor procijenjenog parametra $= a_0 \dots a_4$ identificiran je korištenjem planarne šahovske ploče uzorka poznate veličine opažen sensorom na različitim, ali nepoznatim pozicijama. Postupak umjeravanja također procjenjuje središte višesmjernе slike $O_c = [u_c, v_c]^T$ i afinu matricu $A^{(2 \times 2)}$ koja povezuje stvarnu sliku koordinate (u', v') i (u, v) koordinate idealizirane slike. Prikazano je dvanaest slika šahovskih ploča sa 63 polja koji se koristi za ovo umjeravanje, s uzorkom, koji prekriva cijelo vidno polje kamere. To je omogućilo algoritmu umjeravanje da kompenzira odstupanja između središta kamere i zrcala. Na kraju su parametri modela kamere bili rafinirani korištenjem Levenber-Marquadt algoritma.


Zatim, unutarnji parametri perspektivne kamere umjeravaju se pomoću Camera Calibration Toolbox za Matlab. Model izobličenja identificiranih ovim postupkom sastoji se od 5 koeficijenata koji opisuju radialne i tangencijalna izobličenja slike. Procijenjena perspektiva matrica kamere:

$$K_p = \begin{bmatrix} f_{c_1} & a_c f_{c_1} & c_{c_1} \\ 0 & f_{c_2} & c_{c_2} \\ 0 & 0 & 1 \end{bmatrix}$$

sadrži horizontalnu i vertikalnu žarišnu duljinu f_{c_1} , f_{c_2} , središte slike koordinate c_{c_1} , c_{c_2} , i zakrivljenost piksela koeficijent a_c . Ovaj postupak umjeravanja je također visoko automatizirano, te je pohranjeno s 20 slika istog uzorka, koji je korišten za umjeravanje višesmjernog dijela.

3.4 Rekonstrukcija panoramskog pogleda

Katadioptrička kamera daje mogućnost rekonstrukcije 360° panoramskog prikaza scene. To daje robotu informacije o objektima oko njega, pod pretpostavkom da se robot kreće po približno ravnoj površini. U tom slučaju prepreke koje se nalaze bliže robotu pojavljuju se u donjem dijelu panoramske slike, dok su udaljeniji objekti vidljivi u gornjem dijelu. Informacije o objektima u stvarnom vremenu iz panoramske slike može se pretvoriti u lokalnu kartu zauzetog i slobodnog prostora oko robota i koji se koristi za izbjegavanje prepreka. Ovo implementira periferni vid u našem senzoru, dajući robotu informacije u kojem smjeru i gdje se treba okrenuti da traži predmete. Zatim, udaljenost do ovih objekata može se mjeriti iz stereo-a.



Slika 21. Predodžba geometrijske rekonstrukcije panoramskih slika. Izvor [22].

Moguće je ispraviti iskrivljenu višesmjernu sliku, te stvoriti geometrijski ispravnu panoramsku sliku pomoću umjerenog modela katadioptričke kamere. Da bi postigli panoramsku sliku, koja je kompatibilna s poljem pogleda na perspektivnu sliku našeg hibridnog senzora gdje pratimo položaj vodoravne linije panorame – trebao bi se nalaziti na razini optičkog središta ogledalo, tj. svi pikseli koji pripadaju središnjoj vodoravnoj liniji panoramske slike treba imati koordinatu $z = 0$. Ova središnja linija označena je

točkom P_c na slici. Polupravci koji izlaze iz središta zrcala do točke P_1 i P_2 određuju gornji i donji rub panoramskog cilindra. Visina h od cilindra (u pikselima) je odabrana tako da bude kompatibilna s rezolucijom perspektivne kamere. Rekonstrukcija slike je ostvarena projiciranjem svih piksela iz cilindrične površine koja okružuje zrcalo natrag u neizobličena višesmjerna slika pomoću izračunatog inverznog preslikavanja. Vrijednosti rezultirajućih (u, v) piksela su pridružene s odgovarajućim pikselima panoramske slike. Koordinate projicirane panoramske slike padaju u kružni sektor višesmjerne slike između polumjera R_{min} i R_{max} . Funkcija koja stvara panoramske slike je kritična s obzirom na brzinu senzora. Stoga, implementiran je pomoću OpenCV biblioteke pomoću funkcije `remap()` i koja podržava CUDA i traje samo 0,85 ms.

3.5 Umjeravanje senzora za stereo vid


Budući da želimo koristiti naš hibridni senzor vidnog polja za izravno mjerenje udaljenosti do nepoznatih otkrivenih objekata, moramo zajedno umjeravati dvije kamere dobiti iz vanjskih parametara stereopara. Izabrali smo referentni okvir stereopara da se podudara s referentnim okvirom višesmjerne kamere (središte ogledalo).



Slika 22. Predodžba primjera panoramskih pogleda: dobiveni korištenjem postupaka (a) i rekonstruirani navedenom metodom (b). Izvor [23].

Ovdje ne pokušavamo izravno umjeriti ove dvije vrlo različite kamere. Definirajmo "virtualnu kameru", u kojoj se nalazi ishodište referentnog okvira u optičkom središtu zrcala katadioptriske kamere i parametri (žarišna duljina i razlučivost) odabrani na takav način, da ima vidno polje slično stvarnoj perspektivi kamere (slika 23). Ova je ideja

slična virtualnoj slici ravnine, ali mi definiramo virtualnu kameru slike izravno pomoću panoramske slike, koja je već rekonstruirana u dijelu perifernog vida našeg senzora. Slika virtualne kamere sintetizirana je pomoću panoramske slike, projiciranjem zrake koja izlazi iz središta zrcala prema cilindričnoj površini. Ova zraka prelazi vodoravno i okomito područje definirano pretpostavljenu razlučivost virtualne kamere i odabire vrijednosti piksela iz panoramske slike. Ove vrijednosti su tada povezane s odgovarajućim pikselima virtualne kamere slika.



Slika 23. Predodžba geometrije hibridnog senzora vidnog polja s virtualnom kamerom. Izvor [24].

Umjeravamo virtualnu kameru pomoću istog alata, koji se koristi za perspektivnu kameru, dobivajući matricu kamere K_v . Na kraju dobivamo slike, koje dolaze iz para standardnih kamera – perspektiva i virtualni, koji su umjeravanjem ispravni u odnosu na njihovim intrinzičnim parametrima (K_p , K_v i modeli izobličenja su poznati). Iako ove kamere nisu u fronto-paralelnoj konfiguraciji, možemo ponovno koristiti standardne alate iz Camera Calibration Toolbox kako bismo dobili ekstrinzično umjeravanje stereo opreme. Postupak umjeravanja koristi nekoliko slika istog uzorka, koji smo koristili prije. Ovaj put promatrano istovremeno s obje strane kamere. Matrica rotacije $R_s(3 \times 3)$ i translacijski vektor $t_s = [t_x, t_y, t_z]^T$, koji se odnose na perspektivnu kameru, virtualne kamere izračunavaju se iz korespondencije između točaka uzorka umjeravanja. Poznata relativna rotacija i translacija između slika iz obje kamere koriste se za izračun osnovne matrice za naš umjereni sustav:

$$E = R_s = \begin{bmatrix} 0 & -t_z & t_y \\ t_z & 0 & -t_x \\ -t_y & t_x & 0 \end{bmatrix}$$

3.6 Mjerenje dubine iz stereo uređaja

Umjeravanjem hibridnog vidnog senzora vidnoga polja, dobili smo sve intrinzične i ekstrinzične parametre, koje su potrebne za izračunavanje projekcijskih matrica za obje kamere. Kako se virtualna kamera nalazi u ishodištu koordinatnog sustava stereo-para, njegova projekcijska matrica je jednostavno definirana s $P_v = K_v[I|0]$, dok se matrica projekcije perspektivne kamere računa za procijenjenu rotacije i translacije između kamera: $P_p = K_p[R_s|t_s]$. Kao projekcijske matrice, povezuju promatranu točku u 3D prostoru p na 2D sliku ove točke na virtualnu i perspektivnu kameru, P'_v i P'_p odnosno: $P'_v = P_v p$, $P'_p = P_p p$ možemo rekonstruirati 3D lokaciju točke p iz njezine projekcije na (neiskrivljene) slike s obje kamere. Stereo rekonstrukciju implementiramo koristeći metodu optimalne triangulacije, koja je relativno jednostavna za izračunavanje i radi u stvarnom vremenu na jednododnom računalu u našem senzoru. Da bismo mogli provesti 3D rekonstrukciju moramo odrediti 2D točke, koje predstavljaju iste 3D značajke scene na slikama dobivenim od kamera. Budući da postoji mnogo metoda za određivanje korespondencije točaka u stereo-viziji, upotrijebit ćemo lokalne deskriptore značajki istaknutih točaka, koje se obično koriste u robotskoj navigaciji. Deskriptori će dešifrirati izgled lokalnog susjedstva svake točke kao kompaktna struktura podataka. Alternativne funkcije podudaranja značajki, koje koriste tri algoritma: SIFT, SURF ili ORB ugrađeni su u senzor. Ovaj koncept vodi do "rijetkog" stereo-a, tj. određujemo mjesto ograničenog broja točki na sceni. Točkaste značajke otkrivene su na obje slike pomoću odabranog detektora opisanog pomoću svojih kompatibilnih deskriptora. Koordinate detektiranih točaka su normalizirane i neiskrivljene. Zatim, točke sa obje slika su usklađene minimiziranjem udaljenosti (euklidski za SIFT i SURF ili Hamming za ORB) između njihovih deskriptora. Kada se uspostave početne korespondencije, izračunava se pogreška simetrične projekcije:

$$e_{r_{ep}} = \max \left\{ d \left(e_j, (u_i^v, v_i^v) \right), d \left(e_i, (u_j^p, v_j^p) \right) \right\}$$

gdje (u_i^v, v_i^v) označava normalizirane koordinate od i -te p'_v točke, (u_j^p, v_j^p) označava koordinate j -te p'_p točke, $d(x, y)$ označava operator euklidske udaljenosti od točke y na pravac x , e_i, e_j su izračunate epipolarne linije pomoću bitne matrice :


$$\begin{bmatrix} e_{ix} \\ e_{iy} \\ e_{iz} \end{bmatrix}^T = E [(u_i^v, v_i^v, 1)]^T,$$

$$\begin{bmatrix} e_{jx} \\ e_{jy} \\ e_{jz} \end{bmatrix} = [(u_j^p, v_j^p, 1)] E$$

Podudaranje je prihvaćeno ako je računanjem e_{rep} ispao manje vrijednosti nego odabrani fiksni prag u normaliziranim koordinatama. Parovi točkastih značajki koji su prošli ovaj test su koristi se za izračunavanje udaljenosti do točaka u 3D sceni.


3.7 REZULTAT

Zbog uskog ograničenja broja stranica ovog rada usredotočeni smo samo na procjeni mjerenja udaljenosti, tj. analogni fovealni i binokularni vid kod životinja.




Slika 24. Predodžba rezultata spajanja katadioptriske i tipične web kamere. Primjeri slika za jedan od skupova objekata: iz perspektive kamere (a), od svesmjerne kamere (b) i rekonstruirana panoramska slika (c). Izvor [25].

Postavili smo nekoliko jednostavnih scena, skupljajući zajedničkih kućanskih predmeta ili komada namještaja u setovima od dva ili tri komada predmeta (slika 24). Senzor je postavljen na ravan pod na poznatoj udaljenosti od središnjeg objekta. Tu smo pretpostavili fizičko podrijetlo koordinatnog sustava senzora (u 2D) nalazi se na osi zrcala. Točna udaljenost je tada izmjerena pomoću vrpce usmjerene od kućište senzora prema zadanom objektu. Prvo je temeljito testirano mjerenje udaljenosti pomoću SIFT detektor i deskriptora. (Slika 25a). Ovaj izbor je bio-motiviran činjenicom da se SIFT još uvijek smatra u literaturi kao "zlatni standard" deskriptora, zbog svoje visoke diskriminativne moći. Izmjerali smo udaljenosti do nekoliko točkastih značajki otkrivenih na promatranim objektima (Slika 25b). Kao predmete u prvoj sceni imali smo ravne čeine površine, kada generiranje kvantitativnih rezultata mjerenja koje imamo u prosječnim udaljenostima za sve značajke otkrivenih na datoj površini.



Slika 25. Predodžba primjera rezultata za isti skup objekata: odgovarajući SIFT značajke (a) i rijetke 3D točke izmjerene na sceni (b). Izvor [26].


Kvantitativni rezultati prikazani dijagramima na slici 26, očitno prikazuju da pogreške u mjerenju dometa ovise o izmjerenim udaljenostima. Oni su najmanji u srednjem rasponu mjerenja, odnosno u području koje je zastupljeno s najmanjim greškama interpolacije u rekonstruiranom panoramskom slikom. Također i broj ispravno usklađenih karakteristika točki ovise o udaljenostima od senzora. Za SIFT prikazuje broj točnih podudaranja za scenu prikazanu na (slici 24), varira od 5 do 17, s maksimumom na udaljenosti od 180 cm do srednjeg objekta. Općenito, dobili smo veći broj otkrivenih značajki za udaljene značajke, do 200 cm, ali najveći broj točnih podudaranja za udaljenosti između 160 i 180 cm, što se podudara s najmanjom greškom udaljenosti.



Slika 26. Predodžba Performansi detektora-deskriptora u rijetkom stereo-u. Izvor [27].

Izvedba triju detektora značajki i deskriptora koje smo testirali sažeta je u (Tab.) (n_f označava broj točno usklađenih obilježja) za tri reprezentativne udaljenosti i četiri različite scene koje sadrže razne kutije, jastuke i stolice. Primjeri podudaranja parova su vizualizirani na (slici 27) za scenu (br. 3) na udaljenosti od 140 cm. Također smo izmjerili potrebno vrijeme t_s (u sekundama) potrebno za obradu par slika (perspektivnu i virtualnu) i mjerenje udaljenosti do objekata. Ovo vrijeme pokriva stvaranje virtualne slike, otkrivanje obilježja točke, opis i podudaranje i triangulaciju, ali ne pokriva

rekonstrukciju panoramske slike. (Tablica 1) prikazuje vrijeme obrade t_s za razmatrane scene i udaljenosti. Za SURF i ORB detektor-deskriptor parove, koji imaju OpenCV implementacije koje podržavaju CUDA t_s izmjereno je za izvođenje temeljeno na GPGPU-u. Međutim, SIFT detektor-deskriptor nema takvu implementaciju, stoga je t_s izmjeren na CPU (vrijednosti označene kurzivom u (Tablici 1)). Korištenjem samo Cortex-A15 CPU-a također smo dobili prosječni t_s od 0,3 s za ORB i 3,5 s za SURF. Međutim, koristeći GPGPU senzor je mogao obraditi slike i izračunati udaljenosti u stvarnom vremenu. Vrijeme obrade ovisi uglavnom o vrsti značajki, a donekle i o broju otkrivenih značajki (vrijeme podudaranja).



Slika 27. Predodžba podudaranja pomoću SIFT (a), SURF (b) i ORB (c) detektori i deskriptori na mjestu događaja br. 3. Izvor [28].

TABLE I
 DETECTOR-DESCRIPTOR PERFORMANCE IN SPARSE STEREO
 (SEE TEXT FOR DETAILS)

descr. & dist. [cm]	Scene 1		Scene 2		Scene 3		Scene 4	
	n_f	t_s	n_f	t_s	n_f	t_s	n_f	t_s
SIFT 120	5	7.94	22	7.90	19	7.92	33	7.65
SURF 120	7	0.44	10	0.22	13	0.21	9	0.23
ORB 120	3	0.11	0	0.02	0	0.04	3	0.04
SIFT 160	15	7.64	36	7.79	25	7.62	36	7.52
SURF 160	14	0.17	21	0.22	51	0.19	25	0.19
ORB 160	2	0.07	3	0.06	4	0.05	4	0.04
SIFT 200	16	7.68	10	7.54	24	7.54	17	7.54
SURF 200	40	0.18	18	0.18	8	0.20	3	0.18
ORB 200	2	0.07	4	0.05	1	0.04	2	0.05

Slika 28. Predodžba Tablice 1. Izvor [29].

4. ZAKLJUČAK

Tema završnog rada, koja je zadana od strane mentora, predstavlja inovativno rješenje za orijentaciju vozila u prostoru. U teoretskom dijelu predstavljene su poznate tehnologije za autonomnu orijentaciju vozila u prostoru. U praktičnom dijelu smo detaljno opisali jednu od inovativnih rješenja gdje robotu ili vozilu dajemo periferni vid inspirirani biološkim motivima. Važno je napomenuti da se ova metoda još uvijek usavršava. Iako opći koncept nije u potpunosti nov, govorimo o biološkim motivima za kombiniranje dvije vrlo različite kamere u jednom integriranom senzoru i pokazali smo da takav senzor može biti samostalna vizualna jedinica za percepciju s mogućnostima obrade slike u stvarnom vremenu. Pokazujemo kako umjeriti ovaj senzor pomoću jednostavnog eksperimentalnog seta i standardnih postupaka dostupnih u alatnim kutijama ili knjižnicama otvorenog koda. Predstavljamo novu metodu za rekonstrukciju panoramskih slika, koje su kompatibilne s prikazom perspektivne kamere i definiramo virtualnu kameru na ovim rekonstruiranim slikama. Pokazujemo i korisnost značajke OpenCV point detektora i deskriptora u rijetkim stereo mjerenjima s hibridnim vidnim poljem. Mjerenja udaljenosti su dovoljno precizna za izbjegavanje prepreka i čovjek-robot interakcije. Naši eksperimenti pokazuju da najbolji izbor među popularnim parovima detektor-deskriptor je SURF. Mnogo je brži za izračunavanje od SIFT-a (koristeći CUDA) i daje zadovoljavajući broj točnih podudaranja u rasponu do 2 m. Nažalost, binarni ORB, iako najbrži za izračunavanje, nije dobro funkcionirao u našem sustavu.

Literatura

- [1.] Analiza razina autonomnosti kod cestovnih prijevoznih sredstava Santai, Melani
Završni rad 2021, Sveučilište u Zagrebu, Fakultet prometnih znanosti
- [2.] Autonomna cestovna vozila - Robote, vozi polako, Marina Pavlić, 2021.
(<https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775>)
- [3.] LIDAR: how self-driving cars 'see' where they're going, Jake Port, 2022.
(<https://cosmosmagazine.com/technology/lidar-how-self-driving-cars-see/>)
- [4.] How Radar Works, Marshall Brain 2000,
<https://science.howstuffworks.com/radar.htm>
- [5.] Ultrasonic Sensors in Self-Driving Cars, Babak Shahian Jahromi, 2019.
(<https://medium.com/@BabakShah/ultrasonic-sensors-in-self-driving-cars-d28b63be676f>)
- [6.] Marta Rostkowska and Piotr Skrzypczynski, "Hybrid field of view vision: From biological inspirations to integrated sensor design" :
<http://srv.uib.es/public/MFI2016/papers/0093.pdf>