

UNIVERZITET ODBRANE U BEOGRADU
VOJNA AKADEMIJA

Salem-Bilal Amokrane

Projektovanje naprednih robusnih sistema upravljanja i vođenja besposadnih vozila

DOKTORSKA DISERTACIJA

Beograd, 2025 godine.



UNIVERZITET ODBRANE U BEOGRADU
VOJNA AKADEMIJA



Salem-Bilal Amokrane

Projektovanje naprednih robusnih sistema upravljanja i vodenja besposadnih vozila

DOKTORSKA DISERTACIJA

Beograd, 2025 godine.

UNIVERZITET ODBRANE U BEOGRADU
VOJNA AKADEMIJA
OSNOVNI PODACI O DOKTORSKOJ DISERTACIJI

1. Evidencioni broj:
2. Autor:	Salem-Bilal Amokrane
3. Naziv doktorske disertacije:	Projektovanje naprednih robusnih sistema upravljanja i vođenja besposadnih vozila
4. Jezik (pismo):	Srpski jezik (ćirilica ili latinica).
5. Opis:	Stranice: ukupno 166 (xviii + 148) Poglavlja: 5 Reference: 199 Tabele: 8 Slike: 44 Prilozi: 0
6. Naučna oblast – uža naučna oblast:	Tehničko-tehnološke nauke Vojnoelektronsko inženjerstvo
7. Ključne reči:	Besposadno gusenično vozilo (BGV), upravljanje sa aktivnim potiskivanjem poremećaja (ADRC), Duboko učenje (DL), Učenje sa podrškom (RL), Deep Deterministic Policy Gradient (DDPG), Praćenje vozne trake, Izbegavanje prepreka, Praćenje lidera, Prepoznavanje poza, Adaptivno upravljanje, autonomno kretanje.
8. Mentor (čin, zvanje, ime, prezime, naziv i ustanova)	Vanredni profesor dr Momir Stanković, dipl. inž., Vojna akademija, Univerzitet odbrane u Beogradu
9. Odluka Senata o odborenju teme:	
10. Datum odbrane:	
11. Komisija za ocenu i odbranu: (čin, zvanje, ime, prezime, naziv i ustanova)	Predsednik: Redovni profesor dr Slobodan Simić, dipl. inž., Član: Docent dr Boban Pavlović, dipl. inž., Član: Docent dr Stojadin Manojlović, dipl. inž., Član: Vanredni profesor dr Momir Stanković, dipl. inž., Član: Redovni profesor dr Milenko Andrić, dipl. inž.,
12. Napomena:	

UNIVERSITY OF DEFENCE IN BELGRADE
MILITARY ACADEMY

GENERAL INFORMATIONS ON DOCTORAL THESIS

1. Registry Number:
2. Author:	Salem-Bilal Amokrane
3. Title:	Design of advanced robust control and guidance systems for unmanned vehicles
4. Language (script):	Serbian (Cyrillic or Latin).
5. Description:	Pages: total 166 (xviii + 148) Chapters: 5 References: 199 Tables: 8 Illustrations: 44 Appendices: 0
6. Scientific field – subfield:	Technical-Technological Sciences Military Electronic Engineering
7. Keywords:	Unmanned Tracked Vehicle (UTV), Active Disturbance Rejection Control (ADRC), Deep Learning (DL), Reinforcement Learning (RL), Deep Deterministic Policy Gradient (DDPG), Lane Following, Obstacle Avoidance, Leader Following, Pose Recognition, Adaptive Control, autonomous movement.
8. Supervisor (Rank, Title, Name, Surname, Institution)	Associate Professor Dr. Momir Stanković, Dipl. Ing., Military Academy, University of Defence in Belgrade
9. Decision of the Senate for Thesis Approval:	
10. Date of Defence:	
11. Committee: (Rank, Title, Name, Surname, Institution)	Chairman: Full Professor Dr. Slobodan Simić, Dipl. Ing., Military Academy, University of Defence in Belgrade Member: Assistant Professor Dr. Boban Pavlović, Dipl. Ing., Member: Assistant Professor Dr. Stojadin Manojlović, Dipl. Ing., Member: Associate Professor Dr. Momir Stanković, Dipl. Ing., Member: Full Professor Dr. Milenko Andrić, Dipl. Ing.,
12. Note:	

Zahvalnica

Ovaj rad predstavlja rezultat višegodišnjeg teorijskog i eksperimentalnog istraživanja sprovedenog na Vojnoj akademiji Univerziteta odbrane u Beogradu.

Najpre izražavam duboku zahvalnost Bogu na snazi, mudrosti i istrajnosti koje mi je dao da završim ovu doktorsku disertaciju.

Posebnu zahvalnost dugujem svojoj voljenoj zemlji Alžiru i njenim komandantima na nepokolebljivoj podršci i veri u moje sposobnosti tokom završetka ove teze.

Od srca zahvaljujem svom mentoru na stručnom vođenju, strpljenju i neiscrponoj podršci tokom celog istraživačkog procesa. Njegovi dragoceni saveti i kritički osvrti bili su od presudnog značaja za realizaciju ovog dela.

Srdačno se zahvaljujem svim profesorima i kolegama sa studijskog programa vojnoelektronskog inženjerstva na saradnji, korisnim diskusijama i podršci tokom studiranja.

Veliko priznanje pripada i Vojnoj akademiji na pruženim uslovima i podršci za sprovođenje ovog istraživanja.

Najtoplje zahvaljujem svojoj supruzi i sinovima na neizmernoj ljubavi, strpljenju i podršci tokom ovog zahtevnog perioda. Bez njihovog razumevanja i žrtvovanja ovaj uspeh ne bi bio moguć.

Konačno, od srca zahvaljujem svojim voljenim roditeljima na bezgraničnoj ljubavi, nepokolebljivoj podršci i mudrim savetima koji su pratili moj celokupni obrazovni put. Posebnu zahvalnost upućujem i svojoj braći i sestrama na neprekidnom ohrabrvanju i emotivnoj podršci tokom svih faza mog istraživanja. Bez žrtava i vere moje porodice u moje sposobnosti, ovo istraživanje ne bi bilo moguće.

Srdačno se zahvaljujem i svojim kolegama i dragim prijateljima iz Alžira čija je podrška, inspirativne diskusije i ohrabrujuće reči bile neprocenjive tokom mog boravka i studija u inostranstvu. Ova teza je, umnogome, plod našeg zajedništva i njihovog verovanja u mene.

Salem-Bilal Amokrane,
Jun 2025.

Rezime

Besposadna vozila generalno, a pre svega ona sa guseničnim pogonom (BGV), imaju značajnu ulogu u širokom spektru vojnih i civilnih primena zahvaljujući svojim manevarskim sposobnostima na teškim i nepristupačnim terenima. Međutim, njihovo autonomno kretanje, odnosno upravljanje i vođenje, u realnim okruženjima suočava se sa značajnim izazovima. Tradicionalni pristupi projektovanju upravljanja, poput primene standardnih industrijskih regulatora, često pokazuju ograničene performanse i robusnost usled izražene nelinearne dinamike kretanja, nestacionarnosti modela i značajnih spoljašnjih poremećaja koji se ogledaju u efektu proklizavanja pogonskih gusenica. Shodno prethodnom, ova disertacija razmatra navedene probleme predlažući i detaljno analizirajući napredna robusna rešenja sistema upravljanja BGV zasnovana na tehnicu aktivnog potiskivanja poremećaja (ADRC), sa ciljem unapređenja preciznosti kretanja, robusnosti i adaptivnosti sistema. Paralelno sa razvojem sistema upravljanja, disertacija se bavi projektovanjem i implementacijom sistema vođenja zasnovanih na algoritmima dubokog učenja (DL) i fuziji senzorskih podataka (monokularna kamera, LiDAR). Ovi sistemi su razvijeni za dva ključna i praktično relevantna operativna scenarija: autonomno praćenje zadate vozne trake sa izbegavanjem prepreka i autonomno praćenje ljudskog lidera od strane BGV-a.

Prvi ključni doprinos ovog istraživanja ogleda se u projektovanju, implementaciji i eksperimentalnoj validaciji integrisanog sistema koji objedinjuje ADRC regulatore za longitudinalni i lateralni kanal upravljanja sa DL sistemima vođenja, koji se oslanjaju na obradu vizuelnih informacija sa monokularne kamere. Konkretno, za autonomno praćenje zadate vozne trake i izbegavanje prepreka korišćeni su YOLOPv2 za detekciju vozne trake i YOLOv8 za detekciju prepreka, dok je za autonomno praćenje lidera primjenjen YOLOv8 za detekciju lidera i MediaPipe Pose za prepoznavanje komandi ljudskog lidera. Eksperimenti sprovedeni na laboratorijskoj BGV platformi u realnim uslovima nedvosmisleno su potvrdili efikasnost ADRC-a u odnosu na klasični industrijski pristup upravljanja na bazi PID regulatora, kao i visoku funkcionalnost i pouzdanost projektovanih sistema vođenja.

Drugi značajan doprinos predstavlja uvođenje adaptivnosti u ADRC sistem upravljanja. Naime, kako bi se prevazišla ograničenja ADRC regulatora sa konstantnim parametrima u dinamički promenljivim uslovima, predložena je inovativna strategija adaptivnog podešavanja parametara ADRC-a korišćenjem dubokog učenja sa podrškom (DRL). Specifično, razvijen je sistem gde Deep Deterministic Policy Gradient (DDPG) algoritam u realnom vremenu podešava ključne propusne opsege lateralnog i longitudinalnog ADRC regulatora za zadatku praćenja lidera. Sveobuhvatne simulacije u MATLAB/Simulink okruženju, pod dejstvom kompleksnih poremećaja proklizavanja gusenica i mernog šuma senzora, pokazale su da ADRC-RL značajno nadmašuje performanse ADRC-a sa konstantnim parametrima, postižući smanjenje integralne apsolutne greške lateralnog praćenja za više od 60% u prisustvu poremećaja.

Disertacija pruža sveobuhvatno rešenje koje integriše ADRC tehniku upravljanja BGV, adaptivno podešavanje parametara na bazi RL i algoritme veštačke inteligencije pri obradi slike monokularne kamere, odnosno u projektovanju sistema vođenja BGV. Ovim se demonstrira potencijal kombinovanja naprednih tehnika upravljanja i veštačke inteligencije za unapređenje nivoa autonomije i performansi BGV u realnim i izazovnim scenarijima kretanja.

Ključne reči: Besposadno gusenično vozilo (BGV), upravljanje sa aktivnim potiskivanjem poremećaja (ADRC), Duboko učenje (DL), Učenje sa podrškom (RL), Deep Deterministic Policy Gradient (DDPG), Praćenje vozne trake, Izbegavanje prepreka, Praćenje lidera, Prepoznavanje poza, Adaptivno upravljanje, autonomno kretanje.

Abstract

Unmanned vehicles in general, and above all those Unmanned Tracked Vehicles (UTV), play a significant role in a wide range of military and civilian applications due to their maneuvering capabilities on difficult and inaccessible terrains. However, their autonomous motion, including control and guidance, in real-world environments faces considerable challenges. Traditional industrial control design approaches often exhibit limited performance and robustness due to the inherent nonlinear dynamics of motion, model uncertainties, and significant external disturbances, a result from the drive track slippage. Accordingly, this dissertation addresses these problems by proposing and thoroughly analyzing advanced robust UTV control system solutions based on the Active Disturbance Rejection Control (ADRC) technique, aiming to improve motion precision, system robustness, and adaptability. Parallel to the development of the control system, the dissertation focuses on the design and implementation of guidance systems based on Deep Learning (DL) algorithms and sensor data fusion (monocular camera, LiDAR). These systems have been developed for two key and practically relevant operational scenarios: autonomous lane following with obstacle avoidance and autonomous human leader-following by the UTV.

The first key contribution of the dissertation lies in the design, implementation, and experimental validation of an integrated system that combines ADRC for longitudinal and lateral control channels with DL-based guidance systems, primarily relying on processing visual information from a monocular camera. Specifically, for autonomous lane following and obstacle avoidance, YOLOv2 was used for lane detection and YOLOv8 for obstacle detection, while for autonomous leader-following, YOLOv8 was applied for leader detection and MediaPipe Pose for recognizing human leader commands given by his poses. Experiments conducted on a laboratory UTV platform in real indoor and outdoor conditions conclusively confirmed the effectiveness of ADRC compared to the classic PID approach, as well as the high functionality and reliability of the designed guidance systems.

The second significant contribution is the introduction of adaptability into the ADRC control system. To overcome the limitations of ADRC controllers with constant parameters in dynamically changing conditions, an innovative strategy for adaptive ADRC parameter tuning using Deep Reinforcement Learning (DRL) was proposed and thoroughly analyzed. Specifically, a system was developed where the Deep Deterministic Policy Gradient (DDPG) algorithm adjusts the key bandwidths of the lateral and longitudinal ADRC controllers in real-time for the leader-following task. Comprehensive simulations in the MATLAB/Simulink environment, under the influence of complex track slippage disturbances and sensor measurement noise, showed that ADRC-RL significantly surpasses the performance of ADRC with constant parameters, achieving a reduction in the Integral

Absolute Error (IAE) for lateral tracking more than 60% in the presence of disturbances.

The dissertation provides a comprehensive solution that integrates ADRC control technique for UTV, RL-based adaptive parameter tuning, and artificial intelligence algorithms for monocular camera image processing in the design of the UTV guidance system. This demonstrates the potential of combining advanced control techniques and artificial intelligence to enhance the autonomy and performance of unmanned tracked vehicles in real and challenging motion scenarios.

Keywords: Unmanned Tracked Vehicle (UTV), Active Disturbance Rejection Control (ADRC), Deep Learning (DL), Reinforcement Learning (RL), Deep Deterministic Policy Gradient (DDPG), Lane Following, Obstacle Avoidance, Leader Following, Pose Recognition, Adaptive Control, autonomous movement.

Sadržaj

Spisak slika	xiii
Spisak tabela	xiv
1 Uvod	1
1.1 Obrazloženje teme	1
1.2 Problem i predmet istraživanja	3
1.2.1 Problem istraživanja	3
1.2.2 Predmet istraživanja	4
1.3 Hipoteze, metodologija i očekivani rezultati istraživanja	5
1.3.1 Hipoteze i način njihove provere	5
1.3.2 Metodologija istraživanja	6
1.4 Struktura disertacije	8
2 Osnovne karakteristike besposadnih vozila i autonomnog kretanja	10
2.1 Istorija, karakteristike i podela besposadnih vozila	10
2.1.1 Istorija besposadnih vozila	10
2.1.2 Nivoi autonomije kod BV-a	12
2.1.3 Tipovi besposadnih vozila	13
2.2 Načini autonomnog kretanja	14
2.2.1 Autonomno praćenje zadate vozne trake sa izbegavanjem prepreka	16
2.2.1.1 Detekcija vozne trake	17
2.2.1.2 Detekcija i izbegavanje prepreka	19
2.2.1.3 Pregled literature u oblasti autonomnog praćenja zadate vozne trake i izbegavanja prepreka	20
2.2.2 Autonomno praćenje lidera	22
2.2.2.1 Izbor senzora u sistemima autonomnog praćenja lidera	23
2.2.2.2 Pregled literature u oblasti autonomnog praćenja lidera	24
2.3 Struktura sistema autonomnog kretanja BGV	25
2.3.1 Izazovi pri projektovanju, struktura i pregled sistema vođenja	27
2.3.1.1 Izazovi pri projektovanju sistema vođenja BGV	27

2.3.1.2	Struktura i pristupi projektovanju sistema vođenja BGV	28
2.3.2	Izazovi pri projektovanju, struktura i pregled sistema upravljanja .	34
2.3.2.1	Izazovi pri projektovanju sistema upravljanja BGV	34
2.3.2.2	Struktura sistema upravljanja BGV i pristupi projektovanju upravljanja	35
3	Projektovanje ADRC sistema upravljanja i sistema vođenja BGV-a	40
3.1	Matematički model praćenja definisane putanje od strane BGV	40
3.1.1	Dinamika lateralne greške	44
3.1.2	Dinamika longitudinalne greške	44
3.2	Pristup upravljanju BGV na bazi ADRC algoritma	45
3.2.1	Zašto ADRC ?	46
3.2.2	Projektovanje i implementacija ADRC-a za BGV	50
3.2.2.1	Projektovanje ADRC regulatora lateralnog kanala . . .	50
3.2.2.2	Projektovanje ADRC regulatora longitudinalnog kanala	52
3.2.2.3	Implementacija ADRC regulatora	54
3.3	Projektovanje sistema vođenja BGV	56
3.3.1	Projektovanje sistema vođenja za autonomno praćenje zadate vozne trake sa izbegavanjem prepreka	56
3.3.1.1	Modul za generisanje slike	59
3.3.1.2	Modul za detekciju trake	60
3.3.1.3	Modul za obradu trake	62
3.3.1.4	Modul za detekciju i izbegavanje prepreka	66
3.3.1.5	Modul za planiranje putanje	69
3.3.2	Projektovanje sistema vođenja za autonomno praćenje lidera . .	72
3.3.2.1	Modul ulaznih senzora	75
3.3.2.2	Modul za detekciju i praćenje lidera	75
3.3.2.3	Modul za prepoznavanje poze lidera	76
3.3.2.4	Modul za merenje rastojanja između BGV i lidera . . .	80
3.3.2.5	Modul za merenje i transformaciju greške	80
3.3.2.6	Modul za generisanje komandi vođenja	82
3.4	Eksperimentalna validacija projektovanih sistema autonomnog kretanja .	83
3.4.1	Laboratorijsko gusenično vozilo i senzorski sistemi	83
3.4.2	Integracija projektovanih sistema autonomnog kretanja	85
3.4.2.1	Integracija sistema autonomnog praćenje zadate vozne trake sa izbegavanjem prepreka	85
3.4.2.2	Integracija sistema autonomno praćenje lidera	85
3.4.3	Eksperimentalna validacija autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka	87

3.4.3.1	Eksperimentalna postavka	87
3.4.3.2	Eksperimentalni rezultati	89
3.4.4	Validacija autonomnog praćenja lidera	93
3.4.4.1	Simulaciona validacija autonomnog praćenja lidera . . .	94
3.4.4.2	Eksperimentalna validacija autonomnog praćenja lidera	98
4	Projektovanje adaptivnog ADRC upravljanja na bazi učenja sa podrškom za BGV	102
4.1	Osnove učenja sa podrškom	104
4.2	Algoritam sa determinističkim učenjem na bazi gradijenta (DDPG)	106
4.3	Adaptivno podešavanje ADRC regulatora korišćenjem DDPG algoritma za praćenje lidera	108
4.3.1	Definicija prostora stanja i akcija	109
4.3.1.1	Lateralni agent	109
4.3.1.2	Longitudinalni agent	109
4.3.2	Projektovanje funkcije nagrađivanja	109
4.3.2.1	Nagrada lateralnog agenta $R_l(t)$	110
4.3.2.2	Nagrada Longitudinalnog Agenta $R_v(t)$	110
4.3.3	Arhitektura mreže i proces obučavanja	111
4.3.3.1	Arhitektura mreže	111
4.3.3.2	Proces obučavanja	111
4.3.3.3	Hiperparametri mreže	112
4.4	Simulaciona validacija projektovanog sistema upravljanja	113
4.4.1	Simulaciona postavka	113
4.4.2	Simulacioni rezultati i analiza	113
4.4.2.1	Analiza greške praćenja	120
4.4.2.2	Analiza adaptacije parametara	121
4.4.2.3	Analiza kvantitativnih kriterijuma efikasnosti upravljanja	122
4.4.2.4	Sumarna diskusija rezultata	122
5	Zaključak	124
Literatura		129
Lista publikacija		148

Spisak slika

2.1	Nivoi autonomije kod BV-a	13
2.2	Arhitektura sistema autonomnog kretanja kod BGV-a.	27
3.1	Kinematički model BGV-a sa definisanim koordinatnim sistemima. (sa prilagođenim oznakama).	42
3.2	Opšti problem praćenja cilja za BGV	43
3.3	Prikazi diskretnih funkcija prenosa za (a) lateralni ADRC regulator i (b) longitudinalni ADRC regulator.	54
3.4	Pregled vođenja BGV-a za praćenje trake gde je cilj virtuelna tačka ispred vozila (sa prilagođenim oznakama).	58
3.5	Blok dijagram predloženog sistema za detekciju i praćenje vozne trake.	59
3.6	Primeri izlaza YOLOPv2 modela: Maska detektovane trake (zeleno) prikazana na slikama sa BGV kamere.	62
3.7	Detekcija putanja traka označena bojama: leva traka je označena plavom bojom , desna traka crvenom bojom , a maska identifikovana modelom je istaknuta zelenom bojom . Ovaj prikaz ilustruje proces detekcije trake bez ikakvih ograničenja, fokusirajući se isključivo na najbliže granice levoj i desnoj strani centralne ose slike.	63
3.8	Detekcija putanja traka nakon primene ograničenja i pročišćavanja: leva traka (plavo), desna traka (crveno), maska modela (zeleno). Ovaj prikaz ilustruje rezultat procesa detekcije sa obrađivanjem ograničenja i filtriranjem tačaka, fokusirajući se na tačnu identifikaciju najbližih granica.	65
3.9	Putanja traka nakon poravnjanja: leva (plavo), desna (crveno), originalna maska (zeleno).	67
3.10	Detektovane granične okvire objekata (prepreka) korišćenjem YOLOv8 unutar ROI-a.	68
3.11	Generisanje virtuelnih traka za zaobilaženje detektovane prepreke unutar ROI.	69
3.12	Proračun centralne putanje vođenja i devijacije BGV-a bez prepreka, korišćenjem fiksne virtuelne tačke ispred vozila.	70

3.13 Proračun centralne putanje vođenja i devijacije BGV-a sa izbegavanjem prepreka korišćenjem adaptivne virtuelne tačke ispred vozila.	71
3.14 Pregled vođenja BGV-a za praćenje lidera (sa prilagođenim oznakama). . .	73
3.15 Blok dijagram predloženog sistema vođenja za praćenje lidera.	74
3.16 Detekcija lidera pomoću YOLOv8. Granični okvir plave boje označava detektovanog ljudskog lidera.	76
3.17 Definicija ključnih tačaka u algoritmu MPP [1].	77
3.18 Ekstrakcija ključnih tačaka lidera: a) u uslovima delimično zaklonjenog lidera, b) u uslovima kada lider nije zaklonjen, c) u uslovima čućeće poze lidera.	78
3.19 Prepoznavanje poze u sistemu praćenja lidera, omogućavajući intuitivnu komunikaciju i upravljanje BGV-om: (a) stojeća poza, (b) čućeća poza, (c) čućeća poza sa podignutom desnom rukom, i (d) čućeća poza sa podignutom levom rukom.	79
3.20 Geometrija za izračunavanje lateralne greške.	81
3.21 Frejm sa kamere BGV-a koji demonstrira lateralnu i longitudinalnu grešku.	81
3.22 Grafički prikaz algoritma za generisanje komandi vođenja na osnovu detektovane poze lidera i izračunatih grešaka praćenja.	82
3.23 Laboratorijsko gusenično vozilo: a) osnovna struktura vozila primenjena u zadatku praćenja lidera, b) modifikovana struktura, primenjena u zadatku praćenja vozne trake sa izbegavanjem prepreka.	84
3.24 Blok dijagram pripremljene eksperimentalne postavke za autonomno praćenje zadate vozne trake sa izbegavanjem prepreka.	85
3.25 Blok dijagram pripremljene eksperimentalne postavke za autonomno praćenje lidera.	86
3.26 Laboratorijska staza bez prepreka.	88
3.27 Laboratorijska staza sa preprekama.	88
3.28 Lateralna greška (e_d) tokom autonomnog praćenja zadate vozne trake bez prepreka.	90
3.29 Ugaone brzine leve i desne gusenice (Ω_L i Ω_R) tokom autonomnog praćenja zadate vozne trake bez prepreka. Gornji red odgovara CCW smeru, a donji red odgovara CW smeru.	91
3.30 Lateralna greška (e_d) tokom scenarija autonomnog praćenja zadate vozne trake sa preprekama.	93
3.31 Rezultati simulacije (za scenario #1).	96
3.32 Definisani poremećaji proklizavanja u okviru simulacionog scenarija #2. .	97
3.33 Rezultati simulacije (za scenario #2).	98
3.34 Eksperimentalna postavka zadatka autonomnog praćenja lidera.	99
3.35 Eksperimentalni rezultati autonomnog praćenja lidera.	100

4.1	Struktura DDPG algoritma (zasnovano na izvornom materijalu [2]).	106
4.2	Struktura sistema za autonomno praćenje lidera od strane BGV na bazi ADRC zasnovanog na DDPG algoritmu za podešavanje parametara.	108
4.3	<i>Actor-critic</i> network structure for the DDPG agent.	111
4.4	Rezultati simulacije dobijeni za različite početne pozicije BGV u odnosu na lidera.	115
4.5	Korisnički definisani profili poremećaja i ubrizgavanje šuma tokom simu- laciјe.	117
4.6	Simulirane trajektorije lidera i BGV-a upoređujući ADRC-RL i konstantni ADRC.	118
4.7	Rezultati simulacije: greške praćenja i evolucija ADRC parametara pode- šenih pomoću DDPG	119

Spisak tabela

2.1	Poređenje tipova BV.	15
2.2	Rezime najsavremenijih metoda za detekciju vozne trake i izbegavanje prepreka	22
2.3	Rezime trenutnih pristupa u sistemima autonomnog praćenja lidera	26
2.4	Rezime strategija upravljanja kod autonomnih vozila.	39
3.1	Integrali apsolutne lateralne greške i apsolutne razlike između referentne i dobijene longitudinalne greške za sisteme sa PID i ADRC regulatorima u simulacionom scenariju #1.	95
3.2	Integrali apsolutne lateralne greške i apsolutne razlike između referentne i dobijene longitudinalne greške za sisteme sa PID i ADRC regulatorima u simulacionom scenariju #2.	99
4.1	Hiperparametri oba DDPG agenta	113
4.2	Kvantitativno poređenje sa konvencionalnim ADRC-om (plavom bojom je označen dobitak ADRC-RL u poređenju sa ADRC, crvenom bojom je označen gubitak ADRC-RL u poređenju sa konvencionalnim ADRC-om).	120

Spisak skraćenica

ADRC	Active Disturbance Rejection Control
ADRC-RL	ADRC with Reinforcement Learning
AFS	Active Front Steering
AGEV	Autonomous Ground Electric Vehicle
AGV	Autonomous Guided Vehicle
AMPC	Adaptive Model Predictive Control
ANN	Artificial Neural Networks
BC	Bayesian classifiers
CCW	Counter-Clockwise
CNN	Convolutional Neural Network
CRF	Conditional Random Fields
CVPR	Conference on Computer Vision and Pattern Recognition
CW	Clockwise
DARPA	Defense Advanced Research Projects Agency
DDPG	Deep Deterministic Policy Gradient
DDQN	Dueling Deep Q-Network
DL	Deep Learning
DQN	Deep Q Network
DRL	Deep Reinforcement Learning
E	Energy

EKF	Extended Kalman Filter
ESO	Extended State Observer
FIL	FPGA-in-the-loop
FLC	Fuzzy Logic Control
FOV	Field of View
FPN	Feature Pyramid Network
FPS	Frames Per Second
GA	Genetic Algorithm
Gazebo	Gazebo simulator
GNSS	Global Navigation Satellite System
GPIO	General Proportional Integral Observer
GPS	Global Positioning System
GPS	Global Positioning System
HPE	Human Pose Estimation
IADRC	Improved Active Disturbance Rejection Control
IAE	Integral Absolute Error
IESO	Improved Extended State Observer
IMU	Inertial Measurement Unit
IoU	Intersection over Union
LiDAR	Light Detection and Ranging
LQT	Linear Quadratic Tracker
LRF	Laser Range Finder
LSTM	Long Short-Term Memory
LTV	Linear Time-Variant
ML	Machine Learning

MPC	Model Predictive Control
MPP	MediaPipe Pose
MPP	MediaPipe Pose
MRAC	Model Reference Adaptive Control
NN	Neural Network
PID	Proportional-Integral-Derivative
PPG	Pure Pursuit Guidance
PSO	Particle Swarm Optimization
QFT	Quantitative Feedback Theory
R-CNN	Region-based Convolutional Neural Networks
RANSAC	Random Sample Consensus
ReLU	Rectified Linear Unit
RFID	Radio-Frequency Identification
RL	Reinforcement Learning
RNN	Recurrent Neural Network
ROI	Region of Interest
ROS2	Robot Operating System 2
SAC	Soft Actor-Critic
SAE	Society of Automotive Engineers
SAM	Scene Analysis Module
SFC	State Feedback Control
SIFT	Scale-Invariant Feature Transform
SLAM	Simultaneous Localization and Mapping
SOTA	State-of-the-Art
SPP	Spatial Pyramid Pooling

SSD	Single Shot Detector
SURF	Speeded Up Robust Features
SVM	Support Vector Machines
tanh	Hyperbolic Tangent
TD3	Twin Delayed Deep Deterministic Policy Gradient
TLC	Trajectory Linearization Control
TV	Total Variation
UGV	Unmanned Ground Vehicle
UTV	Unmanned Tracked Vehicle
UWB	Ultra-Wide Band
YOLO	You Only Look Once
YOLOP	You Only Look Once for Panoptic driving perception

Poglavlje 1

Uvod

1.1 Obrazloženje teme

Besposadne platforme predstavljaju jednu od najbrže rastućih tehnologija u savremenoj industriji, pronalazeći primenu kako u vojnom, tako i u civilnom domenu. Besposadne platforme nude potencijal za povećanje efikasnosti, smanjenje rizika po ljudske živote i obavljanje zadataka u okruženjima nepristupačnim ili opasnim za čoveka [3, 4]. Shodno tome, poslednjih godina, njihova primena je sve veća u različitim logističkim operacijama, poljoprivrednim poslovima i industrijskim operacijama, poslovima izviđanja, nadzora, traganja i spasavanja u kriznim situacijama itd.

Besposadne platforme koje se koriste na kopnu se nazivaju besposadna vozila (BV) (eng. Unmanned Ground Vehicle, UGV) i koriste se za obavljanje širokog spektra zadataka, od transporta i logistike do patroliranja i izviđanja u različitim okruženjima. U zavisnosti od primjenjenog mehanizma kretanja dele se na vozila sa točkovima, vozila sa nogama, gusenična vozila i hibridna vozila, od kojih svaka kategorija poseduje specifične prednosti na različitim terenima i u različitim zadacima.

Unutar klase BV, besposadna gusenična vozila BGV (eng. Unmanned Tracked Vehicle, UTV) zauzimaju posebno mesto zahvaljujući svojim mehaničkim karakteristikama koje im omogućavaju veliku pokretljivost i stabilnost na neuređenim, mekim i neravnim terenima, kao što su pesak, blato ili kamenito tlo [5, 6, 7]. Ove sposobnosti čine BGV izuzetno pogodnim za terenske operacije, vojne primene, građevinske radove i druge zadatke u teškim terenskim uslovima.

Ipak, upravo te prednosti u pogledu manevrabilnosti na teškim terenima čine projektovanje upravljanja i vođenja BGV-a izazovnim. Naime, mehanizam skretanja BGV promenom brzina gusenica (eng. skid-steering) unosi jake nelinearnosti u dinamiku kretanja. Pored toga, interakcija između gusenica i podloge je izuzetno složena i promenljiva, dovodeći do čestih i nepredvidivih pojava proklizavanja koje značajno utiču na preciznost kretanja [8, 9, 10]. Tradicionalni pristupi projektovanju upravljanja, koji se često osla-

njaju na linearizovane ili uprošćene modele i klasične regulatore poput proporcionalno-integralno-derivativnog (eng. Proportional-Integral-Derivative, PID) regulatora, pokazuju ograničene performanse i robusnost kada su suočeni sa ovim nelinearnostima, nestacionarnostima modela i različitim spoljašnjim poremećajima [11, 12].

U cilju prevazilaženja navedenih ograničenja, ova disertacija istražuje primenu naprednih tehnika automatskog upravljanja. Kao osnovna strategija upravljanja odabrana je tehnika aktivnog potiskivanja poremećaja (eng. Active Disturbance Rejection Control, ADRC) [13, 14]. ADRC se izdvaja svojom sposobnošću da sve poremećaje sistema – uključujući nelinearnosti, nepoznatu ili promenljivu dinamiku, i spoljašnje poremećaje kao što je proklizavanje – tretira kao jedinstveni "ukupni poremećaj". Ovaj poremećaj se procenjuje u realnom vremenu pomoću ključne komponente ADRC-a, proširenog obsevera stanja (eng. Extended State Observer, ESO), i zatim aktivno potiskuje primenom odgovarajućeg upravljačkog zakona. Time se postiže visok stepen robusnosti i performansi sistema, odnosno značajno smanjene zavisnost od tačnosti matematičkog modela objekta upravljanja [15, 16, 17].

Pored sistema upravljanja, autonomija BGV-a zahteva i projektovanje sistema vođenja koji zahteva definisanje trenutnog i željenog položaja vozila u prostoru, kao i percepciju okruženja u kome se vozilo nalazi. Za određivanje trenutne lokacije BGV-a u širem prostoru, često se koriste podaci sa GNSS (eng. Global Navigation Satellite System), kao što je GPS, koji pružaju apsolutne koordinate u prostoru. Međutim, ovi sistemi mogu imati ograničenu preciznost ili dostupnost u određenim okruženjima, pogotovo u zatvorenom prostoru. Pored toga, informacije o orientaciji vozila i njegovom relativnom kretanju mogu se dobiti pomoću inercijalnih senzora (IMU), mada su one podložne akumulaciji greške u toku rada. U scenarijima vođenja kada je pored generisanja trajektorije potrebna i interakcija sa neposrednim okruženjem, poput praćenja zadate vozne trake, izbegavanje prepreka ili praćenje lidera, neophodna je vizuelna percepcija okruženja, koja se najčešće realizuje pomoću optičkih, laserskih i radarskih senzora.

Razvoj algoritama dubokog učenja (eng. Deep Learning, DL) doneo je napredak u obradi senzorskih podataka, a posebno u obradi slike. Modeli kao što su YOLO (eng. You Only Look Once) za detekciju objekata [18, 19], YOLOP (eng. You Only Look Once for Panoptic driving perception) za panoptičku percepciju (detekcija objekata, voznih traka i vozne površine) [20, 21], i biblioteka MPP (eng. MediaPipe Pose) za estimaciju ljudske poze [1] omogućavaju BGV-u da razume svoje okruženje – da detektuje vozne trake, prepoznaje i izbegava prepreke, identifikuje i prati ljudskog lidera, pa čak i interpretira njegove komande zadate pokretima tela. Integracija ovih DL algoritama sa podacima sa senzora (prvenstveno kamera, ali i LiDAR (eng. Light Detection and Ranging) senzora za precizno merenje rastojanja) ključna je za realizaciju složenih zadataka vođenja, kao što su autonomno praćenje zadate vozne trake sa izbegavanjem prepreka i autonomno praćenje lidera.

Iako ADRC pruža robusnost, njegovi konstantni parametri najčešće nisu optimalni u čitavom spektru dinamičkih promena okruženja i poremećaja. Stoga, ova disertacija ide korak dalje istražujući potencijal učenja sa podrškom (eng. Reinforcement Learning, RL), specifično algoritma DDPG (eng. Deep Deterministic Policy Gradient) [22, 23], za *adaptivno* podešavanje ključnih parametara ADRC regulatora u realnom vremenu. Ideja je da RL agent nauči kako da optimalno prilagodi ponašanje regulatora trenutnim uslovima, dodatno poboljšavajući performanse i robusnost BGV sistema.

Kombinovanjem robusnosti ADRC-a, perceptivnih sposobnosti DL algoritama i adaptivnosti RL-a, ova disertacija teži razvoju integrisanog rešenja za autonomno vođenje BGV-a u realnim i operativnim scenarijima, konkretno u zadacima autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka i autonomnog praćenja lidera.

1.2 Problem i predmet istraživanja

1.2.1 Problem istraživanja

Uprkos značajnom napretku u oblasti autonomnih vozila, pouzdano i efikasno upravljanje i vođenje BGV-a u realnim okruženjima i dalje predstavlja otvoren istraživački problem. Ključni izazovi i pitanja koja motivišu ovo istraživanje mogu se sažeti na sledeći način:

- **Ograničenja klasičnih metoda upravljanja:** standardni industrijski PID i drugi klasični regulatori, iako široko rasprostranjeni, fundamentalno su ograničeni u sposobnosti da se efikasno nose sa kompleksnom, nelinearnom dinamikom BGV-a, jakim spregama između lateralnog i longitudinalnog kretanja, i posebno sa nepredvidivim i vremenski promenljivim poremećajima kao što je proklizavanje gusenica na različitim podlogama [8, 11, 24]. Njihova zavisnost od linearnih modela i konstantnih parametara dovodi do smanjenja performansi i robusnosti u realnim uslovima.
- **Izazovi percepcije i vođenja:** sistemi vođenja zasnovani na optičkim kamerama suočavaju se sa izazovima kao što su promene osvetljenja, senke, nejasne oznake vozne trake ili nepredvidivo ponašanje lidera (operatera). Shodno tome, potrebni su robusni algoritmi koji mogu pouzdano detektovati relevantne elemente okruženja i generisati adekvatne signale za vođenje uprkos ovim poteškoćama [25, 26]. Takođe, za zadatak autonomnog praćenja lidera, pored detekcije, bitna je i interpretacija namera ili komandi lidera, što zahteva prepoznavanje karakterističnih gestova i poza lidera.
- **Nedostatak integrisanih i validiranih rešenja za BGV:** iako literatura sadrži brojne studije koje ispituju pojedinačne aspekte upravljanja BGV-a, treba naglasiti da

nedostaju sveobuhvatna rešenja koja integrišu ove napredne tehnologije u kompletne sisteme, posebno razvijene i eksperimentalno validirane za BGV. Ovo je naročito evidentno u kompleksnim zadacima kao što su autonomno praćenje zadate vozne trake sa simultanim izbegavanjem prepreka i autonomno praćenje lidera u dinamičkim okruženjima [27, 28]. Većina validacija ovakvih sistema se i dalje oslanja na simulacije ili eksperimente sa vozilima na točkovima ili u kontrolisanim uslovima, što stvara jaz između teorijskih dostignuća i njihove praktične primene u realnim scenarijima.

- **Ograničenja ADRC sa konstantnim parametrima:** iako ADRC pruža viši nivo robusnosti u odnosu na konvencionalne regulatore, njegova efektivnost je ograničena izborom konstantnih vrednosti ključnih parametara, kao što su propusni opsezi regulatora i observera. Manuelno podešavanje ovih parametara za optimalne performanse u različitim radnim uslovima predstavlja izazov i često rezultira kompromisnim rešenjem koje ne može biti optimalno u svim scenarijima. Posebno je problematično kada se BGV kreće kroz drastično različite uslove rada (npr. prelazak sa asfalta na blato, nagla promena brzine lidera, visok nivo šuma senzora), što može prouzrokovati ili previše agresivan ili previše spor odziv [29]. Shodno navedenom, nameće se potreba za mehanizmom koji bi adaptivno u realnom vremenu podešavao odgovarajuće parametre regulatora.

Ovi problemi ukazuju na potrebu za razvojem integrisanih, robusnih i adaptivnih sistema upravljanja i vođenja, validiranih kroz realne eksperimente, kako bi se ostvario pun potencijal autonomnih BGV-a.

1.2.2 Predmet istraživanja

U skladu sa identifikovanim problemima, predmet istraživanja ove doktorske disertacije je usmeren na projektovanje, simulacionu analizu, implementaciju i eksperimentalnu verifikaciju integrisanih, robusnih i adaptivnih sistema upravljanja i vođenja za BGV. Istraživanje se fokusira na sledeće ključne aspekte:

- **Modeovanje objekta upravljanja:** u okviru čega je razvijen i kinematički model kretanja BGV-a, koji uključuje efekte proklizavanja pogonskih gusenica.
- **Razvoj i validacija ADRC sistema upravljanja:** što obuhvata projektovanje robusnog upravljačkog sistema zasnovanog na bazi ADRC koncepta za lateralni i longitudinalni kanal upravljanja BGV-a. Ovo uključuje i analizu kinematičkog modela sa proklizavanjem, definisanje ADRC struktura (ESO i upravljački zakon) i podešavanje parametara (ω_{CL} , ω_{ESO}) korišćenjem metode parametrizacije propusnog opsega. Ključni deo je implementacija i eksperimentalna validacija ovog sistema

na realnoj laboratorijskoj BGV platformi za zadatke autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka i autonomnog praćenja lidera.

- **Razvoj i implementacija sistema vođenja zasnovanog na DL-u:** što podrazumeva projektovanje i implementaciju modula za percepцију i vođenje korišćenjem naprednih senzora (monokularna kamera, LiDAR) i algoritama DL-a. Ovaj deo istraživanja obuhvata:
 - Sistem za autonomno praćenje zadate vozne trake i izbegavanje prepreka: korišćenje YOLOv2 i YOLOv8 za detekciju, razvoj algoritama za obradu linija vozne trake, generisanje virtuelnih putanja i izračunavanje signala za vođenje.
 - Sistem za autonomno praćenje lidera: korišćenje YOLOv8 za detekciju/praćenje, MPP za prepoznavanje komandi pozom, obrada LiDAR podataka za merenje rastojanja i izračunavanje grešaka praćenja.

Implementacija ovih sistema se vrši u programskom jeziku Python za potrebe eksperimentalne validacije.

- **Razvoj i simulaciona validacija adaptivnog ADRC sistema (ADRC-RL):** u okviru čega je predložena nova strategije gde se ADRC parametri adaptivno podešavaju pomoću DDPG algoritma. Ovo uključuje formulaciju problema u RL okviru (stanja, akcije, nagrade), projektovanje i obučavanje DDPG agenata (*actor-critic*) u MATLAB/Simulink okruženju. Performanse ADRC-RL sistema se simulaciono ocenjuju i porede sa ADRC regulatorom sa konstantnim parametrima, u zadatku autonomnog praćenja lidera u prisustvu složenih poremećaja.

Kroz integraciju ovih komponenti, disertacija teži da pruži sveobuhvatno rešenje koje unapređuje sposobnosti autonomnog kretanja BGV-a u realnim uslovima.

1.3 Hipoteze, metodologija i očekivani rezultati istraživanja

1.3.1 Hipoteze i način njihove provere

Na osnovu definisanog problema i predmeta istraživanja, postavljene su sledeće hipoteze:

Opšta hipoteza:

Projektovanje naprednih algoritama upravljanja BGV sa aktivnim potiskivanjem poremećaja i adaptivnih načina podešavanja parametara, integrisanih sa sistemima vođenja

BGV zasnovanim na DL-u, omogućava postizanje visokih performansi autonomnog kretanja BGV u uslovima delovanja unutrašnjih i spoljašnjih poremećaja (proklizavanje, šum, dinamički lider).

Posebne hipoteze:

- a) U poređenju sa primenom standardnih industrijskih tehnika upravljanja, primena naprednih robusnih algoritama upravljanja BGV na bazi ADRC koncepta omogućće bolje performanse i robusnost autonomnog kretanja vozila u uslovima dejstva različitih poremećaja.
- b) Realizacija sistema vođenja na bazi primene algoritama DL-a u obradi video izlaza kamere i LiDAR podataka omogućiće pouzdano autonomno praćenje zadate vozne trake, izbegavanje prepreka, autonomno praćenje lidera i prepoznavanje komandi zadatih pozom lidera, čime se postiže viši stepen autonomije BGV-a i poboljšana interakcija sa liderom.
- c) Implementacija projektovanih sistema upravljanja i vođenja na laboratorijskom BGV, pružiće osnovu za dalji razvoj ovakvih sistema i potencijalnu implementaciju na postojeća vojna i civilna besposadna vozila.
- d) Primena adaptivnog podešavanja parametara ADRC regulatora u realnom vremenu, korišćenjem RL (ADRC-RL), omogućiće bolje performanse praćenja u poređenju sa ADRC regulatorom sa konstantnim parametrima, posebno u uslovima promenljivih poremećaja (brzina lidera, proklizavanje) i šuma merenja senzora.

1.3.2 Metodologija istraživanja

Istraživanje u okviru ove disertacije sprovedeno je kombinacijom teorijskih analiza, računarskih simulacija i eksperimentalnih ispitivanja, koristeći sledeće metode i alate:

- **Modelovanje sistema**

U okviru programskog paketa MATLAB/Simulink razvijen je i korišćen kinematički model kretanja BGV-a koji uključuje efekte proklizavanja gusenica.

- **Projektovanje sistema upravljanja**

- ADRC regulatori (lateralni i longitudinalni) sa konstantnim parametrima projektovani su u vremenskom domenu, primenom koncepta ESO-a i zakona upravljanja sa povratnom spregom po stanju. Parametri su podešeni metodom parametrizacije propusnog opsega u MATLAB-u. Diskretna implementacija ovih regulatora za eksperimentalnu validaciju realizovana je u programskom jeziku Python.

- Adaptivni ADRC-RL sistem upravljanja, specifičan za zadatak autonomnog praćenja lidera, projektovan je, obučen i simuliran u MATLAB/Simulink okruženju. DDPG algoritam, zasnovan na *actor-critic* arhitekturi, korišćen je za online podešavanje parametara ADRC regulatora unutar Simulink modela.
- Klasični PID/PI regulatori korišćeni su kao osnova za poređenje performansi u simulacijama (MATLAB/Simulink) i eksperimentima.

- **Projektovanje sistema vođenja**

- Sistem percepcije i vođenja za *autonomno praćenje zadate vozne trake sa izbegavanjem prepreka*, zasnovan na monokularnoj kameri, implementiran je u programskom jeziku Python. Korišćene su OpenCV biblioteka i predtrenirani modeli DL-a (YOLOv2 za vozne trake, YOLOv8 za prepreke). Razvijeni su algoritmi za obradu detektovanih traka, definisanje regiona od interesa (eng. Region of Interest, ROI), generisanje virtualnih traka za izbegavanje i izračunavanje lateralne greške (eng. cross-track error).
- Sistem percepcije i vođenja za *autonomno praćenje lidera*, zasnovan na fuziji podataka sa monokularne kamere i LiDAR senzora, takođe je implementiran u Python-u. YOLOv8 je korišćen za detekciju i praćenje lidera, MPP za prepoznavanje poza, a razvijeni su algoritmi za obradu LiDAR podataka i izračunavanje lateralne i longitudinalne greške praćenja.

- **Eksperimentalna platforma**

U okviru eksperimentalne validacije korišćeno je laboratorijsko BGV sa integriranim monokularnom kamerom, LiDAR senzorom, ugrađenim računarom i Wi-Fi komunikacionim modulom. Upravljački i vodeći algoritmi implementirani u Python-u izvršavani su na eksternom laptop računaru koji je komunicirao sa vozilom preko TCP/IP protokola.

- **Simulaciona validacija**

Za zadatak autonomnog praćenja lidera performanse ADRC sistema upoređene su sa PID/PI regulatorima u MATLAB/Simulink okruženju pod različitim scenarijima poremećaja (proklizavanje, šum, promenljiva brzina lidera). Zatim su, pod istim uslovima, upoređene performanse adaptivnog ADRC-RL sistema sa konstantnim ADRC sistemom. Analizirana je i stabilnost ADRC-RL korišćenjem nasumičnih početnih uslova.

- **Eksperimentalna validacija**

Performanse ADRC sistema i sistema vođenja, implementiranih Python-u, testirane su na realnom laboratorijskom vozilu.

- Za autonomno praćenje zadate vozne trake sa izbegavanjem prepreka korišćena je namenski napravljena unutrašnja test staza sa preprekama (poređenje ADRC vs PID).
- Za autonomno praćenje lidera testovi su sprovedeni u spoljašnjim uslovima na različitim podlogama (asfalt, zemlja), uključujući testiranje reakcije na komande pozom.

- **Parametri za ocenu performansi sistema**

Za kvantitativnu evaluaciju korišćeni su parametri za ocenu performansi kao što su greške praćenja (lateralna e_d , longitudinalna $e_{s(e)}$), integral apsolutne greške (eng. Integral Absolute Error, IAE), energija (eng. Energy, E) upravljačkog signala i ukupna varijacija (eng. Total Variation, TV) upravljačkog signala.

1.4 Struktura disertacije

Doktorska disertacija je organizovana u pet poglavlja, čiji je sadržaj ukratko opisan u nastavku.

Uvodno poglavlje (poglavlje 1) pruža širi kontekst istraživanja, definiše naučni problem i predmet naučnog rada. Zatim se izlažu osnovne i posebne hipoteze koje su vodile istraživanje, zadaci koji su postavljeni i detaljno se opisuje primenjena naučna metodologija. Na kraju, daje se pregled očekivanih rezultata, odnosno naučnih doprinosa disertacije, kao i sama struktura disertacije po poglavlјima.

Poglavlje 2 daje sveobuhvatan pregled oblasti upravljanja i vođenja BV-a. Analizirana je istorija razvoja, nivoi autonomije SAE (eng. Society of Automotive Engineers), različiti tipovi BV prema mehanizmu kretanja, sa posebnim osvrtom na specifičnosti, prednosti i izazove u radu sa BGV. Potom se opisuje standardna arhitektura sistema autonomnog kretanja koja obuhvata sisteme vođenja i upravljanja. Opisuju se osnovni zadaci i načini vođenja. Razmatraju se različite strategije upravljanja, uz argumentaciju za izbor ADRC tehnike kao centralne u ovoj disertaciji. Poglavlje se završava pregledom relevantne literature iz oblasti ADRC primena i specifičnih zadataka autonomnog kretanja BV.

Poglavlje 3 opisuje konkretno projektovanje sistema upravljanja i vođenja BGV-a. Najpre se definiše kinematički model BGV-a sa proklizavanjem. Zatim se projektuju ADRC regulatori (lateralni i longitudinalni). Nakon toga, detaljno se opisuju sistemi vođenja zasnovani na DL-u i senzorima (kamera, LiDAR) za specifične zadatke: autonomno praćenje zadate vozne trake sa izbegavanjem prepreka i autonomno praćenje lidera sa prepoznavanjem poza. Na kraju poglavlja, predstavljena je eksperimentalna postavka i detaljno su analizirani rezultati validacije ADRC sistema i sistema vođenja na realnoj BGV platformi za oba zadatka, uključujući poređenje sa sistemom upravljanja BGV na bazi PID regulatora.

Nadovezujući se na prethodno poglavlje, **poglavlje 4** istražuje unapređenje ADRC sistema kroz adaptivno podešavanje parametara korišćenjem RL, specifično za zadatak autonomnog praćenja lidera. Predstavlja se teorijska osnova RL i DDPG algoritma. Zatim se detaljno razrađuje ADRC-RL pristup: definisanje stanja, akcija, funkcija nagrade i arhitekture DDPG agenata (*actor-critic*). Performanse ADRC-RL sistema se evaluiraju kroz simulacije u MATLAB/Simulink okruženju, poredeći ih sa ADRC sistemom sa konstantnim parametrima.

Konačno, **poglavlje 5** predstavlja sintezu celokupnog rada. Sumiraju se ključni rezultati i doprinosi disertacije, daje se osvrt na stepen potvrđenosti postavljenih hipoteza na osnovu dobijenih simulacionih i eksperimentalnih rezultata. Kritički se sagledavaju ograničenja sprovedenog istraživanja i daju se konkretni predlozi i pravci za buduća istraživanja u ovoj oblasti.

Na kraju disertacije dat je spisak korišćene literature, kao i pregled publikacija autora disertacije.

Poglavlje 2

Osnovne karakteristike besposadnih vozila i autonomnog kretanja

Brz napredak senzorskih sistema, elektronike, sistema automatskog upravljanja i vođenja, doveo je do značajnih mogućnosti razvoja BV-a u pogledu autonomnosti rada. Ova vozila, sposobna da rade bez direktnе ljudske intervencije, pronašla su primenu u širokom spektru oblasti, uključujući vojne operacije, poljoprivredu, traganje i spasavanje, različite logističke operacije, itd. U toku razvoja ovih tehnologija, BGV su se pojavila kao posebno obećavajuće platforme zbog svoje sposobnosti kretanja po nepristupačnim terenima, mogućnosti nošenja teških tereta i generalno obavljanja zadataka u složenim okruženjima. Međutim, autonomni rad BGV-a donosi jedinstvene izazove, posebno u smislu projektovanja odgovarajućih sistema upravljanja i vođenja.

Ova disertacija fokusira se na upravljanje i vođenje BGV-a, sa posebnim naglaskom na scenarije autonomnog praćenja lidera i autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka. Ovi zadaci su kritični za uspešnu primenu BGV-a u aplikacijama u stvarnom svetu, gde moraju da rade u dinamičkim i nepredvidivim okruženjima. Primarni zadatak ovog istraživanja je razvoj robusnih algoritama upravljanja i vođenja koji omogućavaju BGV-u da autonomno prati lidera (bilo čoveka ili drugo vozilo) i prati zadate vozne trake uz izbegavanje prepreka. Shodno tome, a da bi se detaljnije sagledao definisani predmet istraživanja, u nastavku ovog poglavlja analizirani su istorijski aspekt razvoja i tipova BV, stepeni autonomije, opšta struktura i pravci u razvoju sistema vođenja i upravljanja, kao i pregled relevantne literature iz ove oblasti istraživanja.

2.1 Istorija, karakteristike i podela besposadnih vozila

2.1.1 Istorija besposadnih vozila

Najraniji primeri BV javljaju se tokom 1930-ih i njihov rani razvoj uključivao je projektovanje jednostavnih daljinski upravljenih vozila za industrijske i vojne primene, kao što

su sovjetski i nemački radio-upravljeni tenkovi [4, 30, 31, 32, 33], prvenstveno za zadatke kao što su rukovanje eksplozivima i isporuka oružja. Ova rana BV-a, iako ograničena u sposobnostima i pouzdanosti za praktičnu primenu, služila su kao ključni konceptualni prethodnici, demonstrirajući potencijal uklanjanja ljudskih operatera iz opasnih zadataka.

Druga polovina 20. veka svedočila je prelasku ka sofisticirajim konceptima. Krajem 1960-ih, počela je da se pojavljuje ideja o automatski vođenim vozilima, a značajna prekretnica bila je stvaranje mobilnog robota "Shakey" na Univerzitetu Stanford. Shakey, opremljen kamerama i ultrazvučnim senzorima, često se smatra prvom generacijom pravih mobilnih robota sposobnih da donose odluke o kretanju na osnovu svog okruženja [4, 34, 35, 36].

Američki naučni program DARPA (eng. Defense Advanced Research Projects Agency, DARPA), počevši od ranih 2000-ih, delovao je kao glavni katalizator za ubrzanje razvoja BV-a [3, 35]. Ovi izazovi podstakli su inovacije u senzorima, algoritmima i ukupnom projektovanju sistema, pomerajući granice autonomne terenske mobilnosti i otvarajući put za napredne BV sisteme koje vidimo danas [34].

Savremena BV koriste kombinaciju senzora, uključujući kompjutersku viziju, GPS (eng. Global Positioning System), LiDAR i druge, kako bi efikasno razumeli i ostvarili interakciju sa okruženjem. U suštini, tipične funkcije BV-a mogu se podeliti na sledeće tri funkcije: „Razumeti kuda idem i šta treba da uradim“, „Razumeti okruženje i pronaći put kroz njega“ i „Upravljati aktuatorima vozila kako bi pratili željenu trajektoriju“. Ova tri dela su baš kao mozak, oči i noge ljudskog bića. Sofisticirani algoritmi za planiranje kretanja i napredne tehnike upravljanja omogućavaju im da manevrišu kroz različite uslove i obavljaju složene zadatke. Rastuća potražnja za BV-ima u različitim sektorima proizilazi iz njihove sposobnosti da obavljaju zadatke koji su opasni, zamorni ili zahtevaju visok nivo preciznosti i efikasnosti [37, 38, 39, 40]. U vojnem i bezbednosnom domenu, BV se koriste za izviđanje, nadzor i uklanjanje eksploziva, gde pomažu u minimiziranju rizika po ljudsko osoblje [34, 41]. U poljoprivredi, BV se razvijaju za zadatke kao što su sadnja, žetva i praćenje useva, što može poboljšati efikasnost i smanjiti troškove rada [6]. U logistici i transportu, BV se koriste za zadatke kao što su transport materijala i dostava zaliha unutar strukturiranog ili nestrukturiranog okruženja [30, 42]. Pored toga, primene u operacijama traganja i spasavanja, upravljanju opasnim otpadom i građevinarstvu pružaju dodatne dokaze o širokom obimu i prilagodljivosti BV-a [30, 37, 43]. Ova rastuća potražnja za BV-ima u više sektora naglašava potrebu za daljim razvojem i inovacijama u tehnologiji BV-a, posebno u oblastima autonomije, prilagodljivosti i robusnog upravljanja.

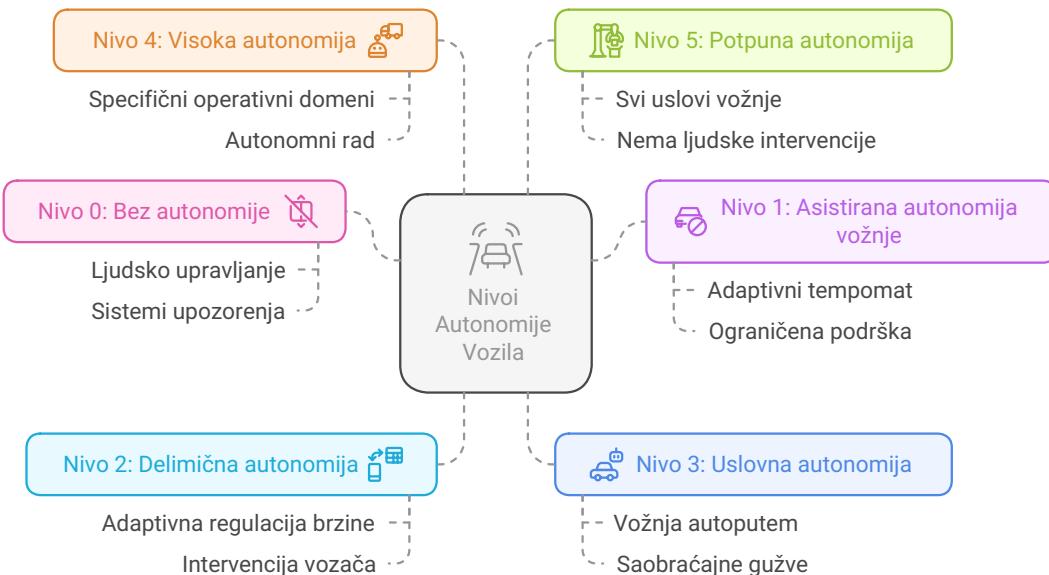
Ovaj istorijski pregled demonstrira dugu evoluciju BV-a, od jednostavnih daljinskih upravljanih uređaja do sve sofisticirajih autonomnih platformi. Progresija ka većoj autonomiji je ključna tema, što je dalje ilustrovano ispitivanjem različitih nivoa autonomije definisanih za BV.

2.1.2 Nivoi autonomije kod BV-a

Da bi se bolje razumele sposobnosti savremenih BV-a, ključno je razmotriti koncept autonomije. Autonomija, u kontekstu besposadnih vozila, odnosi se na stepen do kojeg vozilo može da radi nezavisno od ljudske intervencije, odnosno da se autonomno kreće. SAE je uspostavilo široko priznat sistem klasifikacije nivoa autonomije komercijalnih vozila, koji se može primeniti i na BV. U sklopu toga, definisano je šest nivoa autonomije vožnje (slika 2.1), u rasponu od Nivoa 0 (bez autonomije) do Nivoa 5 (potpuna autonomija) [3, 44].

- **Nivo 0: bez autonomije.** Na ovom nivou, vozilo radi u potpunosti pod ljudskom upravljanjem (od strane vozača u vozilu ili daljinskim putem), bez autonomnih sposobnosti. Vozilo može imati neke tehnologije za pomoć vozaču, kao što su sistemi upozorenja (eng. warning systems).
- **Nivo 1: asistirana autonomija vožnje.** Vozila u ovoj kategoriji uključuju osnovne funkcije autonomne vožnje koje pružaju ograničenu podršku vozaču. Sistemi kao što je adaptivni tempomat mogu upravljati ubrzanjem, kočenjem ili pravcem kretanja, ali vozač ili daljinski operater ostaje potpuno odgovoran za nadzor i celokupno upravljanje vozilom.
- **Nivo 2: delimična autonomija.** BV mogu obavljati složenije zadatke, kombinujući dve ili više autonomnih funkcija kao što je adaptivna regulacija brzine. Vozilo može da upravlja upravljanjem pravcem i ubrzanjem/usporenjem u određenim uslovima, ali vozač ili daljinski operater mora biti spremna da interveniše u svakom trenutku.
- **Nivo 3: uslovna autonomija.** Ovaj nivo označava značajan korak ka pravoj autonomiji. Vozila Nivoa 3 mogu obavljati sve zadatke vožnje u specifičnim, ograničenim uslovima, kao što su vožnja autoputem ili saobraćajne gužve. Od vozača, odnosno operatera, se ne zahteva da kontinuirano nadgleda okruženje, ali mora biti spremna da preuzme upravljanje kada se to zatraži.
- **Nivo 4: visoka autonomija.** BV mogu raditi autonomno u većini scenarija vožnje, čak i ako operater ne odgovori na zahtev za intervencijom. Međutim, rad može i dalje biti ograničen na specifične projektovane operativne domene (eng. operational design domains).
- **Nivo 5: potpuna autonomija.** Vozilo je potpuno autonomno i sposobno da obavlja sve zadatke vožnje u svim uslovima kojima bi operater mogao da upravlja. Nikada nije potrebna ljudska intervencija.

Ovaj spektar nivoa autonomije ističe rastuću sofisticiranost BV-a. Dok niži nivoi nude pomoć vozaču, fokus naprednih istraživanja BV-a, kao i ove disertacije, leži u postizanju



Slika 2.1: Nivoi autonomije kod BV-a

viših nivoa autonomije, posebno za izazovne zadatke i okruženja. Iako je postizanje potpune autonomije (Nivo 5) još uvek rad u toku, mnoga skrašnja istraživanja fokusiraju se na poboljšanje performansi i sposobnosti BV-a na nivoima 3 i 4 u složenim i izazovnim scenarijima stvarnog sveta. Da bi se dalje razumele raznovrsne sposobnosti BV-a, korisno je ispitati različite tipove korišćenih sistema kretanja.

2.1.3 Tipovi besposadnih vozila

Kroz svoj razvoj BV su evoluirala u raznovrstan spektar platformi, svaka sa jedinstvenim mehanizmima kretanja i sposobnostima. Ove razlike proističu iz potrebe za prilagođavanjem različitim operativnim okruženjima i zadacima. Ove razlike u projektovanju i funkcionalnostima naglašavaju raznolikost izazova i mogućnosti u njihovom istraživanju i razvoju. Primarne strategije kretanja koje se koriste kod BV-a mogu se kategorisati u četiri glavna tipa: vozila sa točkovima, gusenična vozila, vozila sa nogama i hibridni sistemi.

- **Vozila sa točkovima:** predstavljaju najčešći tip besposadnih vozila, zbog svoje relativne jednostavnosti, lakoće upravljanja i efikasnosti u kretanju po dobro definisanim i ravnim površinama. Princip kretanja oslanja se na rotaciono kretanje točkova povezanih sa šasijom, omogućavajući im da navigiraju kroz različita okruženja. Ovakva vozila mogu koristiti različite arhitekture mehanike upravljanja, kao što su diferencijalno upravljanje, Akermanovo upravljanje (eng. Ackermann steering), omnididirekciono upravljanje i sistemi upravljanja na sva četiri točka, pružajući različite stepene manevarske sposobnosti i stabilnosti [45, 46, 47].
- **Besposadna gusenična vozila (BGV):** koriste sistem kretanja zasnovan na kontinualnim gusenicama koje obezbeđuju veliku kontaktnu površinu sa terenom, što

poboljšava trakciju, stabilnost i sposobnost kretanja po složenim i neravnim terenima. najčešće primenjuju diferencijalni mehanizam upravljanja, gde se svaka gusenica kreće nezavisno, omogućavajući vozilu da skreće promenom brzine gusenica. Mehanika guseničnog vozila olakšava efikasnu manevarsку sposobnost i robusno kretanje primenom visokog obrtnog momenta, što je neophodno pri kretanju po teškim terenima [5, 6, 8].

- **Vozila sa nogama:** Ona imitiraju biološko kretanje, koristeći aktuatore i zglobove za generisanje niza diskretnih koraka. Ovakvi sistemi se odlikuju sposobnošću da prelaze preko veoma zahtevnih i izazovnih terena sa visokim stepenom mobilnosti i manevarske sposobnosti. Dinamička ravnoteža i koordinacija između različitih nogu čine ih veoma pogodnim za složene zadatke, kao što su kretanje preko prepreka, stepenica i zakrčenih prostora [45, 48].
- **Hibridna besposadna vozila:** Ona kombinuju više mehanizama kretanja, kao što su točkovi, noge i/ili gusenice, kako bi iskoristila njihove prednosti i ublažila njihova ograničenja, pružajući poboljšanu mobilnost i prilagodljivost za različite radne uslove. Ovi složeni sistemi pokušavaju da maksimiziraju svoje performanse kombinovanjem različitih sistema kretanja, kako bi prevazišli ograničenja svakog sistema ponaosob, što dovodi do složenijeg i fleksibilnijeg sistema [45, 49].

Uporedni pregled ključnih prednosti i izazova povezanih sa svakim tipom BV-a, potkrepljen relevantnim referencama, prikazan je u sledećoj tabeli 2.1.

Ova studija se bavi pitanjima vezanim za projektovanje autonomnog kretanja BGV, koji zahteva posebno projektovanje sistema upravljanja i vođenja vozilom. Shodno tome, sledeći odeljak će analizirati načine autonomnog kretanja, dok će nakon toga biti predstavljeni specifični izazovi i složenosti pri projektovanju sistema vođenja i upravljanja BGV-a.

2.2 Načini autonomnog kretanja

Načini autonomnog kretanja BV mogu se kategorisati u tri fundamentalna tipa, i po svojoj složenosti od najjednostavnijeg do najsloženijeg se mogu postaviti na sledeći način:

- **Kretanje od tačke do tačke (eng. Point-to-Point):** od vozila se zahteva da se kreće od jedne specifične lokacije (početne tačke) do druge (ciljne tačke) bez nužnog praćenja unapred definisane putanje. Ovo je najjednostavniji oblik autonomnog kretanja, fokusiran isključivo na dostizanje odredišta uz potencijalno izbegavanje prepreka, ne obraćajući pažnju na geometriju putanje i profile brzine kretanja [27, 55].

Tip BV	Prednosti	Nedostaci	Reference
Sa točkovi-ma	Visoka energetska efikasnost, niski troškovi proizvodnje, jednostavni algoritmi upravljanja, velike brzine na ravnim terenima, pogodni za okruženja koja je napravio čovek.	Ograničena sposobnost savladavanja složenih i neravnih terena, podložnost proklizavanju na rastresitim površinama, nedostatak mobilnosti na veoma grubim terenima.	[35, 45, 46, 47, 49, 50]
Besposadno gusenično vozilo (BGV)	Visoka sposobnost prelaska preko izazovnih terena (pešak, blato, strme padine, kamenite površine), poboljšana trakcija i stabilnost, veća nosivost, dobar kontakt sa tlom.	Veća potrošnja energije, povećana mehanička složenost, manja manevarska sposobnost u poređenju sa vozilima sa točkovima, složena dinamika skretanja i implementacija regulatora, povećana podložnost proklizavanju.	[5, 6, 7, 8, 9, 10, 45, 51, 52, 53]
Sa nogama	Manevarska sposobnost na složenim terenima, sposobnost penjanja uz stepenice i kretanja kroz zakrčene prostore, visoka prilagodljivost i savladavanje prepreka.	Povećana složenost sistema, veći energetski zahtevi, veliko računarsko opterećenje, manje efikasno kretanje na dužim distancama, teže projektovanje algoritma upravljanja.	[45, 48, 54]
Hibridni	Velika svestranost na različitim terenima zbog različitih mehanizama kretanja, prilagodljivost za složene zadatke i okruženja, poboljšane performanse pod različitim uslovima.	Složena implementacija upravljanja za više mehanizama kretanja, visoki troškovi i složenost projektovanja, povećani hardverski i računarski zahtevi.	[45, 49]

Tabela 2.1: Poređenje tipova BV.

- **Praćenje putanje (eng. Path Following):** od vozila se zahteva da konvergira i prati unapred definisanu geometrijsku putanju bez vremenskih zahteva [55, 56]. Zadatak upravljanja je prostorna konvergencija – minimiziranje lateralne greške – uz dozvoljavanje fleksibilnosti u brzini kretanja. Dakle, praćenje putanje znači, kao prvi korak, razmatranje tačke na zadatoj putanji koja je najbliža vozilu, i vođenje vozila da dostigne tu tačku. Nakon toga, drugi korak je da vozilo postigne brzinu koja je uvek tangentna na putanju, bez obzira na njenu veličinu. Ovo znači da je veličina brzine duž putanje slobodno definisana [57]. Pošto je primarni zadatak prostorna konvergencija ka geometrijskoj putanji bez striktnih vremenskih zahteva, praćenje putanje se pretežno oslanja na lateralno upravljanje kako bi se minimizirala lateralna greška i poravnala orijentacija vozila sa tangentom na putanju. Longitudi-

nalno upravljanje, ako postoji, obično teži održavanju željene (često konstantne ili jednostavno profilisane) brzine duž putanje, umesto postizanja precizne vremenske sinhronizacije. U upravljanju praćenjem putanje, često se prepostavlja da brzina kretanja vozila napred prati unapred definisani profil brzine, dok upravljački sistem primarno reguliše orijentaciju vozila kako bi osigurao konvergenciju ka željenoj putanji [27, 58].

- **Praćenje trajektorije (eng. Trajectory Tracking):** predstavlja najsloženiji oblik autonomnog kretanja i podrazumeva kretanje vozila duž unapred definisane geometrijske putanje sa definisanim vremenskim zahtevima. Naime, vozilo mora pratiti vremenski parametrizovanu trajektoriju koja definiše i poziciju i brzinu u svakom trenutku. Pod trajektorijom podrazumevamo kretanje virtualne tačke u ravni definisanom brzinom. U tom slučaju, vozilo mora inicijalno postići brzine veće od onih definisanih trajektorijom kako bi konvergiralo ka njoj. Kada vozilo dostigne virtualni cilj, treba da smanji svoju brzinu kako bi se uskladila sa brzinom trajektorije, osiguravajući da ostane na željenoj putanji [57]. Pošto praćenje trajektorije zahteva istovremenu konvergenciju u prostoru i vremenu (uskladihanje profila pozicije i brzine), ono zahteva koordinisano lateralno i longitudinalno upravljanje. Lateralni regulator osigurava da vozilo ostane na geometrijskoj putanji, dok longitudinalni regulator upravlja brzinom kako bi ispunio vremenske zahteve trajektorije.

Na osnovu prethodnog može se istaći da glavna razlika kod razmatranih načina autonomnog kretanja leži u tome što se kod kretanja od tačke do tačke definiše samo željena destinacija bez specificiranja putanje ili brzine. Praćenje putanje podrazumeva vođenje vozila duž predviđene putanje sa odgovarajućim lateralnim upravljanjem, pri čemu je brzina vozila najčešće unapred definisana. Konačno, najsloženiji zadatak praćenja trajektorije podrazumeva određivanje vremena potrebnog vozilu da pređe zadatu putanju, dok su veličina i pravac brzine vozila definisani praćenom trajektorijom kroz odgovarajuće longitudinalno upravljanje.

Ovde je potrebno napomenuti da se u kontekstu ove disertacije, razmatraju dva specifična načina autonomnog kretanja: **autonomno praćenje zadate vozne trake sa izbegavanjem prepreka i autonomno praćenje lidera**, koji se mogu okarakterisati kao specifični slučajevi prethodno definisanih fundamentalnih načina autonomnog kretanja. Shodno tome, u nastavku će oni biti detaljno objašnjeni.

2.2.1 Autonomno praćenje zadate vozne trake sa izbegavanjem prepreka

Ovaj način autonomnog kretanja se može klasifikovati kao zadatak praćenja putanje. Primarni cilj je održavanje vozila unutar geometrijskih granica vozne trake minimizacijom

lateralnog odstupanja vozila. Iako se brzina može prilagođavati geometriji putanje (npr. u krivinama ili pri izbegavanju prepreka se može smanjiti, a na pravim delovima povećati), ne postoji striktan vremenski zahtev za dostizanje određene tačke duž vozne trake.

Autonomno praćenje zadate vozne trake sa izbegavanjem prepreka predstavlja značajnu sposobnost za BV, omogućavajući im kretanje u strukturiranim i nestrukturiranim okruženjima. Autonomno praćenje zadate vozne trake zahteva da vozilo prati statičke granice vozne trake uz istovremeno detektovanje i izbegavanje prepreka. Ovaj dvostruki zadatak posebno je izazovan za BGV zbog njihove dinamike upravljanja i rada u terenskim uslovima gde vozne trake mogu biti slabo definisane, imati oštре krivine i brojne prepreke. Robusni sistemi vođenja i upravljanja su suštinski važni da bi se osiguralo tačno autonomno praćenje zadate vozne trake, izbegavanje kolizija i stabilnost pod poremećajima kao što su proklizavanje ili neravan teren.

Uspešna realizacija ovog zadatka zahteva rešavanje dva ključna podzadataka: (1) **detekcija vozne trake**, što podrazumeva pouzdano identifikovanje granica vozne trake u kojoj se vozilo trenutno nalazi, čak i u uslovima promenljive vidljivosti ili oštećenih oznaka, korišćenjem obrade senzorskih podataka, najčešće optičkih, kako bi se ekstrahovala geometrija trake; i (2) **detekcija i izbegavanje prepreka**, što obuhvata prepoznavanje statičkih ili dinamičkih prepreka na putanji vozila i generisanje odgovarajućeg manevra za njihovo bezbedno zaobilaženje, uz minimalno narušavanje primarnog zadatka praćenja trake.

Ova dva podzadataka su međusobno povezana, jer detekcija prepreka često zavisi od prethodno definisanih granica vozne trake (npr. za definisanje ROI u kojem radi algoritam za detekciju prepreka), dok manevar izbegavanja mora uzeti u obzir raspoloživi prostor unutar trake. U nastavku će biti detaljnije opisani pristupi i izazovi vezani za svaki od ovih podzadataka, sa posebnim fokusom na metode zasnovane na vizuelnim senzorima koje su korišćene u ovoj disertaciji.

2.2.1.1 Detekcija vozne trake

Percepcija okoline je fundamentalna za autonomno praćenje zadate vozne trake, a posebno za detekciju njenih granica. Sistem vođenja se u velikoj meri oslanja na senzore poput kamera i LiDAR-a za detekciju ovih granica u realnom vremenu.

Metode korišćene za detekciju vozne trake značajno su evoluirale tokom godina, prelazeći sa tradicionalnih pristupa geometrijskog modeliranja na sofisticiranije tehnike mašinskog učenja (eng. Machine Learning, ML) i DL-a. Ova evolucija odražava rastuću složenost voznih okruženja, gde faktori kao što su promenljivi uslovi osvetljenja, tipovi puteva i delimična zaklanjanja predstavljaju izazove za pouzdanu detekciju vozne trake [59].

Među različitim senzorima korišćenim za detekciju vozne trake, kamera se izdvojila kao najšire korišćena opcija [25, 60, 61]. Pregled literature otkriva da se veliki broj

naučnih članaka fokusirao na detekciju vozne trake zasnovanu na kamери, dok samo neznatan broj radova istražuje upotrebu drugih senzora, često u kombinaciji sa kamerama [61]. Ovo naglašava kameru kao primarni perceptivni senzor, čineći je najefikasnijim i najpouzdanim izborom za zadatke detekcije vozne trake.

Postoje dva primarna razloga zašto je pristup zasnovan na viziji postao dominantan. Prvo, vizuelni podaci su modalitet koji koriste ljudski vozači. Oznake vozne trake i granice puta specifično su projektovane da budu jasno vidljive, savršeno se poklapajući sa sposobnostima ljudskog vizuelnog sistema. Drugo, kamere predstavljaju cenovno pristupačnu i robusnu opciju za automobilske primene, zahvaljujući širokoj dostupnosti i značajnim ulaganjima u tehnologiju obrade slike, što omogućava razvoj pouzdanih rešenja [62].

Uprkos ovim prednostima, detekcija oznaka vozne trake pomoću kamera u realnim okruženjima suočava se i sa značajnim izazovima [25]. Oni obuhvataju probleme sa uslovima osvetljenja, gde varijacije poput pojave senki i naglih promena osvetljenosti mogu ozbiljno uticati na vidljivost oznaka. Takođe, nepovoljni vremenski uslovi poput kiše, snega ili magle mogu zakloniti oznake ili zamutiti sliku. Pored toga, česta su zaklanjanja usled prisustva drugih vozila ili objekata koji fizički blokiraju pogled na oznake vozne trake. Konačno, postoji i rizik od pogrešnih detekcija, gde elementi na putu slični oznakama, kao što su tragovi guma ili pukotine, mogu biti pogrešno identifikovani kao trake [63].

Ovi izazovi naglašavaju potrebu za naprednim algoritmima i tehnikama kako bi se poboljšala robusnost i tačnost sistema za detekciju vozne trake zasnovanih na viziji. U tom kontekstu, u nastavku će biti razmotrone različite tehnike detekcije vozne trake, od tradicionalnih metoda do modernih pristupa zasnovanih na ML-u i DL-u, sa fokusom na metode korišćene u ovoj disertaciji.

1. **Metode zasnovane na modelu:** ove metode se oslanjaju na geometrijske pretpostavke o izgledu traka i koriste višestepene procese obrade slike. Tipično uključuju predobradu, ekstrakciju obeležja i fitovanje unapred definisanih matematičkih modela na obeležja korišćenjem tehnika kao što je *Hough transformacija* ili *RANSAC* (eng. Random Sample Consensus) [64, 65]. Mogu uključivati i praćenje pomoću Kalmanovih filtera. Iako jednostavne, ove metode zahtevaju ručno podešavanje parametara i pokazuju ograničenu robusnost u uslovima promenljivog osvetljenja, zaklanjanja ili nejasnih oznaka [66, 67, 68, 69, 70, 71].
2. **Pametne metode (ML/DL pristupi):** ove metode koriste tehnike ML-a i, dominantno, DL-a za učenje složenih obeležja i obrazaca direktno iz podataka. Ove metode su robustne u realnim uslovima puteva - promene osvetljenja, vremenske uticaje i delimično zaklanjanje traka.
 - **ML metode:** kombinuju ekstrakciju obeležja korišćenjem tehnika kao što su adaptivno određivanje praga i morfološke operacije, sa statističkim klasifikatorima poput SVM (eng. Support Vector Machines) ili BC (eng. Bayesian

classifiers) i ANN (eng. Artificial Neural Networks), za razlikovanje piksela trake od pozadine. Njihove performanse i dalje zavise od kvaliteta inicijalno ekstrahovanih obeležja [60, 72, 73, 74].

- **DL metode:** predstavljaju trenutno najnaprednije SOTA rešenje (eng. State-of-the-Art). Najčešće koriste CNN (eng. Convolutional Neural Network) za zadatke poput semantičke segmentacije, gde svaki piksel slike biva klasifikovan kao traka ili ne-traka. Većina metoda DL-a zasnovana je na CNN. RNN (eng. Recurrent Neural Network) i LSTM (eng. Long Short-Term Memory). Arhitekture poput enkoder-dekoder mreža, ponekad sa LSTM ili mehanizmima pažnje (eng. attention mechanisms), omogućavaju učenje hijerarhijskih obeležja i postizanje visoke tačnosti i robusnosti čak i u izazovnim uslovima [75, 76, 77, 78, 79, 80, 81, 82, 83]. Mogu se podeliti na jednosecene (direktno predviđanje parametara trake) i dvosecene (segmentacija pa fitovanje krive) [84]. Zbog bolje fleksibilnosti i performansi u različitim uslovima, DL metode su danas preferirani pristup [61, 83]. Iterativno učenje omogućava ovim modelima da ekstrahuju širok spektar obeležja i da detektuju oznake vozne trake čak i kada su delimično zaklonjene ili degradirane.

2.2.1.2 Detekcija i izbegavanje prepreka

Pored praćenja vozne trake, drugi ključni podzadatak sistema vođenja je detekcija i izbegavanje prepreka. Prepreke, definisane kao regioni koje vozilo ne može ili ne treba da pređe [85], mogu uključivati pešake, druga vozila, statičke objekte i elemente terena. Pouzdana detekcija i identifikacija prepreka su od suštinskog značaja za bezbednost i predstavljaju jednu od ključnih tehnologija autonomnih vozila [86]. Efikasno izbegavanje prepreka zahteva integraciju percepcije u realnom vremenu, brzog donošenja odluka i preciznog upravljanja kako bi se prepreka detektovala i zaobišla uz održavanje primarnog zadatka misije. Uspeh ovog procesa zavisi od izbora senzora i robusnosti korišćenih algoritama.

Za detekciju prepreka koristi se niz senzorskih tehnologija, koje se mogu podeliti u tri osnovne kategorije [87, 88, 89]:

- **Senzori zasnovani na merenju rastojanja:** poput **Lidar-a** koji koristi lasere za precizno 3D mapiranje i merenje rastojanja, i **Radar-a**, koji koristi radio talase za detekciju objekata, rastojanja i brzine, robustan u lošim vremenskim uslovima.
- **Senzori zasnovani na slici:** u njih spadaju **monokularne kamere** koje pružaju bogate semantičke informacije, omogućavajući prepoznavanje objekata i razumevanje scene putem naprednih algoritama obrade slike, ali bez direktne percepcije dubine. U drugu ruku, **stereo kamere** omogućavaju percepciju dubine putem triangulaci-

je, dok su i **infracrvene kamere** efikasne noću i pogodne su za detekciju toplih objekata.

- **Hibridni senzori:** kao što su **RGB-D kamere**, kombinuju informacije o boji i dubini, korisne za 3D prepoznavanje objekata na manjim rastojanjima.

Generalno, kamere su široko korišćeni senzori za detekciju prepreka, često u kombinaciji sa senzorima dometa poput Lidar-a. Vizuelne kamere omogućavaju primenu naprednih algoritama za interpretaciju scene i klasifikaciju objekata [87, 88].

Iako monokularnim kamerama nedostaje direktna percepcija dubine, ovaj nedostatak se može prevazići korišćenjem naprednih algoritama. Njihova prilagodljivost na različite uslove osvetljenja i skalabilnost dodatno povećavaju njihovu isplativost. Ova multifunkcionalnost omogućava obavljanje više zadataka (detekcija prepreka, voznih traka) sa istim hardverom, čime se postiže visok stepen autonomije pri ograničenim resursima. Kompatibilnost sa arhitekturama DL-a omogućila je značajan napredak, gde moderne CNN mreže mogu vršiti klasifikaciju prepreka u realnom vremenu direktno iz slike. Ovo pozicionira monokularnu viziju kao efikasan senzorski modalitet, posebno za BGV sa ograničenim resursima.

Kada su u pitanju pristupi detekciji prepreka zasnovani na monokularnoj viziji, mogu se razlikovati dve glavne grupe metoda:

- **Tradicionalne metode obrade slike:** fokusiraju se na ručno definisana obeležja kao što su uglovi, ivice (npr. SIFT (eng. Scale-Invariant Feature Transform), SURF (eng. Speeded Up Robust Features) i HOG.), obrasci optičkog toka za analizu kretanja [90], ili izgled (boja, tekstura) za segmentaciju [91]. Ove metode se često kombinuju sa klasičnim klasifikatorima kao što je SVM, ali su generalno sporije i manje robusne u složenim scenarijima [92].
- **Moderne metode dubokog učenja (DL):** koriste arhitekture, pretežno CNN, za automatsko učenje hijerarhijskih obeležja direktno iz podataka. Modeli za detekciju objekata poput YOLO, SSD (eng. Single Shot Detector) ili CornerNet mogu locirati i klasifikovati prepreke u realnom vremenu, najčešće generišući granične okvire oko detektovanih objekata [91, 92]. Jednostepeni detektori kao što je YOLO posebno su pogodni za primene u realnom vremenu zbog svoje brzine i tačnosti [18, 93, 94], što ih čini čestim izborom za detekciju prepreka kod autonomnih vozila.

2.2.1.3 Pregled literature u oblasti autonomnog praćenja zadate vozne trake i izbegavanja prepreka

Postojeći naučni radovi u ovoj oblasti mogu se grupisati prema primarnom fokusu – na sistem upravljanja, na sistem vođenja, ili na integrisane pristupe.

Studije fokusirane na upravljanje često prepostavljaju dostupnost informacija o putanji. Tako [95] predlaže unapređeni PI/PID sistem upravljanja skretanjem namenjen držanju vozne trake za autonomna vozila zasnovana na viziji. Sistem izračunava ugao upravljača koristeći merenja ugaone brzine i lateralnog odstupanja, bez potrebe za merenjem lateralnog ubrzanja/brzine. Unutrašnja PI petlja potiskuje poremećaje, dok spoljašnja PID petlja upravlja brzinom skretanja. Simulacije u CarSim-u pokazale su poboljšanu preciznost praćenja i manevre kočenja u odnosu na konvencionalne pristupe. S druge strane, u [96] razvijen je adaptivni MPC (AMPC) za održavanje vozne trake, koristeći LTV (eng. Linear Time-Variant) model sa online estimacijom krutosti pneumatika. Sistem minimizuje greške putanje i uglove upravljanja, pokazujući u simulacijama na krivudavim putevima smanjenu grešku lateralnog pomeranja i bolje performanse u odnosu na MPC. U [97] kombinovani su ADRC sa QFT (eng. Quantitative Feedback Theory), demonstrirajući efikasno održavanje trake u simulacijama i eksperimentima, naglašavajući prednosti QFT-a u podešavanju ADRC-a. Ovi radovi primarno rešavaju problem upravljanja, ali često zanemaruju realne izazove sistema vođenja (poput nesavršene detekcije trake) i uglavnom su validirani u simulacijama na pojednostavljenim modelima, što ograničava primenljivost u realnim uslovima.

Druga grupa radova fokusira se na sistem vođenja, odnosno percepciju i generisanje putanje. Tako, u [98] predložena je metoda za detekciju traka i prepreka u složenim okruženjima, integrišući 2D LiDAR i kameru za generisanje putanja. Metodologija adresira varijacije osvetljenja i zaklanjanja, omogućavajući efikasno praćenje trake i vođenje, potvrđeno eksperimentalnom validacijom u realnim uslovima. U radu [99] predložen je sistem za praćenje trake i detekciju prepreka koristeći kameru s "ribljim okom" (eng. fish-eye camera) i LIDAR. Detekcija trake zasnovana je na Hough transformaciji, dok LIDAR omogućava detekciju prepreka. Sistem je eksperimentalno validiran, pokazujući performanse u realnom vremenu. Iako rešavaju ključne aspekte vođenja, ovi radovi često ne integrišu napredne ili robusne strategije upravljanja potrebne za dinamička okruženja, a neki se oslanjaju na klasične tehnike obrade slike koje mogu ograničiti detekciju trake u složenim okruženjima.

Konačno, integrisani pristupi teže da objedine vođenje i upravljanje. Tako, na primer, u [100] je prikazan hibridni sistem za autonomno držanje trake, kombinujući *LaneFCNet* DL arhitekturu sa CRF (eng. Conditional Random Fields) za preciznu detekciju traka i MPC regulator za stabilno praćenje putanje. Eksperimentalni rezultati potvrdili su robustnost rešenja u realnim uslovima vožnje. U drugu ruku, u [101] je predstavljen sistem za BV malih gabarita koristeći jednu kameru za detekciju trake i prepreka. Detekcija trake zasnovana je na poboljšanoj Hough transformaciji, dok detekcija prepreka identificuje saobraćajne čunjeve i njihove relativne pozicije. Implementiran je PID regulator za podešavanje ugla skretanja vozila. Sistem je validiran kroz numeričke simulacije i eksperimentalne testove, demonstrirajući izvodljivost sistema. Ograničenja ovih pristupa uključuju zavisnost MPC-

a od preciznog modela ili korišćenje klasičnih tehnika vođenja i upravljanja (Hough, PID) koje nisu uvek pogodne za BGV.

Sveobuhvatno poređenje pregledanih studija predstavljeno je u tabeli 2.2. Generalno, iako postoje značajni doprinosi, većina radova se fokusira ili na vođenje ili na upravljanje, dok nedostaju potpuno integrisana rešenja specifično validirana za BGV u realnim uslovima rada. Često se oslanjaju na simulacije ili redukovane modele. Efikasniji pristup, kakav se predlaže u ovoj disertaciji, uključivao bi sistem vođenja zasnovan na DL-u uparen sa naprednom strategijom upravljanja poput ADRC, optimizovanom za BGV u realnim, izazovnim okruženjima.

Tabela 2.2: Rezime najsavremenijih metoda za detekciju vozne trake i izbegavanje prepreka

Rad	Tip vozila	Držanje vozne trake	Izbegavanje prepreka	Fokus	Korišćeni senzori	Validacija
<i>Pristupi fokusirani na upravljanje</i>						
Marino et al. [95]	Standardni model automobila	Da	Ne	Upravljanje (Ugnežđeni PID)	Vizuelni sistem, Žiroskop	Simulacija
Chen et al. [96]	Standardni model automobila	Da	Ne	Upravljanje (AMPC)	Nije specificirano	Simulacija
Chu et al. [97]	Umanjeni model vozila	Da	Ne	Upravljanje (ADRC sa QFT)	Kamera	Simulacija i Eksperiment
Chu et al. [102]	Umanjeni model vozila	Da	Ne	Upravljanje (ADRC)	Kamera	Simulacija i Eksperiment
<i>Pristupi fokusirani na vođenju</i>						
Singhal et al. [98]	Trotokaš sa diferencijalnim pogonom	Da	Da	Vođenje	2D LiDAR, Kamera	Eksperiment
Amaradi et al. [99]	Mobilno vozilo	Da	Da	Vođenje	Kamera sa "ribljim okom", LIDAR	Eksperiment
<i>Integrисани pristupi (Vođenje i upravljanje)</i>						
Liu et al. [100]	Vozilo sa točkovima	Da	Ne	Vođenje i Upravljanje (MPC)	Kamera	Eksperiment
Abd et al. [101]	BV malih razmara	Da	Da	Vođenje i Upravljanje (PID)	Jedna kamera	Simulacija i Eksperiment

2.2.2 Autonomno praćenje lidera

Za razliku od praćenja vozne trake, ovaj zadatak se može klasifikovati kao praćenje trajektorije koja se dinamično menja kretanjem lidera. Ključni zadatak je simultano održavanje željenog poravnjanja u odnosu na lidera minimizacijom lateralnog odstupanja i dinamička adaptacija brzine BGV-a minimizacijom greške longitudinalnog rastojanja. Pošto lider može menjati brzinu i pravac kretanja nepredvidivo, BGV mora prilagođavati i svoju brzinu i ugao skretanja, što implicira postojanje vremenskih zahteva za sinhronizacijom kretanja sa liderom, što predstavlja karakteristiku praćenja trajektorije. Uspešno izvršenje ovog zadatka podrazumeva koordinisano lateralno i longitudinalno upravljanje.

Autonomno praćenje lidera predstavlja fundamentalnu paradigmu u koordinaciji više sistema, sa širokom primenom kod BV-a [26]. U ovim scenarijima, BV autonomno

prati kretanje određenog lidera (čoveka ili drugog vozila). Ova sposobnost je ključna u vojnim primenama (konvoji, izviđanje), operacijama potrage i spasavanja, poljoprivredi i logistici (formiranje kolone), ruderstvu, građevinarstvu, kao i u civilnoj i rehabilitacionoj medicinskoj robotici (lični asistenti, robotska kolica) [34, 103].

Arhitektura sistema autonomnog praćenja lidera zavisi od izbora senzora (npr. LiDAR, kamere) i želenog nivoa autonomije. Senzori se koriste za detekciju lidera i procenu njegovog položaja i rastojanja, na osnovu čega sistem vođenja generiše upravljačke signale. Interakcija može biti eksplisitna (direktne komande putem komunikacije ili markera) ili implicitna, gde se pratilac oslanja na sopstvenu percepciju (npr. vizuelnu) za detekciju i praćenje lidera bez eksplisitnog signaliziranja [26]. Implicitna interakcija, koja je fokus ove disertacije, nameće dodatne izazove u održavanju rastojanja, prilagođavanju brzine i potencijalnom prepoznavanju poza ili gestova lidera.

2.2.2.1 Izbor senzora u sistemima autonomnog praćenja lidera

Za uspešno praćenje lidera, BV se najčešće oslanjaju na kombinaciju više tipova senzora. Vizuelni senzori, poput monokularnih ili stereo kamera, ključni su za detekciju lidera, prepoznavanje njegovih aktivnosti (hodanje, poza, gestovi) i opštu percepciju scene. Međutim, za pouzdano merenje rastojanja, što je kritično za održavanje formacije i bezbednosti, često se koriste dodatni senzori zasnovani na dometu, kao što su LRF (eng. Laser Range Finder), LiDAR ili Radar, koji pružaju precizne podatke o rastojanju [26, 104]. U nekim specifičnim (npr. unutrašnjim) okruženjima koriste se i RGB-D kamere, dok se za direktnu identifikaciju mogu koristiti i UWB (eng. Ultra-Wide Band) i RFID (eng. Radio-Frequency Identification) tehnologije. Pored ovih senzora za percepciju lidera i okruženja, za praćenje sopstvenog kretanja i orientacije BV-a koriste se i IMU senzori. Međutim, IMU su podložne akumulaciji greške tokom vremena. Stoga, **fuzija podataka** sa različitim senzora (npr. kamere, LiDAR-a i IMU, pri čemu je kombinacija kamera/LiDAR korišćena u ovoj disertaciji) često nudi najrobusnije rešenje, kombinujući bogate vizuelne informacije i precizna merenja rastojanja, čime se prevazilaze ograničenja pojedinačnih senzora.

Monokularne kamere sa naprednim tehnikama računarskog vida, uključujući detekciju i praćenje objekata zasnovano na DL-u, pružaju bogate vizuelne podatke za identifikaciju lidera i predviđanje trajektorije. LiDAR ovo dopunjuje pružanjem tačnog merenja rastojanja. Ova fuzija koristi prednosti percepcije zasnovane na viziji i merenja dometa zasnovanog na laseru, rešavajući ključne izazove u sistemima autonomnog praćenja lidera uz održavanje skalabilnosti i robusnosti.

Iako postojeća literatura nudi vredne uvide u opšte upravljanje BV-om i praćenje trajektorija, jedinstveni zahtevi i izazovi autonomnog praćenja lidera specifično kod BGV platformi – uzimajući u obzir njihovu dinamiku, karakteristike upravljanja i izloženost spoljašnjim poremećajima na terenu – zahtevaju posvećenu analizu. Sledеće poglavije

pruža pregled relevantnih radova iz ove oblasti, detaljno opisujući njihov doprinos, tipove vozila koji su razmatrani, kao i primenjene metodologije vođenja i upravljanja.

2.2.2.2 Pregled literature u oblasti autonomnog praćenja lidera

Slično kao kod projektovanja sistema autonomnog praćenja voznih traka, dostupna naučna literatura u oblasti autonomnog praćenja lidera može se razvrstati na pristupe koji se odnose samo na sistem vođenja, samo na sistem upravljanja i na hibridne pristupe koji obuhvataju i vođenje i upravljanje.

Radovi sa fokusom na sistem vođenja bave se unapređenjem detekcije, praćenja i interpretacije lidera. Istraživanje [105] predstavlja metod za vizuelno praćenje lidera u robotskim primenama, koristeći modul za analizu scene SAM (eng. Scene Analysis Module) za razlikovanje lidera od ostatka scene putem unakrsne korelacije. Validiran na spoljašnjim i javnim skupovima podataka, metod pokazuje robusnost u scenarijima s zaklanjanjem i promenama osvetljenja. Članak [106] se fokusira na poboljšanje sposobnosti praćenja čoveka kod robota, izdvajanjem informacija o orijentaciji iz gornjeg dela tela osobe korišćenjem monokularne vizije, uz SURF za uparivanje obeležja i estimaciju homografije. Ove informacije se zatim koriste u regulatoru za poboljšanje ponašanja robota pri praćenju. Nasuprot tome, [107] predstavlja metodu za detekciju ljudskih nogu koristeći LRF kao perceptivni senzor i primenjuju pristup zasnovan na vektorskim podacima za upravljanje. Metoda je dobro uspostavljena u različitim okruženjima, demonstrirajući određenu robusnost i visoku tačnost. Iako ovi radovi unapređuju aspekte vođenja, dele zajednička ograničenja za primene kod BGV-a. Najznačajnije je to što im nedostaje integracija sa robusnim sistemima upravljanja neophodnim za složenu dinamiku BGV-a, a njihovo testiranje je primarno ograničeno na kontrolisana okruženja.

Druga grupa radova fokusira se na sisteme upravljanja, često pod prepostavkom da su informacije o lideru već dostupne. Tako, u [108] je predložena strategija autonomnog praćenja lidera zasnovana na ADRC-u, integrišući upravljanje formacijom sa GPIO (eng. General Proportional Integral Observer) za estimaciju poremećaja kod omnididirekcionih mobilnih robota. Zakoni upravljanja osiguravaju da lider prati zadatu trajektoriju, a vozilo održava željeno rastojanje i ugao formacije. U radu [109], predstavljen je sveobuhvatan pristup projektovanju sistema za praćenje vozila u V2V (vozilo-to-vozilo) konfiguraciji za BV, koristeći TLC (eng. Trajectory Linearization Control) za upravljanje kinematikom i dinamikom, verifikovan kroz MATLAB/SIMULINK simulacije. U [110] analizirani su izazovi upravljanja BGV-om u praćenju lidera predlažući dekuplovani pristup sa MRAC-om (eng. Model Reference Adaptive Control) za upravljanje brzinom i skretanjem, pokazujući poboljšanja u odnosu na PID. Analizirani pristupi demonstriraju sofisticirane strategije upravljanja, ali se često oslanjaju na pojednostavljene modele vozila (koji ne obuhvataju u potpunosti dinamiku BGV-a) i nedostaje im robusna integracija sa realnim sistemima vođenja, što je ključno za autonomni rad u promenljivim uslovima okruženja.

Konačno, hibridni pristupi teže da kombinuju aspekte sistema vođenja i upravljanja. Jedan od takvih pristupa prikazan je u [111] gde je razvijena robusna šema upravljanja za neholonomskе formacije automobila lider-pratilac, koristeći kinematičke modele i ADRC šemu zasnovanu na GPIO za estimaciju poremećaja i grešaka praćenja. Predloženi koncept upravljanja demonstriran je kroz eksperimentalne rezultate na Pioneer 3-DX robotima. Slično, [112] predstavlja ADRC strategiju za formacijsko kretanje omnidirekcionih vozila, koristeći merljive pozicije i poseban ESO zasnovan na grešci. Metoda minimizira oslanjanje na vremenske izvode, potiskuje poremećaje i poboljšava praćenje, uz praktičnu primenljivost. U radu [104] predstavljen je robot *FOLO* za praćenje čoveka, koji koristi RGB-D kameru i 2D vizuelno praćenje za lokalizaciju u realnom vremenu. Unapređeni PID regulator omogućava uspešno praćenje čoveka u kancelarijskim okruženjima. Iako ovi pristupi integrišu oba aspekta, glavna ograničenja uključuju validaciju na jednostavnijim robotskim platformama, sa manje složenom dinamikom i u kontrolisanim laboratorijskim uslovima.

Pregled ključnih karakteristika navedenih pristupa sumiran je u tabeli 2.3.

Kao što pokazuje uporedna analiza u tabeli 2.3, oblast autonomnog praćenja lidera obuhvata raznovrsne pristupe. Iako je postignut značajan napredak, integracija robusnog sistema vođenja i naprednog upravljanja, specifično prilagođenih i validiranih za BGV platforme u izazovnim terenskim okruženjima, ostaje aktivno područje istraživanja i ključni fokus ove disertacije.

Nakon pregleda specifičnih zadataka i relevantne literature, naredni odeljak (2.3) detaljnije će opisati opštu arhitekturu sistema autonomnog kretanja BGV-a koja je usvojena u ovom radu, objašnjavajući uloge i interakcije sistema vođenja i sistema upravljanja.

2.3 Struktura sistema autonomnog kretanja BGV

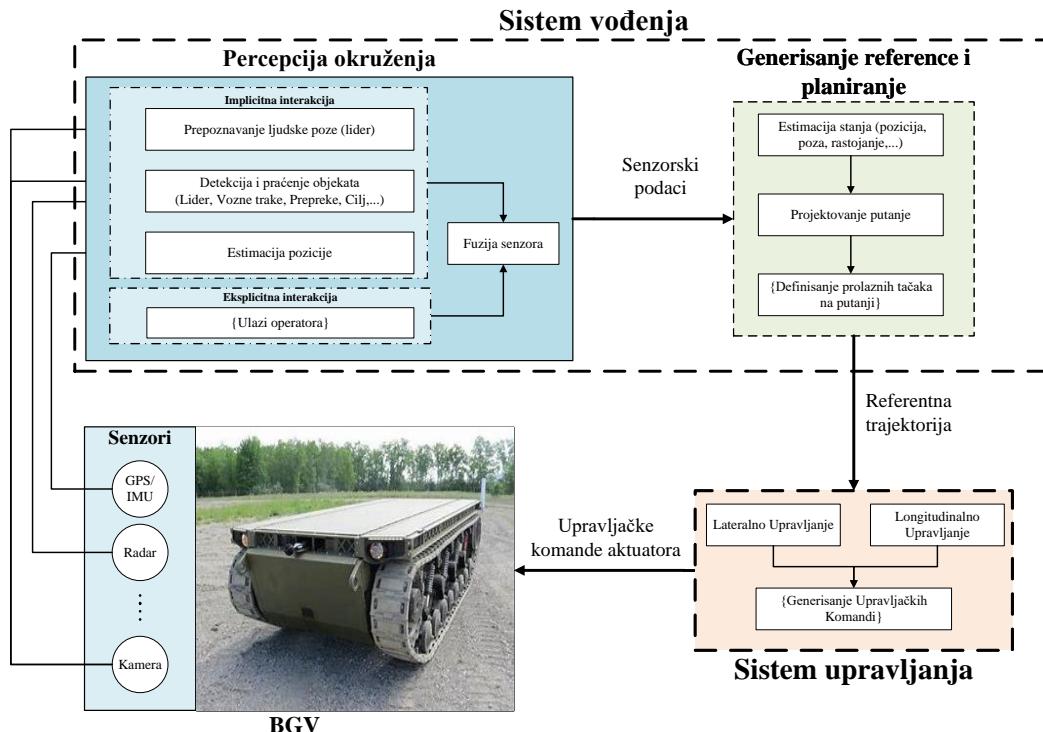
Tipične funkcije svakog od razmatranih načina autonomnog kretanja BGV-a mogu se opisati kroz tri ključna aspekta: „Razumeti kuda idem i šta treba da uradim“, „Razumeti okruženje i pronaći putanju kroz njega“, i „Upravljati aktuatorima vozila kako bi se pratila željena putanja“ [4]. Shodno tome, ovaj odeljak objašnjava opštu strukturu sistema autonomnog kretanja, razrađujući ulogu pojedinačnih podsistema i ilustrujući njihove interakcije kako bi se omogućio željeni nivo autonomije. Da bi se to ostvarilo, struktura BGV-a sadrži dve ključne komponente: (1) sistem vođenja, zadužen za generisanje referentne trajektorije i (2) sistem upravljanja zadužen za praćenje referentne trajektorije. Opšta struktura jednog takvog sistema data je na slici 2.2.

Kao što se može videti sistem autonomnog kretanja BGV-a organizovana je u dva ključna, međusobno povezana podistema: sistem vođenja i sistem upravljanja. Sistem vođenja objedinjuje funkcije percepције okruženja (korišćenjem senzora za detekciju objekata, traka, lidera itd.) i generisanja željene trajektorije ili referentnih signala na osnovu

Referenca	Tip vozila	Sistem vođenja	Pristup upravljanju	Eksperimenti
Cao et al. [105]	Nije primjenjeno	Monokularna vizija sa modulom za analizu scene (SAM)	Nije primjenjeno	Simulacija
Burke et al. [106]	Nije definisano	Monokularna vizija sa SURF za estimaciju poze	Osnovni regulator	Eksperiment
Ramirez-Neria et al. [108]	Omnidirekcioni mobilni roboti	Više kamere, sistem za snimanje pokreta zasnovan na markerima.	ADRC + GPIO	Simulacija + Eksperiment
Chen, Y. [109]	BV	Tragač cilja (kamera + LRF)	TLC + vođenje čistim praćenjem (eng. Pure Pursuit Guidance, PPG)	Simulacija
Fan et al. [110]	BGV	Kamere, Lidar i inercijalna navigacija	dekuplovano upravljanje brzinom i krivinom sa MRAC	Simulacija + Eksperiment
Sira-Ramírez et al. [111]	Neholonomski mobilni robot	Sonar za merenje dometa	ADRC + GPI	Eksperiment
Ramirez-Neria et al. [112]	Omnidirekcionи mobilni roboti	Infracrvene kamere	ADRC + specijalni ESO u formi zasnovanoj na grešci	Eksperiment
Chung et al. [107]	Omnidirekcionи mobilni roboti	Jedan LRF	Nije pomenuto	Simulacija + Eksperiment
Chen et al. [104]	Mobilni roboti	RGB-D kamera	Dvoslojni PID	Eksperiment

Tabela 2.3: Rezime trenutnih pristupa u sistemima autonomnog praćenja lidera

zadatka misije i percipiranih informacija. Ovaj podsistem predstavlja temelj celokupne arhitekture, obezbeđujući ključne ulazne podatke i reference neophodne za kretanje. Sistem upravljanja, oslanjajući se na izlaze sistema vođenja, odgovoran je za generisanje preciznih



Slika 2.2: Arhitektura sistema autonomnog kretanja kod BGV-a.

komandi aktuatorima kako bi BGV pratio zadatu putanju ili referencu [113, 114, 115]. U nastavku poglavljia predstavljeni su izazovi pri projektovanju, detaljne strukture i pregled literature relevantne za projektovanje oba sistema.

2.3.1 Izazovi pri projektovanju, struktura i pregled sistema vođenja

2.3.1.1 Izazovi pri projektovanju sistema vođenja BGV

Imajući u vidu da se BGV najčešće primenjuju u složenim i neravnim terenskim uslovima, kao što su zone prirodnih katastrofa, poljoprivredna polja, vojna bojišta [30, 49], nameću se različiti izazovi pri projektovanju i mogu se definisati prema sledećem:

- **Složeni tereni:** neravan i nepredvidiv teren (padine, prepreke, rastresito tlo, blato, pesak, travnate površine) direktno utiče na sposobnost sistema vođenja da proceni prohodnost terena i isplanira bezbednu i optimalnu putanju kretanja [38, 115].
- **Promenljivi uslovi okruženja:** meteorološki uslovi poput kiše, snega, prašine i magle, kao i drastične promene osvetljenja (senke, jaka svetlost), značajno degradiraju performanse ključnih senzora za percepцију okruženja, naročito optičkih kamera i LiDAR-a, otežavajući pouzdano detektovanje relevantnih elemenata okruženja [115, 116].
- **Dinamičko okruženje:** prisustvo pokretnih prepreka (drugih vozila, ljudi, itd.), zahteva od sistema vođenja sposobnost detekcije, praćenja i predviđanja njihovog

kretanja u realnom vremenu, kao i brzo prilagođavanje planirane putanje radi izbegavanja potencijalnih sudara [30, 49].

- **Ograničenja senzora:** pored uticaja okruženja, sami senzori imaju svoja ograničenja. Kamere (posebno monokularne) imaju problem neodređenosti dubine slike, dok LiDAR može imati poteškoća sa određenim materijalima ili u gustoj magli/prashi. Ograničen vidokrug senzora i postojanje prirodnih i veštačkih zaklona dodatno komplikuju zadatku formiranja potpune i tačne slike okruženja [26]. Vibracije platforme BGV-a takođe mogu negativno uticati na kvalitet senzorskih podataka, posebno vizuelnih.

Ovi opšti izazovi u projektovanju sistema vođenja postaju posebno izraženi u specifičnim zadacima autonomnog kretanja koji su predmet ove disertacije i u nastavku su detaljnije pojašnjeni:

- **Posebni izazovi u projektovanju sistema vođenja pri autonomnom praćenju zadate vozne trake sa izbegavanjem prepreka:** pouzdana detekcija granica vozne trake u realnim uslovima (nejasne ili oštećene oznake) predstavlja osnovni problem u ovom slučaju. Sistem vođenja mora istovremeno detektovati prepreke unutar trake, planirati manevr izbegavanja i generisati putanju koja balansira konkurentne zadatke ostajanja unutar trake i bezbednog zaobilazeњa prepreke [115, 117, 118]. Sve ovo mora biti izvedeno računarski efikasno za rad u realnom vremenu.
- **Posebni izazovi u projektovanju sistema vođenja pri autonomnom praćenju lidera:** dinamička i često nepredvidiva priroda kretanja lidera (čoveka ili vozila), uključujući ubrzanje i nagle promene pravca, zahteva od sistema vođenja visoku prilagodljivost. Potrebno je robusno detektovati i pratiti lidera na različitim udaljenostima i u uslovima delimičnog zaklanjanja. Pored toga, precizno održavanje željenog rastojanja i formacije može biti ograničeno postojanjem mernog šuma senzora i potencijalnih kašnjenja u obradi signala senzora, kao i zbog činjenice da se ugaone greške praćenja povećavaju pri manevrima lidera na malim rastojanjima od vozila [108, 119]. Dodatnu kompleksnost unosi potreba za interpretacijom namera ili komandi lidera, kroz prepoznavanje njegovih poza ili gestova [106, 120].

Prevazilaženje ovih izazova zahteva razvoj sistema vođenja koji integrišu robusne algoritme percepције (sposobne da rade u promenljivim uslovima i sa nesavršenim podacima), efikasne metode planiranja putanje i intelligentne mehanizme donošenja odluka za bezbedno i pouzdano kretanje BGV-a ka zadatom cilju.

2.3.1.2 Struktura i pristupi projektovanju sistema vodenja BGV

Kako što je već napomenuto sistem vođenja predstavlja ključnu komponentu autonomnog kretanja BGV-a. Sistem vođenja deluje kao centralna jedinica za donošenje odluka,

koja integriše zadatke, misije na visokom nivou i senzorske podatke na nižem nivou kako bi odredila putanju, brzinu i ponašanje BGV-a [16, 119, 121]. Sistem je odgovoran za obezbeđivanje sigurnog, efikasnog i prilagodljivog okvira za vođenje koji omogućava BGV-u autonomno kretanje u dinamičkim i zahtevnim okruženjima, garantujući postizanje zadatka misije uz istovremeno izbegavanje kolizija i održavanje stabilnosti [34, 113, 122]. Korišćenjem sposobnosti donošenja odluka na visokom nivou, sistem vođenja osigurava da se BGV efikasno prilagođava izazovima u realnom vremenu i odgovara na različite situacije, istovremeno postižući zadatke na visokom nivou. Projektovanje efikasnog sistema vođenja BGV zahteva objedinjavanje zadataka percepcije okruženja i stanja vozila na osnovu čega se realizuje donošenja odluka o kretanju vozila.

1. Percepcija okruženja i stanja vozila

Da bi sistem vođenja mogao donositi odluke o kretanju vozila, neophodno je da raspolaze informacijama o okruženju i sopstvenom stanju. BGV u velikoj meri zavise od senzora za autonomno kretanje [123]. Njihov sistem percepcije obuhvata različite senzore i algoritme obrade koji deluju u kombinaciji kako bi pružili tačnu reprezentaciju operativnog okruženja u realnom vremenu. Ovo se postiže korišćenjem niza senzora:

- **Senzori za percepciju okoline (eng. Exteroceptive Sensors)** prikupljaju informacije o spoljašnjem okruženju i ključni su za razumevanje okoline BGV-a [124]. Uobičajeni eksterceptivni senzori korišćeni kod BGV-a uključuju:
 - **Kamere:** monokularne, stereo i omnidirekcione kamere omogućavaju prikupljanje vizuelnih podataka okoline. Ovi senzori se koriste za višestruke zadatke uključujući detekciju voznih traka, prepoznavanje objekata, praćenje ljudskih operatora [106, 120], kao i za izbegavanje prepreka [124]. Snimljene slike se obrađuju pomoću ML-a i DL-a, što omogućava realno-vremensku obradu zahvaljujući visokoj rezoluciji i adaptaciji na različite uslove osvetljenja.
 - **LiDAR:** meri precizna rastojanja do objekata korišćenjem lasera, generišući 3D oblake tačaka koji su korisni za izgradnju 3D mapa okruženja, što je ključno za zadatke kretanja [30, 125].
 - **Radar:** koristi radio talase za detekciju objekata i merenje njihovog rastojanja i brzine, efikasan u različitim vremenskim uslovima [125].
- **Senzori stanja vozila (eng. Proprioceptive Sensors)** određuju položaj, brzinu i ubrzanje vozila u prostoru [124]. Koriste se za pružanje informacija o samoj platformi u realnom vremenu, kao što su:
 - **GNSS (npr. GPS):** određuju apsolutnu poziciju vozila u globalnom koordinatnom sistemu.

- **IMU:** pružaju podatke o ubrzaju i ugaonoj brzini, ključne za estimaciju orijentacije i relativnog kretanja.

Često se koristi **fuzija senzora** kako bi se kombinovale prednosti različitih senzorskih modaliteta i dobila robusnija i tačnija slika okruženja i stanja vozila [87]. Ovi algoritmi poboljšavaju tačnost i pouzdanost percepције kombinovanjem informacija sa više senzora i filtriranjem šumnih ili nekonzistentnih podataka.

Algoritmi detekcije:

Ključni deo percepције je primena algoritama za obradu senzorskih podataka radi detekcije, praćenja i prepoznavanja relevantnih elemenata okruženja (objekata, traka, prepreka). Za zadatke detekcije zasnovane na kamери, algoritmi zasnovani na DL-u pokazali su se kao najefikasniji u realnim uslovima [124]. Ovi algoritmi mogu se grubo podeliti na jednostepene i dvostepene detektore [126].

Poslednjih godina, metode DL-a, posebno CNN, postale su dominantne. Jednostepeni detektori objekata kao što je YOLO porodica stekli su popularnost zbog izuzetnog balansa brzine i tačnosti, posebno kada se koriste monokularne kamere. YOLO, autora Josepha Redmona et al., objavljen je na konferenciji CVPR (eng. Conference on Computer Vision and Pattern Recognition) 2016. godine [19]. Po prvi put je predstavio pristup detekciji objekata u realnom vremenu od kraja do kraja (eng. end-to-end). Naziv YOLO je akronim za „Gledaš Samo Jednom“, što se odnosi na činjenicu da je bio u stanju da izvrši zadatak detekcije jednim prolaskom kroz mrežu [18, 93, 94].

YOLO segmentira sliku i istovremeno predviđa granične okvire i klase u jednom prolazu [127]. Zbog svojih sposobnosti detekcije u realnom vremenu, YOLO pronalazi primenu u brojnim oblastima, uključujući autonomna vozila, robotiku, poljoprivredu, medicinu i bezbednosne sisteme [18]. Kao najnovija verzija YOLO serije, YOLOv8 [18] predstavlja značajan napredak u odnosu na prethodne verzije, uključujući efikasniju neuronsku mrežnu arhitekturu, optimizovanje procese obučavanja modela i poboljšane performanse tokom inferencije, što ga čini jednim od najsavremenijih algoritama za detekciju objekata u realnom vremenu.

Tradicionalni pristupi percepцији vozila često tretiraju zadatke kao što su detekcija objekata, segmentacija instanci i semantička segmentacija izolovano, što ograničava njihovu sposobnost da pruže sveobuhvatno razumevanje voznog okruženja. Ovaj nedostatak naglašava potrebu za panoptičkom percepцијом (eng. panoptic perception), jedinstvenim okvirom koji integriše različite perceptivne zadatke. Predstavljena sa YOLOP [20] modelom 2021. godine, panoptička percepција predstavlja značajan napredak u autonomnoj vožnji, sa ciljem poboljšanja percepције okruženja konsolidovanjem više zadataka u kohezivan sistem [128].

Primarni motivi za integraciju panoptičke percepcije u sisteme autonomne vožnje uključuju poboljšanu robusnost i tačnost u razumevanju okruženja. Omogućavanjem međusobnih veza između pojedinačnih perceptivnih zadataka, višenamenske mreže mogu prevazići ograničenja tradicionalnih, izolovanih metoda. Dodatno, korišćenje višemodalnih ulaza unutar ovih mreža poboljšava interpretaciju senzorskih podataka, što dovodi do preciznijih izlaza [129].

Neki modeli neuronskih mreža, uključujući YOLOP, HybridNet i Faster R-CNN (eng. Region-based Convolutional Neural Networks), pokazali su obećavajuće rezultate u kontekstu sistema autonomne vožnje. YOLOP je posebno značajan zbog svoje tačnosti i sposobnosti obrade u realnom vremenu, što ga čini idealnim izborom za autonomnu vožnju, iako se suočava sa izazovima u pogledu preciznosti detekcije malih objekata. HybridNet generalno dobro funkcioniše, ali dolazi sa visokim računarskim troškovima, dok je Faster R-CNN, uprkos visokoj tačnosti, prespor za primene u realnom vremenu. Shodno tome, algoritmi YOLOP serije se često biraju za perceptivne sisteme u autonomnoj vožnji zbog njihovih uravnoteženih performansi i efikasnosti [130]. YOLOPv2 [131, 132] čuva osnovne koncepte projektovanja YOLOP-a i HybridNets-a, dok koristi robusniju strukturu mreže i efikasnu strategiju obučavanja, postižući visoke rezultate prema pregledu literature (SOTA) performanse i u pogledu tačnosti i brzine [21].

YOLOP istovremeno vrši segmentaciju traka, segmentaciju vozne površine i detekciju objekata, koristeći deljenu arhitekturu radi poboljšanja efikasnosti i tačnosti u poređenju sa pristupima sa jednim zadatkom [21, 128, 133]. **YOLOPv2**, kao una-pređena verzija, postiže vrhunske performanse balansirajući brzinu i tačnost [21].

Estimacija ljudske poze (eng. Human Pose Estimation, HPE) pojavila se kao značajan koncept u računarskom vidu, posebno u kontekstu besposadnih vozila. HPE može služiti kao metoda komunikacije, omogućavajući upravljanje gestovima gde operateri (npr. lider) mogu slati komande vozilu putem govora tela [134, 135, 136, 137].

Da bismo razumeli HPE, prvo moramo definisati "pozu", koja se odnosi na raspored ljudskih zglobova na specifičan način. Shodno tome, HPE se može opisati kao lokalizacija ljudskih zglobova ili unapred definisanih ključnih tačaka (eng. landmarks) na slikama i video zapisima. Ovo uključuje različite tipove estimacije poza, kao što su detekcija tela, lica i šaka [138].

Moderne HPE metode, zasnovane na DL-u, lokalizuju ključne tačke (zglove) ljudskog tela na slikama [138]. U ovoj disertaciji, koristi se **MediaPipe Pose (MPP)** [1], otvoreni okvir koji koristi BlazePose arhitekturu za efikasnu 2D estimaciju 33 ključne tačke tela u realnom vremenu.

U skladu sa ovim, za zadatke detekcije vozne trake, YOLOPv2 je odabran zbog efikasnog balansa preciznosti i računarske efikasnosti, što je suštinski važno za

primene u realnom vremenu kod BGV-a. Za detekciju lidera i detekciju prepreka, korišćen je YOLOv8 zbog svojih naprednih sposobnosti. Dodatno, MPP je odabran za estimaciju poze, pružajući tačne 2D koordinate ljudskih zglobova u realnom vremenu.

2. **Donošenje odluka o kretanju vozila**

Na osnovu obrađenih perceptivnih podataka, sistem vođenja donosi odluke o željenom kretanju BGV-a. Ovo uključuje:

- **Planiranje putanje:** određivanje optimalne lokalne ili globalne putanje koju vozilo treba da sledi, uzimajući u obzir geometriju okruženja, detektovane prepreke i cilj misije.
- **Generisanje referentnih signala:** izračunavanje specifičnih signala koje sistem upravljanja treba da prati. U kontekstu ove disertacije, to podrazumeva definisanje virtuelne tačke cilja i izračunavanje grešaka praćenja – lateralne i longitudinalne – u odnosu na tu referencu. Ove greške predstavljaju ključni ulaz za regulatore u sistemu upravljanja.
- **Donošenje odluka o ponašanju:** Odabir odgovarajućih manevara ili režima rada, kao što je praćenje vozne trake, izbegavanje prepreke, praćenje lidera, ili reagovanje na komande (npr. prepoznavanje poze lidera). Vodenje zasnovano na viziji igra ključnu ulogu u ovim zadacima [109, 115, 124].

Sistem vođenja, dakle, deluje kao "mozak" operacije, prevodeći sirove senzorske podatke i zadatke misije u konkretne, merljive ciljeve (reference i greške) koje sistem upravljanja treba da ostvari.

3. **Sistemi vođenja zasnovani na vizuelnim senzorima**

Poslednjih godina, vizuelni senzori postaju sve popularniji kod BV-a, služeći kao značajna dopuna ili alternativa tradicionalnim sistemima zasnovanim na GPS-u i inercijalnim senzorima. Ovi senzori nude nekoliko prednosti, uključujući male dimenzije, lagan dizajn i nisku cenu [139].

Prvo, vizuelni senzori mogu generisati bogate podatke, omogućavajući identifikaciju i lokalizaciju ciljeva i prepreka kada su upareni sa odgovarajućim hardverom i softverom za obradu slike.

Drugo, vizuelni senzori su pasivni, što znači da ne emituju sopstveno zračenje. Ovo smanjuje verovatnoću detekcije u vojnim i bezbednosnim primenama i eliminiše problem međusobne interferencije kada više vozila radi u blizini.

Treće, u unutrašnjim okruženjima ili pretrpanim oblastima (eng cluttered areas), vizuelni senzori mogu biti jedina pouzdana opcija za lokalizaciju i vođenje.

Zbog ovih prednosti, vođenje zasnovano na viziji predstavlja ključni pristup unutar sistema vođenja BGV-a u ovoj disertaciji. Ono omogućava vozilu da koristi podatke sa kamere za fundamentalne zadatke kao što su autonomno praćenje zadate vozne trake, detekcija prepreka, kao i detekcija, praćenje i interpretacija namere lidera [115, 124]. Sposobnost interpretacije vizuelnih podataka pomoći naprednih DL algoritama je suštinska za kretanje u složenim okruženjima i za efikasnu interakciju čovek-vozilo [109].

- **Detekcija vozne trake i izbegavanje prepreka:** vođenje zasnovano na viziji igra ključnu ulogu u identifikaciji oznaka vozne trake i prepreka korišćenjem obrađenih podataka sa kamere. Algoritmi zasnovani na DL-u koriste se za identifikaciju granica vozne trake i generisanje putanje koja omogućava BGV-u da precizno prati voznu traku. Ovaj proces zahteva robusne algoritme koji mogu tačno raditi čak i u dinamičkim okruženjima sa promenljivim uslovima osvetljenja i različitim kvalitetom puta [140, 141]. Slično tome, modeli DL-a koriste se za detekciju i praćenje prepreka, omogućavajući sistemu vođenja da planira putanje bez kolizija. Ovi algoritmi takođe mogu predvideti ponašanje kretanja drugih dinamičkih objekata, stoga omogućavajući proaktivno izbegavanje prepreka i poboljšanu bezbednost.
- **Autonomno praćenje lidera i prepoznavanje poze:** vođenje zasnovano na viziji igra važnu ulogu u detekciji, praćenju i interpretaciji namere ljudskog lidera [106]. Ovo se postiže pomoći naprednih algoritama DL-a za analizu slika lidera, dobijenih u realnom vremenu, kako bi se precizno pratio lider i dobili ključni podaci o njegovoj poziciji i orientaciji [120]. Dalja analiza takođe može proceniti smer kretanja lidera, nameru ili komande praćenjem njegovih poza, što omogućava BGV-u da predvidi akcije lidera i odgovori u skladu s tim. Štaviše, korišćenjem prepoznavanja poze, BGV može ekstrahovati ključne informacije iz ljudskog tela, što pomaže u razumevanju njegovih sledećih poteza i poboljšava proces donošenja odluka. Za ovo se koriste modeli DL-a za obradu slika i identifikaciju jedinstvenih obeležja lidera operatera i njegovih akcija [120].

Sistem vođenja pruža inteligenciju za autonomni rad BGV-a, donoseći odluke na visokom nivou i generišući komande. Informacije koje pruža sistem vođenja definišu željeno ponašanje koje sistem upravljanja treba da izvrši. Informacije koje generiše sistem vođenja (reference i greške) definišu željeno ponašanje koje sistem upravljanja treba da izvrši. Ovaj ključni Sistem Upravljanja biće razmatran u narednom odeljku.

2.3.2 Izazovi pri projektovanju, struktura i pregled sistema upravljanja

Sistem upravljanja predstavlja izvršni deo arhitekture autonomnog kretanja BGV-a. Njegov zadatak je da, na osnovu referentnih signala i izračunatih grešaka dobijenih od sistema vođenja, generiše odgovarajuće komande za aktuatore (u slučaju BGV-a, najčešće komande za brzine leve i desne gusenice) kako bi se postiglo željeno kretanje. Njegov primarni zadatak je da osigura tačno i stabilno izvršenje planiranog kretanja, pridržavajući se fizičkih ograničenja vozila i ublažavajući efekte unutrašnjih i spoljašnjih poremećaja [4, 114].

2.3.2.1 Izazovi pri projektovanju sistema upravljanja BGV

Kao što je već napomenuto, BGV koriste mehanizam diferencijalnog upravljanja, gde se skretanje postiže diferencijalnim pogonom gusenica, stvarajući dinamiku skretanja koja unosi nelinearnosti u njihovo kretanje. Ovo kretanje dodatno komplikuje proklizavanje koje se javlja tokom operacije upravljanja u složenim okruženjima sa rastresitim i neravnim terenima [9, 10, 142]. Ova inherentna neholonomna priroda njihovog kretanja dodaje još jedan nivo složenosti zadatku upravljanja, zahtevajući strategije upravljanja sposobne da se izbore sa nelinearnim i nestacionarnim modelima [5]. Pored toga, uslovi terena mogu prouzrokovati značajne promene u proklizavanju, generišući time vremenski promenljive poremećaje koje će primjenjeni algoritam upravljanja morati da potisne. Štaviše, dinamički parametri, kao što su kontaktne tačke između gusenica i terena, značajno variraju sa uslovima okruženja, čineći tačno modelovanje i robusno upravljanje izazovnijim [8]. Stoga, jedinstvena priroda interakcije gusenica i terena, koja direktno utiče na dinamiku i stabilnost vozila, čini upravljanje BGV izazovnijim u odnosu na druge tipove BV.

Pored poteškoća vezanih za dinamiku proklizavanja, projektovanje upravljačkog sistema dodatno komplikuje i izražena sprega između lateralnog i longitudinalnog kretanja. Usled diferencijalnog mehanizma upravljanja, promena brzine jedne gusenice radi ostvarivanja skretanja neizbežno utiče na rezultujuću longitudinalnu brzinu, i obrnuto. Zanemarivanje ove sprege može dovesti do narušavanja performansi kretanja, posebno pri izrazitim manevrima [143]. Takođe, suočavamo se sa nestacionarnostima modela i varijacijama parametara. Precizno modelovanje interakcije gusenica i terena je veoma zahtevno, a i drugi parametri vozila poput mase i inercije mogu se menjati usled promene tereta ili habanja, doprinoseći nepreciznosti modela objekta upravljanja [15, 124, 144, 145]. Konačno, BGV su izloženi i drugim spoljašnjim poremećajima, kao što su udari vetra, nagibi terena, varijacije trenja tla i udari usled neravnina podloge, koje upravljački sistemi moraju efikasno da potisnu [146, 147].

Definisani opšti izazovi se manifestuju na specifičan način u kontekstu dva razmatrana zadataka autonomnog kretanja i u nastavku su detaljnije objašnjeni:

- **Posebni izazovi upravljanja u zadatku autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka:** ovde je primarni zahtev precizno lateralno upravljanje uprkos svim navedenim poremećajima i nestacionarnostima. Posebno je kritično upravljanje tokom manevara izbegavanja prepreka, gde su potrebne brze i tačne promene ugla skretanja bez preskoka, uzimajući u obzir dinamička ograničenja BGV-a i efekte proklizavanja pri skretanju. Dodatni izazov predstavlja robusnost regulatora na potencijalne greške i šum u signalu povratne sprege koji generiše sistem vođenja [115, 117, 118].
- **Posebni izazovi upravljanja u zadatku autonomnog praćenja lidera:** ovaj zadatak zahteva praćenje dinamičke reference, jer lider može nepredvidivo menjati brzinu i pravac. Upravljački sistem mora imati brz odziv u oba kanala (lateralnom i longitudinalnom) kako bi minimizovao greške praćenja uprkos promenama lidera [108, 119]. Istovremeno regulisanje lateralne greške i održavanje željene longitudinalne distance čine zahtevan problem. Pored toga, sistem mora biti robustan na šum senzora (kamera, LiDAR) i potencijalna kašnjenja signala, a takođe mora biti sposoban da integriše i izvrši diskretne komande (stani, napred, nazad) dobijene na osnovu prepoznavanja poze lidera.

Svi ovi izazovi čine tradicionalne metode upravljanja nepogodnim za dobijanje robusnog i prilagodljivog upravljanja u promenljivim radnim uslovima sistema [11, 12, 55, 144, 148]. Njihova zavisnost od linearnih modela i konstantnih, često empirijski podešenih parametara, ograničava njihovu sposobnost da se efikasno nose sa izraženim nelinearnostima, unakrsnim spregama, nestacionarnostima modela i vremenski promenljivim poremećajima [9, 149].

Stoga, postoji jasna potreba za razvojem i primenom naprednih, robusnih i potencijalno adaptivnih strategija upravljanja koje mogu efikasno da prevaziđu specifične probleme upravljanja BGV-om i omoguće pouzdan autonomni rad u realnim uslovima. Naredni odeljci detaljnije razmatraju arhitekturu sistema upravljanja i specifične upravljačke pripute koji se koriste za rešavanje zadatog upravljačkog problema.

2.3.2.2 Struktura sistema upravljanja BGV i pristupi projektovanju upravljanja

Sistem upravljanja BGV se tipično sastoji od longitudinalnog upravljanja i lateralnog upravljanja. Longitudinalno upravljanje odgovorno je za upravljanje brzinom i ubrzanjem BGV-a, manipulisanjem gasom i kočnicama, sa ključnim zadacima kao što su održavanje brzine, osiguravanje bezbednosti i maksimiziranje efikasnosti potrošnje goriva. Precizna regulacija longitudinalnog kretanja kritična je za održavanje glatkog kretanja i sprečavanje naglih zaustavljanja ili ubrzanja koja mogu ugroziti stabilnost vozila. Dinamika u ovom kanalu može uključivati obrtni moment motora, prenosne odnose, sposobnosti kočenja, nagib puta i spoljašnje poremećaje poput otpora vetra i trenja, što zahteva da algoritam

upravljanja obradi svaki faktor posebno uz posebna razmatranja. S obzirom na dinamičku prirodu njegovog okruženja i interakcija, sistem longitudinalnog upravljanja moraće da se prilagođava promenljivim radnim uslovima. U drugu ruku, lateralno upravljanje generiše skretanje BGV-a, osiguravajući da prati željenu putanju uz održavanje orijentacije u odnosu na voznu traku, odnosno željenu trajektoriju u odnosu na lidera. Njegovi glavni zadaci su smanjenje lateralnog odstupanja od refrentne trajektorije. Da bi se smanjila lateralna greška, komandu vođenja treba pravilno implementirati regulatorom tako da se stvarna i ciljna putanja poravnaju. Regulator mora biti u stanju da potisne bočne poremećaje kako bi BGV pratio ispravna skretanja. Upravljanjem mehanizmom skretanja, minimizira se lateralna greška i vozilo se održava na željenoj putanji.

Specifični algoritmi upravljanja i njihova struktura su suštinski važni za osiguravanje željenih performansi sistema i stoga se mora posvetiti posebna pažnja projektovanju longitudinalnog i lateralnog kanala upravljanja [8, 9, 12, 113, 143, 150, 151, 152, 153]. Rešavanju postavljenog problema upravljanja BGV može se pristupiti na dva načina [9, 113, 143, 148]:

- **Dekuplovano upravljanje:** longitudinalno i lateralno upravljanje projektuju se i implementiraju nezavisno, zanemarujući efekte sprege (eng. coupling effects) između njih. Ovo pojednostavljuje projektovanje upravljanja, ali može ugroziti performanse u visoko dinamičkim manevrima gde su efekti sprege značajni.
- **Spregnuto upravljanje:** projektovanje upravljanja eksplicitno uzima u obzir spregu između longitudinalne i lateralne dinamike, težeći koordinisanjem i robusnjem upravljanju, posebno u izazovnim uslovima. Spregnuto upravljanje poboljšava stabilnost i performanse sistema upravljanja omogućavajući regulatorima da kompenzuju međusobne efekte ili podešavanjem njihovih parametara na osnovu izlaza drugog regulatora. Međutim, povećava složenost projektovanja sistema upravljanja i zahteva sofisticiranije tehnike upravljanja za upravljanje interakcijama između lateralne i longitudinalne upravljačke petlje.

Izbor bilo koje od ovih metoda fundamentalno je određen karakteristikama sistema kojim se upravlja, specificiranim zahtevima za performanse i složenošću projektovanja. U praksi, ovo zahteva izbor odgovarajućeg algoritma upravljanja koji treba da bude odabran u cilju postizanja zahtevanog balansa između jednostavnosti implementacije i potencijala za postizanje visokih performansi i robusnosti sistema.

Generalno algoritmi upravljanja mogu se kategorisati u nekoliko širih metoda na osnovu njihovih fundamentalnih filozofija projektovanja:

- **Klasične metode upravljanja:** zasnovane su na utvrđenim principima teorije upravljanja, često koristeći pojednostavljene modele sistema za generisanje upravljačkih signala. PID upravljanje, prevalentna tehnika u industrijskim primenama, reguliše

upravljačke signale putem proporcionalnih, integralnih i derivativnih članova kako bi minimiziralo greške praćenja. Ova metoda je odabrana kao predstavnik klasičnog upravljanja zbog široke upotrebe, lakoće implementacije i obimne literature koja je pokriva. Međutim, PID regulatori mogu imati ograničene performanse u složenim sistemima upravljanja BGV-a zbog zavisnosti od konstantnih parametara i slabe sposobnosti da adresiraju nelinearnosti i poremećaje u visoko dinamičkim okruženjima [11, 12, 55, 144, 148].

- **Adaptivne metode upravljanja:** projektovane su tako da podešavaju svoje parametre *online* na osnovu stanja sistema i operativnih uslova kako bi kompenzovale varijacije parametara i nestacionarnosti modela. Ove tehnike prilagodavaju upravljački signal putem mehanizma učenja kako bi kompenzovale varijacije sistema i dinamiku okruženja, čime poboljšavaju performanse u dinamičkim scenarijima. Primer adaptivne tehnike je MRAC, koja koristi referentni model za minimizaciju greške praćenja, prilagođavanjem parametara regulatora [154, 155, 156].
- **Robusne metode upravljanja:** teže postizanju visokih margina stabilnosti i performansi sistema u prisustvu poremećaja i nestacionarnosti modela. U teoriji robusnog upravljanja, prethodno znanje o dinamici objekta upravljanja suštinsko je za projektovanje regulatora koji osiguravaju zadovoljavajuće performanse unutar specificiranog ograničenog skupa nestacionarnosti. Međutim, složene matematičke operacije koje su uključene u ovakve strukture regulatora čine njihovu implementaciju i projektovanje izazovnijim u poređenju sa drugim metodama [15, 157].
- **Napredne tehnike upravljanja:** uključujući prediktivno upravljanje na bazi modela (eng. Model Predictive Control – MPC) i upravljanje zasnovano na observerima stanja (eng. Observer-based Control). MPC koristi prediktivni model za optimizaciju upravljačkih akcija tokom budućeg vremenskog horizonta, što je korisno za zadatke optimizacije sa zadatim ograničenjima. Međutim, zahtevne računske operacije, ograničena sposobnost upravljanja nestacionarnostima i uslovjenost preciznim modelom sistema, čine ga zahtevnim za implementaciju [33, 55, 110, 144, 158, 159]. Metode upravljanja zasnovane na observerima stanja sistema koriste observer stanja za procenu unutrašnjih i spoljašnjih poremećaja koji deluju na sistem. Jedna od tih metoda je i ADRC tehnika koja se široko koristi u složenim sistemima; procenjuje ukupni poremećaj u realnom vremenu i koristi ove informacije da neutrališe efekte nestacionarnosti, rezultujući robusnim i pouzdanim upravljanjem. Njegova sposobnost postizanja visokih performansi bez detaljnog poznavanja dinamike sistema čini ga posebno privlačnim [15, 17, 33, 53, 143, 150, 151, 160].
- **Pametne metode upravljanja:** uključujući neuronske mreže (eng. Neural Network, NN), fazi logičko upravljanje (eng. Fuzzy Logic Control, FLC) i RL. Ove metode

nude strategije vođene veštačkom inteligencijom i implementiranjem nematematičkih pristupa zasnovanih na mašinskom učenju. Neuronske mreže koriste se kao aproksimatori funkcija koji uče složene nelinearne odnose direktno iz podataka, ali zahtevaju velike skupove podataka i dugo vreme obučavanja. FLC koristi ljudski jezik i intuiciju u pristupima zasnovanim na pravilima, što mu omogućava efikasno upravljanje nestacionarnostima, iako njegovo složeno projektovanje može biti ograničenje za sisteme višeg reda [12]. RL omogućava sistemu da uči metodom pokušaja i pogrešaka, omogućavajući mu da razvije optimalne politike upravljanja interakcijom sa okruženjem. Iako RL može postići visok nivo autonomije i prilagoditi se složenim okruženjima, obično zahteva obimno obučavanje [12, 15, 52, 158].

Pored kategorizacije zasnovane na filozofijama upravljanja, takođe se može diskutovati i o strategijama upravljanja na osnovu toga da li se oslanjaju na model sistema (eng. model-based) ili se ne oslanjaju na model sistema (eng. model-free), pri čemu neki načini kombinuju aspekte oba pristupa (hibridni pristup) [12, 113, 157, 158].

- **Upravljanje zasnovano na modelu:** ove metode se oslanjaju na upotrebu matematičke reprezentacije za projektovanje zakona upravljanja, uzimajući u obzir dinamiku sistema i operativna ograničenja. Klasične tehnike upravljanja kao što su PID i geometrijski regulatori, zajedno sa naprednim metodama kao što je MPC, spadaju u ovu kategoriju. Iako ove metode imaju čvrstu teorijsku osnovu i dobro poznate principije projektovanja, njihov glavni nedostatak je zavisnost od preciznog matematičkog modela, što može biti teško postići za složene, nelinearne i nestacionarne sisteme.
- **Upravljanje bez modela:** ove strategije upravljanja, kao što su one implementirane putem tehniku veštačke inteligencije (npr. neuronske mreže, fazi logika i RL), ne oslanjaju se na specifičnu matematičku reprezentaciju sistema. Umesto toga, one rade direktnom interakcijom sa okruženjem i ažuriranjem svojih zakona upravljanja na osnovu operativnih povratnih informacija. Prednosti pristupa bez modela leže u njihovoj sposobnosti da rade u veoma složenim i nestacionarnim okruženjima i da uče iz podataka. Međutim, njihova ograničenja uključuju značajno hardversko opterećenje tokom izvršavanja u realnom vremenu i zahtev za velikim skupovima podataka za obučavanje.
- **Hibridno upravljanje:** hibridni regulatori kombinuju aspekte tehnika zasnovanih na modelu i bez modela kako bi poboljšali ukupne performanse. Na primer, metode upravljanja zasnovane na observeru, kao što je ADRC, mogu se smatrati hibridnim zbog njihove sposobnosti da procene poremećaje dok implementiraju metodu upravljanja koja kompenzuje procenjene efekte koristeći znanje o dinamici sistema. Adaptivne tehnike se takođe često kategorisu kao hibridne jer koriste specifičan mo-

del kao referencu dok se prilagođavaju u realnom vremenu promenljivoj dinamici i radnim uslovima.

Radi boljeg i lakšeg razumevanja, u nastavku je data tabela koja pruža rezime razmatranih metoda upravljanja.

Strategija upravljanja	Glavna ideja	Prednosti	Ograničenja
Klasično upravljanje	Korišćenje pojednostavljenih modela sistema za generisanje upravljačkih akcija.	Jednostavno i lako za implementaciju u linearnim sistemima.	Ograničeno u nelinearnim sistemima sa nestacionarnosti ma i poremećajima.
Adaptivno upravljanje	Dinamički podešava parametre upravljanja na osnovu promena sistema i radnih uslova.	Poboljšava performanse u vremenski promenljivim okružnjima.	Složena implementacija i može biti visoko zavisna od modela sistema.
Robusno upravljanje	Projektuje regulatore za održavanje stabilnosti uprkos prisustvu nestacionarnosti.	Garantuje performanse u određenom opsegu nestacionarnosti.	Zahteva detaljne matematičke modele sa opisima nestacionarnosti; osetljivo na greške modeliranja.
MPC	Predviđa ponašanje sistema tokom budućeg horizonta i pronalazi optimalne upravljačke akcije.	Upravlja ograničenjima i pogodan je za nelinearne sisteme.	Računski zahtevno i zavisno od tačnosti modela.
Upravljanje zasnovano na observeru	Koristi observer za procenu stanja sistema i/ili poremećaja.	Pruža tačnu estimaciju stanja i robu snost na poremećaje.	Podešavanje parametara može biti izazovno.
Pametno upravljanje	Koristi tehničke veštacke inteligencije za generisanje robusnih i adaptivnih sistema upravljanja.	Fleksibilno; može naučiti složene nelinearne odnose i prilagoditi se promenljivim okruženjima.	Zahteva veliku računsku snagu, velike skupove podataka za obučavanje i složeno podešavanje parametara.

Tabela 2.4: Rezime strategija upravljanja kod autonomnih vozila.

Poglavlje 3

Projektovanje ADRC sistema upravljanja i sistema vođenja BGV-a

U okviru ovog poglavlja predstavljeno je projektovanje ADRC sistema upravljanja i sistema vođenja za konkretno laboratorijsko BGV. U sklopu toga, prvo je opisan matematički model praćenja definisane putanje od strane BGV-a, a nakon toga je detaljno predstavljen postupak projektovanja ADRC regulatora za longitudinalni i lateralni kanal upravljanja, kao i projektovanje sistema vođenja za specifične zadatke autonomnog praćenja vozne trake i praćenja lidera. Na kraju poglavlja predstavljena je simulaciona i eksperimentalna validacija predloženih rešenja, kao i analiza dobijenih rezultata.

3.1 Matematički model praćenja definisane putanje od strane BGV

Razvoj robusnih i efikasnih upravljačkih sistema za BGV fundamentalno se zasniva na preciznim modelima ponašanja vozila, koji su neophodni za predviđanje kretanja, projektovanje algoritama upravljanja i osiguravanje sigurnog rada u različitim uslovima [7, 8, 55]. Bez adekvatnog modela koji opisuje reakciju vozila na upravljačke signale i spoljašnje poremećaje, nije moguće projektovati regulatore koji mogu ostvariti ključne autonomne funkcionalnosti.

Modeli vozila se generalno mogu podeliti u dve glavne kategorije [7, 8, 55, 56, 144, 158]:

- **Kinematički (matematički) modeli** opisuju kretanje vozila koristeći geometrijske odnose između pozicije, brzine i ubrzanja, bez razmatranja unutrašnjih sila ili dinamike vozila. Ovi modeli se široko koriste u primenama autonomnih vozila zbog svoje računske efikasnosti, što ih čini pogodnim za upravljanje u realnom vremenu. U literaturi je većina tehnika za praćenje putanje projektovana za kinematički model.

- **Dinamički modeli** uključuju sile, momente i interakcije između vozila i terena, čineći ih preciznijim, ali računski intenzivnijim. Iako dinamički modeli mogu pružiti veću preciznost, zahtevaju složenu estimaciju parametara i velike računske resurse.

U okviru ove disertacije, odabran je pristup kinematičkog modeliranja. Ovaj izbor je motivisan sledećim faktorima:

Prvo, realizacija upravljanja u realnom vremenu kod BGV-a, naročito kada su raspoloživi resursi na vozilu ograničeni, podrazumeva korišćenje modela koji omogućava brzu evaluaciju. Dinamički modeli, iako sveobuhvatniji, su znatno složeniji i samim tim računski zahtevniji za praktičnu implementaciju u ovim scenarijima [56].

Drugo, pri umerenim brzinama, koje su karakteristične za rad BGV, kretanje je pretežno određeno geometrijskim odnosima, koje kinematički modeli precizno opisuju [161]. Treće, kinematički model može biti proširen da uključi efekte proklizavanja i druge nestacionarnosti, čime se adaptira za praktičnu upotrebu u operativnim uslovima BGV-a. Konačno, kinematički model je lakše implementirati i podesiti u poređenju sa dinamičkim modelom, što pojednostavljuje razvoj i testiranje algoritama upravljanja. Kao što su primetili Fierro i Lewis [8], problem neholonomnosti, naročito relevantan za BGV, može biti pojednostavljen korišćenjem kinematičkog regulatora.

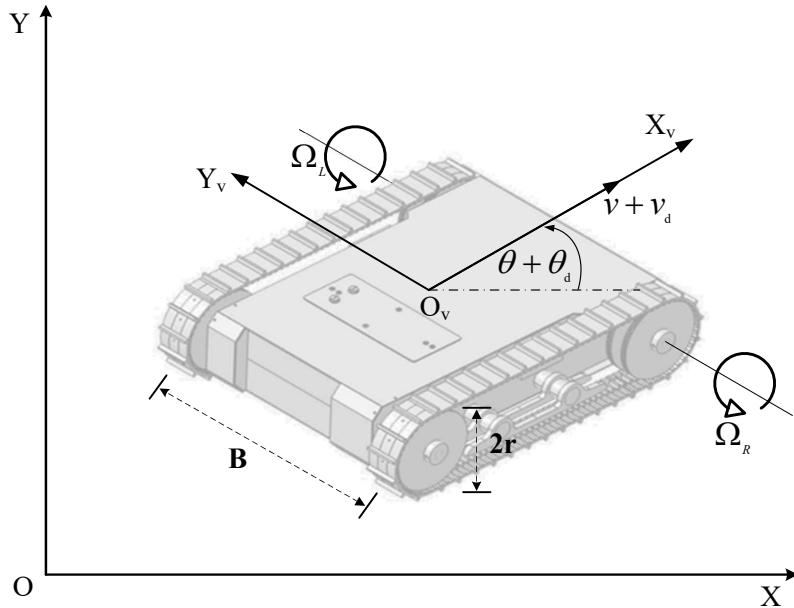
U ovom odeljku predstavićemo kinematički model kretanja BGV-a, koji će poslužiti kao osnova za projektovanje sistema upravljanja za oba zadatka autonomnog kretanja. Razmatramo kretanje BGV-a, definišući globalni (inercijalni) koordinatni sistem (XOY) i lokalni koordinatni sistem vezan za vozilo ($X_vO_vY_v$), čiji se koordinatni početak nalazi u referentnoj tački vozila (npr. geometrijski centar), a X_v osa je usmerena duž uzdužne ose vozila (slika 3.1). Položaj i orientacija vozila u inercijalnom sistemu definisani su koordinatama referentne tačke $(x(t), y(t))$ i ugлом skretanja $\theta(t)$ (ugao između X ose i X_v ose).

Idealni kinematički model (bez proklizavanja) povezuje longitudinalnu brzinu vozila $v(t)$ i ugao brzinu (brzinu promene ugla skretanja) $\dot{\theta}(t)$ sa ugao brzinama desne ($\Omega_R(t)$) i leve ($\Omega_L(t)$) pogonske gusenice:

$$\begin{aligned} v(t) &= \frac{r}{2} \cdot [\Omega_R(t) + \Omega_L(t)], \\ \dot{\theta}(t) &= \frac{r}{B} \cdot [\Omega_R(t) - \Omega_L(t)], \end{aligned} \quad (3.1)$$

gde je r efektivni poluprečnik pogonskog točka gusenice, a B je rastojanje između uzdužnih osa leve i desne gusenice. Kinematika vozila u inercijalnom koordinatnom sistemu u idealnom slučaju data je sa:

$$\begin{pmatrix} \dot{x}(t) \\ \dot{y}(t) \end{pmatrix} = \begin{pmatrix} \cos \theta(t) \\ \sin \theta(t) \end{pmatrix} \cdot v(t). \quad (3.2)$$



Slika 3.1: Kinematički model BGV-a sa definisanim koordinatnim sistemima. (sa prilagođenim oznakama).

Međutim, kretanje BGV-a u realnim uslovima značajno odstupa od idealnog modela usled proklizavanja gusenica. Ovaj efekat modelujemo uvođenjem aditivnih poremećaja na longitudinalnu brzinu ($v_d(t)$) i ugaonu brzinu ($\dot{\theta}_d(t)$). Efektivna brzina kretanja vozila u pravcu njegovog ugla skretanja ($\theta(t) + \theta_d(t)$) postaje $v(t) + v_d(t)$. Kinematika BGV-a u inercijalnom sistemu sada glasi:

$$\begin{pmatrix} \dot{x}(t) \\ \dot{y}(t) \end{pmatrix} = \begin{pmatrix} \cos(\theta(t) + \theta_d(t)) \\ \sin(\theta(t) + \theta_d(t)) \end{pmatrix} \cdot (v(t) + v_d(t)). \quad (3.3)$$

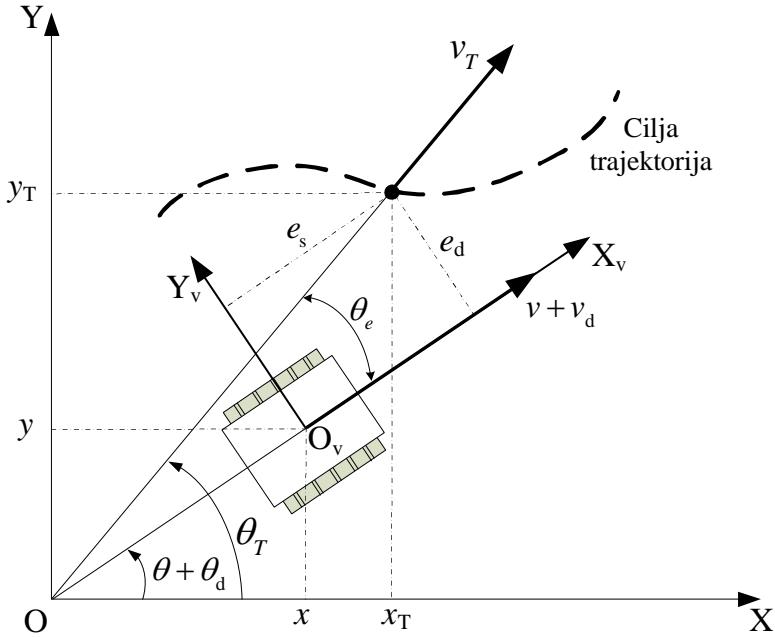
Uz prisustvo poremećaja proklizavanja pogonskih gusenica, jednačina (3.1) se može modifikovati kako bi preciznije opisala kinematiku BGV-a:

$$\begin{aligned} v(t) + v_d(t) &= \frac{r}{2} \cdot [a_R(t) \cdot \Omega_R(t) + a_L(t) \cdot \Omega_L(t)], \\ \dot{\theta}(t) + \dot{\theta}_d(t) &= \frac{r}{B} \cdot [a_R(t) \cdot \Omega_R(t) - a_L(t) \cdot \Omega_L(t)], \end{aligned} \quad (3.4)$$

gde su $a_R(t)$ i $a_L(t)$ nepoznati koeficijenti trenja desne i leve gusenice respektivno, čiji su opsezi vrednosti $[0, 1]$, pri čemu vrednost 1 odgovara slučaju bez poremećaja proklizavanja (model (3.1)), a vrednost 0 označava potpuno proklizavanje gusenica. Ovaj kinematički model sa proklizavanjem koristiće se kao osnova za projektovanje upravljačkih strategija.

Generalno, zadatok sistema upravljanja BGV je generisanje odgovarajućih komandi za aktuator (ugaonih brzina gusenica Ω_L, Ω_R) tako da BGV prati željenu definisanu trajektoriju.

Grafički prikaz zadatka sistema upravljanja je dat na slici 3.2, gde se vidi da BGV



Slika 3.2: Opšti problem praćenja cilja za BGV

treba da prati virtuelni cilj, čije se kretanje u inercijalnom koordinatnom sistemu (X, Y) opisuje pozicijom $(x_T(t), y_T(t))$, brzinom $v_T(t)$ i uglom skretanja $\theta_T(t)$. Kinematika cilja je opisana jednačinom:

$$\begin{pmatrix} \dot{x}_T(t) \\ \dot{y}_T(t) \end{pmatrix} = \begin{pmatrix} \cos \theta_T(t) \\ \sin \theta_T(t) \end{pmatrix} \cdot v_T(t). \quad (3.5)$$

Shodno prethodnom, uloga upravljačkog sistema je da minimizuje odstupanje BGV-a od definisanog virtuelnog cilja. Greške praćenja u lokalnom koordinatnom sistemu vozila se mogu definisati kao:

- **lateralna greška** ($e_d(t)$), bočno odstupanje BGV-a od cilja i
- **longitudinalna greška** ($e_s(t)$), odstupanje BGV od cilja duž uzdužne ose BGV-a.

U opštem slučaju se može reći da algoritam upravljanja treba da obezbedi da lateralna i longitudinalna greška teže ka odgovarajućim zadatim referentnim vrednostima, $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}(t)$, odnosno da odstupanja $e_d(t) - e_{d(\text{ref})}(t)$ i $e_s(t) - e_{s(\text{ref})}(t)$ konvergiraju nuli. Definisanje referentnih vrednosti $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}(t)$ zavisi od konkretnog zadatka vođenja, ali u najvećem broju slučajeva $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}$ imaju vrednost nula, pa se zadatak upravljanja svodi na problem regulacije.

Lateralnu i longitudinalnu grešku moguće je proračunati transformacijom razlike pozicija $(x_T - x, y_T - y)$ iz inercijalnog u lokalni koordinatni sistem vozila:

$$\begin{pmatrix} e_s(t) \\ e_d(t) \end{pmatrix} = \begin{pmatrix} \cos(\theta(t) + \theta_d(t)) & \sin(\theta(t) + \theta_d(t)) \\ -\sin(\theta(t) + \theta_d(t)) & \cos(\theta(t) + \theta_d(t)) \end{pmatrix} \begin{pmatrix} x_T(t) - x(t) \\ y_T(t) - y(t) \end{pmatrix}, \quad (3.6)$$

odnosno:

$$e_s(t) = (x_T(t) - x(t)) \cdot \cos(\theta(t) + \theta_d(t)) + (y_T(t) - y(t)) \cdot \sin(\theta(t) + \theta_d(t)), \quad (3.7)$$

$$e_d(t) = -(x_T(t) - x(t)) \cdot \sin(\theta(t) + \theta_d(t)) + (y_T(t) - y(t)) \cdot \cos(\theta(t) + \theta_d(t)). \quad (3.8)$$

3.1.1 Dinamika lateralne greške

Kako bismo detaljnije analizirali zadate upravljačke probleme, potrebno je detaljno opisati dinamiku grešaka. U tom cilju, definišimo prvo grešku ugla skretanja vozila i cilja, $\theta_e(t)$, kao razliku između ugla skretanja cilja $\theta_T(t)$ i ugla skretanja BGV-a ($\theta(t) + \theta_d(t)$):

$$\theta_e(t) = \theta_T(t) - (\theta(t) + \theta_d(t)). \quad (3.9)$$

Diferenciranjem jednačine za lateralnu grešku (3.8) po vremenu i zamenom kinematičkih jednačina (3.5) i (3.3), nakon sređivanja, dobija se:

$$\dot{e}_d(t) = v_T(t) \cdot \sin \theta_e(t) - (v(t) + v_d(t)) \cdot \sin \theta_d(t) - \dot{\theta}(t) \cdot e_s(t). \quad (3.10)$$

Da bi se olakšalo projektovanje upravljanja, lateralni podsistem upravljanja može se formulisati iz (3.10) grupisanjem određenih članova kao poremećaj kao:

$$\dot{e}_d(t) = v_T(t) \cdot \sin \theta_e(t) + d_p(t), \quad (3.11)$$

gde $d_p(t) = -(v(t) + v_d(t)) \cdot \sin \theta_d(t) - \dot{\theta}(t) \cdot e_s(t)$ predstavlja zbirni poremećaj koji uključuje efekte proklizavanja (v_d, θ_d) i sprege sa longitudinalnim kanalom (e_s).

Daljim diferenciranjem (3.11) i zamenom izvoda $\dot{\theta}_e(t) = \dot{\theta}_T(t) - \dot{\theta}(t) - \dot{\theta}_d(t)$, dobija se dinamika drugog reda za lateralnu grešku:

$$\begin{aligned} \ddot{e}_d(t) &= \dot{v}_T(t) \cdot \sin \theta_e(t) + v_T(t) \cdot \cos \theta_e(t) \cdot [\dot{\theta}_T(t) - \dot{\theta}(t) - \dot{\theta}_d(t)] + \dot{d}_p(t). \\ &= -v_T(t) \cdot \cos \theta_e(t) \cdot \dot{\theta}(t) + \dot{v}_T(t) \cdot \sin \theta_e(t) + v_T(t) \cdot \cos \theta_e(t) \cdot [\dot{\theta}_T(t) - \dot{\theta}_d(t)] + \dot{d}_p(t). \end{aligned} \quad (3.12)$$

Regulacija lateralne greške $e_d(t)$ se postiže dejstvom na upravljački ulaz $\dot{\theta}(t)$ (tj. ugao-nu brzinu BGV-a), uprkos prisustvu poremećaja $d_p(t)$ i njegove dinamike $\dot{d}_p(t)$, kao i dinamike cilja ($\dot{v}_T, \dot{\theta}_T$) i proklizavanja ($\dot{\theta}_d$).

3.1.2 Dinamika longitudinalne greške

Slično, diferenciranjem jednačine za longitudinalnu grešku (3.7) po vremenu i zamenom kinematičkih jednačina (3.5) i (3.3), dobija se:

$$\dot{e}_s(t) = v_T(t) \cdot \cos \theta_e(t) - (v(t) + v_d(t)) + \dot{\theta}(t) \cdot e_d(t). \quad (3.13)$$

U ovom slučaju, longitudinalna brzina BGV-a, $v(t)$, predstavlja upravljački ulaz za longitudinalni kanal. Zadatak longitudinalnog upravljanja je da obezbedi da $e_s(t)$ prati željenu referentnu vrednost $e_{s(\text{ref})}(t)$ pomoću upravljačkog ulaza $v(t)$, uprkos varijacijama brzine cilja $v_T(t)$, prisustvu poremećaja proklizavanja $v_d(t)$, $\theta_d(t)$ i sprege sa lateralnim kanalom ($\dot{\theta}(t) \cdot e_d(t)$).

Na osnovu izvedenih jednačina dinamike grešaka (3.12) i (3.13), jasno je da postoji sprege (coupling) između lateralnog i longitudinalnog kretanja BGV-a pri praćenju cilja. Promena ugaone brzine $\dot{\theta}(t)$ utiče i na lateralnu i na longitudinalnu grešku, dok promena longitudinalne brzine $v(t)$ takođe implicitno utiče na obe greške kroz kompleksnu interakciju sa proklizavanjem i orijentacijom.

Uprkos ovoj sprezi, uobičajeni pristup u projektovanju upravljanja mobilnim robotima, koji je usvojen i u ovoj disertaciji, jeste da se primeni *dekompozicija* problema. Prepostavlja se da se $v(t)$ primarno koristi za regulaciju longitudinalne greške, a $\dot{\theta}(t)$ primarno za regulaciju lateralne greške. Opšti zadaci upravljanja se stoga definišu kao:

- **Lateralno upravljanje:** projektovati upravljački zakon za $u_l(t) = \dot{\theta}(t)$ tako da greška $e_{d(\text{ref})}(t) - e_d(t)$ konvergira ka nuli, tretirajući uticaj longitudinalne greške (e_s), longitudinalne brzine (v) i poremećaja proklizavanja (θ_d, v_d) kao deo ukupnog poremećaja koji treba kompenzovati.
- **Longitudinalno upravljanje:** projektovati upravljački zakon za $u_v(t) = v(t)$ tako da greška $e_{s(\text{ref})}(t) - e_s(t)$ konvergira ka nuli, tretirajući uticaj lateralne greške (e_d), ugaone brzine ($\dot{\theta}$) i poremećaja proklizavanja (v_d, θ_d) kao deo ukupnog poremećaja koji treba kompenzovati.

Ovakav pristup omogućava projektovanje regulatora za svaki kanal posebno. U ovom odeljku formulisana je opšta postavka problema upravljanja praćenjem trajektorije za BGV na osnovu kinematičkog modela sa proklizavanjem. Definisane su lateralna (e_d) i longitudinalna (e_s) greška praćenja u odnosu na pokretni virtuelni cilj, i izvedene su njihove (spregnute i nelinearne) dinamike. Postavljen je zadatak regulacije ovih grešaka ka željenim referentnim vrednostima. Usvojen je dekomponovani pristup upravljanju, gde će se projektovati odvojeni regulatori za $v(t)$ i $\dot{\theta}(t)$ sa primarnim zadatkom regulacije e_s odnosno e_d . U narednom odeljku biće detaljno predstavljeno projektovanje regulatora korišćenjem ADRC-a, tehnike koja je posebno pogodna za upravljanje sistemima sa nestacionarnostima i spoljašnjim poremećajima kakvi su prisutni u izvedenim modelima dinamike grešaka.

3.2 Pristup upravljanju BGV na bazi ADRC algoritma

U prethodnom odeljku izvedene su dinamike lateralne i longitudinalne greške za BGV, uzimajući u obzir kinematički model sa proklizavanjem. Pokazano je da su ove dinamike

podložne značajnim poremećajima usled proklizavanja, nestacionarnosti modela i sprega između kanala. Da bi se obezbedilo robusno i precizno praćenja referentne trajektorije u takvim uslovima, u ovom odeljku predstavljeno je projektovanje upravljačkog sistema zasnovanog na ADRC algoritmu.

ADRC je izabran zbog svoje robusnosti na nestacionarnosti modela i spoljašnje poremećaje, koji su osnovni problem kod operacija BGV-a u realnim izazovnim terenskim uslovima. Ovaj upravljački pristup omogućava estimaciju i aktivnu kompenzaciju ukupnog poremećaja u oba kanala upravljanja, čime se postižu željene performanse bez potrebe za tačnim poznavanjem svih parametara sistema i poremećaja. U nastavku prvo će detaljno biti razmotreni razlozi primene ADRC algoritma sa detaljnim pregledom relevantne literature o primeni ovog algoritma u upravljanju BV, dok će se nakon toga detaljno predstaviti postupak projektovanja ADRC regulatora za lateralni i longitudinalni kanal upravljanja.

3.2.1 Zašto ADRC ?

Izbor odgovarajuće strategije upravljanja BGV, s obzirom na njihov rad na nepredvidivim terenima i uslovima, kao i nestacionarnosti i nelinearnosti samog objekta upravljanja, od ključne je važnosti. Klasični industrijski regulatori, iako teorijski dobro zasnovani, pokazuju ograničenja u suočavanju sa složenom dinamikom BGV-a, unakrsnim spregama i poremećajima poput proklizavanja, delimično zbog zavisnosti od konstantnih parametara i uprošćenih modela regulatora [8, 24]. Dok naprednije tehnike poput robusnog i adaptivnog upravljanja teže da prevaziđu ove probleme, njihovo projektovanje često zahteva precizno poznavanje dinamike sistema što je teško ostvarivo u slučaju BGV [15, 17]. Pametne metode, s druge strane, često imaju ograničenu hardversku implementaciju zbog složenosti algoritma i visokih računarskih zahteva.

Nasuprot tome, ADRC se pojavljuje kao veoma obećavajuća alternativa, posebno pogodnu za BGV [14, 29, 162]. Razvijen od strane Jingqing Han-a 1990-ih, ADRC se razlikuje od tradicionalnih, pa čak i mnogih modernih tehnika upravljanja, svojim eksplicitnim fokusom na aktivno procenjivanje i potiskivanje poremećaja sistema, umesto pasivnog prilagođavanja njima [13, 163]. ADRC primarno zahteva poznavanje reda sistema i približne vrednosti pojačanja u direktnoj grani, čineći ga manje osetljivim na nepreciznosti i nestacionarnosti definisanog modela sistema [16].

Naime, ADRC se izdvaja sposobnošću da svu nemodelovanu i promenljivu dinamiku sistema tretira kao jedinstveni "ukupni poremećaj". Ovaj poremećaj se estimira u realnom vremenu pomoću ključne komponente ADRC-a, ESO, i zatim aktivno potiskuje primenom odgovarajućeg upravljačkog zakona [13, 163, 164, 165, 166]. ADRC ne brine o poreklu ili strukturi poremećaja; fokusira se na njegov efekat [14]. Ovakav pristup značajno smanjuje zavisnost od preciznog matematičkog modela, zahtevajući primarno poznavanje reda sistema i aproksimaciju upravljačkog pojačanja, što pojednostavljuje projektovanje i povećava

robustnost sistema [16, 122, 167].

Svestranost ADRC-a potvrđena je uspešnom primenom u brojnim oblastima, uključujući industrijsku automatizaciju, vazduhoplovstvo, robotiku i mehatroniku, automobilske sisteme, energetsku elektroniku i biomedicinsko inženjerstvo [14, 15, 16, 143, 151, 160, 168, 169, 170, 171].

Ključne prednosti ADRC-a za upravljanje BGV-om [13, 14, 15, 16, 17, 122, 167, 169, 172, 173] mogu se definisati prema sledećem:

1. **Robustnost na nestacionarnosti i poremećaje:** ADRC je projektovan za upravljanje unutrašnjim nestacionarnostima i spoljnim poremećajima, koristeći ESO za procenu i kompenzaciju "ukupnog poremećaja". Ova sposobnost potiskivanja poremećaja ključna je za BGV na nepredvidivim terenima.
2. **Smanjena zavisnost od modela:** ADRC značajno smanjuje potrebu za preciznim modelima sistema, zahtevajući samo poznavanje reda sistema i procenu upravljačkog pojačanja. Ova osobina čini ADRC praktičnim za složene BGV sisteme s izazovnom dinamikom i interakcijama.
3. **Jednostavnost implementacije i podešavanja:** ADRC nudi relativno jednostavniju strukturu i proces podešavanja (npr. propusni opsezi ključnih parametara). Ova jednostavnost je ključna za implementaciju i primenu na BGV platformama gde računarski resursi mogu biti ograničeni.
4. **Efikasnost za nelinearne sisteme:** ADRC je inherentno primenljiv na nelinearne sisteme bez zahteva za eksplicitnom linearizacijom ili složenom identifikacijom nelinearnog modela.
5. **Prilagodljivost promenljivim uslovima:** sposobnost ADRC-a da proceni i kompenzuje poremećaje u realnom vremenu omogućava mu da se prilagodi promenljivim radnim uslovima (tereni, kretanja lidera).

Ove karakteristike čine ADRC posebno pogodnim za zadatke autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka (gde je ključno nositi se sa proklizavanjem i greškama percepcije [49, 115]) i autonomnog praćenja lidera (gde je neophodno kompenzovati dinamičko kretanje lidera i šum senzora [15, 28]). Izbor ADRC-a za upravljanje BGV-om u ovim zadacima opravдан je njegovom sposobnošću da adresira jedinstvene izazove BGV-a, nudeći bolje performanse u poređenju sa klasičnim pristupima.

Kroz relevantnu literaturu mogu se razmotriti nekoliko različitih pristupa primene ADRC-a u sistemima upravljanja BV, i to od samo longitudinalnog upravljanja do integriranih rešenja koja ukjelučuju i lateralno i longitudinalno upravljanje.

Gao et al. [150] predložili su poboljšani ADRC pristup za praćenje longitudinalne brzine kod autonomnih vozila, specifično u scenarijima praćenja vozila (eng. car-following).

Uveli su poboljšani ESO koji uključuje estimacione greške višeg reda i povratnu spregu greške praćenja kako bi poboljšali estimaciju poremećaja i stabilnost sistema. Sprovedene simulacije demonstrirale su bržu konvergenciju i smanjene greške praćenja u poređenju sa konvencionalnim ADRC-om. Jin et al. [174] istraživali su ADRC za praćenje trajektorije autonomnih električnih vozila (eng. Autonomous Ground Electric Vehicles, AGEV), fokusirajući se na poboljšanje performansi u manevrima dvostrukе promene trake i serpentinama. Uključujući nelinearnosti sistema, nestacionarnosti i spoljašnje poremećaje, razvili su model dinamike vozila u prostoru stanja i projektovali ADRC koji uključuje ESO za estimaciju i kompenzaciju poremećaja u realnom vremenu. Rezultati simulacija u MATLAB/Simulink-u pokazali su da je ADRC nadmašio linearno upravljanje i upravljanje na bazi predikcije modela u smislu smanjenja grešaka praćenja i poboljšanja potiskivanja poremećaja. Wang et al. [143] predložili su kaskadnu ADRC strategiju za BV, sa ciljem poboljšanja upravljanja kretanjem. Naime, predložen je dvostepeni kaskadni ADRC sa polu-spregnutim dinamičkim modelom kako bi poboljšali potiskivanje poremećaja i tačnost praćenja. Prvi stepen osigurava ograničenost grešaka stanja sistema, dok drugi stepen koristi konvencionalni ADRC za estimaciju i kompenzaciju poremećaja. Rešenje je validirano kroz simulacione i eksperimentalne studije, demonstrirajući veću tačnost praćenja i robusnost u poređenju sa konvencionalnim pristupima upravljanju kao što je upravljanje sa povratnom spregom po stanjima (eng. State Feedback Control, SFC). Uprkos efikasnosti predloženih struktura ADRC-a u longitudinalnom upravljanju i praćenju brzine, ove studije ne uspevaju da u potpunosti potisnu i savladaju nelinearnosti i složenu dinamiku BGV-a. Shodno tome, ova disertacija teži da unapredi postojeća rešenja integrišući ih sa novim algoritmima. Tako na primer, strategije upravljanja [143] i [150] nude interesantne pristupe u upravljanju spregnutom dinamikom, ali ne adresiraju u potpunosti specifične zahteve scenarija autonomnog praćenja lidera, gde je ključna brza adaptacija na nepredvidiva kretanja lidera.

Primena u lateralnom upravljanju BGV predstavljena je u [151], gde su autori kombinovali ADRC sa teorijom diferencijalne monotonosti (eng. differential flatness theory) za lateralno praćenje putanje autonomnih vozila (eng. Autonomous Guided Vehicles, AGV), sa ciljem pojednostavljenja projektovanja upravljanja i poboljšanja robusnosti. Autori su linearizovali dinamički model AGV-a koristeći diferencijalnu monotonost i projektovali ADRC regulator sa ESO-om za kompenzaciju poremećaja u realnom vremenu. Ova transformacija pojednostavila je projektovanje upravljanja smanjenjem složenosti regulatora. Simulacije su pokazale visoku tačnost praćenja i robusnost u poređenju sa metodom linearnog kvadratnog praćenja (eng. Linear Quadratic Tracker, LQT). Kang et al. [175] fokusirali su se na poboljšanje lateralne stabilnosti u praćenju putanje autonomnih vozila koristeći poboljšanu ADRC (eng. Improved Active Disturbance Rejection Control, IADRC) metodu. Njihov IADRC, koji uključuje novu kontinualnu nelinearnu funkciju unutar unapređenog ESO-a (eng. Improved Extended State Observer, IESO) i kompenzator greške zasnovan na

LQR radi optimizacije podešavanja parametara i poboljšanja robusnosti na poremećaje, demonstrirao je bolju tačnost praćenja putanje i potiskivanje poremećaja u CarSim/Simulink simulacijama u poređenju sa tradicionalnim LQR i ADRC regulatorima. Sang et al. [176] istraživali su ADRC za sistem aktivnog upravljanja prednjom osovinom (eng. Active Front Steering, AFS) kako bi poboljšali upravljinost i stabilnost vozila. Simulacije u MATLAB/Simulink-u i CarSim-u pokazale su da je ADRC značajno nadmašio konvencionalno PID upravljanje u smanjenju lateralnog odstupanja i poboljšanju praćenja putanje za vozila opremljena AFS-om. Wang et al. [177] analizirali su izazove upravljanja skretanjem (eng. Turning Control) BV, koji predstavlja kritičan aspekt manevarskih sposobnosti, posebno za BGV. Autori su predložili novu strategiju upravljanja koja kombinuje ESO za smanjenje vršnih vrednosti signala (eng. anti-peak ESO) sa diferencijatorom praćenja (eng. tracking differentiator) kako bi poboljšali robusnost i tačnost upravljanja skretanjem vozila.

Ovde je potrebno napomenuti da su navedeni radovi uglavnom demonstrirali dobre rezultate u lateralnom upravljanju i stabilnosti sistema, ali se većina fokusira na konvencionalna vozila umesto na BGV.

Primena ADRC kod BGV razmotrena je u [17] gde se analizira ADRC okvir za rešavanje problema kompenzacije proklizavanja kod BGV-a na zahtevnim terenima kao što su trava, šljunak i asfalt. Autori uvode generalizovani kinematički model proširen parametrima skaliranja i pomeranja kako bi uzeli u obzir poremećaje izazvane proklizavanjem, uparen sa proširenim kalmanovim filterom (eng. Extended Kalman Filter, EKF) za estimaciju ovih parametara u realnom vremenu. Eksperimentalna validacija pokazala je značajno smanjenje lateralne greške i poboljšanu energetsku efikasnost u poređenju sa PD upravljanjem. U drugu ruku, Stanković et al. [27] analiziraju problem upravljanja praćenjem trajektorije BGV na bazi ADRC šeme upravljanja. ADRC okvir sveobuhvatno upravlja nestacionarnostima modela i poremećajima usled proklizavanja, pružajući robusne performanse bez zahteva za preciznim modelima sistema. Autori pružaju sistematičnu proceduru projektovanja, uključujući diskretizaciju i analizu performansi, i validiraju svoj pristup koristeći simulacije sa FPGA hardverom u petlji (eng. FPGA-in-the-loop, FIL). Njihov rad demonstrira bolje performanse ADRC-a u odnosu na PI/PID regulatorima za praćenje trajektorije BGV-a. Liu et al. [53] predložili su robusni okvir upravljanja zasnovan na ADRC kombinovanom sa ESO kako bi se nosili sa složenostima rada BGV-a u rudarskim okruženjima, uključujući ulazna ograničenja i diskretne poremećaje poput promena trenja izazvanih terenom usled kamenja. Simulacije i laboratorijski eksperimenti demonstrirali su bolje performanse praćenja u poređenju sa PI regulatorima, posebno u prisustvu diskretnih poremećaja. Chen et al. [168] istraživali su upravljanje zasnovano na ADRC-u sa tehnikom povratnog upravljanja (eng. backstepping control) za praćenje putanje kod AGV-a. Predložen je pristup zasnovan na ADRC-u sa povratnim upravljanjem sa dva ESO-a redukovanih reda za procenu ukupnih poremećaja u podsistemima upr-

vljanja lateralnom greškom i uglom skretanja AGV-a. Koristeći ove procene, autori su projektovali virtualni upravljački ulaz kako bi kompenzovali nestacionarnosti i eliminisali zasićena upravljačkog signala. Simulacije pod različitim scenarijima, uključujući trapezoidne i sinusoidalne poremećaje, demonstrirale su efikasno smanjenje lateralne greške čak i sa značajnim nestacionarnostima modela, pokazujući robusnost ADRC-a.

Prethodna analiza različitih strategija upravljanja nedvosmisleno ukazuju na potencijal ADRC pristupa, ali i na izazove u postizanju robusnog autonomnog rada BGV-a, posebno u zadacima autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka i autonomnog praćenja lidera. Iako su postojeće metode pokazale efikasnost u određenim aspektima ili pod specifičnim uslovima, nedostatak integrisanih rešenja koja kombinuju naprednu percepciju i robusno upravljanje, posebno prilagođeno jedinstvenoj dinamici BGV-a, ostaje evidentan. Shodno tome, u nastavku rada će biti predložen detaljan postupak projektovanja strukture sistema vođenja na bazi vizuelnih senzora i upravljanja na bazi ADRC regulatora u cilju rešavanja postojećih izazova.

3.2.2 Projektovanje i implementacija ADRC-a za BGV

3.2.2.1 Projektovanje ADRC regulatora lateralnog kanala

Kao što je već definisano, zadatak ovog regulatora je da osigura da stvarna lateralna greška $e_d(t)$ (definisana u (3.8)) prati željenu referentnu vrednost $e_{d(\text{ref})}$, odnosno da greška regulacije $e_{d(\text{ref})}(t) - e_d(t)$ konvergira ka nuli. Upravljački ulaz koji se koristi za postizanje ovog zadatka je ugaona brzina BGV-a, $u_1(t) = \dot{\theta}(t)$. Ovaj opšti pristup projektovanju je primenljiv na različite zadatke, gde se specifičnost zadatka ogleda u definisanju reference $e_{d(\text{ref})}(t)$ i eventualno u izboru nominalnog pojačanja b_{0_l} .

Polazeći od dinamike lateralne greške drugog reda, izvedene u Odeljku 3.1.1. Dinamika greške lateralnog upravljanja (3.12) može se predstaviti u kompaktnom obliku kao:

$$\ddot{e}_d(t) = b(t) \cdot \dot{\theta}(t) + d_1(t), \quad (3.14)$$

gde je $b(t) = -v_T(t) \cdot \cos \theta_e(t)$ promenljivo pojačanje sistema, a:

$$d_1(t) = \dot{v}_T(t) \cdot \sin \theta_e(t) + v_T(t) \cdot \cos \theta_e(t) \cdot [\dot{\theta}_T(t) - \dot{\theta}_d(t)] + \dot{d}_p(t), \quad (3.15)$$

predstavlja spoljašnji poremećaj u lateralnom kanalu. Primenom ADRC pristupa, (3.14) se može zapisati u obliku:

$$\ddot{e}_d(t) = b_{0_l} \cdot \dot{\theta}(t) + f_1(t), \quad (3.16)$$

gde je $b_{0_l} = -\bar{v}_T$ predstavlja nominalnu (očekivanu) vrednost pojačanja sistema u

direktnoj grani, odnosno očekivanu brzinu cilja, dok

$$f_1(t) = (b(t) - b_{01}) \cdot \dot{\theta}(t) + d_1(t). \quad (3.17)$$

predstavlja ukupni poremećaj u lateralnom kanalu, koji obuhvata spoljašnje poremećaje, nestacionarnosti modela i varijacije parametara.

Na ovaj način, (3.16) se može predstaviti u proširenom obliku prostora stanja kao:

$$\begin{cases} \dot{x}_{1l} = x_{2l}, \\ \dot{x}_{2l} = b_{01} \cdot u_l + f_1, \end{cases} \quad (3.18)$$

gde je $x_{1l} = e_d$, $x_{2l} = \dot{e}_d$, a $u_l = \dot{\theta}$.

Uzimajući $x_{3l} = f_1$ kao dodatnu promenljivu stanja, sistem (3.18) može se predstaviti u proširenom obliku stanja:

$$\underbrace{\begin{bmatrix} \dot{x}_{1l} \\ \dot{x}_{2l} \\ \dot{x}_{3l} \end{bmatrix}}_{\mathbf{A}_l} = \underbrace{\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}}_{\mathbf{B}_l} \cdot \begin{bmatrix} x_{1l} \\ x_{2l} \\ x_{3l} \end{bmatrix} + \underbrace{\begin{bmatrix} 0 \\ b_{01} \\ 0 \end{bmatrix}}_{\mathbf{B}_l} u_l + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \dot{f}_1. \quad (3.19)$$

Stanja sistema mogu se proceniti na osnovu izmerene izlazne veličine sistema $e_d(t)$ korišćenjem ESO-a:

$$\begin{bmatrix} \dot{\hat{x}}_{1l} \\ \dot{\hat{x}}_{2l} \\ \dot{\hat{x}}_{3l} \end{bmatrix} = \mathbf{A}_l \cdot \begin{bmatrix} \hat{x}_{1l} \\ \hat{x}_{2l} \\ \hat{x}_{3l} \end{bmatrix} + \mathbf{B}_l \cdot u_l + \begin{bmatrix} l_{1l} \\ l_{2l} \\ l_{3l} \end{bmatrix} \cdot [x_{1l} - \hat{x}_{1l}], \quad (3.20)$$

gde su l_{1l} , l_{2l} i l_{3l} pojačanja observera.

Na osnovu procenjenih stanja sistema, zakon upravljanja za lateralni kanal definisan je kao:

$$u_l = \frac{1}{b_{01}} [k_{1l} \cdot (e_{d(\text{ref})} - \hat{x}_{1l}) + k_{2l} \cdot (\dot{e}_{d(\text{ref})} - \hat{x}_{2l}) + \ddot{e}_{d(\text{ref})} - \hat{x}_{3l}], \quad (3.21)$$

gde su k_{1l} i k_{2l} parametri podešavanja regulatora.

Prepostavljajući $f_l(t) \approx \hat{f}_l(t)$, $\dot{e}_d(t) \approx \hat{e}_d(t)$, i $e_d(t) \approx \hat{e}_d(t)$, i zamenjujući 3.21 u 3.16, dinamika lateralnog kanala upravljanja se predstavlja kao:

$$\ddot{e}_d(t) - k_{2l} \cdot (\dot{e}_{d(\text{ref})} - \dot{e}_d(t)) - k_{1l} \cdot (e_{d(\text{ref})} - e_d(t)) - \ddot{e}_{d(\text{ref})} \approx 0, \quad (3.22)$$

koja se može podesiti izborom parametara k_{1l} i k_{2l} .

U ovoj tezi, parametri regulatora se podešavaju metodom *parametrizacije propusnog opsega* [29] postavljanjem polova regulatora zatvorene petlje na zajedničku lokaciju $\lambda = -\omega_{CL_1}$:

$$(\lambda + \omega_{CL_1})^2 \stackrel{!}{=} \lambda^2 + k_{2_1} \cdot \lambda + k_{1_1}, \quad (3.23)$$

gde je ω_{CL_1} željeni propusni opseg sistema zatvorene petlje lateralnog upravljanja. Solving this equation yields the controller gains:

$$[k_{1_1} \ k_{2_1}] = [\omega_{CL_1}^2 \ 2\omega_{CL_1}], \quad (3.24)$$

Na sličan način, pojačanja ESO (3.20) se podešavaju postavljanjem polova na zajedničku lokaciju $\lambda = -\omega_{ESO_1}$, tj.:

$$(\lambda + \omega_{ESO_1})^3 \stackrel{!}{=} \lambda^3 + l_{1_1} \cdot \lambda^2 + l_{2_1} \cdot \lambda + l_{3_1}, \quad (3.25)$$

gde je ω_{ESO_1} željeni propusni opseg ESO-a. Solving this equation yields the observer gains:

$$[l_{1_1} \ l_{2_1} \ l_{3_1}] = [3\omega_{ESO_1} \ 3\omega_{ESO_1}^2 \ \omega_{ESO_1}^3], \quad (3.26)$$

3.2.2.2 Projektovanje ADRC regulatora longitudinalnog kanala

Longitudinalni ADRC regulator projektuje se sa zadatkom da longitudinalna greška $e_s(t)$ (definisana u jednačini (3.7)) prati željenu referentnu vrednost $e_{s(\text{ref})}$. Ovaj regulator je relevantan za zadatke gde je potrebno aktivno upravljati rastojanje do cilja ili brzinom kretanja duž putanje.

Dinamika longitudinalne greške (jednačina (3.13)) može se predstaviti u kompaktnom obliku:

$$\dot{e}_s(t) = b_{0_v} \cdot v(t) + f_v(t), \quad (3.27)$$

gde je $f_v(t) = v_T(t) \cdot \cos \theta_e(t) - v_d(t) + \dot{\theta}(t) \cdot e_d(t)$ ukupni poremećaj u longitudinalnom kanalu upravljanja a $b_{0_v} = -1$ očekivano pojačanje u direktnoj grani sistema.

Izražavanjem jednačine (3.27) u modelu prostora stanja, koristeći $x_{1_v} = e_s$ i $u_v = v$, dobija se:

$$\dot{x}_{1_v} = b_{0_v} u_v + \dot{f}_v. \quad (3.28)$$

Proširenje modela stanja (3.28) dodatnim stanjem $x_{2v} = f_v$ dobija se model:

$$\begin{bmatrix} \dot{x}_{1v} \\ \dot{x}_{2v} \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}}_{A_v} \cdot \begin{bmatrix} x_{1v} \\ x_{2v} \end{bmatrix} + \underbrace{\begin{bmatrix} b_{0v} \\ 0 \end{bmatrix}}_{B_v} u_v + \begin{bmatrix} 0 \\ 1 \end{bmatrix} \dot{x}_{2v}. \quad (3.29)$$

U tom slučaju, stanja sistema (3.29) mogu se proceniti na osnovu izmerene izlazne veličine sistema $e_s(t)$ korišćenjem ESO-a u sledećem obliku:

$$\begin{bmatrix} \dot{\hat{x}}_{1v} \\ \dot{\hat{x}}_{2v} \end{bmatrix} = A_v \cdot \begin{bmatrix} \hat{x}_{1v} \\ \hat{x}_{2v} \end{bmatrix} + B_v \cdot u_v + \begin{bmatrix} l_{1v} \\ l_{2v} \end{bmatrix} \cdot [x_{1v} - \hat{x}_{1v}], \quad (3.30)$$

gde su l_{1v} i l_{2v} pojačanja observera.

Zakon upravljanja za longitudinalni kanal se definiše kao:

$$u_v = \frac{1}{b_{0v}} [k_{1v} \cdot [e_{s(\text{ref})} - \hat{x}_{1v}] + \dot{e}_{s(\text{ref})}(t) - \dot{\hat{x}}_{2v}], \quad (3.31)$$

gde je k_{1v} parametar podešavanja regulatora.

Prepostavljajući $f_v(t) \approx \hat{f}_v(t)$ i $e_s(t) \approx \hat{e}_s(t)$, i zamenjujući 3.31 u 3.28, dinamika longitudinalnog kanala upravljanja se predstavlja kao:

$$\dot{e}_s(t) - k_{1v} \cdot (e_{s(\text{ref})} - e_s(t)) - \dot{e}_{s(\text{ref})} \approx 0. \quad (3.32)$$

Na sličan način kao kod lateralnog ADRC regulatora, pojačanja regulatora i ESO-a se podešavaju metodom *parametrizacije propusnog opsega* [29], odnosno.:

$$\lambda + \omega_{\text{CL}_v} \stackrel{!}{=} \lambda + k_{1v}, \quad (3.33)$$

$$(\lambda + \omega_{\text{ESO}_v})^2 \stackrel{!}{=} \lambda^2 + l_{1v} \cdot \lambda + l_{2v}, \quad (3.34)$$

gde su ω_{CL_v} i ω_{ESO_v} propusni opsezi sistema longitudinalnog upravljanja u zatvorenoj spredi i longitudinalnog ESO-a, respektivno. Na osnovu prethodnog, pojačanja regulatora i observera imaju vrednosti:

$$\begin{aligned} [l_{1v} \ l_{2v}] &= [2\omega_{\text{ESO}_v} \ \omega_{\text{ESO}_v}^2], \\ [k_{1v}] &= [\omega_{\text{CL}_v}]. \end{aligned} \quad (3.35)$$

Ovde je potrebni naglasiti da uspešna primena projektovanih ADRC regulatora u realnom vremenu zahteva dve ključne informacije koje predstavljaju ulaze regulatora:

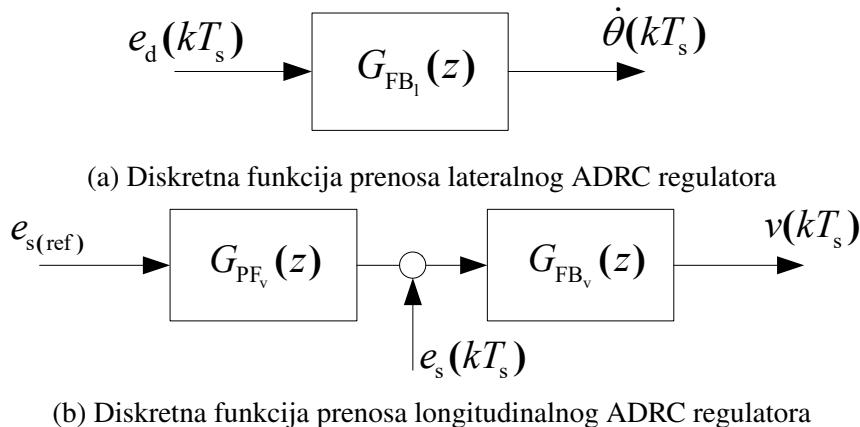
1. **Željene referentne vrednosti:** vrednosti $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}(t)$ i njihovi izvodi, moraju biti definisane u skladu sa specifičnim zadatkom autonomne vođenja.

2. **Merenja grešaka:** vrednosti grešaka $e_d(t)$ i $e_s(t)$ moraju biti dostupne kao povratna sprega za ESO i upravljački zakon. Ove vrednosti se ne mere direktno, već se moraju izračunati na osnovu podataka dobijenih sa senzora vozila (npr. kamera, LiDAR) i informacija o okruženju ili cilju.

Definisanje referenci i izračunavanje grešaka na osnovu senzorske percepcije predstavlja zadatak **sistema vođenja**. Stoga, naredni odeljak (3.3) detaljno će opisati kako se projektuju specifični sistemi vođenja za zadatke praćenja vozne trake sa izbegavanjem prepreka i praćenja lidera.

3.2.2.3 Implementacija ADRC regulatora

Projektovani lateralni i longitudinalni ADRC regulatori (3.21 i 3.31) implementirani su u Python-u koristeći njihovu odgovarajuću diskretnu reprezentaciju. Diskretizacija regulatora je izvedena na osnovu metoda predstavljenih u [178]. Slika 3.3 prikazuje blok dijagrame rezultujućih diskretnih regulatora.



Slika 3.3: Prikazi diskretnih funkcija prenosa za (a) lateralni ADRC regulator i (b) longitudinalni ADRC regulator.

Diskretizacija lateralnog ADRC regulatora: diskretna funkcija prenosa lateralnog ADRC regulatora, $G_{FB_l}(z)$, data je izrazom:

$$G_{FB_l}(z) = \frac{\beta_{10} + \beta_{11} \cdot z^{-1} + \beta_{12} \cdot z^{-2}}{1 + \alpha_{11} \cdot z^{-1} + \alpha_{12} \cdot z^{-2}} \cdot \frac{1}{(1 - z^{-1})}, \quad (3.36)$$

gde z^{-1} predstavlja operator jediničnog kašnjenja. Koeficijenti α_{11} , α_{12} , β_{10} , β_{11} i β_{12} izračunavaju se na sledeći način, na osnovu parametara kontinualnog regulatora i perioda odabiranja $T_s = 0, 2s$:

$$\begin{aligned}
 \alpha_{11} &= \frac{-1}{8} \cdot (1 + z_{\text{CL}_l})^2 \cdot (1 + z_{\text{ESO}_l})^3 + z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^3 + 1, \\
 \alpha_{12} &= z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^3, \\
 \beta_{10} &= \frac{1}{b_0 T_s^2} \left[\frac{1}{4} \cdot (1 + z_{\text{CL}_l})^2 \cdot (1 + z_{\text{ESO}_l})^3 - 2 \cdot (z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^3 \right. \\
 &\quad \left. + 2z_{\text{CL}_l} + 3z_{\text{ESO}_l} - 2) \right], \\
 \beta_{11} &= \frac{1}{b_0 T_s^2} \left[-(1 + z_{\text{CL}_l})^2 \cdot (1 + z_{\text{ESO}_l})^3 + 2 \cdot (1 + z_{\text{CL}_l})^2 \right. \\
 &\quad \left. + 6 \cdot (z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^3 + 2 \cdot z_{\text{CL}_l} \cdot z_{\text{ESO}_l} + z_{\text{ESO}_l}^2 + z_{\text{ESO}_l} - 1) \right], \\
 \beta_{12} &= \frac{1}{b_0 T_s^2} \left[-\frac{1}{4} \cdot (1 + z_{\text{CL}_l})^2 \cdot (1 + z_{\text{ESO}_l})^3 + 2 \cdot (-2z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^3 + \right. \\
 &\quad \left. 3z_{\text{CL}_l}^2 \cdot z_{\text{ESO}_l}^2 + 2z_{\text{CL}_l} \cdot z_{\text{ESO}_l}^3 + 1) \right],
 \end{aligned}$$

gde su $z_{\text{CL}_l} = \exp^{-\omega_{\text{CL}_l} \cdot T_s}$ i $z_{\text{ESO}_l} = \exp^{-k_{\text{ESO}_l} \cdot \omega_{\text{CL}_l} \cdot T_s}$. k_{ESO_l} je parametar podešavanja koji povezuje propusne opsege observera i regulatora.

Diskretizacija longitudinalnog ADRC regulatora: diskretne funkcije prenosa za longitudinalni ADRC regulator date su izrazima:

$$G_{\text{FB}_v}(z) = \frac{\beta_{20} + \beta_{21} \cdot z^{-1}}{1 + \alpha_{21} \cdot z^{-1}} \cdot \frac{1}{(1 - z^{-1})}, \quad (3.37)$$

$$G_{\text{PF}_v}(z) = \frac{1}{\beta_{20}} \frac{\gamma_{20} + \gamma_{21} \cdot z^{-1} + \gamma_{22} \cdot z^{-2}}{1 + \frac{1}{\beta_{20}} \cdot (\beta_{21} z^{-1})}, \quad (3.38)$$

sa koeficijentima koji se dobijaju na osnovu izraza:

$$\begin{aligned}
 \alpha_{21} &= -2z_{\text{CL}_v} \cdot z_{\text{ESO}_v}^2, \\
 \beta_{20} &= \frac{1}{b_0 T_s} \cdot [z_{\text{CL}_v} \cdot z_{\text{ESO}_v}^2 - 2z_{\text{ESO}_v} - z_{\text{CL}_v} + 2], \\
 \beta_{21} &= \frac{1}{b_0 T_s} \cdot [2z_{\text{CL}_v} \cdot z_{\text{ESO}_v} - 2z_{\text{CL}_v} \cdot z_{\text{ESO}_v}^2 + z_{\text{ESO}_v}^2 - 1], \\
 \gamma_{20} &= \frac{1 - z_{\text{CL}_v}}{b_0 \cdot T_s}, \\
 \gamma_{21} &= -2z_{\text{ESO}_v} \cdot \frac{(1 - z_{\text{CL}_v})}{b_0 \cdot T_s}, \\
 \gamma_{22} &= z_{\text{ESO}_v}^2 \cdot \frac{(1 - z_{\text{CL}_v})}{b_0 \cdot T_s},
 \end{aligned}$$

gde su $z_{CL_v} = \exp^{-\omega_{CL_v} \cdot T_s}$ i $z_{ESO_v} = \exp^{-k_{ESO_v} \cdot \omega_{CL_v} \cdot T_s}$, dok je k_{ESO_v} parametar podešavanja odnosa propusnih opservera i regulatora u zatvorenoj povratnoj spredi.

3.3 Projektovanje sistema vođenja BGV

Sistem vođenja na osnovu zadatka misije i percepcije okruženja generiše neophodne ulazne signale za longitudinalni i lateralni regulator BGV-a. Naime, njegov osnovni zadatak je da definiše referentnu trajektoriju i kontinuirano izračunava odstupanja trenutne pozicije vozila u odnosu na referentnu trajektoriju.

U sklopu projektovanog sistema upravljanja ADRC regulatori zahtevaju informacije o greškama praćenja – lateralnoj $e_d(t)$ i longitudinalnoj $e_s(t)$ – kao i o željenim referentnim vrednostima ovih grešaka, $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}(t)$. Da bi se to obezbedilo sistem vođenja koristi podatke senzora (u ovom radu monokularne kamere i LiDAR senzora) kako bi: identifikovao relevantne elemente okruženja (npr. linije vozne trake, prepreke, lidera), definisao željenu putanju ili poziciju cilja u skladu sa zadatkom, izračunao trenutne greške $e_d(t)$ i $e_s(t)$, i definisao trenutne referentne vrednosti $e_{d(\text{ref})}(t)$ i $e_{s(\text{ref})}(t)$ koje ADRC regulatori treba da prate.

Kao što je već napomenuto, u okviru ove disertacije, projektovanje i razvoj sistema vođenja usmereni su na dva fundamentalna i praktično relevantna zadatka:

1. **Autonomno praćenje zadate vozne trake sa izbegavanjem prepreka:** ovaj zadatak zahteva od BGV-a da se kreće unutar obeležene trake, održavajući centralnu poziciju, uz sposobnost detekcije i bezbednog zaoblilaženja prepreka koje se mogu naći na putanji.
2. **Autonomno praćenje lidera:** ovaj zadatak podrazumeva sposobnost BGV-a da prati kretanje dinamičkog cilja (u ovom radu, ljudskog lidera) na definisanom rastojanju, prilagođavajući svoju brzinu i pravac kretanja, uz dodatnu mogućnost interpretacije komandi zadatih pozom lidera radi poboljšane interakcije.

U nastavku je predstavljen postupak projektovanja sistema vođenja za oba razmatrana zadatka autonomnog kretanja,

3.3.1 Projektovanje sistema vođenja za autonomno praćenje zadate vozne trake sa izbegavanjem prepreka

Kao što je definisano u odeljku 2.2, ovaj zadatak spada u kategoriju praćenja definisane geometrijske putanje. Ključna karakteristika praćenja putanje jeste da ne postoji zahtev za praćenjem specifične vremenske komponente, već je fokus na prostornoj konvergenciji ka željenoj geometrijskoj putanji – u ovom slučaju, centralnoj liniji vozne trake.

U kontekstu ovog zadatka, prepostavlja se da se željena brzina BGV-a, v , održava konstantnom ili je zadaje nezavisni mehanizam. Pod ovom prepostavkom, longitudinalna greška $e_s(t)$ ostaje približno nula, što implicira da je njen izvod zanemarljiv ($\dot{e}_s(t) \approx 0$). Iz tog razloga, za uspešno izvršenje zadatka autonomnog praćenja zadate vozne trake neophodno je projektovati samo lateralni sistem upravljanja.

Lateralna greška $e_d(t)$ predstavlja ključnu veličinu koju treba regulisati. Zadatak je održati vozilo centriranim u traci, što znači da je željena lateralna greška nula, odnosno:

$$e_{d(\text{ref})}(t) = 0. \quad (3.39)$$

Sistem vođenja mora kontinualno da izračunava lateralnu grešku $e_d(t)$ u odnosu na centralnu liniju trake (ili putanju za izbegavanje prepreke) i da je prosledi lateralnom ADRC regulatoru.

Da bi se izračunala $e_d(t)$, sistem vođenja definiše virtualni cilj kao virtualnu tačku ispred vozila (eng. Look-ahead point) koja leži na centralnoj liniji trake na određenom rastojanju od prednje ivice BGV. Lateralna greška $e_d(t)$ se izračunava kao horizontalno odstupanje ove tačke od vertikalne centralne linije slike kamere (slika 3.4). Primarna funkcija projektovanog sistema vođenja je da, na osnovu vizuelne percepције, precizno odredi centralnu liniju i izračuna $e_d(t)$.

Ova izračunata greška $e_d(t)$ se prosleđuje lateralnom ADRC regulatoru. Budući da je za ovaj zadatak $e_{d(\text{ref})}(t) = 0$, a time i $\dot{e}_{d(\text{ref})}(t) = 0$ i $\ddot{e}_{d(\text{ref})}(t) = 0$, opšti upravljački zakon (3.21) se pojednostavljuje na:

$$u_l(t) = \dot{\theta}(t) = \frac{1}{b_{0_l}} (-k_{p_l} \hat{x}_{1_l}(t) - k_{d_l} \hat{x}_{2_l}(t) - \hat{x}_{3_l}(t)). \quad (3.40)$$

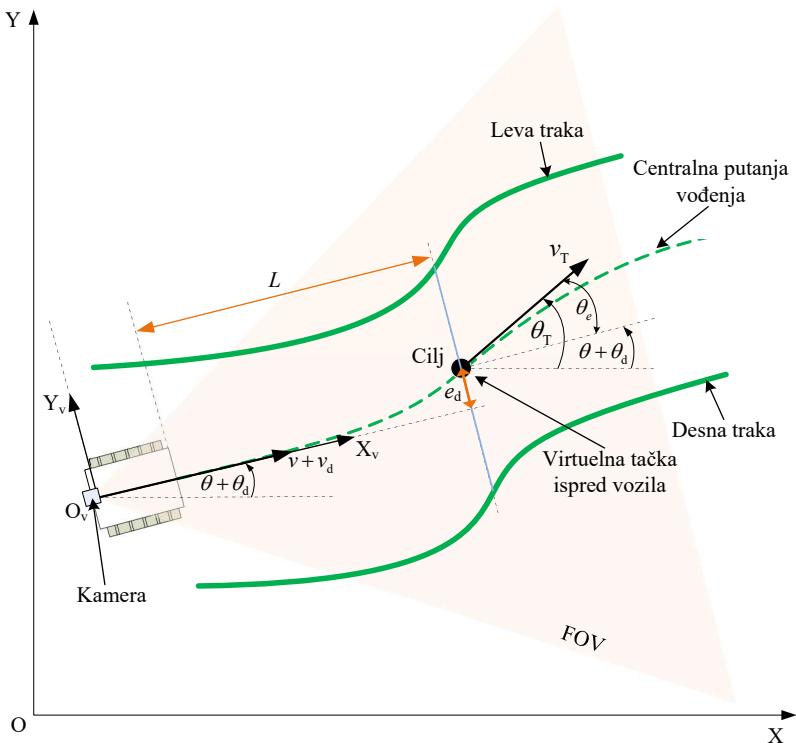
Nominalno pojačanje b_{0_l} , definisano kao $b_{0_l} = -\bar{v}_T$, za ovaj zadatak se određuje prepostavkom da je očekivana brzina cilja jednaka brzini BGV-a:

$$b_{0_l} = -v. \quad (3.41)$$

Regulator ((3.40) sa (3.41)) u kombinaciji sa ESO (3.20) teži da minimizira lateralnu grešku $e_d(t)$, obezbeđujući precizno autonomno kretanje duž centralne linije trake. Ključni faktori koji utiču na performanse regulatora uključuju: (1) dinamičke promene ugla skretanja željene putanje $\dot{\theta}_T(t)$ (koja zavisi od zadate brzine kretanja vozila), i (2) efekti proklizavanja - kako lateralnog (θ_d) tako i longitudinalnog (v_d), sa njihovim dinamičkim promenama ($\dot{\theta}_d$, \dot{v}_d).

Predloženi sistem vođenja za ovaj zadatak, čija je opšta arhitektura prikazana na slici 3.5, zasnovan je na korišćenju jedne monokularne kamere i naprednih algoritama obrade slike i DL-a.

Predloženi sistem za detekciju i praćenje vozne trake sastoji se od pet modula, kao što

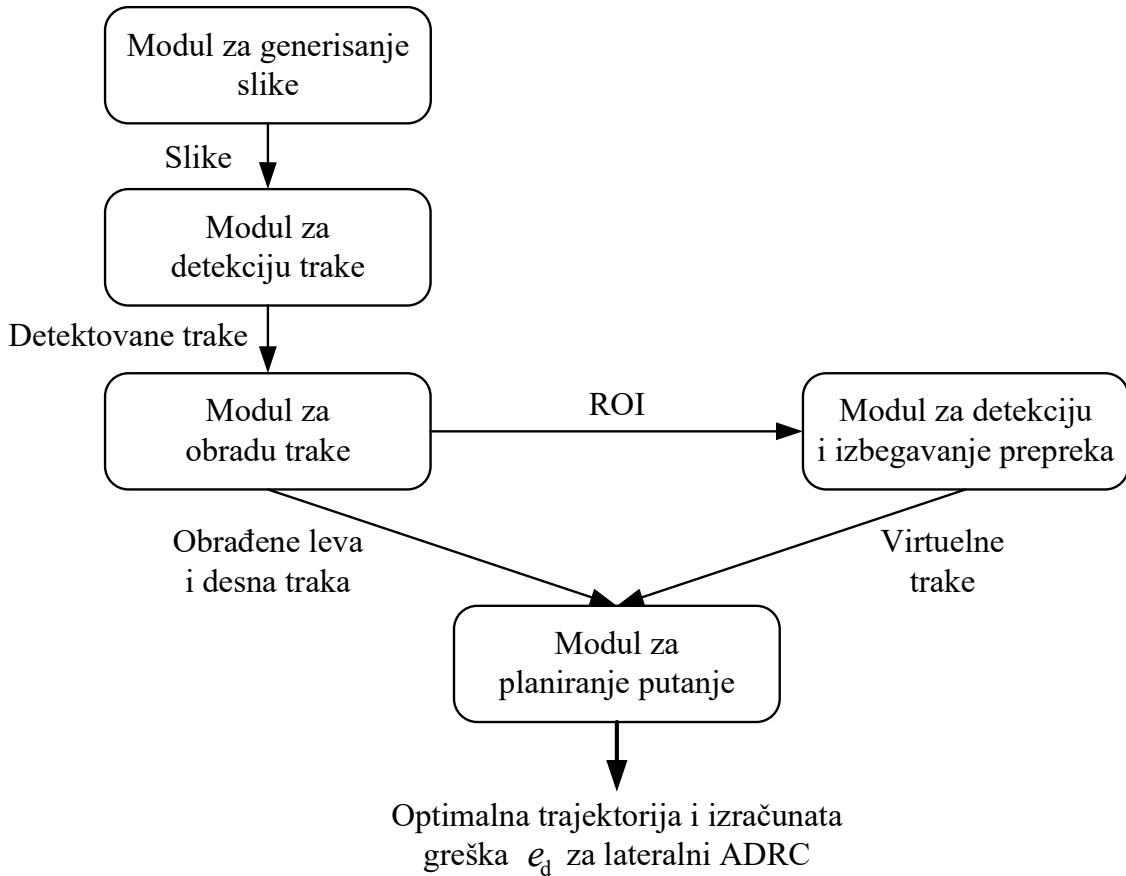


Slika 3.4: Pregled vođenja BGV-a za praćenje trake gde je cilj virtuelna tačka ispred vozila (sa prilagođenim oznakama).

je prikazano na blok dijagramu 3.5:

1. **Modul za generisanje slike:** generiše sliku, vrši akviziciju slike i predobradu frejmova slike.
2. **Modul za detekciju trake:** identificuje granice vozne trake na slici korišćenjem segmentacije zasnovane na DL-u.
3. **Modul za obradu trake:** ekstrahuje, filtrira i interpolira tačke detektovanih traka kako bi se dobole kontinualne i glatke reprezentacije leve i desne ivice trake.
4. **Modul za detekciju i izbegavanje prepreka:** identificuje prepreke unutar definisnog ROI-a na putanji vozila i, ukoliko je prepreka detektovana, generiše alternativne, tzv. virtuelne trake, koje zaobilaze prepreku.
5. **Modul za planiranje putanje:** na osnovu obrađenih informacija o traci (originalnih ili virtuelnih) generiše optimalnu lokalnu putanju za vozilo i određuje tačku na putanji ispred vozila ka kojoj se vozilo treba usmeriti. Iz pozicije ove tačke u odnosu na vozilo, direktno izračunava lateralnu grešku $e_d(t)$ koja se prosleđuje lateralnom ADRC regulatoru.

Ovi moduli obrađuju frejm po frejm slike kamere, generišući vrednost ulaza ($e_d(t)$) za lateralni ADRC upravljački sistem, kako bi se BGV kretalo u željenoj traci, uz izbegavanje detektovanih prepreka. Detaljn opis uloge i strukture svakog modula dat je u nastavku.



Slika 3.5: Blok dijagram predloženog sistema za detekciju i praćenje vozne trake.

3.3.1.1 Modul za generisanje slike

Modul za generisanje slike predstavlja osnovni senzorski interfejs sistema. Koristi monokularnu kameru montiranu na zadnjem delu BGV-a, na visini od 90 cm i sa nagibom u odnosu na vozilo od 45 stepeni. Modul vrši akviziciju slika (frejmova) u rezoluciji od 640×480 piksela. Ova rezolucija je odabrana jer pruža dovoljno detalja za detekciju trake i prepreka, dok istovremeno održava računsku efikasnost potrebnu za rad u realnom vremenu. Kamera radi sa frekvencijom akvizicije od 5 frejmova u sekundi (eng. Frames Per Second - FPS), što je sinhronizovano sa radnom frekvencijom aktuatora BGV-a.

Pored same akvizicije slika, ovaj modul obavlja i nekoliko ključnih koraka predobrade:

- Konverziju prostora boja iz BGR (uobičajeni format za OpenCV) u RGB, radi kompatibilnosti sa modelima DL-a koji su obično trenirani na RGB slikama.
- Promenu veličine slike kako bi odgovarala očekivanoj ulaznoj dimenziji neuronskih mreža koje se koriste u narednim modulima.
- Normalizaciju vrednosti piksela u opseg [0, 1], što je standardna praksa za poboljšanje performansi i stabilnosti neuronskih mreža.

Osnovni zadatak ovih koraka predobrade je da se osigura da naredni moduli (za detekciju trake i prepreka) dobiju konzistentan i optimizovan ulazni podatak.

3.3.1.2 Modul za detekciju trake

Modul za detekciju trake koristi pristup zasnovan na DL-u, oslanjajući se na model **YOLOPv2** koji je specifično treniran za zadatak segmentacije vozne trake. YOLOPv2 predstavlja proširenje YOLO radnog okvira i projektovan je kao mreža za učenje koja istovremeno obavlja detekciju trake, segmentaciju vozne površine i detekciju prepreka. Arhitektura YOLOPv2 modela poboljšava ekstrakciju obeležja, unapređuje računsku efikasnost i postiže visoku tačnost segmentacije u poređenju sa tradicionalnim tehnikama obrade slike. YOLOPv2 postiže visoku brzinu rada od 91 FPS, uz zadržavanje visoke tačnosti. Dodatno, korišćenje hibridne funkcije gubitka (hybrid loss function) tokom treniranja poboljšava njegovu robusnost na izazovne oblike voznih traka.

Korišćenjem arhitekture sa paralelnim radom na više zadataka YOLOPv2 unapređuje sposobnosti detekcije trake, jer takva mreža omogućava sveobuhvatnije razumevanje scene u poređenju sa mrežom koja bi bila fokusirana isključivo na jedan zadatak (detekciju trake). Ovo omogućava robusnu detekciju trake u kompleksnim scenarijima, uključujući promenljive uslove osvetljenja, neuobičajene ili oštećene oznake traka i delimična zaklanjanja traka.

1. Arhitektura YOLOPv2 modela

Model YOLOPv2 sastoji se od tri primarne komponente:

- **Osnova (eng. Backbone):** koju čini modifikovana CSPDarknet53 mreža, odgovorna za ekstrakciju hijerarhijskih obeležja iz ulazne slike. Ona hvata kako fine detalje, tako i kontekstualne informacije visokog nivoa.
- **Vrat (eng. Neck):** uključuje piridalnu mrežu obeležja (eng. Feature Pyramid Network, FPN) i modul za prostorno piridalno združivanje (eng. Spatial Pyramid Pooling, SPP). Ove komponente unapređuju reprezentaciju obeležja na više skala i poboljšavaju robusnost na različite strukture voznih traka.
- **Glava (eng. Head):** sastoji se od tri odvojene grane, specifične za svaki zadatak (detekcija objekata, segmentacija vozne površine, segmentacija vozne trake). Glava za segmentaciju trake koristi specijalizovanu strukturu zasnovanu na dekonvoluciji kako bi se precizirala predikcija granica trake.

2. Metodologija treniranja

Kako bi se poboljšala sposobnost projektovanog modela, on je treniran na raznovrsnom skupu podataka koji sadrži slike snimljene pod različitim uslovima terena, u

različitim svetlosnim okruženjima i sa različitim strukturama voznih traka. Proces treniranja je uključivao nekoliko ključnih tehnika.

- **Augmentacija podataka:** primenjene su nasumične promene osvetljenosti, kontrasta i nijanse boje, kao i geometrijske transformacije poput rotacije i skaliranja slika.
- **Transferno učenje (Transfer learning):** korišćeno je inicijalizovanjem osnove modela sa prethodno utreniranim težinskim koeficijentima dobijenim na velikim skupovima podataka za klasifikaciju slika, kao što je ImageNet.
- **Hibridna funkcija gubitka:** zadatak treniranja je koristio kombinaciju binarne unakrsne entropije (binary cross-entropy), dice gubitka i fokalnog gubitka. Ova kombinacija optimizuje kako tačnost na nivou piksela, tako i strukturu konzistentnost segmentacije, istovremeno rešavajući problem neuravnoteženosti klase, koji je čest kod segmentacije traka.

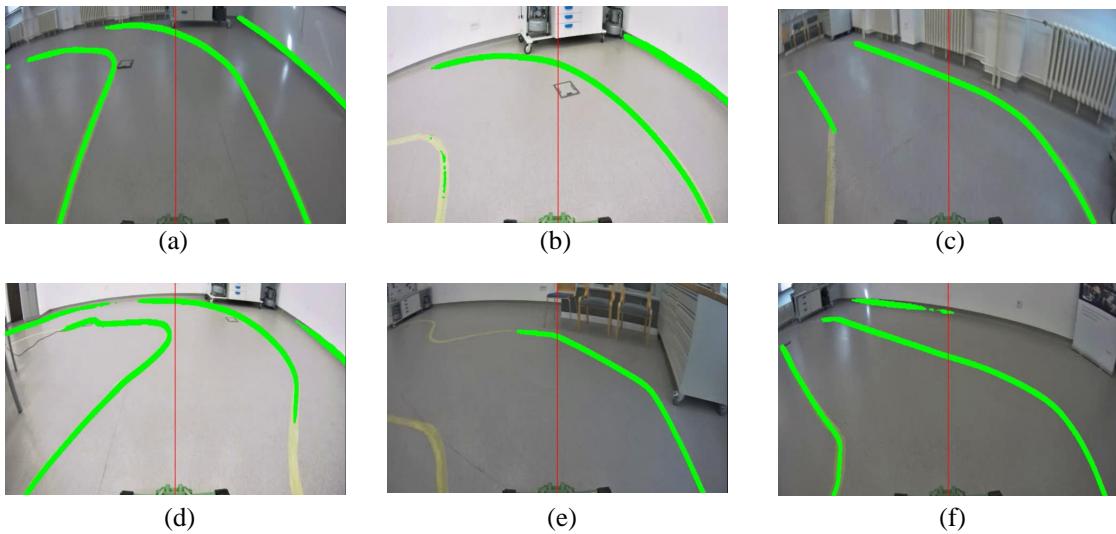
3. Proces inferencije

Tokom faze inferencije, koji predstavlja primenu projektovanog modela na novim slikama, model prati strukturiran proces za ekstrakciju oznaka trake, koji se sastoji od:

- **Početna obrada (eng. Forward pass):** odgovarajući frejm prolazi kroz YOLOPv2 model kako bi se generisao inicijalni izlaz segmentacije (segmentaciona mapa).
- **Naknadna obrada (eng. Post-processing):** izlazna segmentaciona mapa se konvertuje u binarnu masku koja ističe piksele predviđene kao deo trake.
- **Fina obrada (eng. Mask refinement):** da bi se dodatno poboljšala kontinualnost i jasnoća vozne trake, primenjuju se morfološke operacije na binarnu masku. Ove operacije smanjuju šum i poboljšavaju strukturu konzistentnost detektovanih segmenata trake.

Finalna binarna maska (kao što je prikazano na slici 3.6) služi kao osnova za ekstrakciju tačaka koje pripadaju traci, omogućavajući robusnu i tačnu detekciju granica trake čak i u izazovnim uslovima.

Slika 3.6 prikazuje primere snimaka sa BGV kamere gde su maske traka, dobijene kao izlaz YOLOPv2 modela, istaknute zelenom bojom. Generalno posmatrano, detektor daje dobre rezultate; međutim, evidentno je da primetna promena u uslovima osvetljenja utiče na detekciju trake. Rezultati detekcije značajno variraju; neke trake su u potpunosti detektovane, dok su druge ili delimično detektovane ili potpuno promašene. U određenim slučajevima, trake sa obe strane nisu u potpunosti prepoznate, što naglašava izazove



Slika 3.6: Primeri izlaza YOLOv2 modela: Maska detektovane trake (zeleno) prikazana na slikama sa BGV kamere.

sa kojima se suočava precizna detekcija traka pod promenljivim uslovima okruženja i opravdava potrebu za narednim koracima obrade i filtriranja.

3.3.1.3 Modul za obradu trake

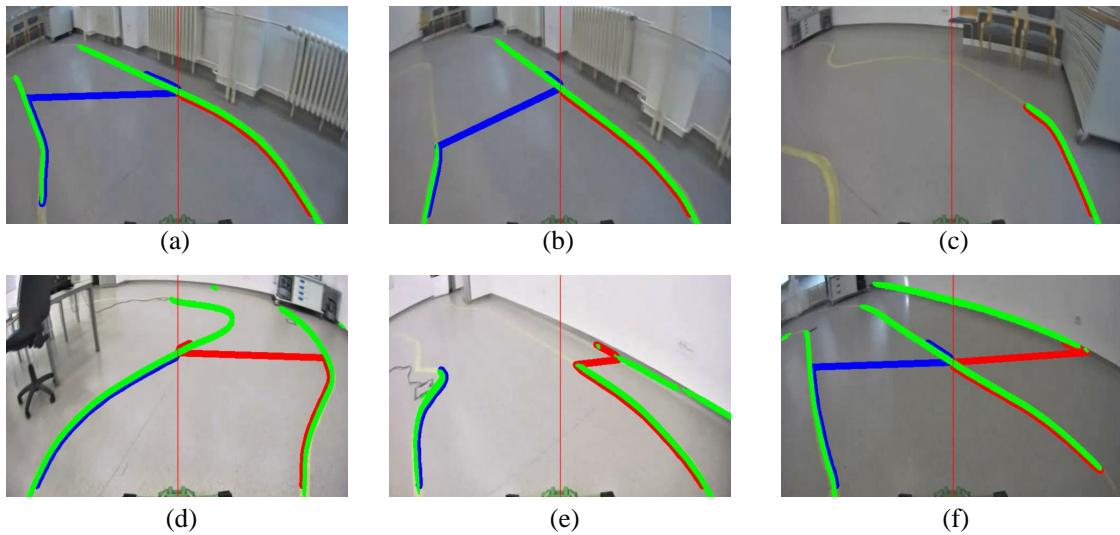
Nakon dobijanja binarne maske iz modula za detekciju trake, sistem dalje obrađuje informacije o traci primenom nekoliko sofisticiranih algoritama kako bi ekstrahovao, pročistio i interpolirao tačke koje pripadaju traci. Ovaj modul je dizajniran da se nosi sa različitim izazovnim scenarijima, uključujući delimičnu detekciju trake, detekciju samo jedne strane trake, ili potpuno odsustvo oznaka trake.

1. Ekstrakcija tačaka trake

Proces ekstrakcije tačaka trake identificiše tačke koje pripadaju levoj i desnoj granici vozne trake analizom binarne maske i klasifikacijom tačaka u odnosu na centar slike. Ovaj proces uključuje skeniranje maske na unapred definisanim vertikalnim pozicijama, kako bi se smanjilo računsko opterećenje, izbegavajući potrebu za analizom svih tačaka maske. Na svakom nivou se zatim identificišu horizontalne pozicije koje odgovaraju oznakama trake.

Algoritam ekstrakcije primenjuje nekoliko ključnih tehnika:

- **Klasifikacija zasnovana na centru:** tačke maske se klasifikuju kao pripadajuće levoj ili desnoj traci putanje na osnovu njihove pozicije u odnosu na centar slike. Konkretno, na svakom vertikalnom nivou identificišu se najbliže tačke maske levo i desno od centralne vertikalne ose. Ovo omogućava nezavisnu detekciju svake granice trake.



Slika 3.7: Detekcija putanja traka označena bojama: leva traka je označena **plavom bojom**, desna traka **crvenom bojom**, a maska identifikovana modelom je istaknuta **zelenom bojom**. Ovaj prikaz ilustruje proces detekcije trake bez ikakvih ograničenja, fokusirajući se isključivo na najbliže granice levoj i desnoj strani centralne ose slike.

- **Ograničenja kontinuiteta:** detektovane tačke se validiraju korišćenjem dve provere konzistentnosti:

- (a) Horizontalna blizina detekcija na istom nivou, što podrazumeva da rastojanje između detektovane leve i desne tačke na istom vertikalnom nivou mora da premaši minimalni prag širine trake.
- (b) Vertikalno poravnanje za svaku traku pojedinačno sa prethodno validiranim tačkama iste trake. Dozvoljeno horizontalno odstupanje između uzastopnih tačaka se vertikalno prilagođava kako bi se uzeo u obzir efekat perspektive, jer trake izgledaju uže u daljinji.

Dodatno, prilikom detekcije susednih traka koje nisu deo trenutne putanje, vrši se analiza skoka širine: nagle promene u širini trake u poređenju sa prethodno validiranim trakama dovode do diskvalifikacije nekonzistentnih detekcija i eliminisanju pogrešnu traku.

- **Uklanjanje atipičnih vrednosti:** kada se detektuju prekidi u nizu tačaka vozne trake (usled zaklanjanja, senki ili propuštenih oznaka), ovi prekidi mogu dovesti do pogrešne detekcije putanje jer se njima zaobilaze prethodne provere kontinuiteta. Da bi se ovo rešilo, sistem koristi tehnike klasterovanja kako bi eliminisao atipične tačke i održala uniformnost detektovanih traka.
- **Čuvanje poslednje vrednosti širine:** u slučaju uspešne detekcije i validacije obe putanje traka (leve i desne), vrednost širine trake se čuva. Ova vrednost se koristi za adaptivno upravljanje u slučaju privremenog gubitka detekcije ili promene uslova na putu, omogućavajući stabilnije ponašanje BGV.

Ovaj pristup omogućava robusnu ekstrakciju tačaka trake čak i u izazovnim scenarijima, kao što su situacije kada su oznake trake delimično nejasne ili neusklađene. Na primer, tokom oštrih krivina, jedna te ista fizička linija trake može se pojaviti i levo i desno u odnosu na centar kamere zbog ograničenog vidnog polja (eng. Field of View, FOV) kamere i promene položaja vozila u odnosu na traku. Metoda osigurava pouzdanu detekciju održavanjem odvojenih skupova tačaka za levu i desnu traku, koji služe kao osnova za naredne korake obrade.

Slike 3.7 ilustruju nekoliko primera pogrešne klasifikacije putanja traka, posebno u krivinama gde leva traka može biti pogrešno klasifikovana kao desna, i obrnuto. Dodatno, u slučajevima gde postoje druge trake u vidnom polju ali nisu detektovane kao željene putanje traka, algoritam ih može pogrešno identifikovati kao takve. Iako ovo predstavlja pogrešnu klasifikaciju sa aspekta globalnog razumevanja saobraćajne situacije, važno je napomenuti da iz perspektive kamere BGV i применjenog algoritma klasifikacije, ova klasifikacija može izgledati ispravna (npr. najbliža linija levo/desno od centra). Ovo naglašava izazove sa kojima se suočava precizna identifikacija granica traka u složenim scenarijima na putu i potrebu za daljim koracima obrade i filtriranja.

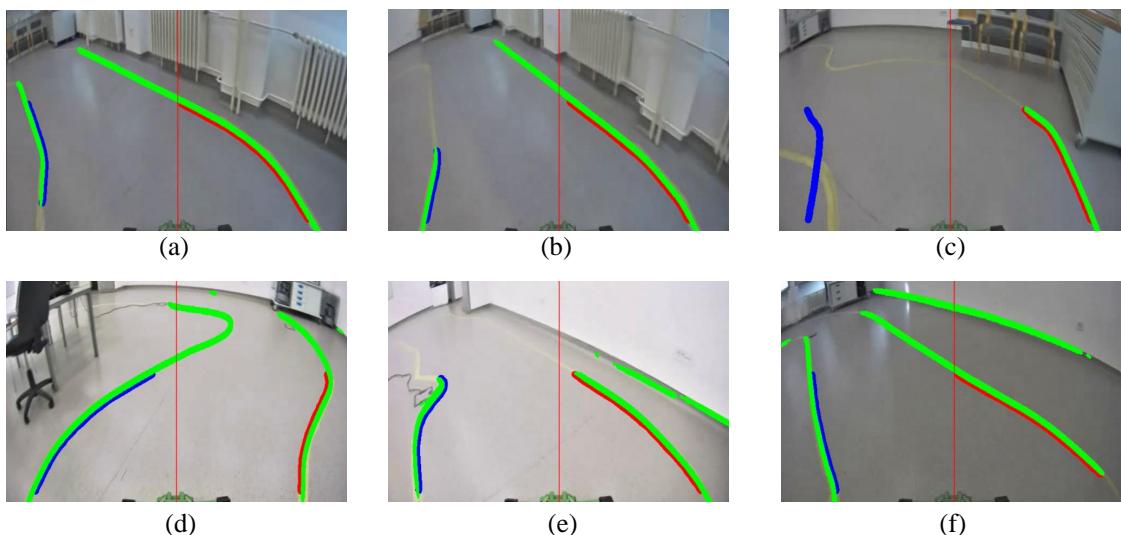
2. Pročišćavanje i upravljanje tačkama trake

Nakon inicijalne ekstrakcije, sistem implementira sveobuhvatno rešenje za upravljanje trakama koje adresira različite scenarije u kojima oznake trake mogu postati privremeno nedostupne ili nejasne. Ovo je ključno za održavanje kontinualnog praćenja putanje. Sistem koristi hijerarhijski pristup donošenju odluka za upravljanje različitim scenarijima vožnje:

- **Potpuna detekcija trake:** kada su obe trake jasno detektovane i validirane, sistem kreira njihove kontinualne reprezentacije povezivanjem susednih ekstrahovanih tačaka linijskim segmentima. Ovim se čuvaju geometrijske karakteristike detektovanih traka.
- **Detekcija jedne trake:** kada je samo jedna traka pouzdano detektovana (bilo leva ili desna), sistem prvo pokušava da koristi prethodne podatke o nedostajućoj traci, ako su dostupni i konzistentni sa trenutnom detekcijom. Korišćenje prethodnih podataka je ograničeno na specifičan broj uzastopnih frejmova (u našem slučaju, 3 frejma). Ako prethodni podaci nisu dostupni ili je prekoračen maksimalni dozvoljeni broj frejmova za njihovo korišćenje, sistem na bazi procene širine trake predviđa poziciju nedostajuće trake:
 - Koristeći poslednju sačuvanu validnu vrednost širine trake (iz prethodnih frejmova gde su obe bile detektovane) i poziciju trenutno detektovane trake, sistem procenjuje poziciju nedostajuće trake paralelnim pomeranjem

(eng. offsetting) od detektovane trake, uz kompenzaciju efekta perspektive.

- Ovako procenjena (inferirana) traka se označava kao "izvedena" kako bi se razlikovala od direktno detektovanih traka.
- **Nema detekcije trake:** u retkim slučajevima kada nijedna traka nije detektovana ili validirana:
 - Sistem prvo pokušava da koristi prethodne podatke o obe trake, sve dok ne premaši maksimalni dozvoljeni prag od 3 frejma.
 - Ako su prethodni podaci nedovoljni ili je maksimalni prag dostignut, sistem vraća prazne reprezentacije traka.
 - Sistem kontinuirano prati da li će se oznake trake ponovo pojaviti kako bi nastavio normalan rad čim to bude moguće.



Slika 3.8: Detekcija putanja traka nakon primene ograničenja i pročišćavanja: leva traka (**plavo**), desna traka (**crveno**), maska modela (**zeleno**). Ovaj prikaz ilustruje rezultat procesa detekcije sa obrađivanjem ograničenja i filtriranjem tačaka, fokusirajući se na tačnu identifikaciju najbližih granica.

Slika 3.8 demonstrira da su pogrešne klasifikacije uočene u prethodnom koraku (pričuvane na slici 3.7) efektivno rešene primenom opisanih ograničenja i mehanizama za upravljanje podacima. Kao rezultat, putanje traka su sada tačnije detektovane i generisane. Ovo poboljšanje ističe efikasnost procesa pročišćavanja ograničenjima, što vodi ka pouzdanijoj reprezentaciji granica trake.

Međutim, važno je napomenuti da u nekim slučajevima (npr. zbog delimičnih detekcija ili inferencije jedne trake), leva i desna generisana traka ne pokrivaju isti vertikalni opseg na slici, što dovodi do pojave praznina ili neusklađenosti u dužini. Rešavanje ovih neusklađenosti je ključno za tačno generisanje virtualnih ciljnih ta-

čaka koje BGV treba da prati, kako bi se osiguralo glatko i stabilno vođenje. Ovaj problem se adresira u modulu za planiranje putanje.

3. Poravnjanje traka

Poravnjanje traka predstavlja održavanje kontinualnog praćenja traka kada one imaju različite vidljive opsege ili su delimično zaklonjene. Ovaj proces osigurava konzistentne granice traka primenom sofisticiranih tehnika procene i interpolacije. Dodatno, pomaže u kreiranju ispravnog i koherentnog ROI za modul detekcije prepreka.

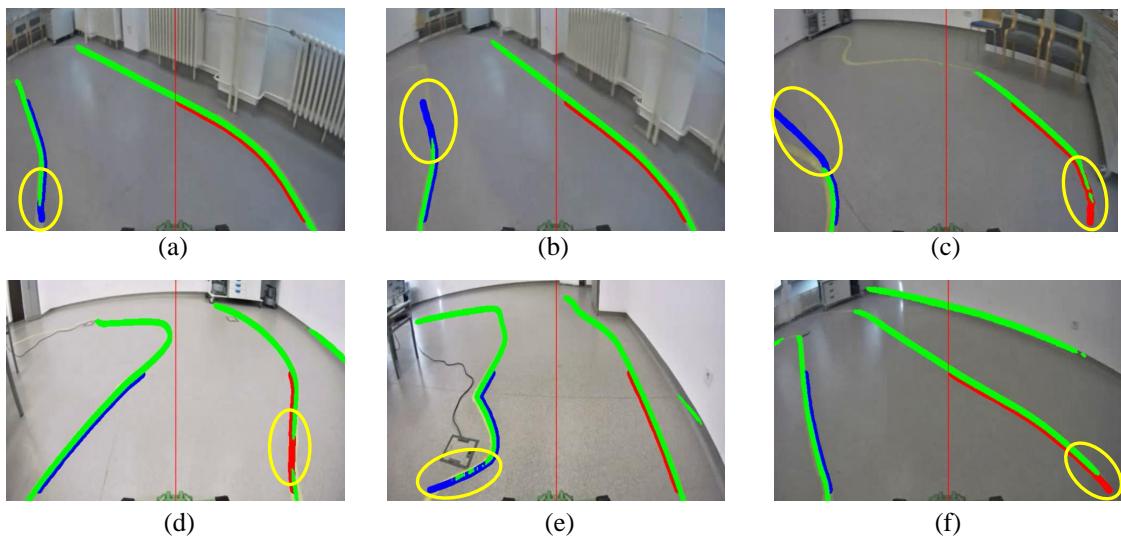
Sistem poravnjanja traka funkcioniše na osnovu dva fundamentalna principa:

- **Unifikacija opsega** osigurava da su obe trake poravnate tako da pokrivaju isti vidljivi vertikalni opseg na slici. Sistem identificuje maksimalni vidljivi opseg koji pokriva bilo koja od dve trake, a zatim proširuje kraću traku tako da odgovara opsegu duže trake. Ovo proširenje se vrši na način da se održi geometrijska konzistentnost sa postojećim detektovanim segmentima trake, osiguravajući glatke i kontinualne reprezentacije traka.
- **Adaptivno modeliranje širine** koristi pristup zasnovan na podacima za procenu nedostajućih delova kraće trake unutar zajedničkog opsega. Prvo se, koristeći delove obe trake koji se preklapaju po vertikalnom opsegu, postavlja model koji opisuje kako se širina trake menja duž tog opsega. Izbor modela – kvadratni (za kompleksnije krivine), linearni (za jednostavnije, pravije segmente) ili model konstantne širine (u slučajevima sa veoma malo preklapajućih tačaka) – zavisi od broja dostupnih tačaka u preklapajućem regionu. Nakon što je model širine odabran, nedostajući deo kraće trake se generiše primenom ovog modela na odgovarajuće tačke duže trake. Ovaj adaptivni pristup efektivno proširuje kraću traku, uzimajući u obzir promene širine usled perspektive ili geometrije puta, i osigurava robusno poravnanje čak i u izazovnim scenarijima sa delimičnim zaklanjanjima ili nejednakom vidljivošću traka.

Slika 3.9 ilustruje rezultate procesa poravnjanja, gde se jasno uočava kako su nedostajući delovi graničnih linija (leva - plava i desna - crvena linija) uspešno interpolirani korišćenjem dostupnih informacija o geometriji puta. Sistem je na osnovu postojećih detekcija i poznatih parametara širine trake rekonstruisao kontinualne linije koje precizno predstavljaju procenjene granice vozne trake, čime je obezbedio pouzdanu putanju za dalju obradu u sistemu vođenja.

3.3.1.4 Modul za detekciju i izbegavanje prepreka

Modul za detekciju i izbegavanje prepreka omogućava vozilu da identificuje i bezbedno zaobiđe prepreke koje se nalaze na njegovoj putanji, što predstavlja značajnu sposobnost



Slika 3.9: Putanja traka nakon poravnjanja: leva (plavo), desna (crveno), originalna maska (zeleno).

za autonomno kretanje BGV u realnim okruženjima.

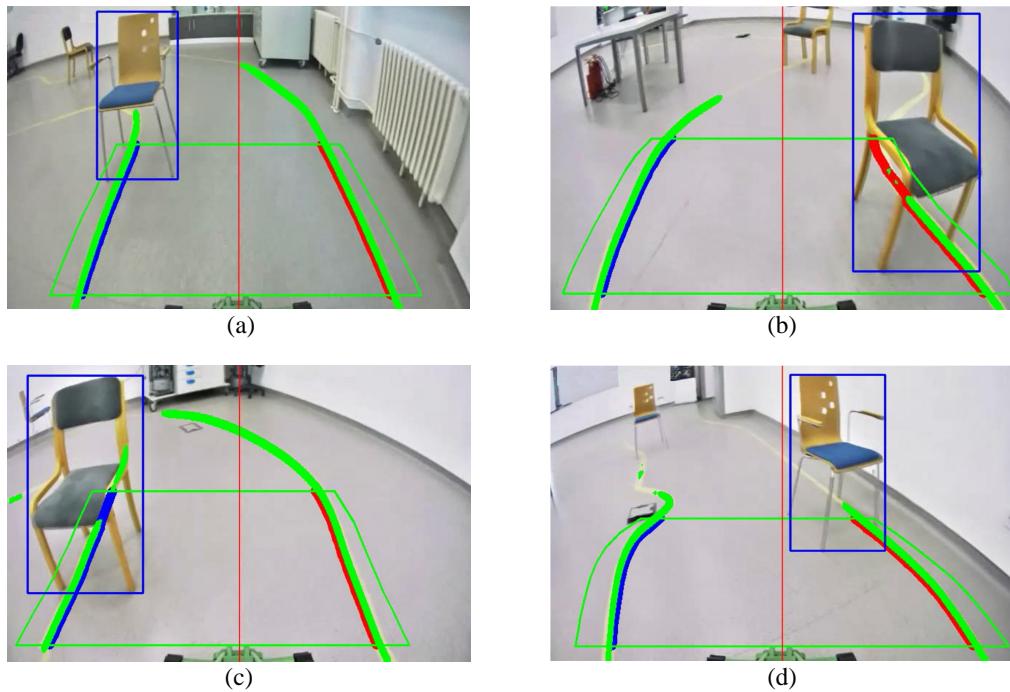
1. Detekcija prepreka

Sistem detektuje prepreke unutar vozne trake koristeći YOLOv8 model, koji predstavlja trenutno najnaprednije rešenje SOTA u oblasti detekcije objekata u realnom vremenu. Proces detekcije obuhvata sledeće korake:

- **Definisanje ROI:** detekcija objekata se ograničava na oblast unutar i neposredno oko prethodno detektovanih i obrađenih putanja traka. Ovo smanjuje verovatnoću lažno pozitivnih detekcija (detekcija objekata van relevantne zone) i redukuje računsko opterećenje.
- **Inferencija modela:** ulazni frejm se prosleđuje kroz YOLOv8 model kako bi se identifikovali objekti i odredile njihove ivice.
- **Filtriranje relevantnosti:** detektovani objekti se filtriraju na osnovu njihove pozicije u odnosu na definisani ROI i njihove klase (npr. pešak, torba, drugo vozilo). Prioritet se daje objektima koji su bliži vozilu i nalaze se direktno na putanji vozila.

Sistem je fokusiran na detekciju relevantnih objekata koji bi mogli zahtevati prilagođavanje putanje. Kao što je navedeno, detekcija je ograničena na ROI definisan granicama trake. Treba istaći da je ključni doprinos projektovanog modula njegova sposobnost detekcije i reagovanja na prepreke bez eksplicitnog izračunavanja njihove udaljenosti od BGV. Umesto toga, sistem koristi poziciju objekta unutar okvira slike (njegove koordinate u pikselima) i relativnu veličinu njegovih ivica da kao relevantne podatke za planiranje putanje, odnosno generisanje zaobilazne putanje.

Ovim se eliminiše potreba za dodatnim senzorima kao što su LiDAR ili stereo kamere u svrhu procene udaljenosti prepreka i time značajno utiče na cenu i složenost senzorskog sistema vozila.



Slika 3.10: Detektovane granične okvire objekata (prepreka) korišćenjem YOLOv8 unutar ROI-a.

Slika 3.10 ilustruje kako se ROI generiše tako da prati oblik detektovanih traka. Na slici je prikazana efikasna detekcija prepreke (u ovom slučaju, stolice) unutar definisanog ROI-a. Takođe je važno istaći da modul za detekciju trake konzistentno radi čak i kada prepreke delimično zaklanjavaju pogled na oznake trake, osiguravajući pouzdano praćenje trake kao osnovu za definisanje ROI-a.

2. Generisanje virtuelnih traka

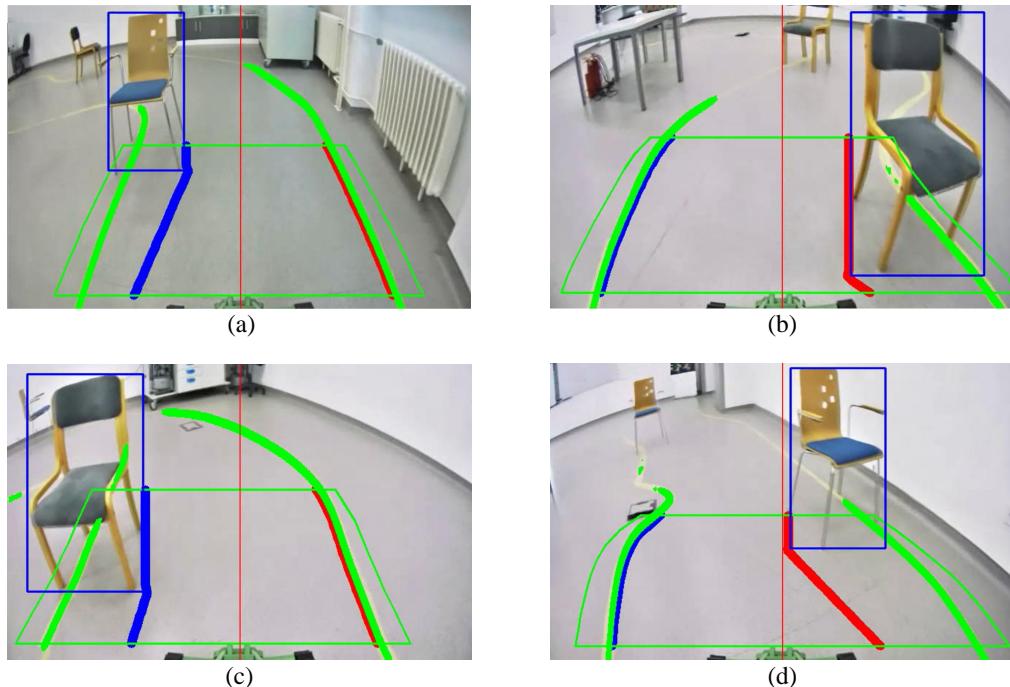
Kada je relevantna prepreka detektovana unutar putanje vozila, sistem dinamički generiše virtuelne trake kako bi realizovao vođenje vozila oko prepreke. Algoritam za generisanje virtuelnih traka obavlja sledeće funkcije:

- **Analiza pozicije prepreke:** određuje poziciju prepreke u odnosu na centar trake i procenjuje raspoloživi prostor sa obe strane prepreke
- **Generisanje alternativne putanje:** kreira virtuelnu traku koja vodi vozilo oko prepreke uz minimalno odstupanje od originalne putanje. Virtuelna traka se projektuje na osnovu raspoloživog prostora između prepreke i granica trake, obezbeđujući glatke prelaze između originalne i virtuelne trake

Ovaj pristup omogućava vozilu da bezbedno zaobiđe prepreke uz održavanje stabilne trajektorije i poštovanje granica definisane vozne trake.

Nakon generisanja virtuelnih traka (slika 3.11), sistem ponovo izračunava referentnu putanju i vrednosti greške korišćene za vođenje vozila. Ova preračunavanja obuhvataju:

- Ažuriranje centra trake u skladu sa generisanim virtuelnom trakom;
- Prilagođavanje vrednosti lateralne greške (e_d) za sistem upravljanja;
- Proveru uslova za povratak u originalnu traku nakon zaobilaska prepreke.



Slika 3.11: Generisanje virtuelnih traka za zaobilaženje detektovane prepreke unutar ROI.

3.3.1.5 Modul za planiranje putanje

Na osnovu obrađenih i poravnatih informacija o traci (bilo originalnih ili virtuelnih), Modul za planiranje putanje definiše putanju koju BGV treba da prati.

1. Generisanje centralne putanje

Sistem izračunava centralnu putanju kao geometrijsko središte između detektovane leve i desne granice trake. U slučaju detekcije prepreke i generisanja virtuelne trake, centralna putanja se u tom segmentu računa između virtuelne trake i suprotne, ne-promenjene originalne trake. Ovako izračunata putanja služi kao referentna putanja za BGV. Proces uključuje sledeće korake:

- **Identifikacija odgovarajućih tačaka:** ovaj korak podrazumeva pronalaženje parova tačaka na levoj i desnoj traci (ili virtuelnoj i suprotnoj traci) koje se nalaze na istom vertikalnom nivou (ista y-koordinata na slici).

- **Izračunavanje srednjih tačaka:** računa se horizontalna srednja tačka (srednja x-koordinata) za svaki identifikovani par odgovarajućih tačaka.
- **Kreiranje kontinualne putanje:** povezivanjem izračunatih srednjih tačaka formira se kontinualna centralna putanja vođenja za BGV.

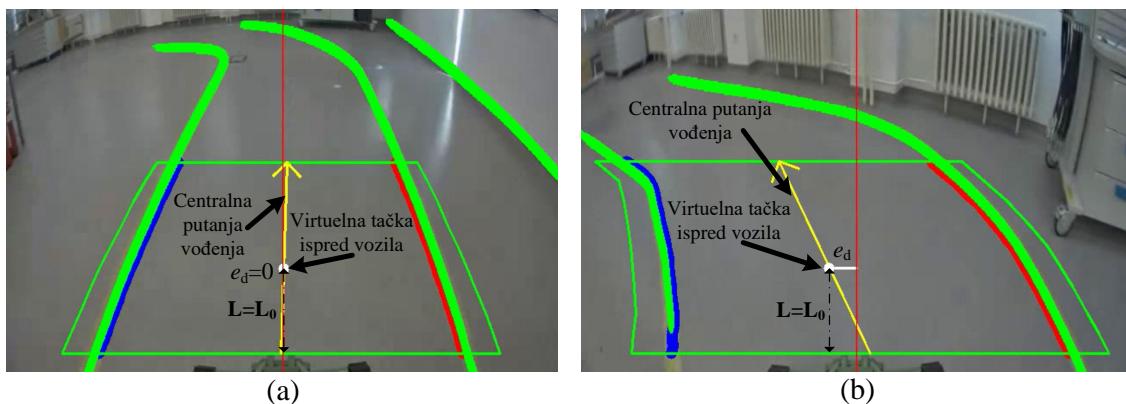
Centralna putanja vođenja predstavlja definisanu putanju koje vozilo treba da prati. Kako bi se obezbedila glatka i stabilna vožnja, sistem generiše pojednostavljenu putanju spajanjem početne i krajnje tačke, formirajući prediktivnu putanju koja eliminiše nagle promene pravca. Ovaj pristup, uz primenu filtara i interpolacije, omogućava prirodno kretanje vozila bez oscilacija, čime se obezbeđuje i stabilnost kretanja, dok se putanja kontinuirano ažurira u skladu sa promenama u okruženju i trenutnim stanjem vozila.

2. Izbor virtualne tačke ispred vozila i računanje greške

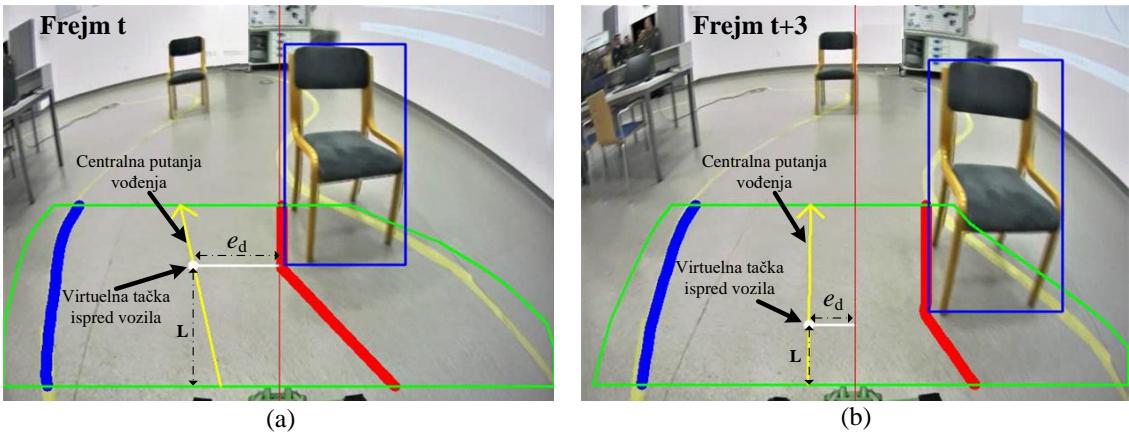
Sistem koristi prediktivni pristup za upravljanje, birajući virtualnu tačku ispred vozila na unapred definisanom rastojanju L od vozila. Ovakav pristup se često koristi u robotici, gde se ulaz za upravljanje zasniva na tački ispred vozila umesto na njegovoj trenutnoj poziciji.

Rastojanje za virtualnu tačku ispred vozila se adaptivno određuje na osnovu:

- **Odsustvo prepreka:** koristi se fiksno rastojanje $L = L_0$ kako bi se obezbedilo stabilno upravljanje, gde je L_0 unapred definisana vrednost.
- **Prisustvo prepreka:** kada su prepreke detektovane, rastojanje L se dinamički prilagođava kako bi se olakšalo obilaženje prepreke. Ovakav način adaptacije zasniva se na trenutnoj poziciji prepreke, obezbeđujući da je L uvek poravnata sa donjom koordinatom najbliže detektovane prepreke.



Slika 3.12: Proračun centralne putanje vođenja i devijacije BGV-a bez prepreka, korišćenjem fiksne virtualne tačke ispred vozila.



Slika 3.13: Proračun centralne putanje vođenja i devijacije BGV-a sa izbegavanjem prepreka korišćenjem adaptivne virtuelne tačke ispred vozila.

Nakon što je virtuelna tačka ispred vozila određena (bilo fiksno ili adaptivno), izračunava se **lateralna greška** $e_d(t)$ kao lateralno odstupanje centra BGV-a od ove tačke (projektovano na Y_v osu vozila, kao na slici 3.4). Ova greška $e_d(t)$ je finalni izlaz Modula za planiranje putanje i ulaz za lateralni ADRC regulator.

Slika 3.12 ilustruje dva različita prikaza sa kamere BGV-a, prikazujući centralnu putanju vođenja (žuto) i fiksnu virtuelnu tačku ispred vozila (beli krug) na specifičnom rastojanju L_0 od vozila u scenariju bez prepreka. Virtuelna tačka ispred vozila služi kao virtuelni cilj za izračunavanje lateralne greške (e_d), koja se koristi za vođenje vozila duž željene putanje.

Slika 3.13 sastoji se od dva frejma snimljena u različitim vremenskim trenucima, demonstrirajući adaptivno ponašanje virtuelne tačke ispred vozila u prisustvu prepreke. Kada je prepreka detektovana i manevr izbegavanja aktivovan, rastojanje gledanja unapred L se dinamički prilagođava (skraćuje) tako da se virtuelna tačka ispred vozila poklopi sa donjom ivicom detektovane prepreke. Ovo adaptivno prilagođavanje osigurava da BGV generiše neophodnu lateralnu grešku (e_d) za precizno i blagovremeno izbegavanje prepreke, istovremeno održavajući glatku i stabilnu putanju unutar granica trake (bilo originalnih ili virtuelnih). Slika naglašava kako sistem reaguje na prisustvo prepreke kroz prilagodljivo rastojanje gledanja unapred L , osiguravajući bezbednu i efikasnu vođenje.

Sistem vođenja zasnovan na vizuelnim senzorima, opisan u ovom pododeljku i baziран isključivo na monokularnoj kameri, čini temelj autonomne vođenja BGV-a u zadatku praćenja zadate vozne trake generisanjem preciznih informacija o željenoj putanji i izračunavanjem lateralnog odstupanja. Ova vrednost odstupanja, odnosno **lateralna greška** $e_d(t)$, izračunata u odnosu na (fiksnu ili adaptivnu) virtuelnu tačku ispred vozila, predstavlja kritični ulazni signal za sloj upravljanja zasnovan na ADRC (detaljno opisan u Odeljku 3.2). Lateralni ADRC regulator (3.40) koristi ovu grešku $e_d(t)$ da generiše odgovarajuće komande za upravljanje (promenu ugla $\dot{\theta}(t)$) koje održavaju vozilo na izračunatoj centralnoj putanji, istovremeno kompenzujući spoljašnje poremećaje i nestacionarnosti

modela.

Dodatno je potrebno napomenuti da predloženo modularno projektovanje sistema vođenja osigurava laku integraciju sa upravljačkim sistemom, kreirajući robusnu arhitekturu.

Pored toga, ovakav pristup projektovanju sistema vođenje postavlja osnovu za proširenje sposobnosti na scenarije praćenja lidera. U paradigmi vođenja za autonomno praćenje lidera, koja će biti predstavljena u narednom pododeljku (3.3.2), BGV mora da detektuje, prati i održava određeno rastojanje u odnosu na lidera. Ova proširena funkcionalnost koristi neke od osnovnih komponenti sistema zasnovanog na primeni vizuelnih senzora, posebno modul za detekciju objekata (YOLOv8), tretirajući lidera kao virtualnu tačku koju treba pratiti.

3.3.2 Projektovanje sistema vođenja za autonomno praćenje lidera

U ovom odeljku detaljno je opisan sistem vođenja projektovan za zadatak autonomnog praćenja lidera. Za razliku od praćenja vozne trake, praćenje lidera zahteva od BGV-a da prati dinamički cilj (lidera) čija trajektorija nije unapred poznata i čija brzina može varirati. Kao što je već napomenuto ovaj zadatak se može smatrati kao praćenje trajektorije, pa stoga, sistem vođenja treba da definiše odgovarajuće referentne vrednosti grešaka ($e_{d(\text{ref})}$, $e_{s(\text{ref})}$) i da izračuna greške (e_d , e_s), koje predstavljaju ulazne podatke longitudinalnog i lateralnog ADRC regulatora. Koordinatni sistem vozila je postavljen na prednjem delu vozila gde je postavljena i senzorski sistem koji se sastoji od kamere i LIDAR senzora (slika 3.14).

U kontekstu autonomnog praćenja lidera zadatak lateralnog upravljanja je da se BGV kreće iza lidera, odnosno da referentno lateralno odstupanje bude nula:

$$e_{d(\text{ref})}(t) = 0. \quad (3.42)$$

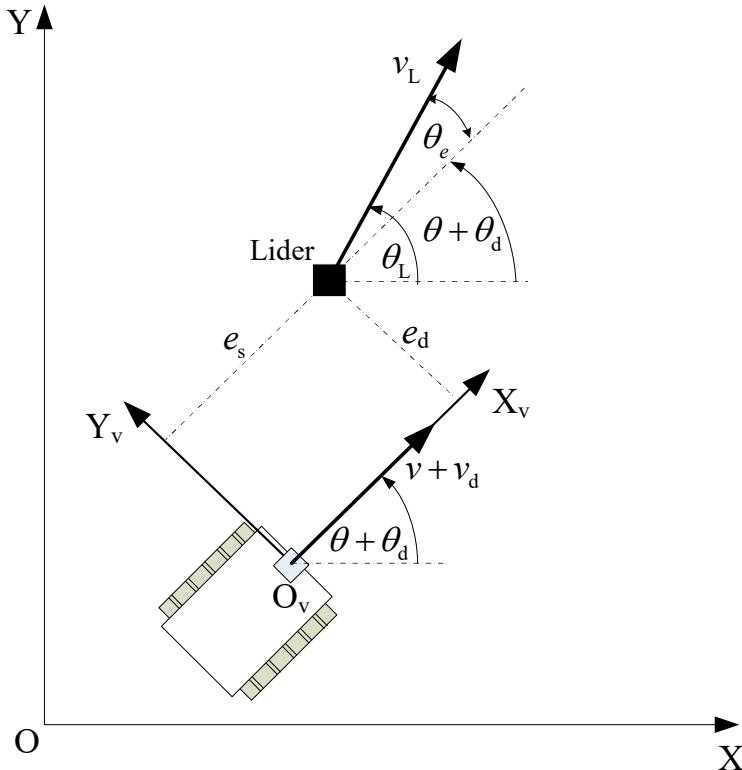
Imajući u vidu da je $e_{d(\text{ref})} = 0$, opšti lateralni ADRC upravljački zakon (3.21) se tada pojednostavljuje na:

$$u_l(t) = \dot{\theta}(t) = \frac{1}{b_{0_l}} (-k_{p_l}\hat{x}_{1_l}(t) - k_{d_l}\hat{x}_{2_l}(t) - \hat{x}_{3_l}(t)). \quad (3.43)$$

Nominalno pojačanje se postavlja na $b_{0_l} = -\bar{v}_L$, gde je \bar{v}_L očekivana brzina lidera. Sistem vođenja treba da kontinualno izračunava stvarnu lateralnu grešku $e_d(t)$ u odnosu na detektovanu poziciju lidera.

Zadatak longitudinalnog upravljanja je održavanje unapred definisanog bezbednog rastojanja L_{follow} iza lidera. Stoga, referentno longitudinalno odstupanje se definiše kao željena konstanta:

$$e_{s(\text{ref})}(t) = L_{follow}. \quad (3.44)$$



Slika 3.14: Pregled vođenja BGV-a za praćenje lidera (sa prilagođenim oznakama).

Shodno tome, opšti longitudinalni ADRC upravljački zakon (3.31) se pojednostavljuje i ima oblik:

$$u_v(t) = v(t) = \frac{1}{b_{0_v}} [k_{p_v} \cdot (L_{\text{follow}} - \hat{x}_{1v}(t)) - \hat{x}_{2v}(t)], \quad (3.45)$$

gde je $b_{0_v} = -1$. Sistem vođenja treba da obezbedi merenje $e_s(t)$.

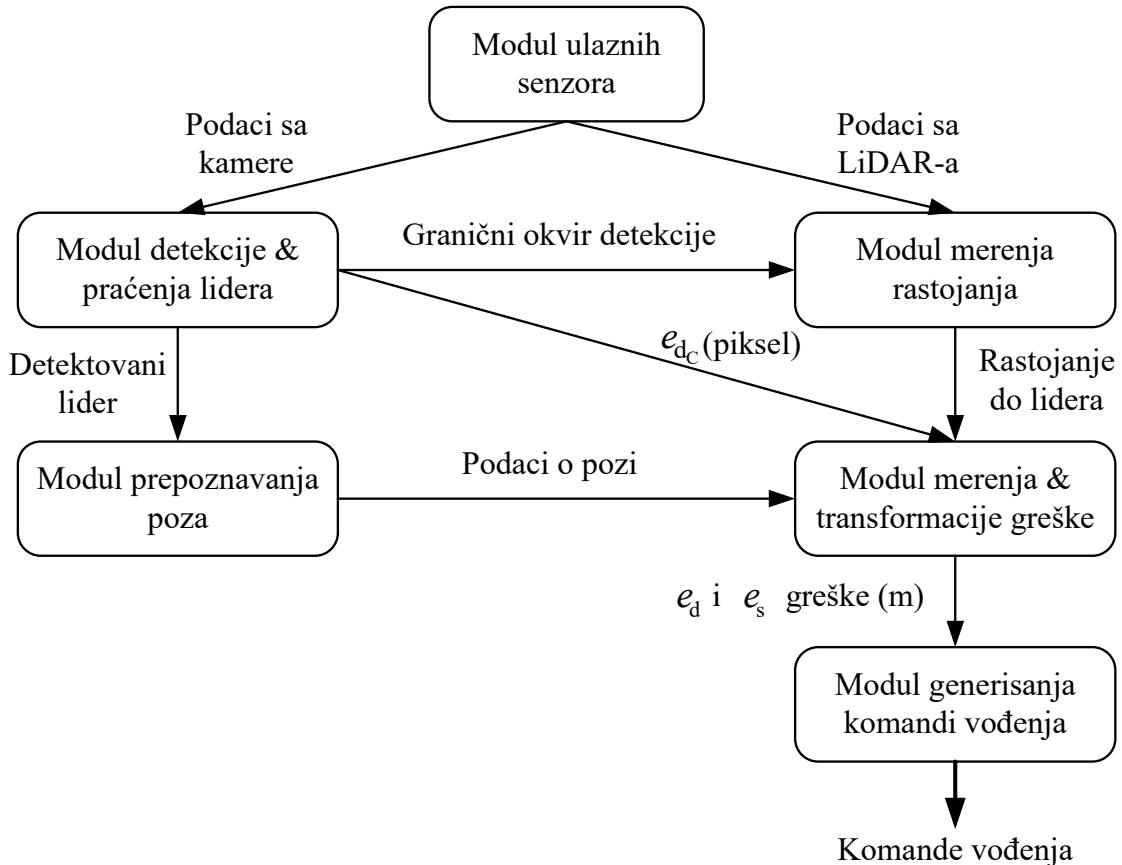
Da bi ADRC regulatori, koristeći ove specifične upravljačke zakone ((3.43) i (3.45)), mogli da ostvare postavljene zadatke, sistem vođenja mora da obezbedi tačna merenja (ili procene) stvarnih grešaka $e_d(t)$ i $e_s(t)$.

Pored izračunavanja grešaka $e_d(t)$ i $e_s(t)$, sistem vođenja za praćenje lidera u ovoj disertaciji uključuje i modul za prepoznavanje poza lidera, omogućavajući BGV-u da reaguje na specifične vizuelne komande (npr. stani, kreni napred/nazad).

Zbog dinamičke prirode lidera i potrebe za preciznim merenjem rastojanja (e_s), ovaj sistem vođenja koristi *hibridni senzorski pristup*, integrišući podatke sa monokularne kamere i LiDAR senzora. Kamera se koristi za detekciju, praćenje i interpretaciju poza lidera, dok LiDAR omogućuje merenje rastojanja od lidera.

Predložena struktura sistem vođenja za praćenje lidera prikazana je na slici 3.15 i kao što se može videti sastoji se od sledećih modula:

1. **Modul ulaznih senzora:** vrši akviziciju i sinhronizaciju podataka sa monokularne kamere i LiDAR senzora.
2. **Modul za detekciju i praćenje lidera:** koristi YOLOv8 algoritam za detekciju i



Slika 3.15: Blok dijagram predloženog sistema vođenja za praćenje lidera.

praćenje ljudskog lidera na osnovu izlaza kamere.

3. **Modul za prepoznavanje poze lidera:** koristi MPP algoritam u obradi slike u cilju estimacije ključnih tačaka tela lidera i klasifikacije predefinisanih poza lidera (stajanje, čučanj, čučanj sa podignutom rukom) koje služe kao komande BGV-u.
4. **Modul za merenje rastojanja između BGV i lidera:** obrađuje podatke sa LiDAR senzora kako bi se odredilo rastojanje $d_{VL}(t)$ do detektovanog lidera.
5. **Modul za merenje i transformaciju greške:** na osnovu pozicije lidera na slici i izmerenog rastojanja $d_{VL}(t)$ izračunava lateralnu grešku $e_d(t)$ i longitudinalnu grešku $e_s(t)$.
6. **Modul za generisanje komandi vođenja:** prima generisane vrednosti grešaka $e_d(t)$ i $e_s(t)$ i informacije o prepoznatoj poziciji i na osnovu ovih ulaza generiše signale za upravljački sistem.

Ovi moduli zajedno omogućavaju BGV-u da autonomno prati lidera, prilagodavajući se njegovom kretanju, održavajući bezbedno rastojanje i reagujući na komande zadate gestovima, čime se postiže robusno i adaptivno ponašanje u zadatku praćenja lidera. Naredna poglavља detaljnije opisuju ključne algoritme unutar ovih modula.

3.3.2.1 Modul ulaznih senzora

Ovaj modul čini senzorsku osnovu sistema za autonomno praćenje lidera. On integriše podatke sa dva različita senzora:

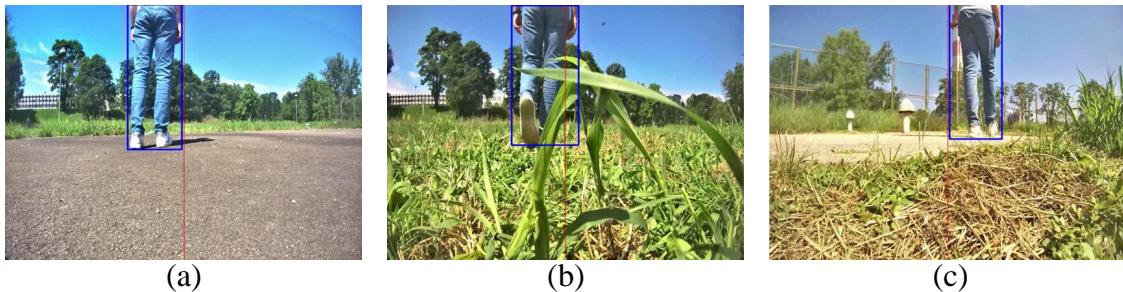
- **Monokularna kamera:** vrši akviziciju vizuelnih informacija. Ova kamera je ključna za detekciju lidera, njegovo praćenje i prepoznavanje poza. Kamera je montirana na prednjem delu BGV-a na visini od 0.1 m, što je bila inicijalna pozicija na testiranom BGV-u. Korišćena kamera ima sledeće specifikacije: rezolucija 640×480 piksela, radna frekvencija 5 frejmova u sekundi (originalno 30 fps, smanjeno radi sinhronizacije sa radnom frekvencijom BGV-a od 5 Hz), žižna daljina $f_c = 2.8$ mm, i dimenzija piksela $P = 19 \mu\text{m}$.
- **LiDAR senzor:** omogućuje direktna merenja rastojanja do lidera. Akvizicija podataka sa LiDAR-a uslovljena je frekvencijom frejmova kamere, koja takođe iznosi 5 fps. Ova sinhronizacija osigurava da se LiDAR informacije prikupljaju u željenim trenucima, održavajući koherentnost između ova dva sistema.

3.3.2.2 Modul za detekciju i praćenje lidera

Detekcija lidera je početni korak u sistemu praćenja lidera i realizovana je pomoću YOLOv8 algoritma, koji je sposoban da detektuje objekte u realnom vremenu uz njihovo konzistentno praćenje.

Slično kao kod detekcije prepreka kod praćenja zadate vozne trake, YOLOv8 se koristi i za prepoznavanje ljudi, pri čemu je posebno podešen da identificuje *person* klasu. Visoka tačnost i brzina obrade YOLOv8 algoritma omogućavaju pouzdano detektovanje ljudi u vidnom polju kamere u realnom vremenu. Nakon toga, YOLOv8 generiše granične okvire oko detektovanog lidera. Ovi granični okviri obuhvataju lokaciju lidera unutar frejma slike. Praćenje lidera u ovoj implementaciji postiže se pomoću izvornih funkcionalnosti za praćenje integrisanih unutar samog YOLOv8 okvira. Naime, YOLOv8, kada je konfigurisan za praćenje objekata u videu, inherentno održava identitete objekata kroz uzastopne frejmove, omogućavajući robusno praćenje bez potrebe za dodatnim algoritmom za praćenje. U svakom novom frejmu, detektovane osobe se porede sa liderom iz prethodnog frejma, koristeći metrike kao što su blizina (blizina centara graničnih okvira) i presek nad unijom (eng. Intersection over Union, IoU), kako bi se potvrdilo da li nova detekcija odgovara praćenom lideru. Sistem takođe održava ID za lidera, obezbeđujući konzistentno prepoznavanje čak i kod malih promena u poziciji graničnog okvira.

Slika 3.16 ilustruje tipičan scenario gde YOLOv8 uspešno detektuje ljudskog lidera, čak i u izazovnim uslovima. Posebno, u specifičnom slučaju prikazanom na slici 3.16.b, kamera je delimično zaklonjena travom, ali YOLOv8 i dalje efikasno identificuje lidera. Granični okvir jasno ocrtava osobu, pružajući sistemu početne informacije o lokaciji



Slika 3.16: Detekcija lidera pomoću YOLOv8. Granični okvir plave boje označava detektovanog ljudskog lidera.

potrebne za praćenje. Iako YOLOv8 može detektovati više osoba, u kontekstu praćenja lidera, obično prepostavljamo jednog lidera. Kada se detektuje više osoba, sistem određuje osobu najbližu centru frejma slike kao lidera.

Ovaj pristup je opravдан našim primarnim fokusom na upravljanje BGV-om na izazovnom, neravnom terenu. Odabijom lidera na osnovu centralnog pozicioniranja, zadatak nam je da pojednostavimo proces donošenja odluka, omogućavajući upravljačkom sistemu da efikasnije radi u promenljivim uslovima. Ova metoda obezbeđuje pravovremene i relevantne informacije za podešavanja upravljanja, što je ključno za održavanje stabilnosti i odziva u složenim okruženjima.

Dalje unapređenje strategija odabira lidera, potencijalno uključujući faktore kao što su veličina, položaj tela ili određene procedure inicijalizacije, što predstavlja pravac za buduća istraživanja.

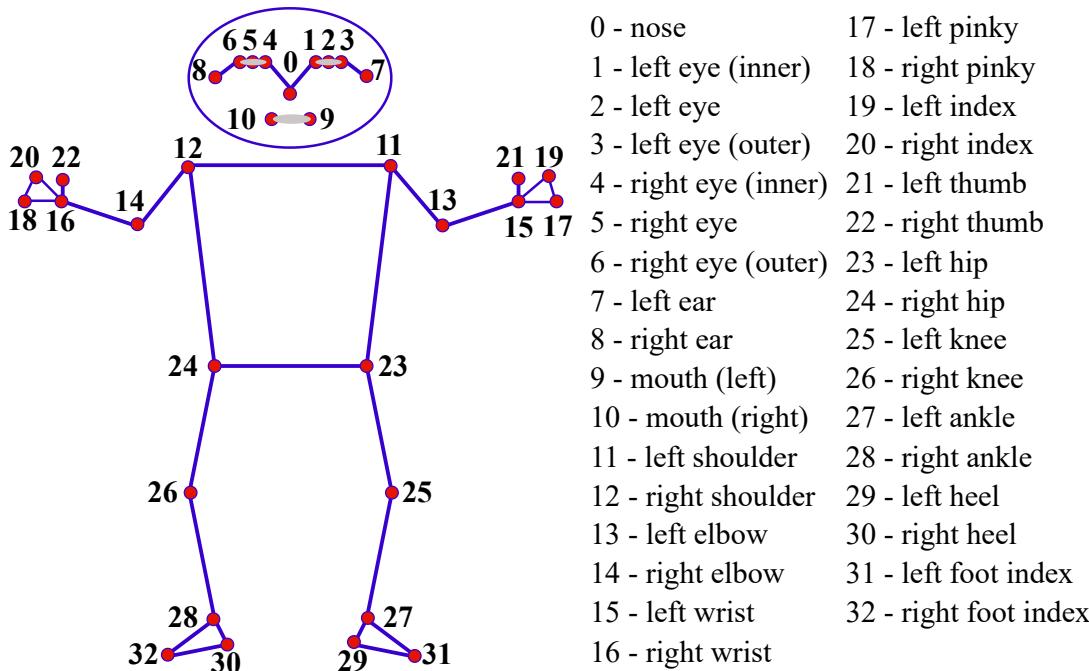
3.3.2.3 Modul za prepoznavanje poze lidera

Modul za prepoznavanje poze lidera koristi algoritam MPP za estimaciju ljudske poze u realnom vremenu. MPP detektuje i prati ključne tačke na ljudskom telu, omogućavajući robusno i efikasno prepoznavanje poze. Ovaj modul je ključan za interpretaciju gestova lidera i njihovo prevođenje u izvršne komande za BGV. Ključne faze u radu ovog modula objašnjene su u nastavku.

Ekstrakcija ključnih tačaka:

U prvoj fazi procesa prepoznavanja poze lidera MPP algoritam ekstrahuje 33 ključne tačke sa ljudskog tela, kao što je ilustrovano na slici 3.17. Za zadatok praćenja lidera, koristi se podskup od 20 ključnih tačaka, koje odgovaraju gornjem delu tela, rukama, kolenima i člancima i koje su najrelevantnije za prepoznavanje definisanih poza i gestova lidera. Odabrane ključne tačke uključuju:

- Ramena (11, 12): pružaju referencu za orientaciju gornjeg dela tela.
- Laktovi (13, 14, 15, 16): ukazuju na pokrete ruku i gestove.
- Ručni zglobovi (17, 18, 19, 20): detektuju gestove podizanja ruku.



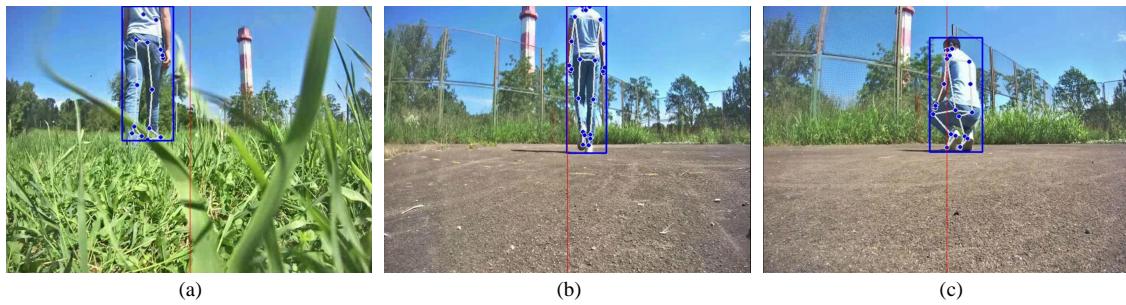
Slika 3.17: Definicija ključnih tačaka u algoritmu MPP [1].

- Mali prst i kažiprst (21, 22): pružaju dodatnu preciznost za prepoznavanje gestova rukama.
- Kukovi (23, 24): pomažu u razlikovanju stojeće i čučeće poze.
- Kolena (25, 26): pomažu u identifikaciji čučećih poza.
- Članci (27, 28): pružaju dodatni kontekst za držanje donjeg dela tela.
- Pete(29, 30): dopunjuju ključne tačke članaka za tačnu detekciju poze donjeg dela tela.

Ovaj podskup ključnih tačaka je odabran jer obuhvata suštinska obeležja potrebna za klasifikaciju poza lidera. Fokusiranjem na ove ključne tačke, sistem može efikasno prepoznati četiri unapred definisane poze: stojeću, čučeću, čučeću sa podignutom desnom rukom i čučeću sa podignutom levom rukom.

Da bi se dodatno optimizovala brzina rada MPP algoritma obrada se vrši samo na regiju slike koji sadrži detektovanog lidera. Ovaj pristup smanjuje vreme obrade i osigurava rad u realnom vremenu, što je ključno za efikasno praćenja lidera.

Kao što je ilustrovano na slici 3.18, kada je lider detektovan, sistem ekstrahuje ključne tačke tela. Značajan izazov proizilazi iz postavke kamere, koja je pozicionirana nisko na vozilu, pa iz tog razloga često je samo donji deo tela lidera vidljiv. Uprkos ovom ograni-



Slika 3.18: Ekstrakcija ključnih tačaka lidera: a) u uslovima delimično zaklonjenog lidera, b) u uslovima kada lider nije zaklonjen, c) u uslovima čućeće poze lidera.

čenju, model pokazuje konzistentne performanse pouzdano detektujući ključne tačke tela vidljivih delova lidera čak i u uslovima delimične zaklonjenosti.

Detekcija odgovarajuće poze:

Nakon ekstrakcije ključnih tačaka, MPP algoritam vrši klasifikaciju poze na osnovu prostornih odnosa između ključnih tačaka za prepoznavanje definisanih poza. Ova metodologija klasifikacije čini osnovu interakcionog sistema praćenja lidera, omogućavajući BGV-u da interpretira i odgovori na komande lidera izražene kroz držanje tela i gestove. Naime, sistem identificuje četiri različite poze čije su karakteristike date u nastavku.

1. Detekcija stojeće poze:

Stojeća poza se prepoznaje analizom prostornih odnosa između ključnih tačaka kuka, kolena i članka. Kada osoba stoji, rastojanje između ključnih tačaka kuka i kolena pokazuje karakteristično vertikalno razdvajanje, dok rastojanje između ključnih tačaka kuka i članka prati tipične proporcije stojećeg držanja. Sistem proverava da li su ključne tačke i desne i leve strane vidljive i u odgovarajućim pozicijama.

2. Detekcija čućeće poze:

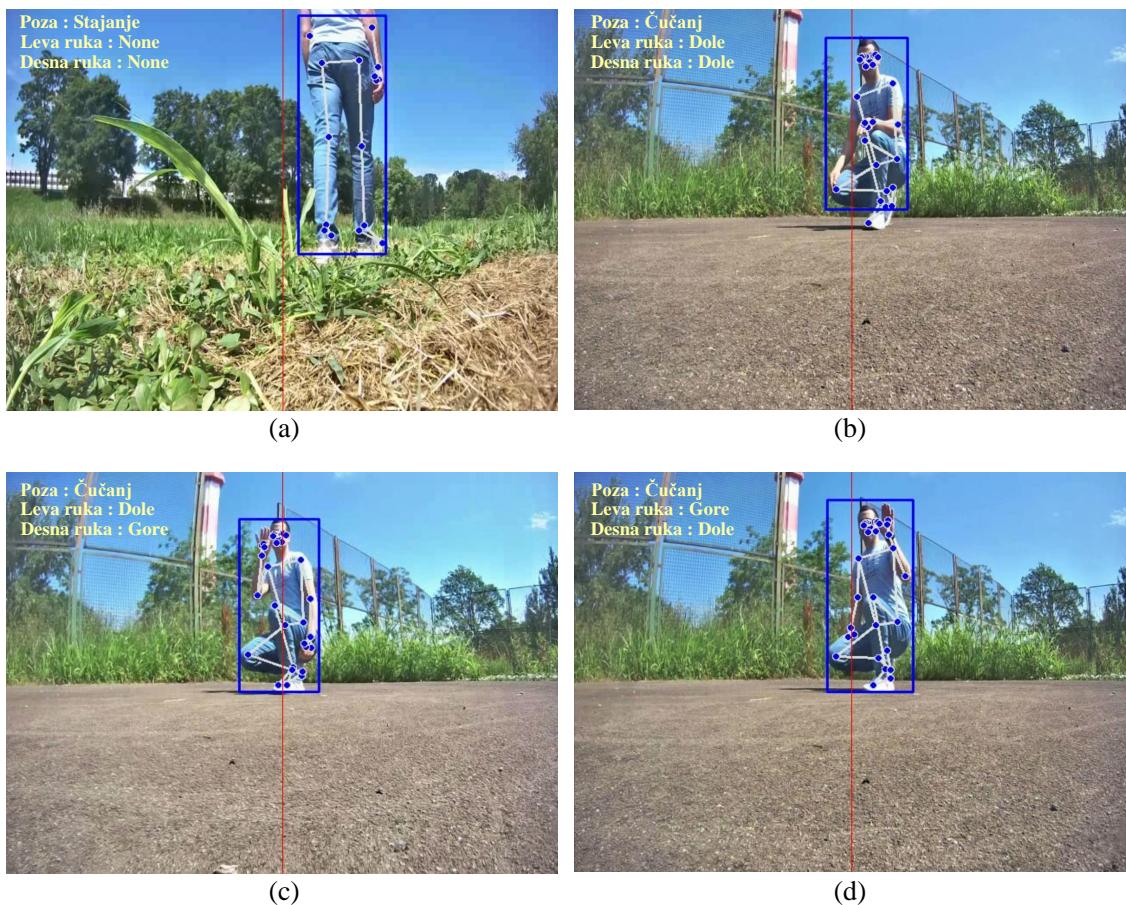
Čućeća poza se identificuje pomoću više kriterijuma kako bi se osigurala robusna detekcija uprkos potencijalnim zaklonima. Prvo, sistem ispituje odnos kuk-koleno: kada osoba čuči, vertikalno rastojanje između ključnih tačaka kuka i kolena značajno se smanjuje. Sistem detektuje ovu pozu kada rastojanje padne ispod empirijski određenog praga (približno 12% visine osobe). Kao dopunsku meru, sistem analizira odnos kuk-članak/peta, koji se takođe značajno smanjuje tokom čučanja. Dodatno, u nekim čućećim pozicijama, ruke mogu doći blizu ili ispod nivoa kolena. Sistem ovo detektuje proveravajući da li se ključne tačke ručnih zglobova pojavljuju blizu ključnih tačaka kolena, pružajući dalju potvrdu čućeće poze.

3. Detekcija podignute ruke (leva i desna):

Sistem razlikuje podignite i spuštene ruke analizirajući pozicije ključnih tačaka laka, ramena i šake. Ruka se smatra podignutom kada su njene ključne tačke

(ručni zglob, mali prst, kažiprst ili palac) pozicionirane iznad ključne tačke lakta u vertikalnom pravcu. Ovo ukazuje na pokret ruke nagore. Kao sekundarnu potvrdu, sistem proverava da li su ključne tačke šake takođe pozicionirane iznad ključne tačke ramena, osiguravajući konzistentnost u detekciji. Važno je napomenuti da se ova detekcija podignute ruke obrađuje samo kada je lider u čučećoj poziciji, jer se gestovi rukama ne koriste za komunikaciju u stoećoj poziciji. Da bi osigurao pouzdanost, sistem proverava vidljivost relevantnih ključnih tačaka pre donošenja klasifikacije, uzimajući u obzir potencijalna zaklanjanja.

Kao što je prethodno napomenuto svaka poza se identificiše koristeći više odnosa delova tela, umesto oslanjanja na jedno merenje. Ova redundantnost osigurava pouzdanu klasifikaciju čak i kada neke ključne tačke mogu biti delimično zaklonjene ili nesavršeno detektovane. Dodatno, umesto korišćenja apsolutnih udaljenosti, sistem procenjuje relativne proporcije između ključnih tačaka. Na ovaj način klasifikacija je pouzdana za različite osobe, bez obzira na njihovu visinu ili proporcije i nije osetljiva na različite udaljenosti između kamere i lidera.



Slika 3.19: Prepoznavanje poze u sistemu praćenja lidera, omogućavajući intuitivnu komunikaciju i upravljanje BGV-om: (a) stoeća poza, (b) čučeća poza, (c) čučeća poza sa podignutom desnom rukom, i (d) čučeća poza sa podignutom levom rukom.

Slika 3.19 ističe sposobnost sistema da prepozna i klasificiše poze lidera u realnom

vremenu. Četiri ključne poze uključuju: (a) stojeću pozu, (b) čučeću pozu, (c) čučeću pozu sa podignutom desnom rukom, i (d) čučeću pozu sa podignutom levom rukom. Važno je napomenuti da kada je lider u stojećoj poziciji, sistem vraća samo informaciju o poziciji tela (stoji ili čuči) i ne nastavlja sa proverom ruke, jer su gestovi rukama relevantni samo u čučećoj poziciji za naš specifičan scenario. Ove poze su ključne za interpretaciju gestova lidera i njihovo prevođenje u izvršne komande za BGV, osiguravajući intuitivnu i pouzdanu komunikaciju u dinamičkim okruženjima.

3.3.2.4 Modul za merenje rastojanja između BGV i lidera

Ovaj modul obezbeđuje merenje rastojanja između BGV-a i lidera, označeno kao d_{VL} , što je kritičan ulaz za izračunavanje longitudinalne greške (e_s) i održavanje željenog rastojanja praćenja (videti Slike 3.20 i 3.21). Ovo rastojanje se meri direktno pomoću LiDAR senzora, koji generiše 3D oblak tačaka okruženja. Ovaj oblak tačaka se zatim mapira na 2D frejmu monokularne kamere, omogućavajući sistemu da poveže detektovanog lidera u 2D frejmu kamere sa odgovarajućom 3D tačkom u LiDAR oblaku tačaka [179]. Ovo povezivanje omogućava tačno izračunavanje rastojanja do detektovanog lidera, d_{VL} , u realnom vremenu.

Sposobnost LiDAR-a da pruži precizne 3D prostorne podatke, u kombinaciji sa bogatim vizuelnim informacijama kamere, stvara robustan sistem percepције. Ova fuzija podataka sa LiDAR-a i kamere osigurava tačno merenje rastojanja i poboljšava ukupnu pouzdanost sistema praćenja lidera.

3.3.2.5 Modul za merenje i transformaciju greške

Ovaj modul izračunava i transformiše lateralnu i longitudinalnu grešku potrebnu za upravljački sistem, osiguravajući precizno kretanje BGV-a u odnosu na lidera. Lateralna greška e_d izvodi se iz pozicije lidera u frejmu kamere i transformiše u grešku u metrima. Longitudinalna greška e_s izračunava se pomoću rastojanja d_{VL} izmerenog LiDAR senzorom i prethodno proračunate lateralne greške e_d .

Važno je napomenuti da modul radi u diskretnim vremenskim trenucima. To znači da se kontinualni signali, kao što su video izlaz kamere i merenja rastojanja sa LiDAR-a periodično odabiraju sa periodom T_s . Stoga, vreme u kojem se uzima k -ti uzorak definisano je sa kT_s , gde je k ceo broj koji predstavlja indeks odbiraka. Detaljan opis faza rada ovog modula dat je u nastavku.

- **Proračun centra graničnog okvira lidera:** za svaki frejm video signala kamere u diskretnom vremenskom trenutku kT_s , dobija se granični okvir detektovanog i praćenog lidera, koji je definisan sa $D_L(kT_s)$. Horizontalna koordinata centra $D_L(kT_s)$ izračunava se kao $C_{D_L}(kT_s)$, što je središnja tačka horizontalnih koordinata graničnog okvira.

- **Proračun lateralne greške u pikselima:** kao što je ilustrovano na slici 3.21, lateralna greška u pikselima, $e_{d_c}(kT_s)$, izračunava se kao razlika između horizontalne koordinate u pikselima centra graničnog okvira lidera, $C_{D_L}(kT_s)$, i horizontalne koordinate u pikselima koja predstavlja centar vidnog polja (VP) kamere.
- **Transformacija lateralne greške u metre:** lateralna greška u pikselima, $e_{d_c}(kT_s)$, konvertuje se u grešku u metrima, $e_d(kT_s)$, koristeći fokusnu daljinu kamere (f_c), veličinu piksela (P), i željeno longitudinalno rastojanje ($e_{s(\text{ref})}$). Ova transformacija se zasniva na principu sličnosti trouglova (videti Slike 3.20 i 3.21), i matematički je opisana sa:

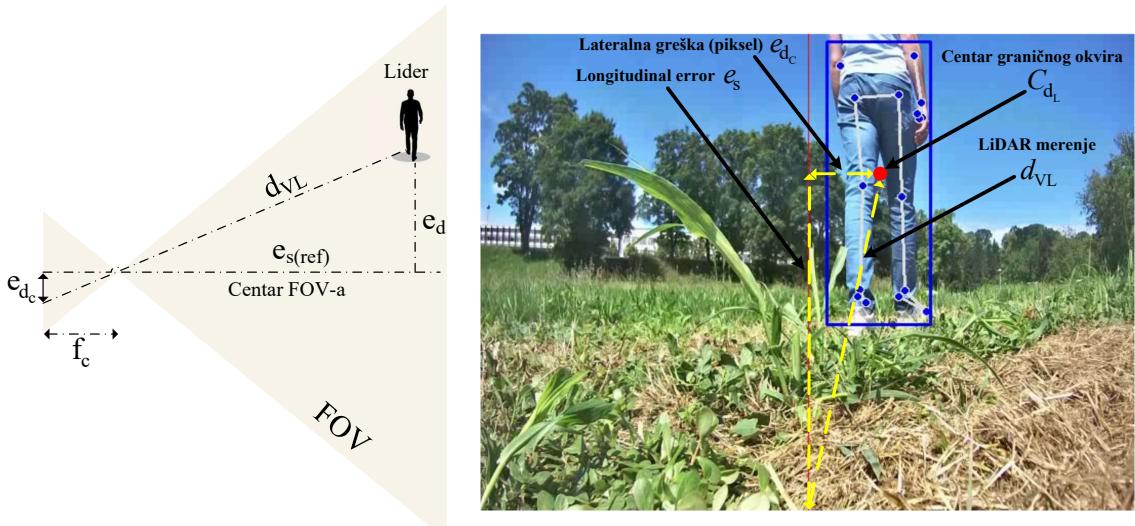
$$\frac{e_d(kT_s)}{e_{s(\text{ref})}} = \frac{e_{d_c}(kT_s) \cdot P}{f_c}, \quad (3.46)$$

odakle sledi:

$$e_d(kT_s) = \frac{e_{s(\text{ref})} \cdot e_{d_c}(kT_s)}{f_c} \cdot P. \quad (3.47)$$

- **Izračunavanje longitudinalne greške:** longitudinalna greška praćenja lidera, $e_s(kT_s)$, izračunava se koristeći prethodno određenu lateralnu grešku $e_d(kT_s)$ i izmereno rastojanje između lidera i BGV-a $d_{VL}(kT_s)$ (videti Slike 3.20 i 3.21), odnosno:

$$e_s(kT_s) = \sqrt{d_{VL}^2(kT_s) - e_d^2(kT_s)}, \quad (3.48)$$

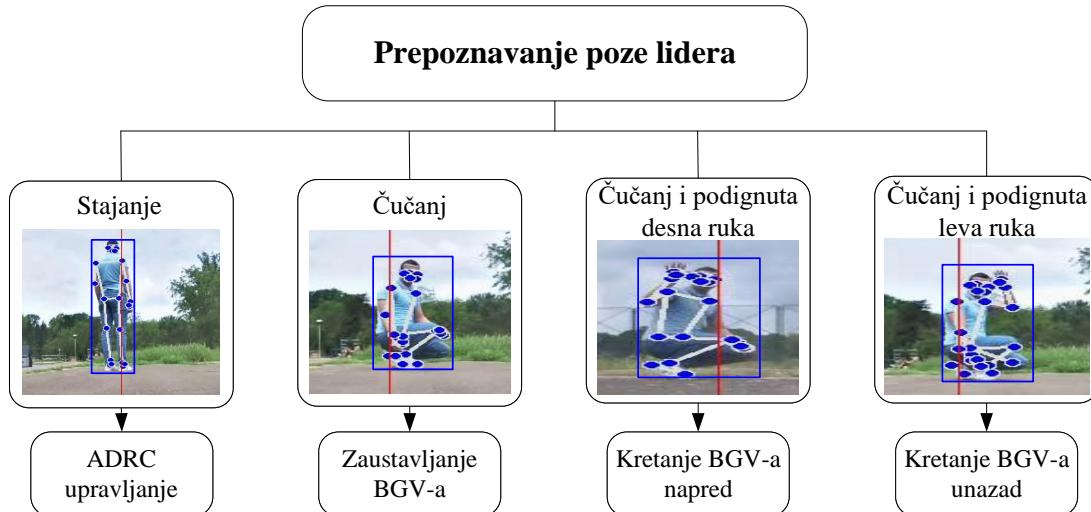


Slika 3.20: Geometrija za izračunavanje lateralne greške.

Slika 3.21: Frejm sa kamere BGV-a koji demonstrira lateralnu i longitudinalnu grešku.

3.3.2.6 Modul za generisanje komandi vođenja

Ovaj modul predstavlja finalni korak u sistemu vođenja za autonomno praćenje lidera. Njegova osnovna uloga je da integriše informacije dobijene iz prethodnih modula i na osnovu njih generiše odgovarajuće referentne signale za upravljački sistem.



Slika 3.22: Grafički prikaz algoritma za generisanje komandi vođenja na osnovu detektovane poze lidera i izračunatih grešaka praćenja.

Logika rada modula, ilustrovana na slici 3.22, može se opisati na sledeći način:

- **Standardno praćenje (uspravna poza lidera):** ukoliko je prepoznata poza lidera uspravna (što signalizira normalan mod praćenja), modul kao izlazne signale prosleđuje izračunate vrednosti lateralne greške $e_d(t)$ i longitudinalne greške $e_s(t)$. Ove vrednosti predstavljaju ulaze za lateralni i longitudinalni kanal upravljačkog sistema. Sistem upravljanja će na osnovu ovih signala težiti da minimizuje odstupanja i održi željeno kretanje u odnosu na lidera.
- **Rad sistema u zavisnosti od detektovane poze lidera:**
 - **Čučeća poza (komanda STANI):** kada je lider u čučećoj poziciji, on generiše signal koji rezultira zaustavljanjem BGV-a. U ovom slučaju, željena longitudinalna brzina $v(t)$ i željena ugaona brzina $\dot{\theta}(t)$ postavljaju se na nulu.
 - **Čučeća poza sa podignutom desnom rukom (komanda NAPRED):** ako lider zauzme čučeću poziciju sa podignutom desnom rukom, modul generiše signale koji iniciraju kretanje BGV-a napred konstantnom, unapred definisanim malom brzinom (npr. v_{cmd}), dok se željena ugaona brzina održava na nuli ($\dot{\theta}(t) = 0$). Ovo omogućava BGV-u da se približi lideru.
 - **Čučeća poza sa podignutom levom rukom (komanda NAZAD):** ukoliko lider zauzme čučeću poziciju sa podignutom levom rukom, modul generiše signale

za kretanje BGV-a unazad konstantnom, unapred definisanom malom brzinom (npr. $-v_{cmd}$), uz održavanje željene ugaone brzine na nuli ($\dot{\theta}(t) = 0$). Ovo omogućava BGV-u da se udalji od lidera.

Na ovaj način, modul za generisanje komandi vođenja efikasno prevodi percipirane informacije o lideru i njegovim gestovima u specifične reference i komande ponašanja koje upravljački sistem treba da realizuje, omogućavajući time intuitivnu i adaptivnu interakciju između BGV-a i ljudskog lidera.

3.4 Eksperimentalna validacija projektovanih sistema autonomnog kretanja

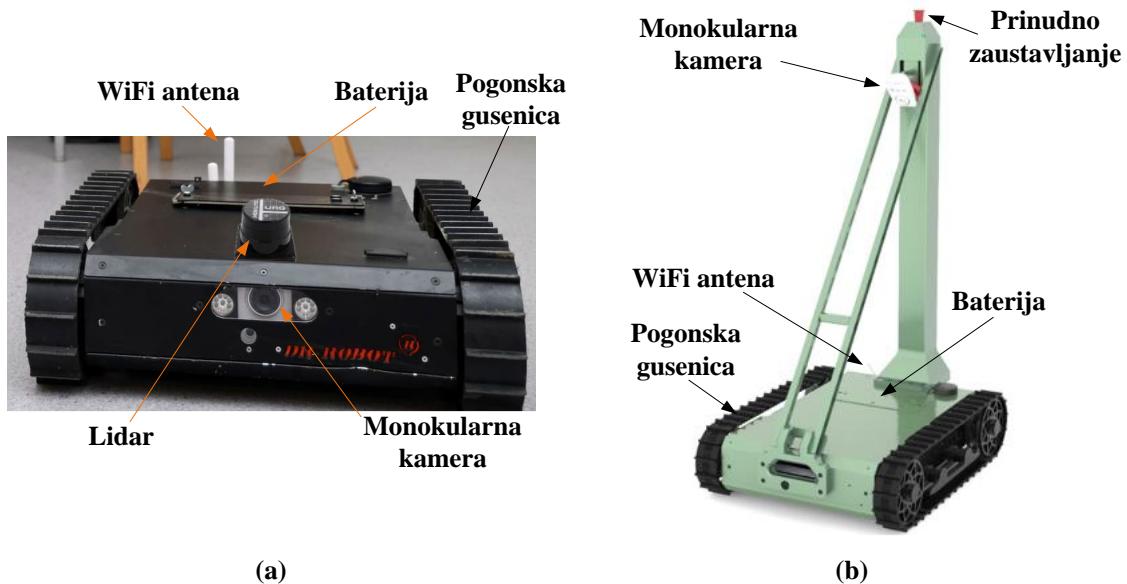
U ovom poglavlju je opisana eksperimentalna validacija predloženih sistema vođenja i upravljanja za zadatok autonomnog praćenja lidera i za zadatok autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka. Prvo je predstavljeno laboratorijsko gusenično vozilo korišćeno u eksperimentima, opisana je integracija sistema autonomnog kretanja za oba razmatrana zadatka, kao i eksperimentalne postavke i dobijeni rezultati. Zadatak autonomnog praćenja lidera je evaluiran kroz simulacije i realne eksperimente, pružajući sveobuhvatnu procenu dostignutih performansi. Zadatak autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka validiran je samo na bazi realnih eksperimenata, zbog svoje specifičnosti.

3.4.1 Laboratorijsko gusenično vozilo i senzorski sistemi

Eksperimenti su sprovedeni korišćenjem laboratorijskog BGV-a *Jaguar-Lite* [180], prikazanog na slici 3.23a. Vozilo ima širinu od 0,65 m, visinu od 0,15 m i dužinu od 1 m. Rastojanje između centara desne i leve gusenice, B , iznosi 0,52 m, a poluprečnik pogonskog točka gusenice, r , iznosi 0,085 m. Treba napomenuti da je za eksperimente autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka realizovano repozicioniranje monokularne kamere, što se može videti na slici 3.23b.

Karakteristike integrisanih senzora laboratorijskog BGV-a su bile sledeće:

- **Monokularna kamera:** mrežna kolor kamera AXIS M1065-LW sa objektivom od 4,4 mm koji pruža horizontalno vidno polje od 110 stepeni. Za eksperimente autonomnog praćenja zadate vozne trake (slika 3.23b), kamera je bila montirana na zadnjem delu BGV-a na visini od 90 cm, sa nagibom nadole od 45 stepeni. Ova konfiguracija pruža optimalnu perspektivu za detekciju vozne trake i izbegavanje prepreka. Nasuprot tome, za eksperimente autonomnog praćenja lidera (slika 3.23a), zadržana je originalna konfiguracija BGV-a, sa kamerom montiranom na prednjem delu BGV-a na visini od 0,1 metra.



Slika 3.23: Laboratorijsko gusenično vozilo: a) osnovna struktura vozila primenjena u zadatu praćenja lidera, b) modifikovana struktura, primenjena u zadatu praćenja vozne trake sa izbegavanjem prepreka.

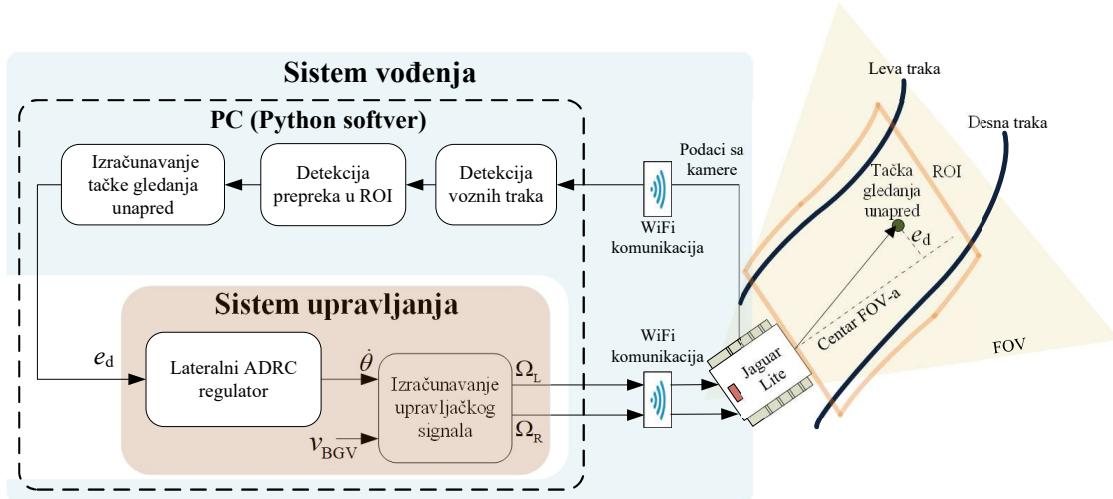
- **LiDAR senzor:** URG-04LX je uključen samo u eksperimente autonomnog praćenja lidera. Ovaj senzor pruža tačna merenja rastojanja do lidera, što je kritično za održavanje bezbednog rastojanja praćenja i izračunavanje longitudinalne greške. LiDAR ima sledeće specifikacije: detektabilni opseg od 0,02 m do 4 m, tačnost od ± 10 mm unutar opsega 0,02–1 m, i ugao skeniranja od 240 stepeni. Podaci sa LiDAR-a su sinhronizovani sa frekvencijom frejmova kamere od 5 fps (frejmova u sekundi), osiguravajući koherentnu integraciju vizuelnih podataka i podataka o rastojanju.
- **Ostale komponente:** laboratorijski BGV platforma je takođe opremljena dodatnim komponentama neophodnim za autonomni rad. One uključuju ugrađeni računar PMS5006 za pogon aktuatora i čitanje podataka senzora, zasnovan na ARM Cortex-M4 procesoru, Wi-Fi modul (802.11G) za komunikaciju i baterijski paket LiPo baterija od 22,2V i 10Ah. Komunikacija između udaljenog laptopa i ugrađenog računara BGV-a uspostavljena je putem Wi-Fi mreže korišćenjem TCP/IP protokola. Ova postavka omogućava prenos upravljačkih komandi (upravljanje pravca i brzina) ka BGV-u i prijem senzorskih podataka, uključujući slike sa kamere i podatke sa LiDAR senzora.

Softverski okvir je implementiran u Python-u i izvršava se na udaljenom prenosnom računaru, komunicirajući bežično sa laboratorijskim BGV-om. Prenosni računar je bio opremljen procesorom 11. generacije Intel(R) Core(TM) i7-11800H sa 16 virtualnih CPU-a koji rade na frekvenciji od 2,30 GHz, 16 GB RAM memorije i grafičkom pločom NVIDIA RTX 3060.

3.4.2 Integracija projektovanih sistema autonomnog kretanja

3.4.2.1 Integracija sistema autonomnog praćenje zadate vozne trake sa izbegavanjem prepreka

Za eksperimentalnu validaciju ovog zadatka, implementirana je arhitektura sistema prikazana na slici 3.24. Sistem integriše module za vođenje i upravljanje kako bi omogućio laboratorijskom BGV-u autonomno kretanje po definisanoj stazi uz izbegavanje prepreka.



Slika 3.24: Blok dijagram pripremljene eksperimentalne postavke za autonomno praćenje zadate vozne trake sa izbegavanjem prepreka.

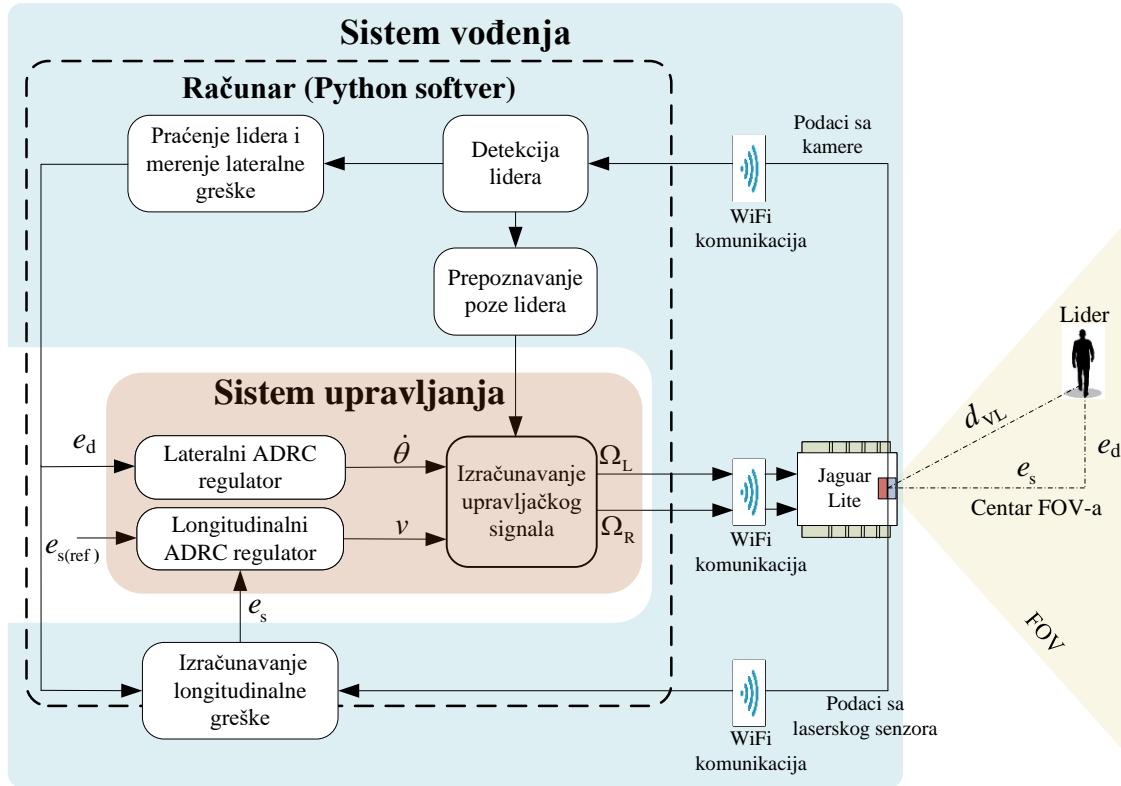
Sistem vođenja je primarno zasnovan na obradi podataka sa monokularne kamere (odeljak 3.3.1). Koristi YOLOv2 model za detekciju vozne trake i YOLOv8 model za detekciju prepreka unutar dinamički definisanog ROI-a koji prati detektovane granice trake. Razvijeni algoritmi za obradu trake filtriraju tačke i interpoliraju nedostajuće delove, generišući kontinualnu levu i desnu granicu trake. U slučaju detekcije prepreke, aktivira se mehanizam za generisanje virtuelne putanje. Konačno, modul za planiranje putanje izračunava centralnu referentnu liniju (na osnovu originalnih ili virtuelnih granica) i, koristeći adaptivnu virtuelnu tačku ispred vozila, određuje lateralnu grešku $e_d(t)$, koja se prosleđuje sistemu upravljanja.

Sistem upravljanja koristi samo lateralni ADRC regulator. Kao ulaz prima lateralnu grešku $e_d(t)$ iz sistema vođenja i generiše komandu za željenu ugaonu brzinu BGV-a ($\dot{\theta}$). Modul za izračunavanje upravljačkog signala zatim prevodi ovu komandu, zajedno sa zadatom konstantnom brzinom v_{BGV} , u odgovarajuće komande za ugaone brzine leve i desne gusenice ($\Omega_R(t)$ i $\Omega_L(t)$) korišćenjem inverznog kinematičkog modela (3.1).

3.4.2.2 Integracija sistema autonomno praćenje lidera

Za eksperimentalnu validaciju zadatka autonomnog praćenja lidera, primenjena je arhitektura sistema prikazana na slici 3.25. Ovaj sistem integriše podatke sa više senzora

i napredne algoritme kako bi omogućio laboratorijskom BGV-u da prati ljudskog lidera i reaguje na njegove komande.



Slika 3.25: Blok dijagram pripremljene eksperimentalne postavke za autonomno praćenje lidera.

Sistem vođenja u ovom zadatku odgovoran je za percepciju lidera i okruženja, interpretaciju komandi i generisanje signala greške (Odeljak 3.3.2) za sistem upravljanja. Njegovu funkcionalnost realizuju sledeći moduli: modul detekcije i praćenja lidera koristi YOLOv8 model za identifikaciju i praćenje lidera u video strimu. Modul prepoznavanja poza primenjuje MPP algoritam radi klasifikacije predefinisanih poza lidera. Podatke o rastojanju do lidera, $d_{VL}(t)$, obezbeđuje modul merenja rastojanja obradom podataka sa LiDAR senzora. Na osnovu pozicije lidera u slici i izmerenog rastojanja, modul merenja i transformacije greške izračunava lateralnu grešku $e_d(t)$ i longitudinalnu grešku $e_s(t)$. Konačno, Modul generisanja komandi vođenja integriše izračunate greške sa željenom rastojanjem praćenja i prepoznatom pozom, prosleđujući odgovarajuće signale sistemu upravljanja ili direktno modifikujući izlaz u slučaju komandnih poza (slika 3.22).

Sistem upravljanja sastoji se od dva regulatora: lateralnog ADRC regulatora (Odeljak 3.2.2.1) i longitudinalnog ADRC regulatora (Odeljak 3.2.2.2). Lateralni regulator koristi e_d za generisanje komande upravljanja pravcem, $\dot{\theta}$, dok longitudinalni regulator koristi e_s i referentno rastojanje praćenja, $e_{s(\text{ref})}$, za generisanje komande brzine, v . Blok za izračunavanje upravljačkog signala ima za zadatak dobijanje odgovarajućih upravljačkih signala BGV-a $\Omega_R(t)$ i $\Omega_L(t)$ koristeći izlaz bloka za prepoznavanje poze i signale lateralnog i longitudinalnog regulatora $\dot{\theta}(t)$ i $v(t)$. Grafički prikaz korišćenog algoritma prikazan je

na slici 3.22, gde se može videti da se u slučaju kada je poza čoveka uspravna, izračunanje upravljačkih komandi realizuje pomoću izlaza lateralnog i longitudinalnog ADRC regulatora, koji se transformišu u odgovarajuće $\Omega_R(t)$ i $\Omega_L(t)$ na osnovu (3.1). S druge strane, kada je poza lidera čučeća, BGV se zaustavlja, dok se za čučeće poze lidera sa podignutom desnom ili levom rukom, BGV kreće napred odnosno nazad, konstantnom longitudinalnom brzinom i nultom ugaonom brzinom.

3.4.3 Eksperimentalna validacija autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka

3.4.3.1 Eksperimentalna postavka

Eksperimenti autonomnog praćenja zadate vozne trake sprovedeni su na posebno napravljenoj kružnoj laboratorijskoj stazi. Dužina staze je 35 metara sa prosečnom širinom od oko 1,5 metara. Oznake vozne trake su napravljenе korišćenjem bele lepljive trake širine 8 cm na podu svetle boje. Raspored staze uključivao je dve prave deonice, svaka dužine 3 metra, povezane krivinama sa dva oštra skretanja sa uglovima većim od 90 stepeni i više manjih krivina.

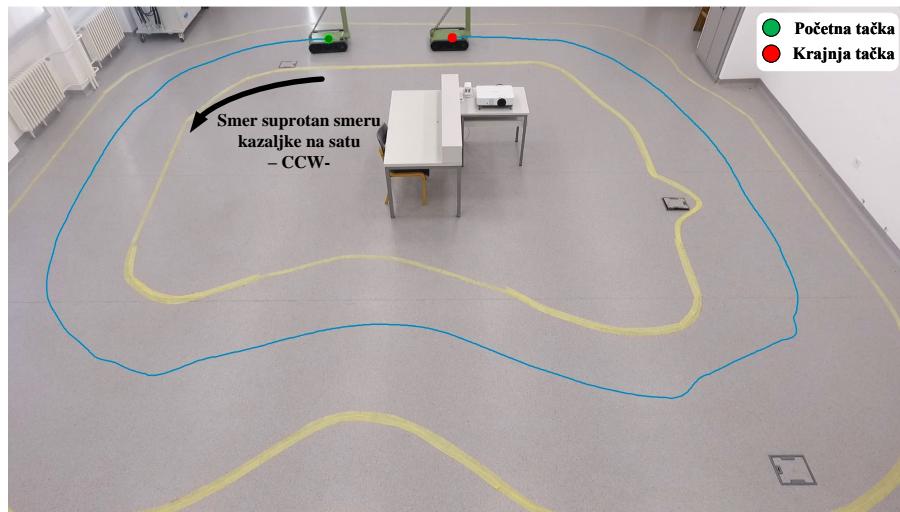
Da bi se procenila robusnost sistema, delovi vozne trake bili su namerno oštećeni, što je simuliralo scenarije iz stvarnog sveta gde oznake vozne trake mogu biti istrošene ili prljave.

Sposobnosti BGV za izbegavanje prepreka testirane su korišćenjem stolica dimenzija 40 cm x 50 cm x 80 cm, koje su bile postavljene u krivinama staze, kako bi se testirala sposobnost sistema da se nosi sa preprekama u najnepovoljnijim slučajevima, kao što su oštra skretanja gde su vidljivost i sposobnost manevriranja ograničeni. Konfiguracija staze i pozicije prepreka prikazane su na slikama 3.26 i 3.27, rspektivno.

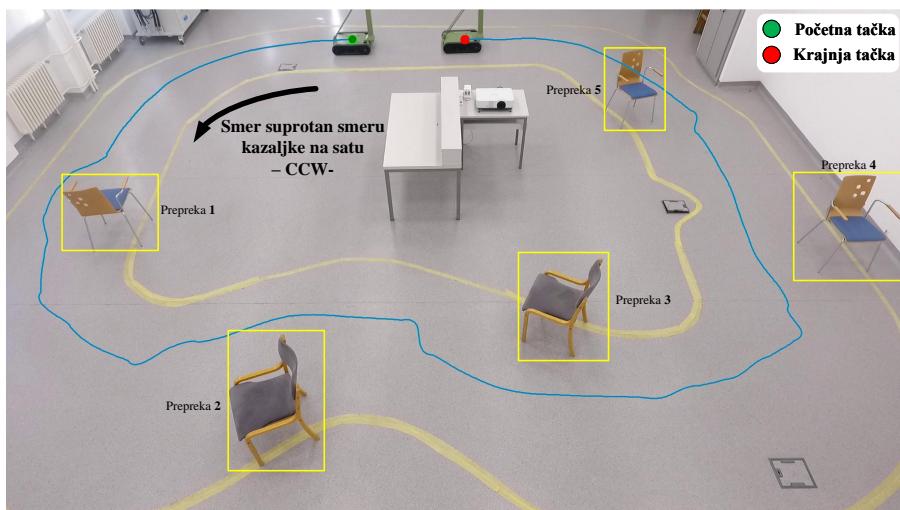
Eksperimenti su sprovedeni za scenarije bez i sa preprekama. U okviru oba scenarija, izveli smo dve eksperimentalne vožnje - jednu u smeru kazaljke na satu (eng. Clockwise, CW) i drugu suprotno od smera kazaljke na satu (eng. Counter-Clockwise, CCW). Ovaj pristup dvosmernog testiranja efikasno proverava dve različite putanje dok pruža nekoliko prednosti: (1) eliminiše potencijalnu pristrasnost usled geometrije staze, (2) potvrđuje dosledne performanse bez obzira na smer skretanja, (3) testira sposobnosti izbegavanja prepreka i sa leve i sa desne strane, i (4) potvrđuje dosledne performanse u odzivu upravljanja.

- **Scenario 1: bez prepreka** - BGV se kretalo stazom i u smeru kazaljke na satu (CW) i suprotno od smera kazaljke na satu (CCW) i bez prepreka na putanji. Ovim je procenjena osnovna tačnost sistema u praćenju zadate vozne trake (slika 3.26).
- **Scenario 2: sa preprekama** - prepreke (stolice) su postavljene duž staze. BGV se kretao u dva smera CW i CCW kako bi se testirale sveobuhvatne sposobnosti

izbegavanja prepreka. Ovaj scenario je procenio sposobnost sistema da detektuje, izbegne prepreke održavajući tačnost praćenja zadate vozne trake (slika 3.27).



Slika 3.26: Laboratorijska staza bez prepreka.



Slika 3.27: Laboratorijska staza sa preprekama.

Pre samog testiranja empirijski su podešene sledeće konfiguracije sistema autonomnog kretanja:

- **Region od interesa** za detekciju vozne trake i prepreka bio je dinamički definisan unutar vidnog polja kamere. Vertikalne granice ROI-a postavljene su od 95% visine slike (najbliže BGV-u) do 50% visine slike. Ovaj izbor je napravljen nakon obimnog testiranja, jer je pružio najbolji balans između nekoliko faktora. Prvo, uključivanje donjih 50% slike pruža dovoljno rastojanje gledanja unapred, omogućavajući BGV-u da efikasno predviđa krivine i prepreke. Dodatno, ograničavanje ROI-a smanjuje računarske zahteve modula percepcije, minimizirajući vreme obrade i kašnjenje.

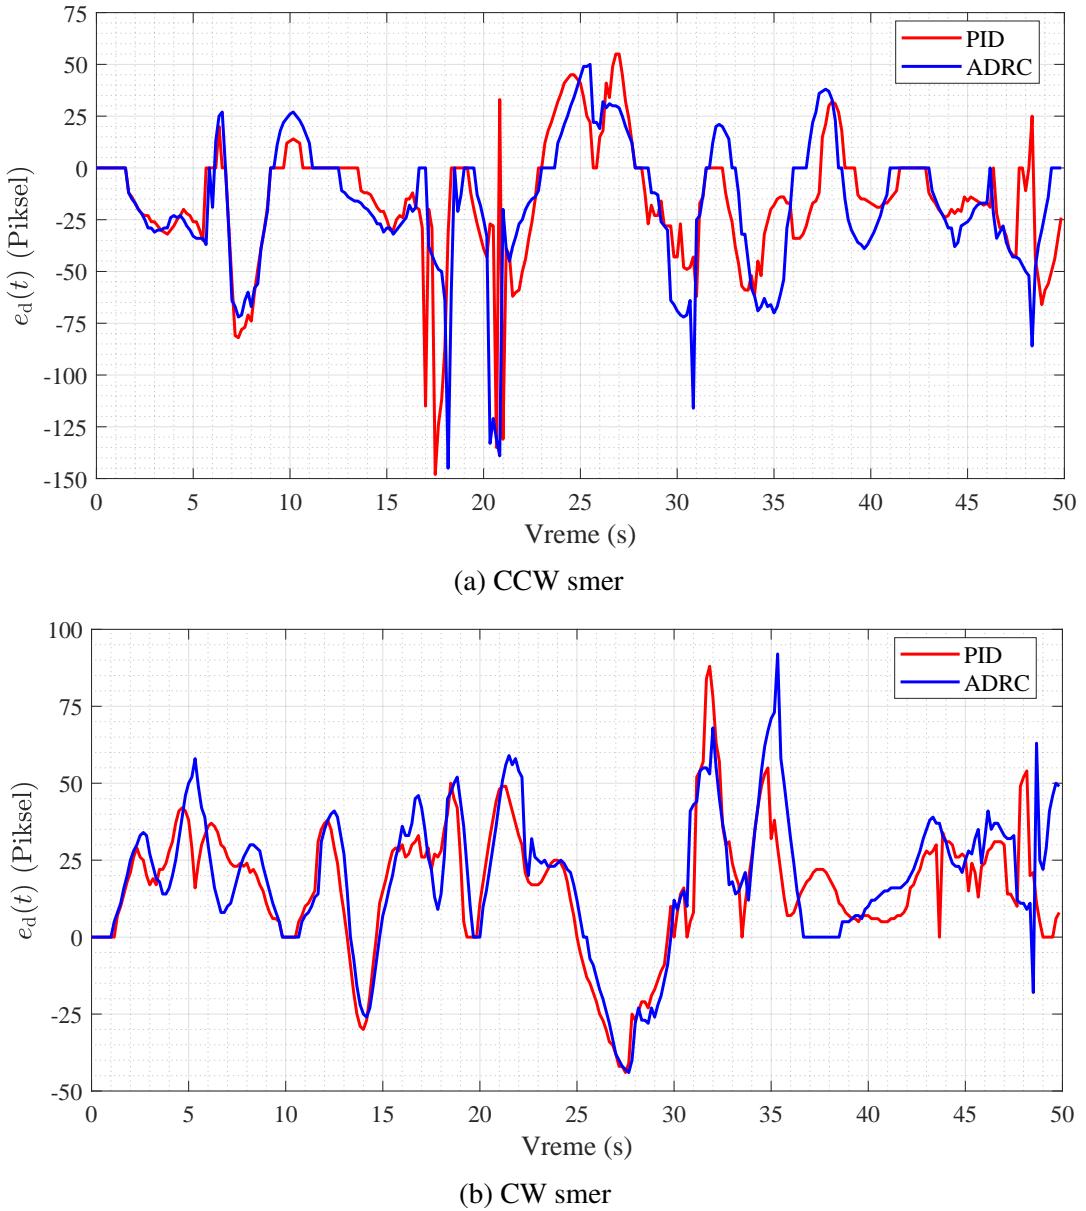
Štaviše, isključivanje gornjeg dela slike sprečava detekciju udaljenih objekata, koji bi mogli biti irrelevantni ili pogrešno interpretirani kao prepreke, posebno kada se objekti pojavljuju centralno u dalekim regionima. Ako bi ROI bio kraći, to bi moglo kompromitovati izbegavanje prepreka smanjenjem rastojanja za reakciju. Pored toga, neposredno područje ispred BGV-a, predstavljeno donjim 5% slike, isključeno je zbog pozicije kamere, koja prvenstveno prikazuje prednji deo BGV-a.

- **Virtuelna tačka ispred vozila** korišćena za izračunavanje lateralne greške i generisanje komandi upravljanja pravcem, postavljena je na poziciju koja se nalazi na približno 40% vertikalnog opsega ROI-a. Ova pozicija je izabrana da pruži balans između brzine odziva i stabilnosti. Virtuelna tačka ispred vozila koja je preblizu BGV-u rezultirala bi previše osetljivim korekcijama upravljanja, potencijalno dovodeći do nestabilnog ponašanja, posebno u krivinama. Suprotno tome, ako je virtuelna tačka ispred vozila previše udaljena, to bi moglo prouzrokovati da BGV reaguje prerano na krivine, dovodeći do nepotrebnih odstupanja od centralne linije ili uzrokujući da BGV "seče krivine". Pozicija od 40% omogućava BGV da pravi "glatke" prolaze kroz krivine i stabilno kretanje.
- **Longitudinalna brzina BGV-a** imala je konstantnu vrednost $v_{BGV} = 0,5 \text{ m/s}$. Ova brzina je izabrana na osnovu nekoliko razmatranja. Naime, kompletna petlja vođenja i upravljanja radi na frekvenciji od 5 Hz, sa periodom odabiranja od $T_s = 0,2$ sekunde. Pri ovoj brzini, ima dovoljno vremena da sistem obradi senzorske podatke, generiše upravljačke komande i prenese ih BGV-u. Dodatno, veće brzine bi zahtevale bržu obradu, što bi moglo dovesti do neprihvatljivog kašnjenja i nestabilnosti. Izabrana brzina od 0,5 m/s osigurava da BGV prima i odgovara na upravljačke komande na vreme, izbegavajući probleme kao što su prekoračenje ili oscilacije.

3.4.3.2 Eksperimentalni rezultati

- **Scenario 1: autonomno praćenje zadate vozne trake bez prepreka**

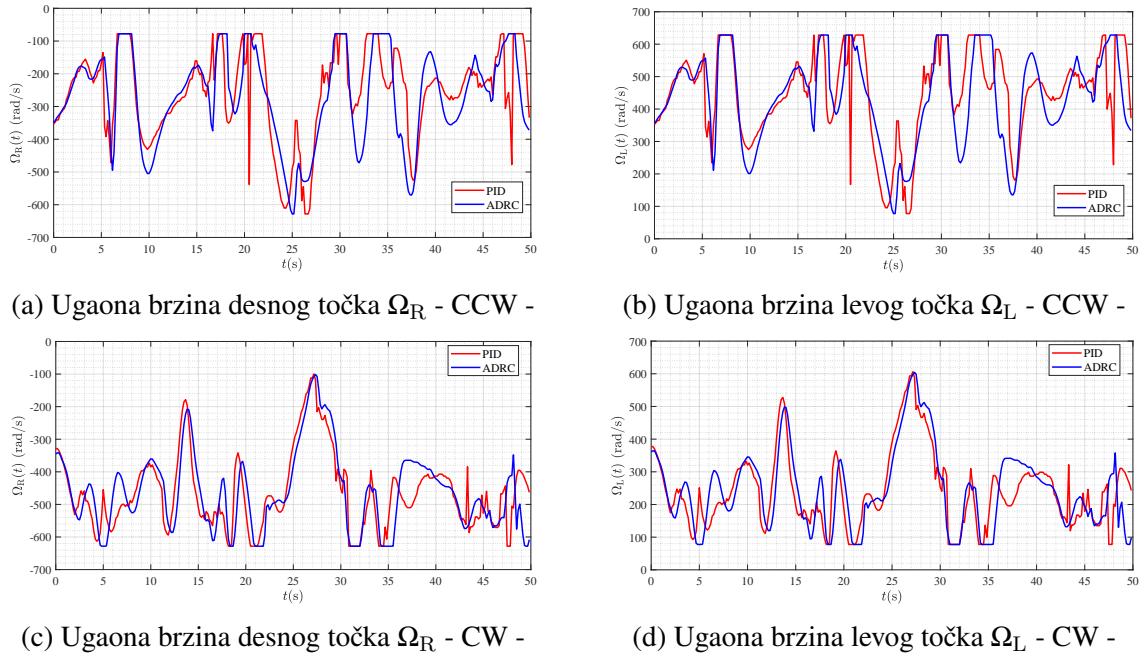
U okviru ovog scenarija, da bi se demonstrirale prednosti predloženog ADRC regulatora, sprovedena je uporedna analiza sa tradicionalnim PID regulatorom. Oba regulatora su implementirana i testirana pod identičnim uslovima. Parametri regulatora i za ADRC i za PID podešeni su empirijski kako bi se postigle najbolje moguće performanse za svaki od njih. Za PID regulator, proporcionalno, integralno i derivativno pojačanje usvojeni su kao $K_p = 2$, $K_i = 0,01$ i $K_d = 0,005$, redom. Parametri za ADRC regulator postavljeni su na osnovu predložene metode *parametrizacije propusnog opsega* odabirom $\omega_{CL_1} = 0,7 \text{ rad/s}$ i $\omega_{ESO_1} = 2,1 \text{ rad/s}$, dok je parametar b_0 postavljen prema vrednosti brzine BGV-a, tj. $b_{0_1} = -v_{BGV}$. Vrednosti podešenih parametara regulatora zadržane su za preostale eksperimente.



Slika 3.28: Lateralna greška (e_d) tokom autonomnog praćenja zadate vozne trake bez prepreka.

Slika 3.26 prikazuje praćenu putanju BGV-a tokom CCW vožnje bez prepreka korišćenjem ADRC regulatora. BGV se uspešno kretao celom stazom, uključujući prave deonice i, posebno, oštra skretanja. Putanja je generalno glatka, ukazujući na efikasno upravljanje, iako su uočljiva manja odstupanja vozila od sredine vozne trake, odnosno prilasci levoj i desnoj ivici trake, naročito u krivinama. Ova odstupanja se pripisuju prvenstveno nesavršenostima u procesu detekcije i interpolacije vozne trake. Međutim, može se zaključiti da je sistem dosledno održavao BGV unutar granica vozne trake, demonstrirajući robusnost ADRC algoritma lateralnog upravljanja.

Lateralna greška, e_d , za obe, CCW i CW vožnje, i to za ADRC i PID upravljanje, predstavljena je na slici 3.28, dok slika 3.29 prikazuje ugaone brzine leve i desne gusenice (Ω_L i Ω_R) za CCW i CW vožnje sistema sa ADRC i PID regulatorima.



Slika 3.29: Ugaone brzine leve i desne gusenice (Ω_L i Ω_R) tokom autonomnog praćenja zadate vozne trake bez prepreka. Gornji red odgovara CCW smeru, a donji red odgovara CW smeru.

Može se primetiti da u oba smera kretanja stazom (CCW i CW) i ADRC i PID regulatori pokazuju slične karakteristike, lateralna greška se kreće u opsegu od -75 do 50 piksela, sa povremenim vršnim vrednostima koje dostižu oko -125 piksela. Veličina greške se povećava tokom oštih skretanja, kao što se očekivalo, ali oba regulatora efikasno koriguju odstupanje i vraćaju BGV ka centru vozne trake. Veći negativni vrhovi (oko 15s i 22s) predstavljaju trenutke kada je vozilo naišlo na najoštrijia skretanja, zahtevajući značajnije korekcije. U tim trenucima PID regulatori pokazuju veće oscilacije u poređenju sa ADRC regulatorima.

Slike 3.29 mogu se uočiti ključne razlike u upravljačkom naporu применjenom od strane dva tipa regulatora. ADRC regulator proizvodi glatkije komande brzine točkova za oba smera kretanja. PID regulator, za razliku od toga, pokazuje mnogo osculatornije ponašanje, sa brzim promenama brzine točkova. Glatkiji upravljački signali kod ADRC regulatora ukazuju na njegovu sposobnost da proceni i kompenzuje poremećaje efikasnije nego PID regulator, što vodi ka stabilnijem kretanju uz manju potrošnju energije.

Sveukupno, rezultati za scenario 1 demonstriraju da i ADRC i PID regulatori mogu postići autonomno praćenje zadate vozne trake. Ovi rezultati demonstriraju da upravljački sistem uspešno održava sposobnost autonomnog praćenja zadate vozne trake u oba smera, sa očekivanim povećanjima greške praćenja tokom izazovnih deonica kao što su oštra skretanja. Sličnost u performansama između CW i CCW vožnji potvrđuje nezavisnost upravljačkog sistema od smera i eliminiše potencijalne pristrasnosti povezane sa geometrijom staze. Međutim, ADRC regulator pokazuje bolje

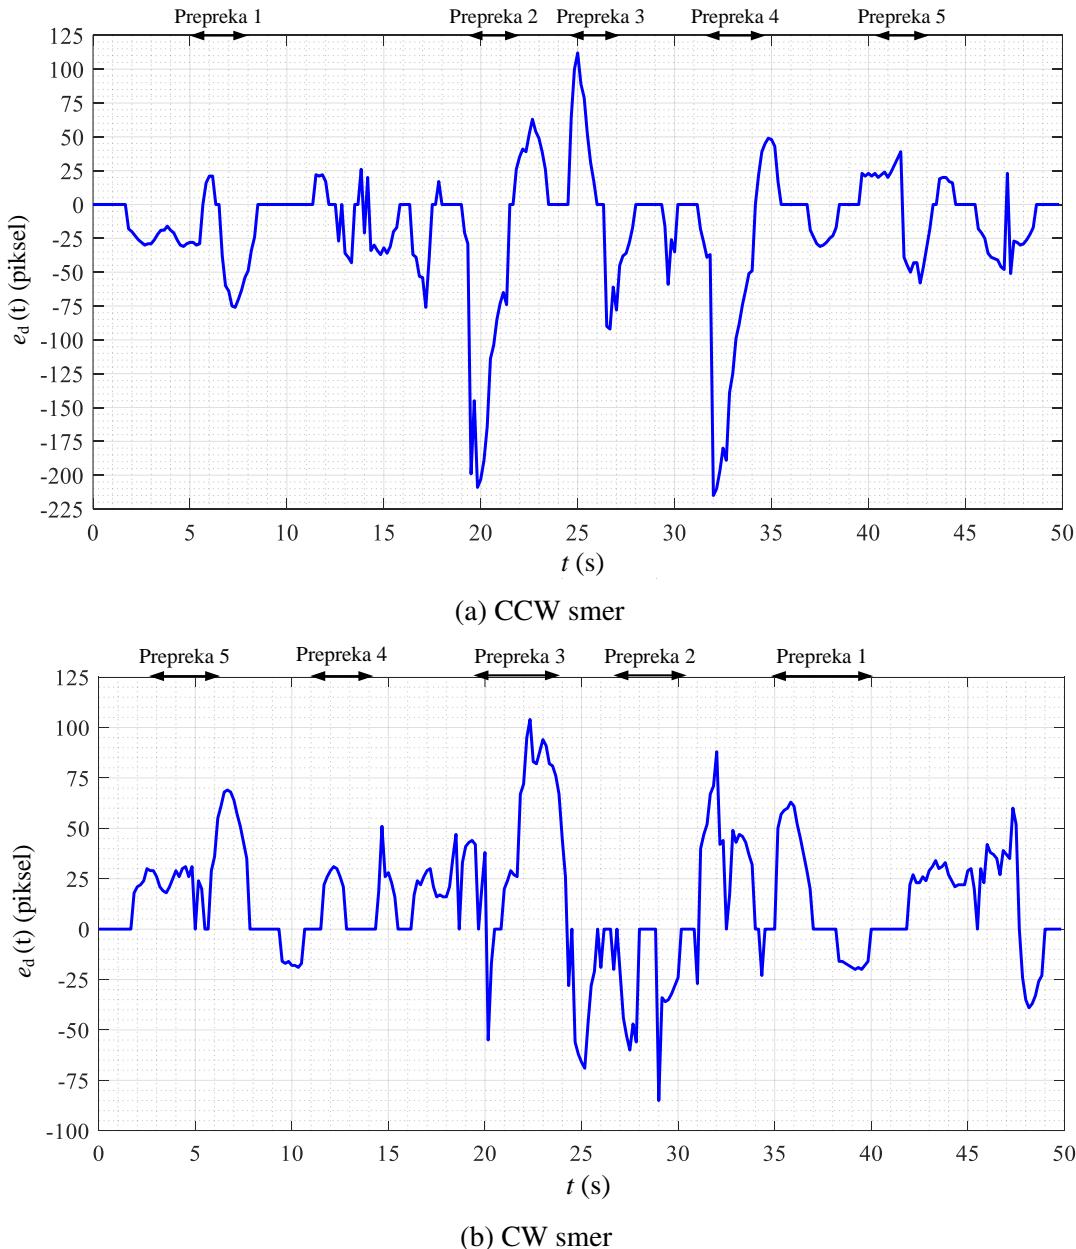
performanse u pogledu manjih grešaka praćenja, bržeg potiskivanja poremećaja i glatkijih upravljačkih signala. Ove poboljšane performanse pripisuju se sposobnosti ADRC-a da proceni i kompenzuje i unutrašnje i spoljašnje poremećaje sistema, što je ključna prednost u odnosu na tradicionalno PID upravljanje.

- **Scenario 2: autonomno praćenje zadate vozne trake sa preprekama**

U sklopu ovog scenarija prikazani su samo rezultati sistema sa ADRC regulatorom, jer sistem sa PID regulatorom nije dao dobre rezultate u izbegavanju prepreka. Slika 3.27 vizuelno prikazuje putanju BGV-a tokom CCW vožnje sa postavljenim preprekama korišćenjem ADRC upravljanja. BGV se uspešno kretao stazom, izbegavajući sve prepreke dok je održavao svoju poziciju unutar vozne trake. Rezultati jasno pokazuju kako BGV prilagođava svoju putanju kako bi bezbedno zaobišao prepreke, a zatim nastavlja kretanje držeći se definisanih ivica vozne trake. Ovo demonstrira efikasnu integraciju izbegavanja prepreka sa autonomnim praćenjem zadate vozne trake. BGV je uspešno rešio čak i prepreke postavljene u oštrim skretanjima, pokazujući robusnost sistema u izazovnim situacijama.

Lateralna greška, e_d , za obe, CCW i CW vožnje sa preprekama, predstavljena je na slici 3.30. Iz dobijenih rezultata mogu se uočiti veća odstupanja u grešci u poređenju sa slučajem bez prepreka, što je očekivano zbog manevara potrebnih za izbegavanje prepreka. Veće vrednosti grešaka odgovaraju tačkama gde se BGV kreće oko prepreka, dok vršne vrednosti odgovaraju tačkama koje se nalaze na izlazu iz oštrih skretanja. Profili greške za neke prepreke razlikuju se između dva smera, naglašavajući kako prilazak istoj prepreci iz različitih smerova predstavlja jedinstvene izazove. Značajno je da najviši vrh odgovara Prepreci 2 kod CCW smera kretanja, jer je pozicionirana direktno na izlazu iz oštrog skretanja. Uočava se da maksimalne vrednosti greške tokom manevara izbegavanja prepreka izgledaju uporedivo između oba smera, sugerujući dosledne performanse algoritma za izbegavanje prepreka. Ovi rezultati potvrđuju sposobnost sistema da izvrši izbegavanje prepreka uz održavanje sposobnosti autonomnog praćenja zadate vozne trake.

Tokom eksperimentalne analize, primećeno je nekoliko slučajeva neočekivanih pojava greške kada se to usled pozicije vozila unutar vozne trake ne očekuje. Ove anomalije se mogu pripisati višestrukim faktorima: (1) algoritam za detekciju prepreka povremeno može propustiti da dosledno prepozna prepreku, što rezultira trenutnim propustima u detekciji. Ovi kratki prekidi mogu prouzrokovati da se sistem privremeno vrati na centar vozne trake, generišući iznenadna pozitivna ili negativna odstupanja greške. (2) proces detekcije i interpolacije vozne trake može naići na izazove u doslednom identifikovanju traka putanje, posebno u regionima sa delimičnim zaklanjanjem ili smanjenom vidljivošću. Takve nedoslednosti mogu dovesti do blagih varijacija u proceni centra vozne trake, proizvodeći male, prolazne fluktuacije greške.



Slika 3.30: Lateralna greška (e_d) tokom scenarija autonomnog praćenja zadate vozne trake sa preprekama.

Važno je napomenuti da se ove anomalije karakterišu malom veličinom i retkom pojavom. Ukupne performanse sistema ostaju robusne, pri čemu ADRC regulator efikasno upravlja ovim manjim perturbacijama i održava stabilno ponašanje autonomnog praćenja zadate vozne trake.

3.4.4 Validacija autonomnog praćenja lidera

Validacija rada i ocena performansi i robusnosti projektovanog sistema autonomnog praćenja lidera od strane BGV realizovana je prvo na bazi računskih simulacija, a nakon toga u eksperimentalnom okruženu u terenskim uslovima, što je detaljno opisano u

nastavku poglavlja.

3.4.4.1 Simulaciona validacija autonomnog praćenja lidera

Da bi se procenile performanse predloženog upravljačkog sistema za autonomno praćenje lidera, sprovedene su simulacije korišćenjem MATLAB/Simulink softvera. Simulacije su koristile kinematički model laboratorijskog BGV-a, sa parametrima detaljno opisanim u odeljku 3.1. ADRC regulatori (lateralni i longitudinalni) upoređeni su sa upravljačkim sistemom na bazi PID regulatora sa filterom šuma za lateralni kanal i PI regulatora za longitudinalni kanal. Da bi se uzela u obzir ograničenja realnog BGV, maksimalna ugaona brzina $\dot{\theta}_{max}$ u simulaciji ograničena je na 5 rad/s. Analizirana su dva različita simulaciona scenarija autonomnog praćenja lidera, a njihove karakteristike i rezultati dati su u nastavku.

Scenario #1: praćenje lidera u različitim uslovima dinamike poremećaja i šuma merenja.

U ovom scenariju, trajektorija lidera je definisana uglom skretanja lidera prema sledećem:

$$\theta_L(t) = \begin{cases} -0.12 \cdot t, & \text{kada } 0 \leq t < 10, \\ 0.88 \cdot t, & \text{kada } 10 \leq t < 15, \\ 1.07 \cdot t, & \text{kada } 15 \leq t < 35, \\ 1.22 \cdot t, & \text{kada } 35 \leq t < 37, \\ 0.87 \cdot t, & \text{kada } 37 \leq t < 40, \\ 1.17 \cdot t, & \text{kada } 40 \leq t < 45, \\ 0.97 \cdot t, & \text{kada } 45 \leq t < 47, \\ 0.92 \cdot t, & \text{kada } 47 \leq t < 52, \\ 0.77 \cdot t, & \text{kada } 52 \leq t < 60. \end{cases} \quad (3.49)$$

Kako bi se detaljno analizirale performanse projektovanog upravljanja BGV-om u različitim radnim uslovima, simulacija je podeljena u pet intervala:

- i) U prvom intervalu (od 0 do 10 sekundi), simulacija se izvodi pod pretpostavkom savršenih uslova bez dinamike proklizavanja gusenica ($a_L = a_R = 1$) i bez šuma merenja u lateralnom i longitudinalnom kanalu, dok su brzina lidera i referentna longitudinalna greška postavljeni na $v_L(t) = 2 \text{ m/s}$ i $e_{s(\text{ref})} = 2 \text{ m}$, respektivno. Prepostavlja se da BGV i lider imaju iste početne koordinate (tj. $X = 3 \text{ m}$ i $Y = 20 \text{ m}$).
- ii) U drugom intervalu (od 10 do 15 sekundi), lider prestaje da se kreće, tj. $v_L(t) = 0 \text{ m/s}$.
- iii) U trećem intervalu (od 15 do 30 sekundi), brzina lidera je postavljena na $v_L(t) = 2 + 1.4 \sin(t) \text{ m/s}$, i pretpostavljaju se kompleksni poremećaji proklizavanja sa koeficijentima proklizavanja gusenica $a_R(t) = 0.7 + 0.3 \sin(5t)$ i $a_L(t) = 0.7 + 0.3 \sin(2t)$.

- iv) U četvrtom intervalu (od 30 do 45 sekundi), zadržavaju se prethodni uslovi, a dodatno su uključeni šumovi merenja, modelovani kao Gausov šum sa standardnim odstupanjem 0.02 m u lateralnom kanalu i 0.01 m u longitudinalnom kanalu.
- v) U poslednjem intervalu (od 45 do 60 sekundi), kako bi se analizirala promena referentne longitudinalne greške, ona se povećava na $e_{s(\text{ref})} = 3 \text{ m}$, dok ostali parametri simulacije ostaju isti kao u prethodnom intervalu.

Kako bi se omogućilo odgovarajuće poređenje dva razmatrana algoritma upravljanja, oni su empirijski podešeni da imaju slične performanse praćenja u odsustvu poremećaja (prvi interval). Ovaj pristup osigurava da su obe strukture inicijalno podešene da postignu uporedive sposobnosti praćenja u idealnim uslovima. Shodno tome, za lateralni PID regulator, proporcionalno, integralno, diferencijalno pojačanje i koeficijenti filtera šuma podešeni su prema sledećem $K_{p_l} = 4$, $K_{i_l} = 2$, $K_{d_l} = 0.5$ i $N = 50$, respektivno, dok su proporcionalno i integralno pojačanje longitudinalnog PI regulatora imali vrednosti $K_{p_v} = 3$ i $K_{i_v} = 3$. Parametri za lateralni i longitudinalni ADRC regulator podešeni su izborom $\omega_{CL_l} = 1.2 \text{ rad/s}$ i $\omega_{ESO_l} = 10 \text{ rad/s}$, odnosno $\omega_{CL_v} = 1 \text{ rad/s}$ i $\omega_{ESO_v} = 10 \text{ rad/s}$, dok je parametar b_0 u lateralnom ADRC regulatoru podešen u skladu sa vrednošću longitudinalne brzine lidera u prvom intervalu, tj. $b_0 = -2$. Podešene vrednosti parametara regulatora zadržane su tokom cele simulacije.

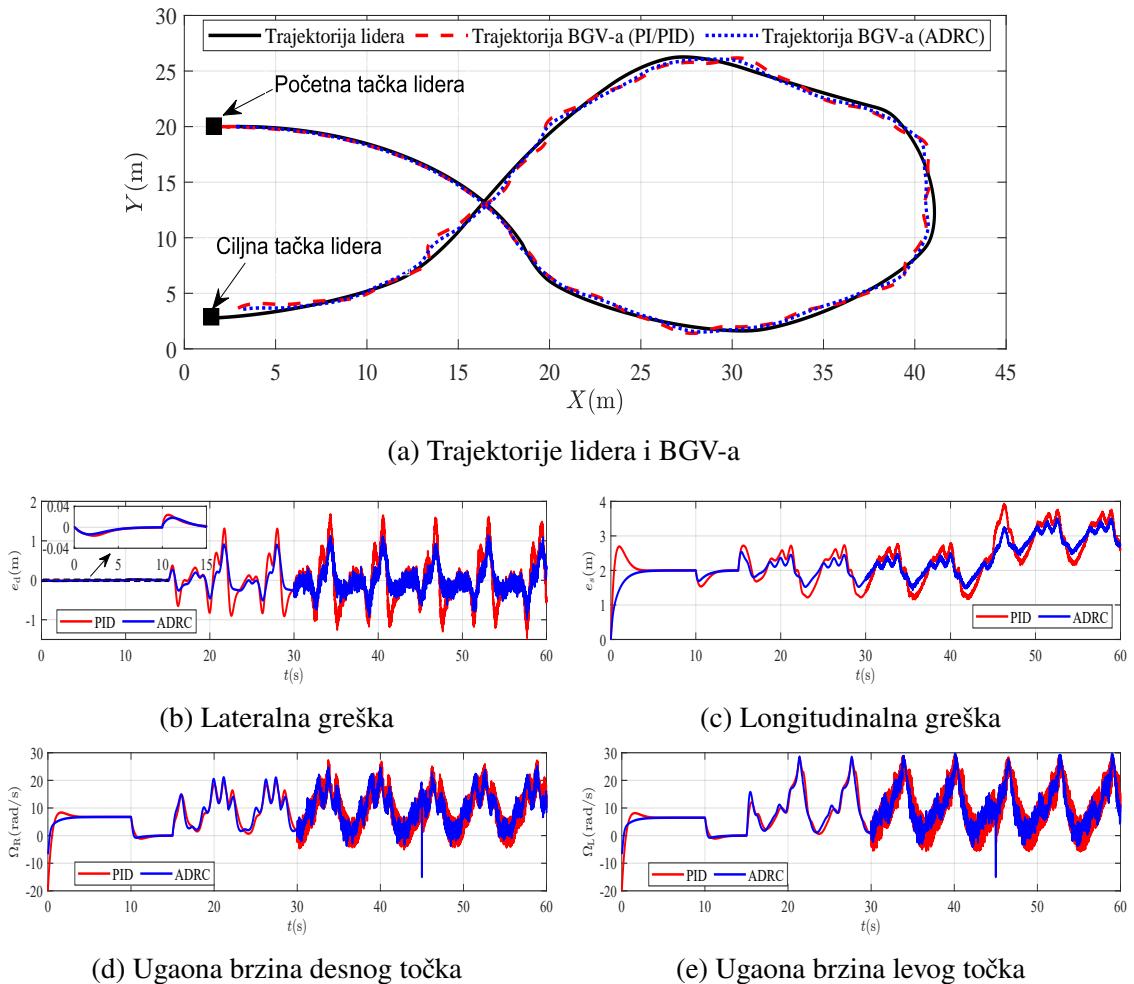
Rezultati simulacije, koji uključuju praćenje trajektorije lidera, lateralne greške, longitudinalne greške i ugaone brzine točkova gusenica prikazani su na slici 3.31. Kako bi se kvantitativno analizirali dobijeni rezultati simulacije, integrali apsolutnih lateralnih grešaka ($|e_d(t)|$) i razlika između referentnih i dobijenih longitudinalnih grešaka ($e_{s(e)} = |e_{s(\text{ref})}(t) - e_s(t)|$) tokom svakog simulacionog intervala su izračunati i upoređeni u Tabeli 3.1.

Tabela 3.1: Integrali apsolutne lateralne greške i apsolutne razlike između referentne i dobijene longitudinalne greške za sisteme sa PID i ADRC regulatorima u simulacionom scenariju #1.

	Prvi interval (od 0 do 10 s)		Drugi interval (od 10 do 15 s)		Treći interval (od 15 do 30 s)		Četvrti interval (od 30 do 45 s)		Petи interval (od 45 do 60 s)	
	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$
PID	0.059	1.318	0.056	0.667	5.891	6.183	6.329	6.188	7.052	6.385
ADRC	0.050	1.583	0.050	0.414	3.439	3.483	3.720	3.255	4.220	3.654

Na osnovu dobijenih rezultata simulacije, evidentno je da u prvom intervalu, bez efekta poremećaja proklizavanja, oba pristupa upravljanju efikasno prate trajektoriju lidera i pokazuju slične performanse. Profili brzina pogonskih točkova su glatki u oba sistema, iako PID pristup proizvodi veće vršne vrednosti na početku simulacije.

U drugom intervalu, kada se lider zaustavi, primetno je da oba sistema uspevaju da održe stabilno praćenje, bez oscilacija u dinamici longitudinalne greške. Međutim, može



Slika 3.31: Rezultati simulacije (za scenario #1).

se uočiti da ADRC pristup pokazuje bolje prelazne performanse u poređenju sa PI/PID algoritmom.

Treći interval je ključan za procenu robusnosti algoritama upravljanja u prisustvu poremećaja proklizavanja. Rezultati pokazuju efikasnost ADRC pristupa u rešavanju poremećaja proklizavanja. Zapravo, ADRC struktura postiže značajno niže vrednosti integrala apsolutnih lateralnih i longitudinalnih grešaka kao i niže vršne vrednosti obe greške, u poređenju sa PI/PID strukturom, pri čemu su vrednosti brzina pogonskih točkova slične.

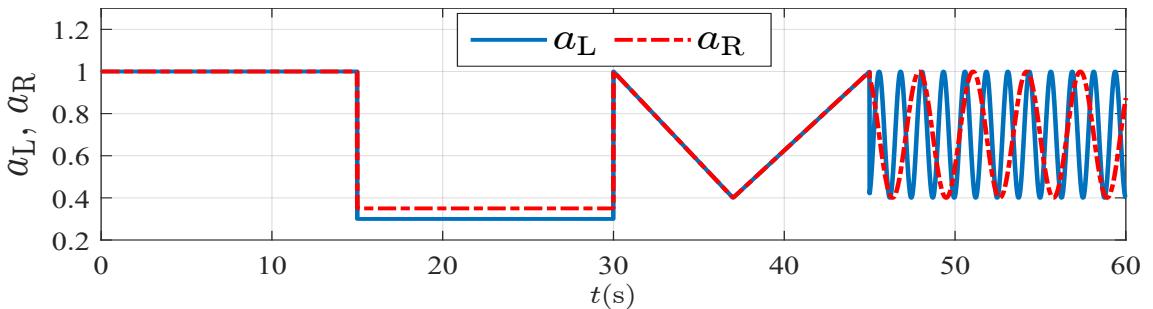
Posmatrajući rezultate simulacije u četvrtom intervalu, može se primetiti da ADRC nadmašuje PI/PID pristup u uslovima postojanja šuma merenja. ADRC održava precizno praćenje lidera i generiše glatkije brzine pogonskih točkova u poređenju sa PI/PID, dodatno potvrđujući svoju efikasnost za praktičnu implementaciju.

Na kraju, iz rezultata simulacije u poslednjem, petom intervalu, evidentno je da povećanje referentne longitudinalne greške nije imalo značajan uticaj na degradaciju performansi praćenja i da je ADRC struktura zadržala svoje prednosti u odnosu na PID strukturu.

Scenario #2: praćenje kružne trajektorije lidera sa kompleksnim poremećajima proklizavanja.

U ovom scenariju simulacije, analiziraju se performanse razmatranih algoritama upravljanja sistema praćenja lidera u prisustvu kompleksnih poremećaja proklizavanja. Podešavanja regulatora ostaju ista kao u prethodnom scenariju, dok je trajektorija lidera ovoga puta definisana kao kružna trajektorija, sa konstantnom brzinom lidera $v_L = 2 \text{ m/s}$ i referentnom longitudinalnom greškom $e_{s(\text{ref})} = 2 \text{ m}$. Prepostavlja se da BGV i lider imaju iste početne koordinate (tj. $X = 25\text{m}$ i $Y = 45\text{ m}$). Simulacija je podeljena u sledeća četiri intervala sa kompleksnom dinamikom (tj. poremećajima proklizavanja), prikazanim na slici 3.32:

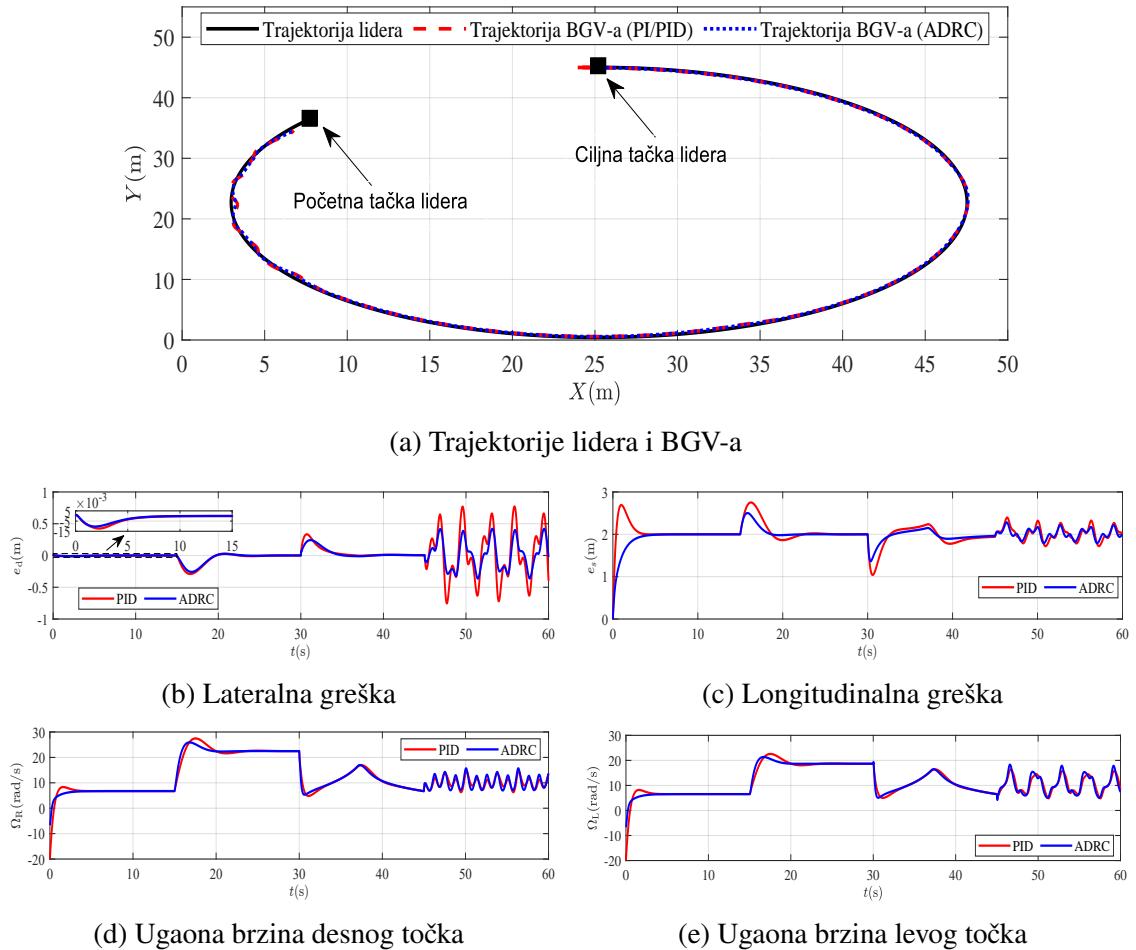
- i) U prvom intervalu (od 0 do 15 sekundi), simulacija se izvodi bez dinamike proklizavanja gusenica ($a_L = a_R = 1$).
- ii) U drugom intervalu (od 15 do 30 sekundi), pretpostavljeni su konstantni poremećaji proklizavanja za levu i desnu gusenicu.
- iv) U trećem intervalu (od 30 do 45 sekundi), pretpostavljeni su linearno rastući poremećaji proklizavanja.
- iv) U četvrtom intervalu (od 45 do 60 sekundi), pretpostavljeni su sinusoidalni poremećaji proklizavanja.



Slika 3.32: Definisani poremećaji proklizavanja u okviru simulacionog scenarija #2.

Rezultati simulacije, koji uključuju praćenje trajektorije lidera, lateralne greške, longitudinalne greške i ugaone brzine točkova gusenica, prikazani su na slici 3.33. Na isti način kao u prethodnom scenariju, integrali apsolutne lateralne greške i razlike između referentne i postignute longitudinalne greške ($e_{s(e)}$) izračunati su za svaki simulacioni interval i upoređeni u tabeli 3.2 za upravljačke sisteme sa PID i ADRC regulatorima.

Na osnovu dobijenih rezultata, evidentno je da ADRC algoritam, u poređenju sa PI/PID pristupom, postiže bolje performanse praćenja u prisustvu svih analiziranih tipova poremećaja proklizavanja. Zapravo, u slučaju step poremećaja proklizavanja, oba algoritma uspevaju da minimizuju greške praćenja, ali ADRC pokazuje bolje prelazne karakteristike, posebno u praćenju definisane referentne longitudinalne greške. Slični rezultati uočeni su i pri linearno promenljivim poremećajima proklizavanja (treći interval), pri čemu



Slika 3.33: Rezultati simulacije (za scenario #2).

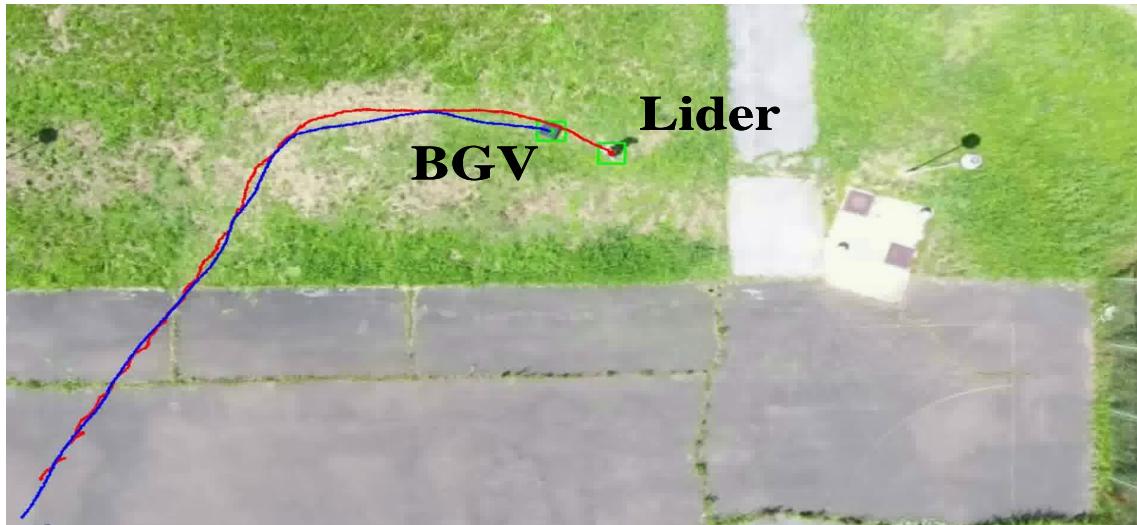
ADRC ostvaruje značajno manje vrednosti integrala apsolutnih grešaka. Prednosti ADRC algoritma potvrđene su i u četvrtom intervalu, gde ADRC postiže niže vrednosti amplitude grešaka i integrale apsolutnih grešaka.

3.4.4.2 Eksperimentalna validacija autonomnog praćenja lidera

Da bi se procenila performansa razvijenog algoritma za praćenje lidera od strane laboratorijskog BGV-a, izvedeni su eksperimenti sa ljudskim liderom na poligonu sa asfaltnom i zemljanim podlogom. Longitudinalni i lateralni ADRC regulatori su podešeni kao u poglavlju 3.4.4.1, a diskretizacija je izvršena sa periodom odabiranja $T_s = 0.2$ s, što odgovara unapred definisanoj brzini slanja podataka vozila putem WiFi modula. Tokom eksperimenata, ljudski lider se kretao ispred BGV-a, zauzimajući različite pozicije i izdavajući komande za kretanje BGV-a. U poslednjem intervalu (između 65 i 80 sekundi), lider zauzima položaj u čučnju kako bi generisao signal za zaustavljanje BGV-a, a zatim lider podiže levu i desnu ruku kao komandu za BGV da se kreće od lidera i ka lideru, respektivno. Eksperimentalna postavka, prikazana iz ptičje perspektive i sa kamerom montiranom na na laboratorijskom BGV, prikazana je na slici 3.34.

Tabela 3.2: Integrali apsolutne lateralne greške i apsolutne razlike između referentne i dobijene longitudinalne greške za sisteme sa PID i ADRC regulatorima u simulacionom scenariju #2.

	Prvi interval (od 0 do 15 s)		Drugi interval (od 15 do 30 s)		Treći interval (od 30 do 45 s)		Četvrti interval (od 45 do 60 s)	
	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$	e_d	$e_{s(e)}$
PID	0.0451	11.3195	0.8716	2.0132	0.7671	2.8979	4.9933	2.0054
ADRC	0.0377	11.5815	0.7485	0.9617	0.6920	1.6281	2.8620	1.3692



(a) Pogled iz ptičje perspektive



(b) Pogled iz ptičje perspektive (uvećano)

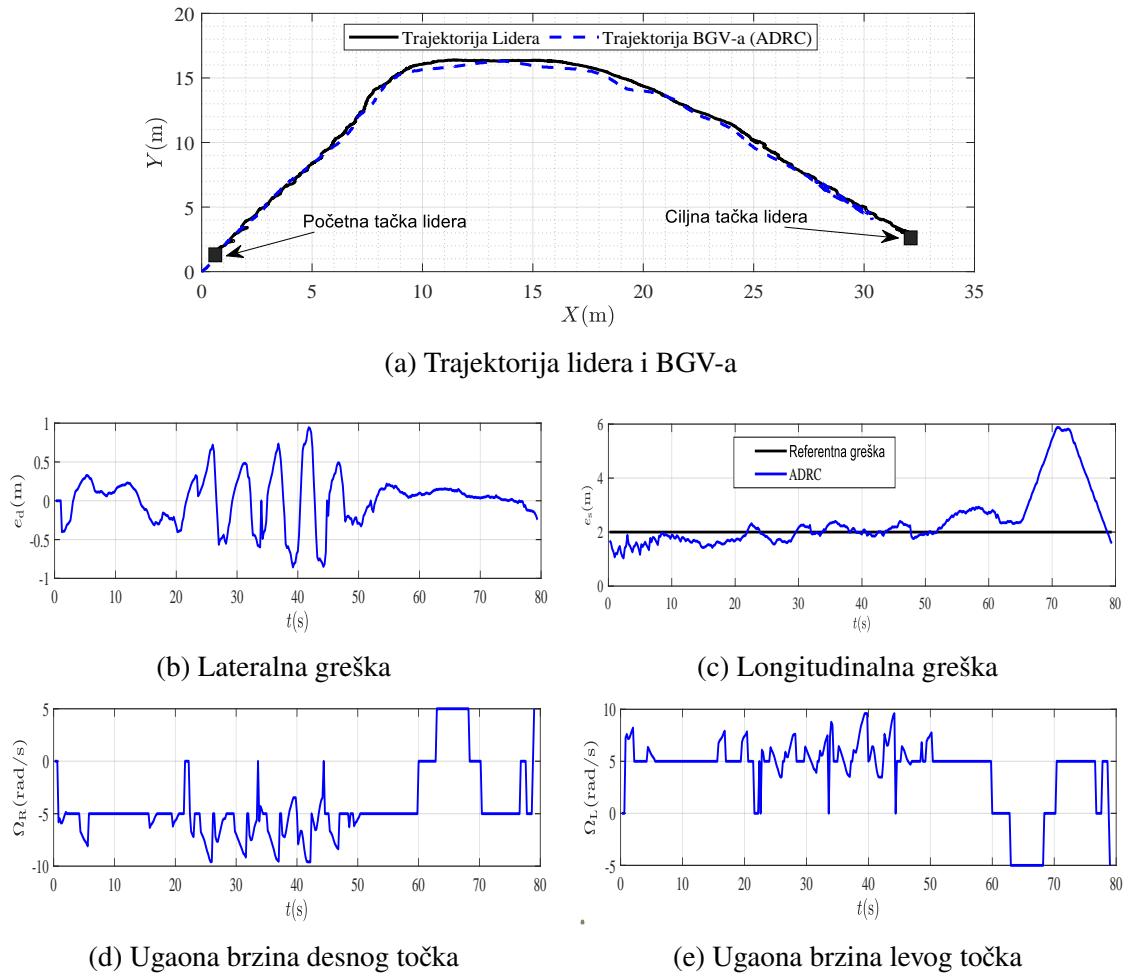


(c) Pogled sa kamere montirane na BGV

Slika 3.34: Eksperimentalna postavka zadatka autonomnog praćenja lidera.

Grafički prikaz dobijenih rezultata, koji uključuju trajektorije lidera i BGV-a, odgovarajuće lateralne i longitudinalne greške, kao i ugaone brzine pogonskih točkova BGV-a, prikazani su na slici 3.35.

Na osnovu dobijenih rezultata može se videti da BGV demonstrira robusne sposobnosti detekcije i praćenja kretanja lidera na asfaltu i neravnom terenu, minimizirajući lateralnu grešku i održavajući longitudinalnu grešku na željenoj distanci. Kao što se očekivalo, greške su se povećale kada se BGV prebacio na neravni teren (otprilike od 20 do 50 sekundi) zbog značajno veće dinamike proklizavanja na takvom terenu. Ipak, može se



Slika 3.35: Eksperimentalni rezultati autonomnog praćenja lidera.

videti da su vršne vrednosti grešaka bliske onima dobijenim kroz simulacionu analizu.

Ugaone brzine desnog i levog točka pokazuju sinhronizovane obrasce, što ukazuje na uravnoteženo kretanje BGV-a tokom celog eksperimenta, kao što je prikazano na slikama 3.35d i 3.35e. Uočene su male varijacije u ugaonim brzinama točkova tokom neravnog terena, što odražava prilagođavanje BGV-a neravnoj površini. Pored toga, performanse predloženog podsistema za prepoznavanje poze ljudskog lidera ocenjene su u završnom delu eksperimenta (od 65 do 80 sekundi), gde se BGV prvo zaustavlja kada lider zauzme položaj u čučnju, a zatim se pomera unazad, tj. povećava longitudinalnu grešku, kada lider podigne levu ruku (od 65 do 70 sekundi), i pomera se napred, tj. smanjuje longitudinalnu grešku, kada lider podigne desnu ruku (od 73 do 80 sekundi).

Generalno se može zaključiti da je u projektovani sistem autonomnog praćenja lidera na bazi ADRC regulator pokazao visoke performanse u uslovima uticaja poremećaja, održavajući stabilno praćenje uprkos proklizavanju izazvanom terenom i dinamičkim pokretima lidera. Simulacioni rezultati pokazali su smanjenje lateralne greške u poređenju sa PID regulatorom pod sinusoidalnim poremećajima proklizavanja, dok su testovi u realnom svetu potvrdili ove nalaze na neravnom terenu. Sposobnost sistema da interpretira

Ljudske gestove (npr. komande zaustavi/nazad) dodatno je naglasila njegovu primenljivost u praktičnim primenama.

Demonstrirana efikasnost ADRC regulatora u ovom poglavlju zasnivala se na pažljivo odabranim i konstantnim vrednostima ključnih parametara, kao što su propusni opsezi regulatora i observera. Dok ovaj pristup pruža značajnu robusnost, konstantni parametri možda neće biti odgovarajući u čitavom spektru mogućih radnih uslova sa kojima se BGV može susresti, uključujući drastične promene u dinamici lidera, uslovima zahtevnog terena ili značajnog nivou šuma merenja. Stoga, naredno poglavlje istražuje metode za automatsko, adaptivno podešavanje ključnih ADRC parametara u realnom vremenu, koristeći tehnike dubokog učenja sa podrškom (eng. Deep Reinforcement Learning, DRL), sa ciljem daljeg unapređenja performanse BGV-a, posebno u zahtevnim zadacima autonomnog kretanja.

Poglavlje 4

Projektovanje adaptivnog ADRC upravljanja na bazi učenja sa podrškom za BGV

Prethodna poglavlja disertacije su detaljno opisala projektovanje i validaciju sistema upravljanja zasnovanog na konceptu ADRC-a u zadacima autonomnog kretanja BGV. Rezultati su pokazali efikasnost ADRC pristupa, koja se ogleda u mogućnosti procene i potiskivanja svih poremećaja sistema, uključujući nelinearnosti i nestacionarnosti modela, kao i spoljašnje uticaje poput proklizavanja gusenica. Međutim, razmatrani ADRC regulatori koristili su konstantne vrednosti parametara, konkretno propusnog opsega regulatora (ω_{CL}) i proširenog obesverva stanja (ω_{ESO}), koji su podešeni empirijski primenom tehnike parametrizacije propusnog opsega [29]. Iako ovaj pristup sa konstantnim parametrima daje zadovoljavajuće performanse, očekivano je da on neće dati optimalne rezultate u uslovima značajnih promena brzine lidera, neočekivanih manevra, promenljivih uslova terena koji uzrokuju nepredvidivo proklizavanje gusenica, kao i postojanja značajnijeg šuma merenja senzorskih sistema. Stoga se aktuelna istraživanja fokusiraju na razvoj metoda za adaptivno online podešavanje parametara kako bi se postigla adaptacija regulatora na različite poremećaje.

U naučnoj literaturi mogu se naći različiti pristupi za rešavanje analiziranog problema. Tako na primer, heuristički algoritmi, kao što su optimizacija na bazi rojeva (eng. Particle Swarm Optimizatio, PSO) [181] i genetski algoritam (eng. Genetic Algorithm, GA) [182] pokazali su svoju efikasnost u optimizaciji konstantnih parametara. Iako popularni, ovi algoritmi zahtevaju velike računarske resurse, teško se adaptiraju u nepredviđenim okruženjima, često ostaju zarobljeni u lokalnim optimumima i daju samo konstantan skup optimalnih parametara regulatora [183]. Alternativni pristupi koji uključuju NN [184], FLC [185] i adaptivno upravljanje [186], pružaju određeni stepen adaptacije parametara. NN algoritmi imaju prednost u računskoj efikasnosti, ali im nedostaju sposobnosti dono-

šenja odluka, dok efikasnost FLC u velikoj meri zavisi od tačnih informacija o modelu. Iako je adaptivno upravljanje teoretski robusno, njegova složenost je često prepreka za primenu u realnim inženjerskim zadacima [183].

Da bi se prevazišla ova ograničenja i dodatno poboljšala adaptivnost i performanse sistema upravljanja BGV-om, ova disertacija istražuje primenu strategije adaptivnog podešavanja parametara ADRC regulatora, korišćenjem tehnika DRL, konkretno algoritma DDPG, za kontinualno prilagođavanje propusnih opsega ADRC regulatora (ω_{CL} i ω_{ESO}) u realnom vremenu.

RL algoritam je pogodan za rešavanje problema sekvencijalnog donošenja odluka bez potrebe za detaljnim modelima sistema [183]. Posmatrajući podešavanje parametara kao sekvencijalni proces, RL donosi kontinualne odluke na osnovu trenutnog stanja sistema kako bi pronašao optimalne parametre upravljanja [187]. Ovo je posebno korisno za BGV, gde se dinamika sistema može brzo i nepredvidivo menjati. Kombinovanjem RL-ove sposobnosti donošenja odluka sa računskim prednostima neuronskih mreža, tehnika DRL unapređuje interakciju u realnom vremenu i adaptivno podešavanje, procesuiranjem velikih količina podataka i optimizacijom parametara regulatora u kompleksnim dinamičkim okruženjima [188]. Naime, motivacija za korišćenje DRL-a, a posebno DDPG-a, proizilazi iz njegove sposobnosti da uči optimalne politike upravljanja kroz interakciju sa okruženjem, bez potrebe za preciznim matematičkim modelom sistema ili poremećaja [187, 188]. Među različitim DRL algoritmima, kao što su DQN (eng. Deep Q Network, DQN), TD3 (eng. Twin Delayed Deep Deterministic Policy Gradient) i SAC (eng. Soft Actor-Critic), DDPG je ocenjen kao najpogodniji za zadatak upravljanja BGV iz sledećih razloga: 1) DDPG podržava kontinualna stanja i akcije, dok je DQN ograničen na diskretna stanja; 2) DDPG-ova deterministička politika poboljšava efikasnost odabiranja i stabilizuje učenje za BGV sisteme, dok TD3 može imati problem potcenjivanja (eng. underestimation bias) [188]; 3) DDPG postiže balans između performansi i računske efikasnosti, što je ključno za primenu u realnim aplikacijama; 4) *Actor-critic* struktura DDPG algoritma, koja koristi dve odvojene neuronske mreže - za funkciju politike (*actor*) i Q funkciju (*critic*) [22, 189, 190], omogućava efikasnije i stabilnije učenje u kontinualnim akcionim prostorima u poređenju sa drugim DRL metodama.

Shodno prethodnom, ideja ovog istraživanja je da DDPG agent nauči optimalnu politiku za podešavanje ključnih ADRC parametara (ω_{ESO} i ω_{CL}) na osnovu trenutnog stanja sistema (npr. greške praćenja, upravljačkog signala) i signala nagrade koji kvantifikuje performanse upravljanja. Na ovaj način, ADRC regulator može dinamički da prilagodi svoje karakteristike kako bi održao visoke performanse praćenja lidera uprkos promenama u dinamici lidera, uslovima proklizavanja gusenica i prisustvu mernog šuma.

Poslednjih godina, integracija DRL sa upravljačkim strategijama privukla je značajnu pažnju. Na primer, [191] razvili su DRL model za upravljanje brzinom tokom praćenja vozila, koristeći funkciju nagrade zasnovanu na podacima ljudske vožnje. Iako je njihov

model pokazao bolje performanse od ljudskih vozača u pogledu vremena do kolizije (eng. time-to-collision) i održavanja rastojanja, bio je ograničen samo na longitudinalno upravljanje. Slično, [192] predstavlja determinističku RL metodu za longitudinalno upravljanje brzinom autonomnih vozila. Iako su postigli stabilnost i efikasnost kroz unapređenu evaluaciju politike, potvrđenu eksperimentima sa stvarnim vozilima, ova studija nije obuhvatila kombinovano lateralno i longitudinalno upravljanje neophodno za složene zadatke praćenja trajektorija. S druge strane, [193] predlaže DRL-baziranu politiku donošenja odluka za autonomna vozila za rešavanje problema pri preticanju na autoputevima. Njihov hijerarhiski upravljački okvir, kombinovan sa DDQN (eng. Dueling Deep Q-Network) algoritmom, omogućio je efikasne manevre vozila u zadatku preticanja. U radu [194], upoređeni su DRL algoritmi (DQN i DDPG) za upravljanje autonomnim vozilima u simuliranim urbanim sredinama korišćenjem CARLA platforme [195]. Ostvareni rezultati su pokazali bolje performanse DDPG-a u zadacima vođenja. Primena DRL-baziranog ADRC regulatora za praćenje putanje pod dejstvom spoljašnjih poremećaja analizirana je u [187]. Predložili su RL-ADRC algoritam za upravljanje nelinearnim sistemima čiji je model delimično poznat, koristeći *actor-critic* mrežu za aproksimaciju optimalne upravljačke strategije. U drugu ruku, [2] predstavlja DDPG-pomoći regulator zasnovan na ADRC-u za autonomno vozilo sa 3 stepena slobode. Primenjen je DDPG za postizanje adaptivnog podešavanja upravljačkih parametara u realnom vremenu za probleme praćenja putanje, gde su demonstrirana potencijalna kombinovanja DDPG-a sa ADRC-om. Međutim, treba istaći da ovi pristupi nisu direktno primenljivi na raznovrsnija i nepredvidivija okruženja sa kojima se susreću BGV platforme, posebno u scenarijima autonomnog praćenja lidera.

Iako su ovi pristupi pokazali poboljšane performanse u kompleksnim okruženjima, kao što su pomorski i vazdušni konteksti, i istakli efikasnost kombinovanja DDPG-a sa ADRC-om, njihova praktična primena na BGV sisteme je i dalje ograničena na rad u laboratorijskim uslovima.

U okviru ovog poglavlja nadograđuje se implementacija ADRC regulatora sa konstantnim parametrima uvodeći DDPG mehanizam adaptivnog podešavanja parametara. U nastavku je prvo data osnovna struktura DRL i DDPG algoritma, zatim je detaljno opisana integracija DDPG-a za adaptivno podešavanje lateralnog i longitudinalnog ADRC regulatora, uključujući definiciju stanja, akcija, nagrada i arhitekturu mreže, a nakon toga su predstavljeni simulacioni rezultati koji potvrđuju prednosti predloženog ADRC-DDPG pristupa za zadatak autonomnog praćenja lidera u poređenju sa ADRC-om sa konstantnim parametrima.

4.1 Osnove učenja sa podrškom

Da bismo objasnili osnovnu ideju RL-a, neophodno je prvo definisati najvažnije elemente u procesu učenja. Donosilac odluka u procesu RL-a naziva se agent, dok se okolina

koja komunicira sa agentom naziva okruženje. U svakom diskretnom trenutku t , okruženje može biti u određenom stanju s_t , koje pripada ograničenom skupu mogućih stanja $S = [s_1, s_2, \dots, s_n]$. Agent odlučuje o akciji a_t koju će preuzeti, iz ograničenog skupa akcija $A = [a_1, a_2, \dots, a_n]$, dostupnih u stanju s_t . Okruženje reaguje na akciju agenta pružajući povratnu informaciju. Ova povratna informacija uključuje novo stanje okruženja s_{t+1} i numeričku nagradu (dobitak) r_{t+1} za preuzetu akciju [196, 197].

Na osnovu vrednosti nagrade, okruženje daje informaciju agentu o korisnosti akcija koje preuzima. Zadatak agenta je pronalaženje optimalne politike π^* , odnosno akcija koje treba preuzeti u svakom stanju, tako da se maksimizuje akumulirana diskontovana nagrada [198]:

$$R_t = \sum_{i=t}^T \gamma^{i-t} r(s_i, a_i), \quad (4.1)$$

gde $\gamma \in [0, 1]$ predstavlja faktorom obezvređivanja (eng. discount factor) koji određuje važnost budućih nagrada, a T predstavlja vreme trajanja epizode obuke [196]. Proces obuke agenta se realizuje u interakciji sa okruženjem na bazi metode pokušaja i pogrešaka kroz veliki broj iteracija [198].

Da bi agent mogao da doneše odluku koju akciju odabratи u određenom trenutku, važno je da proceni kvalitet trenutnog stanja u kojem se nalazi. Ovaj proces se postiže putem funkcije vrednosti stanja $V^\pi(s_t)$, koja se definiše kao očekivana akumulirana nagrada koju bi agent dobio ako nastavi da prati politiku π iz stanja s :

$$V^\pi(s_t) = \mathbb{E}[R_t | s = s_t, \pi]. \quad (4.2)$$

Slično tome, vrednost akcije u stanju za datu politiku π , označena kao akciona vrednost ili Q -funkcija, može se definisati kao očekivana akumulirana nagrada koja se postiže delovanjem akcijom a u stanju s , prateći politiku π :

$$Q^\pi(s_t, a_t) = \mathbb{E}[R_t | s = s_t, a = a_t, \pi]. \quad (4.3)$$

Očekivana nagrada $J(\pi)$ je funkcija evaluacije politike π definisana kao:

$$J(\pi) = \mathbb{E}[R_t | \pi]. \quad (4.4)$$

Politika π se smatra optimalnom ($\pi^*(a_t | s_t)$) kada bira akciju a^* za dato stanje s_t koja daje maksimalnu vrednost Q -funkcije. Ovo se može matematički izraziti kao:

$$a^* = \operatorname{argmax}_{a_t} Q^\pi(s_t, a_t). \quad (4)$$

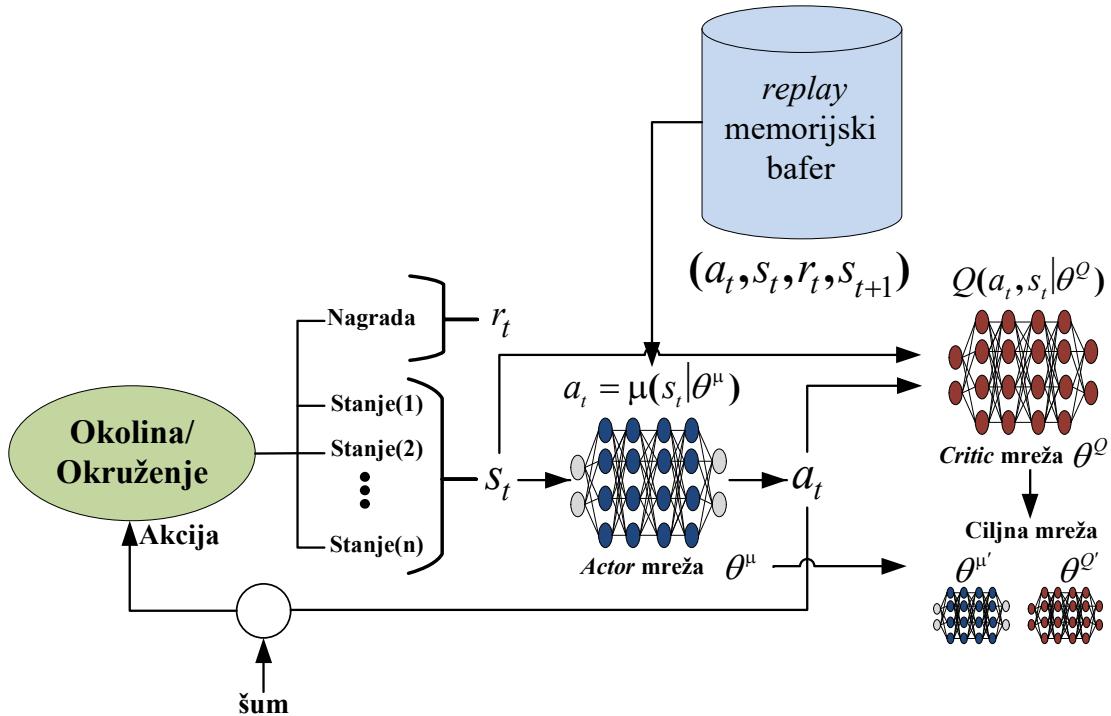
S obzirom da ovaj rad analizira problem podešavanja parametara ADRC-a za upravljanje BGV-om u zadatku autonomnog praćenja lidera, primenjuje se kontinualna repre-

zentacija stanja i akcija. Politika π je deterministički definisana korišćenjem neuronskih mreža (DRL), primenom DDPG algoritma.

4.2 Algoritam sa determinističkim učenjem na bazi građijenta (DDPG)

DDPG [22, 191, 199] spada u grupu *actor-critic* algoritama, koji koristi teoremu o determinističkom gradijentu za ažuriranje funkcije politike. DDPG omogućava obučavanje kontinualne aproksimacije Q -funkcije (4.3) pomoću *critic* neuronskih mreža parametriзовanih sa θ^Q i politike π korišćenjem *actor* neuronskih mreža parametrizovanih sa θ^μ , kao što je prikazano na slici 4.1.

Actor mreža obrađuje trenutno stanje okruženja i proizvodi akciju u kontinualnom prostoru stanja-akcija. Istovremeno, *critic* mreža procenjuje efikasnost *actor*-a izračunavanjem Q -vrednosti. Ovo se postiže uzimajući u obzir i trenutno stanje okruženja i akciju *actor*-a. Ova konfiguracija omogućava *critic*-u da proceni koliko su dobre odluke *actor*-a.



Slika 4.1: Struktura DDPG algoritma (zasnovano na izvornom materijalu [2]).

Shodno tome, parametri θ^Q *critic* neuronske mreže mogu se optimizovati funkcijom gubitka na sledeći način:

$$L(\theta^Q) = \mathbb{E}[(y_t - Q(s_t, a_t | \theta^Q))^2], \quad (4.5)$$

gde je $y_t = r(s_t, a_t) + \gamma Q(s_{t+1}, a_{t+1} | \theta^Q)$.

Funkcija *actor*-a, označena kao $\mu(s | \theta^\mu)$, preslikava stanja u akcije. Ova funkcija je implementirana kao neuronska mreža, čiji se parametri podešavaju da optimizuju očekivanu kumulativnu nagradu, predstavljenu sa $J(\pi)$. Proces ažuriranja ove mreže može se izraziti na sledeći način:

$$\nabla_{\theta^\mu} J(\pi) = \mathbb{E} \left[\nabla_a Q(s, a | \theta^Q) \Big|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s | \theta^\mu) \Big|_{s=s_i} \right]. \quad (4.6)$$

Treba napomenuti da su u zadatku povećanja stabilnosti algoritma uključene još dve pomoćne neuronske mreže (ciljne) sa istom strukturom kao *actor* i *critic*, označene na slici 4.1 kao $\theta^{\mu'}$ i $\theta^{Q'}$.

U praksi se uvodi slučajni poremećaj u svaku akciju kako bi se promovisalo istraživanje. Nestabilnost algoritma tokom obuke, kao i kovarijansa između podataka prikupljenih tokom jedne epizode u okruženju, rešavaju se korišćenjem replay memorijskog bafera (eng. replay memory buffer).

Sistem čuva svaku tranziciju (s_t, a_t, r_t, s_{t+1}) u replay baferu nakon izvršavanja akcije. *Critic* mreža se ažurira na osnovu (4.7) korišćenjem mini-grupe (eng. minibatch) uzoraka iz replay bafera, gde je F veličina mini-grupe.

$$L(\theta^Q) = \left(\frac{1}{F} \right) \cdot \sum_{i=1}^F (y_i - Q(s_i, a_i | \theta^Q))^2, \quad (4.7)$$

gde $y_i = r_i + \gamma Q'(s_{i+1}, \mu'(s_{i+1} | \theta^{\mu'}) | \theta^{Q'})$. Ova procena se dobija pomoću ciljnih mreža: ciljne *critic* mreže, čiji izlaz označavamo sa $Q'(s, a | \theta^{Q'})$, i ciljne *actor* mreže, čiji izlaz označavamo sa $\mu'(s | \theta^{\mu'})$, pri čemu $\theta^{\mu'}$ i $\theta^{Q'}$ predstavljaju parametre ciljnih mreža.

Parametri *actor* mreže se podešavaju za svaki korak na sledeći način:

$$\nabla_{\theta^\mu} J \approx \frac{1}{F} \sum_i \nabla_a Q(s, a | \theta^Q) \Big|_{s=s_i, a=\mu(s_i)} \nabla_{\theta^\mu} \mu(s | \theta^\mu) \Big|_{s_i}. \quad (4.8)$$

Zatim se ciljne mreže mogu ažurirati kao:

$$\begin{aligned} \theta^{Q'} &= \tau \theta^Q + (1 - \tau) \theta^{Q'}, \\ \theta^{\mu'} &= \tau \theta^\mu + (1 - \tau) \theta^{\mu'}, \end{aligned} \quad (4.9)$$

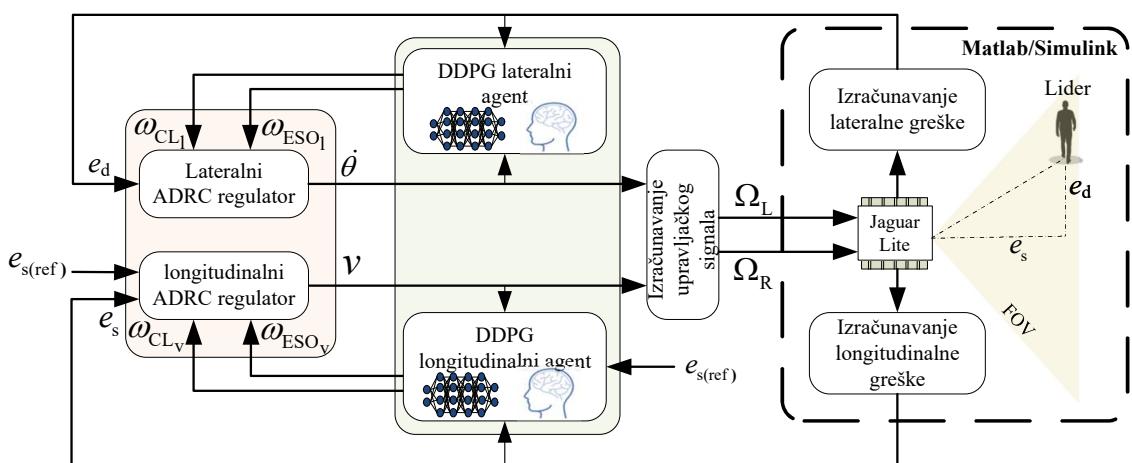
gde je $\tau \ll 1$. Kada ciljne mreže konvergiraju nakon dovoljno obuke, mogu se koristiti za rešavanje problema.

4.3 Adaptivno podešavanje ADRC regulatora korišćenjem DDPG algoritma za praćenje lidera

U ovom poglavlju predstavljeno je projektovanje upravljanja BGV sa adaptivnim podešavanjem propusnih opsega ADRC regulatora, korišćenjem DDPG algoritma, na osnovu trenutnog stanja sistema kako bi se optimizovale performanse autonomnog praćenja lidera, specifično minimiziranjem grešaka praćenja (e_d i $e_{s(e)} = e_{s(\text{ref})} - e_s$).

Struktura projektovanog sistema upravljanja sa DDPG algoritmom za podešavanje propusnih opsega regulatora i observera u lateralnom i longitudinalnom kanalu prikazana je na slici 4.2. Kao što se može videti, projektovana su i obučena dva odvojena DDPG agenata, jedan za podešavanje parametara lateralnog ADRC regulatora i jedan za podešavanje parametara longitudinalnog ADRC regulatora.

Svaki DDPG agent posmatra relevantno stanje BGV sistema, određuje optimalne ADRC parametre (akcije) za trenutnu situaciju i prima nagradu zasnovanu na rezultirajućim performansama praćenja. Okruženje BGV obezbeđuje stanja i nagrade, dok agenti generišu propusne opsege ADRC regulatora. Ove vrednosti se koriste za dinamičko podešavanje pojačanja regulatora: lateralna pojačanja ($k_{1_l}, k_{2_l}, l_{1_l}, l_{2_l}, l_{3_l}$) i longitudinalna pojačanja ($k_{1_v}, l_{1_v}, l_{2_v}$), prema metodi parametrizacije propusnog opsega (Jed. 3.24, 3.26, 3.35). ADRC regulator zatim izračunava neophodne upravljačke signale $\dot{\theta}(t)$ i $v(t)$ na osnovu $e_d(t)$, $e_{s(e)}(t)$ i adaptivnih vrednosti parametara.



Slika 4.2: Struktura sistema za autonomno praćenje lidera od strane BGV na bazi ADRC zasnovanog na DDPG algoritmu za podešavanje parametara.

Komponente DDPG okvira za svakog agenta definisane su u nastavku.

4.3.1 Definicija prostora stanja i akcija

4.3.1.1 Lateralni agent

- **Stanje (s_l):** stanje koje lateralni agent posmatra u trenutku t obuhvata: (i) trenutnu lateralnu grešku ($e_d(t)$), (ii) ugaonu brzinu BGV ($\dot{\theta}(t)$) koja predstavlja izlaz lateralnog ADRC regulatora, i (iii) ugaono ubrzanje BGV ($\ddot{\theta}(t)$) kao brzinu promene upravljačkog izlaza. Matematički se stanje može predstaviti kao $s_l(t) = [e_d(t), \dot{\theta}(t), \ddot{\theta}(t)]$.

Lateralna greška $e_d(t)$ dobija se iz sistema za vođenje (Pododeljak 3.3.2.5), dok je $\dot{\theta}(t)$ izlaz lateralnog ADRC regulatora. Ugaono ubrzanje $\ddot{\theta}(t)$ se dobija diferenciranjem upravljačkog izlaza.

- **Akcija (a_l):** akcija lateralnog agenta predstavlja izbor propusnih opsega ADRC regulatora za lateralni kanal, gde je $a_l(t) = [\omega_{CL_l}(t), \omega_{ESO_l}(t)]$. Prva komponenta $\omega_{CL_l}(t)$ predstavlja propusni opseg lateralnog regulatora u zatvorenoj petlji, dok $\omega_{ESO_l}(t)$ označava propusni opseg lateralnog ESO observera.

4.3.1.2 Longitudinalni agent

- **Stanje (s_v):** stanje longitudinalnog agenta obuhvata: (i) trenutnu longitudinalnu grešku u odnosu na referentnu distancu ($e_{s(e)}(t) = e_{s(\text{ref})}(t) - e_s(t)$), (ii) longitudinalnu brzinu BGV ($v(t)$) kao izlaz longitudinalnog ADRC regulatora, i (iii) longitudinalno ubrzanje BGV ($\dot{v}(t)$) koje predstavlja brzinu promene upravljačkog izlaza. Matematički zapisano: $s_v(t) = [e_{s(e)}(t), v(t), \dot{v}(t)]$.

Longitudinalna greška $e_s(t)$ dobija se iz sistema za vođenje (Pododeljak 3.3.2.5)), dok $v(t)$ predstavlja izlaz longitudinalnog ADRC regulatora.

- **Akcija (a_v):** akcija longitudinalnog agenta sastoji se u izboru propusnih opsega ADRC regulatora za longitudinalni kanal, definisanih kao $a_v(t) = [\omega_{CL_v}(t), \omega_{ESO_v}(t)]$.

4.3.2 Projektovanje funkcije nagrađivanja

Funkcije nagrade imaju ključnu ulogu u usmeravanju procesa učenja. Projektovane su tako da podstiču precizno praćenje reference, dok istovremeno kažnjavaju prekomeren upravljački napor i brze promene upravljačkih signala. Promenljive stanja koje se koriste u izračunavanju nagrade skaliraju se na interval [-10, 10] kako bi se normalizovao njihov uticaj.

4.3.2.1 Nagrada lateralnog agenta $R_l(t)$

Funkcija nagrade za lateralnog agenta projektovana je da minimizira lateralnu grešku praćenja e_d , napor upravljanja $\dot{\theta}$ i brzinu promene napora upravljanja $\ddot{\theta}$. Takođe uključuje dodatne članove za održavanje malih grešaka i glatkog upravljanja, kao i granični uslov koji prekida epizodu učenja ako greška pređe definisani prag. Shodno tome može se predstaviti u obliku:

$$R_l(t) = w_{l_1} \cdot R_{l_1}(t) + w_{l_2} \cdot R_{l_2}(t) + w_{l_3} \cdot R_{l_3}(t), \quad (4.10)$$

gde su pojedinačne komponente definisane na sledeći način:

$$\begin{cases} R_{l_1}(t) = -|e_d(t)| - 0.025 \cdot \dot{\theta}(t)^2 - 0.25 \cdot |\ddot{\theta}(t)| & \text{(osnovna komponenta kažnjavanja),} \\ R_{l_2}(t) = \begin{cases} 1, & \text{if } |e_d(t)| < 0.5 \\ 0.5, & \text{if } \dot{\theta}(t)^2 < 20 \\ 0.5, & \text{if } |\ddot{\theta}(t)| < 2 \end{cases} & \text{(dodatni član),} \\ R_{l_3}(t) = 0.2 \cdot (1 - H) - H, \text{ where } \begin{cases} H = 0, & \text{if } |e_d(t)| < 10 \\ H = 1, & \text{otherwise} \end{cases} & \text{(granični uslov).} \end{cases}$$

Član R_{l_1} kažnjava velike greške i napore upravljanja, R_{l_2} daje diskretne nagrade za ostanak unutar željenih granica greške/napora i R_{l_3} nameće značajnu kaznu ako greška pređe definisane limite (što prekida epizodu). Težinski faktori $w_{l_1}, w_{l_2}, w_{l_3}$ postavljeni su na vrednost 1. U slučaju da poprečna greška $|e_d(t)|$ dostigne ili pređe vrednost 10 (što odgovara graničnom uslovu $H = 1$), trenutna epizoda obuke se prekida.

4.3.2.2 Nagrada Longitudinalnog Agenta $R_v(t)$

Funkcija nagrade za longitudinalnog agenta projektovana je da minimizira longitudinalnu grešku $e_{s(e)}$, napor upravljanja v i brzinu promene napora upravljanja \dot{v} , i ima oblik:

$$R_v(t) = w_{v_1} \cdot R_{v_1}(t) + w_{v_2} \cdot R_{v_2}(t) + w_{v_3} \cdot R_{v_3}(t), \quad (4.11)$$

gde su pojedinačne komponente definisane na sledeći način:

$$\begin{cases} R_{v_1}(t) = -0.75 \cdot |e_{s(e)}(t)| - 0.025 \cdot v(t)^2 - 0.25 \cdot |\dot{v}(t)| & \text{(osnovna komponenta kažnjavanja),} \\ R_{v_2}(t) = \begin{cases} 1, & \text{if } |e_{s(e)}(t)| < 1 \\ 0.5, & \text{if } v(t)^2 < 30 \\ 0.5, & \text{if } |\dot{v}(t)| < 2 \end{cases} & \text{(dodatni član),} \\ R_{v_3}(t) = 0.2 \cdot (1 - F) - F, \text{ where } \begin{cases} F = 0, & \text{if } |e_{s(e)}(t)| < 10 \\ F = 1, & \text{otherwise} \end{cases} & \text{(granični uslov),} \end{cases}$$

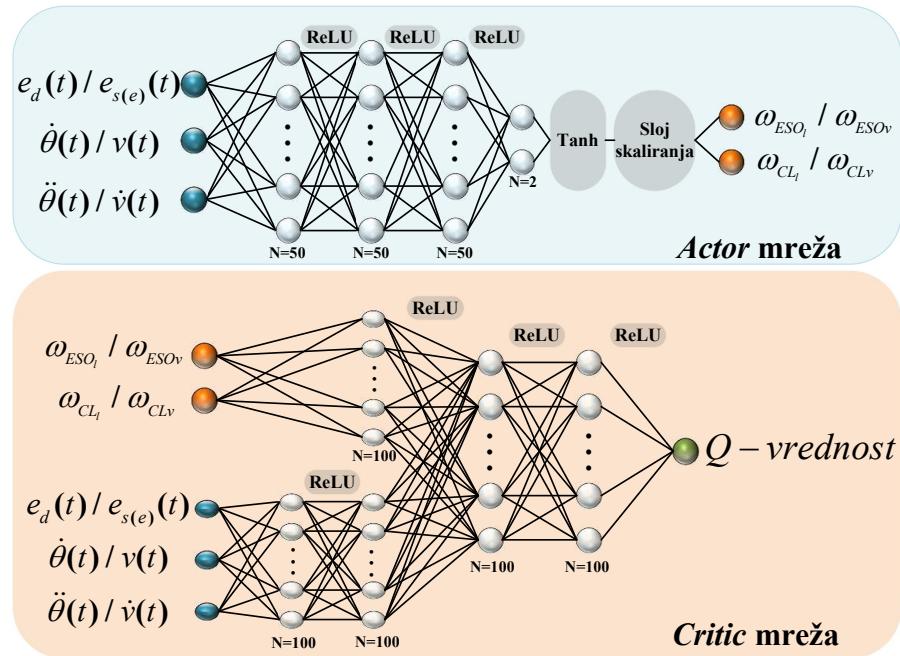
gde R_{v_1} , R_{v_2} i R_{v_3} imaju slične uloge kao komponente lateralne nagrade, ali su specifične za upravljanje longitudinalnim greskama. Težine w_{v_1} , w_{v_2} , w_{v_3} su takođe postavljene na 1. Ako $|e_{s(e)}(t)| \geq 10$ (granični uslov $F = 1$), epizoda obuke se prekida.

4.3.3 Arhitektura mreže i proces obučavanja

4.3.3.1 Arhitektura mreže

Projektovani lateralni i longitudinalni DDPG agenti koriste istu *actor-critic* arhitekturu prikazanu na slici 4.3, sa N neurona po sloju.

- **Actor mreža ($\mu(s|\theta^\mu)$)**: prima stanje (s_l za lateralno ili s_v za longitudinalno upravljanje) i generiše akciju (a_l ili a_v). Skriveni slojevi koriste ReLU (eng. Rectified Linear Unit, $f(x) = \max(0, x)$), aktivacionu funkciju, dok izlazni sloj koristi tanh (eng. Hyperbolic Tangent) funkciju ograničenu na $[-1, 1]$, nakon čega blok skaliranja prilagođava opseg parametara.
- **Critic mreža ($Q(s, a|\theta^Q)$)**: prima i stanje (s_l ili s_v) i akciju (a_l ili a_v) kao ulaz, i vraća skalarnu Q-vrednost $Q(s_t, a_t)$. Takođe koristi ReLU aktivacione funkcije u skrivenim slojevima.



Slika 4.3: Actor-critic network structure for the DDPG agent.

4.3.3.2 Proces obučavanja

Proces obučavanja DDPG algoritma obuhvata sledeće ključne komponente:

- *Replay bafer*: sačuvane tranzicije (s_t, a_t, r_t, s_{t+1}) koje agent doživi. Tokom obuke, nasumično se biraju mini-grupe (eng. minibatch) iz bafera za ažuriranje mreža, što smanjuje vremenske korelacije i povećava efikasnost korišćenja podataka.
- Ciljne mreže: posebne mreže za *actor*-a ($\mu'(s|\theta^{\mu'})$) i *critic*-a ($Q'(s, a|\theta^{Q'})$), koje se sporo ažuriraju:

$$\begin{aligned}\theta^{Q'} &= \tau\theta^Q + (1 - \tau)\theta^{Q'}, \\ \theta^{\mu'} &= \tau\theta^{\mu} + (1 - \tau)\theta^{\mu'},\end{aligned}\tag{4.12}$$

gde τ predstavlja stopu ažuriranja.

- Šum istraživanja: Ornstein-Uhlenbeck ili Gausov šum se dodaje izlazu *actor*-a tokom faze obuke kako bi se podstaklo istraživanje prostora akcija.
- Ažuriranja mreža:
 - *Critic*: ažurira se minimizacijom funkcije gubitka (Jednačina 4.7)
 - *Actor*: ažurira se korišćenjem gradijenta politike (Jednačina 4.8)

4.3.3.3 Hiperparametri mreže

Hiperparametri (parametri postavljeni pre procesa obučavanja) za predložene DDPG agente prikazani su u tabeli 4.1. Odabir hiperparametara zasniva se na kombinaciji postojećih uspešnih implementacija iz literature i empirijskog podešavanja putem pokušaja i grešaka. Za izlazne vrednosti akcija definisani su specifični opsegi kako bi se omogućilo efikasno podešavanje tokom obuke.

Parametri propusnih opsega ω_{CL_l} i ω_{CL_v} postavljeni su u opseg [5, 9] rad/s. Odgovarajući propusni opsezi za ESO iznose [40, 90] rad/s (ω_{ESO_l} za lateralni i ω_{ESO_v} za longitudinalni sistem). Ovi opsezi odabrani su na osnovu analize očekivane varijabilnosti terena i nivoa spoljašnjih poremećaja karakterističnih za BGV. Gornje granice opsega (9 rad/s za regulatore i 90 rad/s za observee) odgovaraju najzahtevnijim radnim uslovima, dok donje granice (5 odnosno 40 rad/s) odgovaraju nominalnim uslovima rada.

Propusni opseg regulatora ω_{CL} određuje fundamentalni kompromis između brzine odziva sistema i njegove robustnosti na nestacionarnosti modela. S druge strane, propusni opseg proširenog observera stanja ω_{ESO} balansira između efikasnosti otklanjanja poremećaja i osetljivosti na šumove u merenjima. Širi opseg ESO-a (40 – 90 rad/s) u odnosu na regulator (5 – 9 rad/s) omogućava brzu estimaciju i kompenzaciju poremećaja uz održavanje stabilnosti sistema.

Tabela 4.1: Hiperparametri oba DDPG agenta

Parametar	Vrednost
Stopa učenja <i>actor</i> mreže	10^{-4}
Stopa učenja <i>critic</i> mreže	10^{-3}
Faktor obezvredjivanja (γ)	0.9
Veličina <i>replay</i> bafera	10^6
Veličina mini-grupe	32
Period odabiranja (T_s)	0, 1 s
Varijansa šuma σ^2	0.3
Koeficijent opadanja varijanse šuma	10^{-5}

4.4 Simulaciona validacija projektovanog sistema upravljanja

4.4.1 Simulaciona postavka

Performanse predloženog adaptivnog ADRC-RL sistema zasnovanog na DDPG evaluiran je kroz simulacije u MATLAB/Simulink okruženju, koristeći kinematički model laboratorijskog BGV-a definisan u odeljku 3.1. Performanse predloženog ADRC-RL regulatora upoređene su sa standardnim ADRC regulatorom sa konstantnim parametrima, kao što je predstavljeno u odeljku 3.2. Konstantni parametri su postavljeni na osnovu početnih performansi ADRC-RL u idealnim uslovima ($\omega_{CL_1} = 5.14$ rad/s, $\omega_{ESO_1} = 42.37$ rad/s, $\omega_{CL_v} = 9$ rad/s, $\omega_{ESO_v} = 90$ rad/s). Hiperparametri za DDPG agente postavljeni su prema tabeli 4.1.

DDPG agenti su obučavani na izazovnoj trajektoriji pod uslovima promenljivih brzina lidera i prisustva poremećaja kao što su proklizavanje gusenica i šum merenja. Ovo je omogućilo da DDPG agenti nauče optimalna podešavanja parametara u najsloženijim uslovima.

Da bi se pružio jasan uvid u algoritam rada ADRC regulatora podržanog DDPG algoritmom u zadatku autonomnog praćenja lidera, predstavljen je sledeći pseudo-kod (Algoritam 1). On detaljno opisuje proceduru upravljanja koja se izvršava nakon završetka faze obučavanja, uključujući adaptivno podešavanje ADRC parametara u realnom vremenu i primenu upravljačkih ulaza na bazi akcija DDPG agenta.

4.4.2 Simulacioni rezultati i analiza

Nakon uspešnog obučavanja, agenti su testirani kako bi se evaluirala generalizacija i adaptabilnost naučenih politika podešavanja parametara u različitim scenarijima.

U okviru prvog simulacionog scenarija analiziran je rad DDPG ADRC algoritma u zadatku praćenje lidera u uslovima bez poremećaja, ali sa različitim početnim pozicijama

Algorithm 1 Upravljanje sistemom autonomnog praćenja lidera pomoću ADRC regulatora podržanog DDPG algoritmom

```

1: Inicijalizacija
2:   Inicijalizuj pozicije BGV-a i lidera
3:   Inicijalizuj DDPG agente za oba kanala:
4:     DDPG_L sa lateralnim Actor i Critic mrežama
5:     DDPG_V sa longitudinalnim Actor i Critic mrežama
6: while vreme_simulacije <  $T_{kraj}$  do
7:   Izmeri trenutna stanja
8:     Izmeri lateralnu grešku:  $e_d(t)$ 
9:     Izmeri longitudinalnu grešku:  $e_{s(e)}(t)$ 
10:    Izmeri trenutnu brzinu BGV-a:  $v(t)$ 
11:    Izmeri trenutnu ugaoanu brzinu BGV-a:  $\dot{\theta}(t)$ 
12:   Pripremi stanja za DDPG agente
13:      $Stanje\_L \leftarrow [e_d(t), \dot{\theta}(t), \ddot{\theta}(t)]$ 
14:      $Stanje\_V \leftarrow [e_{s(e)}(t), v(t), \dot{v}(t)]$ 
15:   Odaber ADRC parametre korišćenjem DDPG agenata
16:      $[\omega_{CL_l}(t), \omega_{ESO_l}(t)] \leftarrow DDPG\_L(Stanje\_L)$ 
17:      $[\omega_{CL_v}(t), \omega_{ESO_v}(t)] \leftarrow DDPG\_V(Stanje\_V)$ 
18:   Ažuriraj ADRC regulatore
19:     Ažuriraj_L_ADRC( $\omega_{CL_l}(t), \omega_{ESO_l}(t)$ )
20:     Ažuriraj_V_ADRC( $\omega_{CL_v}(t), \omega_{ESO_v}(t)$ )
21:   Izračunaj upravljačke ulaze korišćenjem ADRC
22:      $\dot{\theta}(t) \leftarrow ADRC\_L(e_d(t), \omega_{CL_l}(t), \omega_{ESO_l}(t))$ 
23:      $v(t) \leftarrow ADRC\_V(e_{s(e)}(t), e_{s(\text{ref})}(t), \omega_{CL_v}(t), \omega_{ESO_v}(t))$ 
24:   Primeni upravljačke ulaze na BGV
25:     BGV.PostaviBrzinu( $\Omega_{\text{desni}}(t), \Omega_{\text{levi}}(t)$ )
26:   Ažuriraj poziciju lidera na osnovu trajektorije
27:     Lider.AžurirajPoziciju(t)
28:   Povećaj vreme simulacije
29:      $t \leftarrow t + \Delta t$ 
30: end while

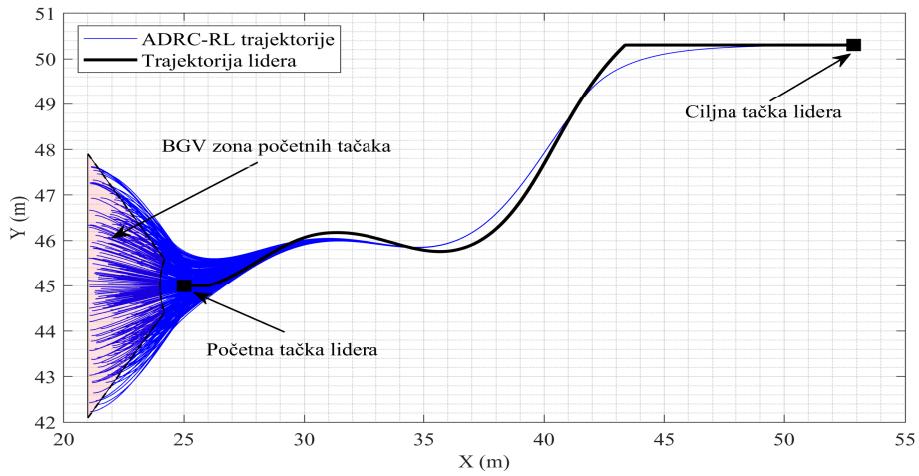
```

BGV-a u odnosu na lidera. Da bi se eliminisao faktor slučajnosti, izvršeno je više simulacija (ukupno 300) gde je početna pozicija BGV-a nasumično generisana u bliskom okruženju početne tačke lidera. Praktična konvergencija putanje BGV-a ka trajektoriji lidera, zajedno sa lateralnim i longitudinalnim greškama, prikazana je na slici 4.4.

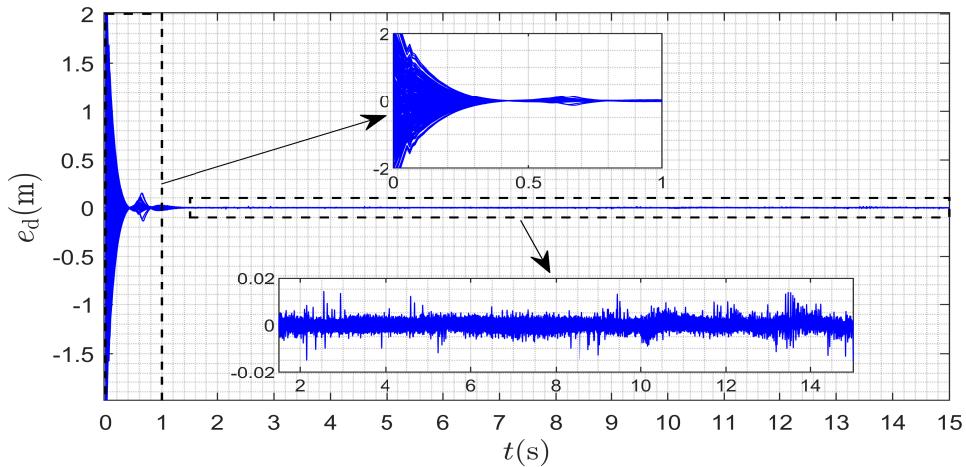
Ovde je potrebno napomenuti da je početna tačka BGV-a (x, y) zadovoljavala uslov da vozilo inicijalno uvek ostane iza lidera:

$$\begin{aligned}
 y + \tan(\alpha) \cdot (x - X_L) - Y_L &\leq 0, \\
 y - \tan(\alpha) \cdot (x - X_L) + Y_L &\geq 0, \\
 (x - X_L)^2 + (y - Y_L)^2 &\geq 1,
 \end{aligned}$$

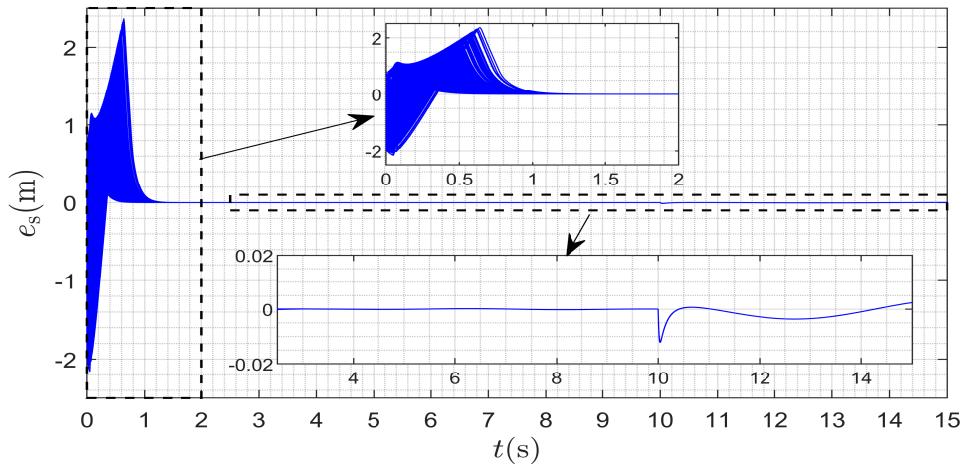
gde je $x \in [X_L - x_{\min}, X_L - x_{\max}]$ i $\alpha \in [-\frac{\pi}{5}, \frac{\pi}{5}]$. Dodatno, slučajno definisane y-koordinate



(a) Trajektorije lidera i BGV-a dobijene za različite nasumične početne uslove.



(b) Lateralna greška



(c) Longitudinalna greška

Slika 4.4: Rezultati simulacije dobijeni za različite početne pozicije BGV u odnosu na lidera.

generisane su na bazi Gausove raspodele, odnosno:

$$Y \sim \mathcal{N}(Y_L, 6h),$$

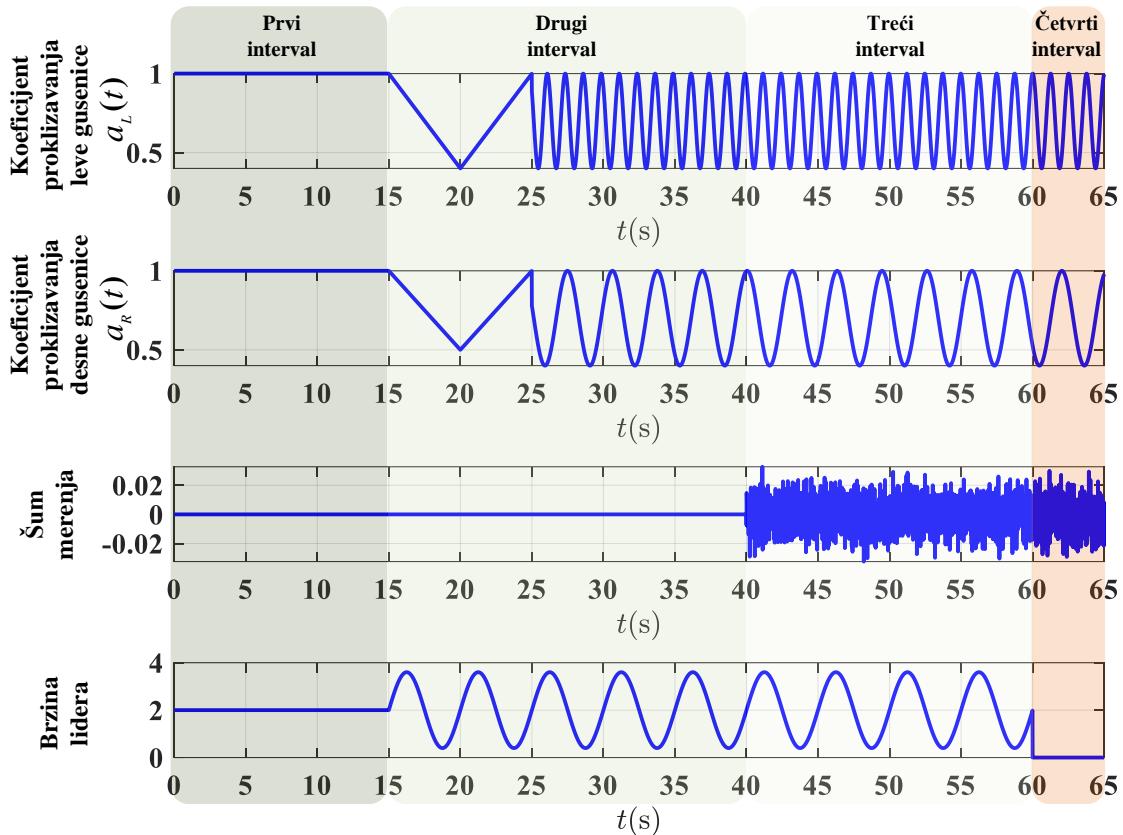
gde je

- $\alpha = \frac{\pi}{5}$ poluugao u odnosu na početnu tačku lidera gledajući unazad ka BGV-u.
- $x_{\min} = 4$ i $x_{\max} = 0.5$ definišu opseg rastojanja duž x -ose od lidera.
- $h = x_{\min} \cdot \tan(\alpha)$.
- (X_L, Y_L) predstavlja početnu poziciju lidera u inercijalnom koordinatnom sistemu (X, Y) .

Kao što se može videti na slici 4.4a, sve generisane trajektorije BGV-a, uprkos različitim početnim pozicijama unutar definisane zone (označene svetlo crvenom bojom), uspešno konvergiraju ka trajektoriji lidera (crna linija). Skup plavih linija koje predstavlja kretanje BGV-a formira karakterističan levkasti oblik, jasno pokazujući kako se vozilo usmerava i približava željenoj trajektoriji, bez obzira na početno odstupanje. Ovo potvrđuje efikasnost projektovanog DDPG-ADRC sistema upravljanja pri različitim početnim stanjima u odsustvu spoljašnjih poremećaja. Nakon inicijalne konvergencije, BGV precizno prati lidera kroz definisanu kompleksnu trajektoriju. Analiza grešaka praćenja (slike 4.4b i 4.4c) dodatno potvrđuje prethodni zaključak. Slika 4.4b pokazuje da se inicijalno velike lateralne greške (e_d) brzo smanjuju, te nakon približno 1 sekunde konvergiraju ka vrednostima bliskim nuli, održavajući se unutar veoma uskog opsega od približno ± 0.01 m (donji uvećani prikaz). Slično, slika 4.4c ilustruje da longitudinalna greška (e_s) u odnosu na željeno rastojanje praćenja od 2 m takođe brzo konvergira (gornji uvećani prikaz), ostajući stabilna blizu nule čak i tokom prolaska lidera kroz krivinu oko 10. sekunde (donji uvećani prikaz). Manje odstupanje tokom krivine se brzo koriguje, demonstrirajući sposobnost sistema da održi željeno rastojanje BGV i lidera. Sveukupno, ovi rezultati jasno demonstriraju robusnost i efikasnost predloženog DDPG-ADRC sistema u zadatku konvergencije ka putanji lidera i održavanja praćenja iz širokog spektra početnih uslova.

U okviru drugog scenarija izvršena je sveobuhvatna komparativna analiza performansi ADRC algoritma sa konstantnim parametrima i DDPG ADRC algoritma. Da bi se detaljno analizirale performanse pod različitim radnim uslovima, uključujući poremećaje kao što su varijacije brzine lidera, proklizavanje gusenica i šum merenja, simulacija je podeljena na četiri intervala sa vrednostima poremećaja i šuma merenja prikazanih na slici 4.5.

- i) Tokom prvog intervala (od 0 do 15 s), simulacija prepostavlja idealne uslove bez ikakvih efekata proklizavanja gusenica ($a_{levi}(t) = a_{desni}(t) = 1$) i nema šuma merenja u lateralnom i longitudinalnom kanalu. Brzina lidera je data kao $v_L(t) = 2$ m/s, a referentna longitudinalna greška kao $e_{s(ref)} = 2$ m. Početna tačka u inercijalnom koordinatnom sistemu za BGV postavljena je na koordinatu (23, 45), dok lider kreće sa (25, 45).

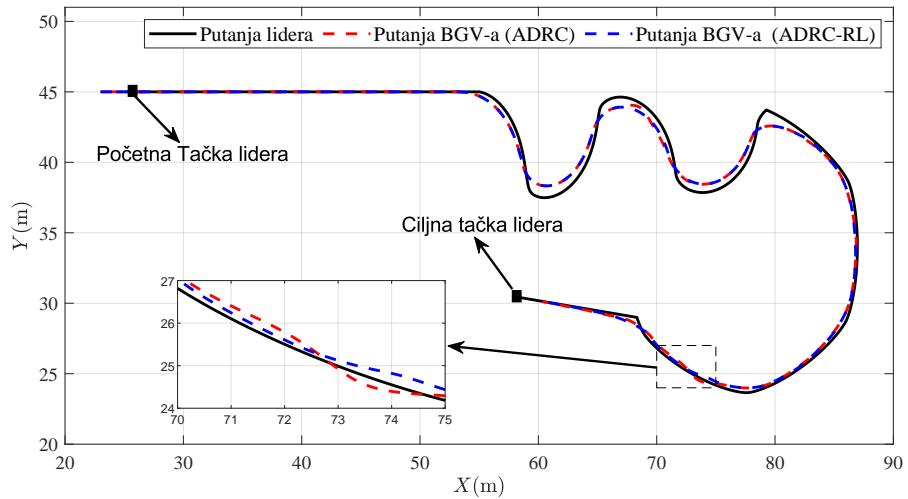


Slika 4.5: Korisnički definisani profili poremećaja i ubrizgavanje šuma tokom simulacije.

- ii) Tokom drugog intervala (od 15 do 40 s), brzina lidera definisana je kao $v_L(t) = 2 + 1.4 \sin(t)$ m/s. Razmatrani su složeni poremećaji proklizavanja sa koeficijentima proklizavanja gusenica: $a_{desni}(t) = 1 - 0.1 \cdot t$ i $a_{levi}(t) = 1 - 0.12 \cdot t$ za $t \in [15, 20]$, $a_{desni}(t) = 0.5 + 0.1 \cdot t$ i $a_{levi}(t) = 0.4 + 0.12 \cdot t$ za $t \in [20, 25]$, i $a_{desni}(t) = 0.7 + 0.3 \sin(2t)$, $a_{levi}(t) = 0.7 + 0.3 \sin(5t)$ kada je $t \in [25, 40]$.
- iii) Tokom trećeg intervala (od 40 do 60 s), prethodni uslovi proklizavanja se zadržavaju ($a_{desni}(t) = 0.7 + 0.3 \sin(2t)$, $a_{levi}(t) = 0.7 + 0.3 \sin(5t)$). Dodatno, Gausov šum sa standardnom devijacijom od 0.001 m uključen je u oba merna kanala (lateralni i longitudinalni).
- iv) Tokom poslednjeg intervala (od 60 do 65 s), lider se zaustavlja, što znači $v_L(t) = 0$ m/s, bez ikakvih poremećaja i šuma merenja.

Dobijeni rezultati u okviru ovog simulacionog scenarija, koji uključuju praćenje trajektorije lidera, lateralne greške sa vrednostima parametara lateralnog regulatora, i longitudinalne greške sa vrednostima parametara longitudinalnog regulatora, prikazani su na slikama 4.6 i 4.7, respektivno.

Da bi se kvantitativno evaluirali rezultati simulacije, predloženi su sledeći kvantitativni kriterijumi:



Slika 4.6: Simulirane trajektorije lidera i BGV-a upoređujući ADRC-RL i konstantni ADRC.

- Integral apsolutne greške IAE, definisan kao integral apsolutnih vrednosti lateralne greške ($|e_d(t)|$) i razlike između referentne i ostvarene longitudinalne greške ($e_{s(e)} = |e_{s(\text{ref})}(t) - e_s(t)|$) tokom intervala simulacije:

$$\text{IAE} = \int_{t_0}^{t_f} |e(t)| dt.$$

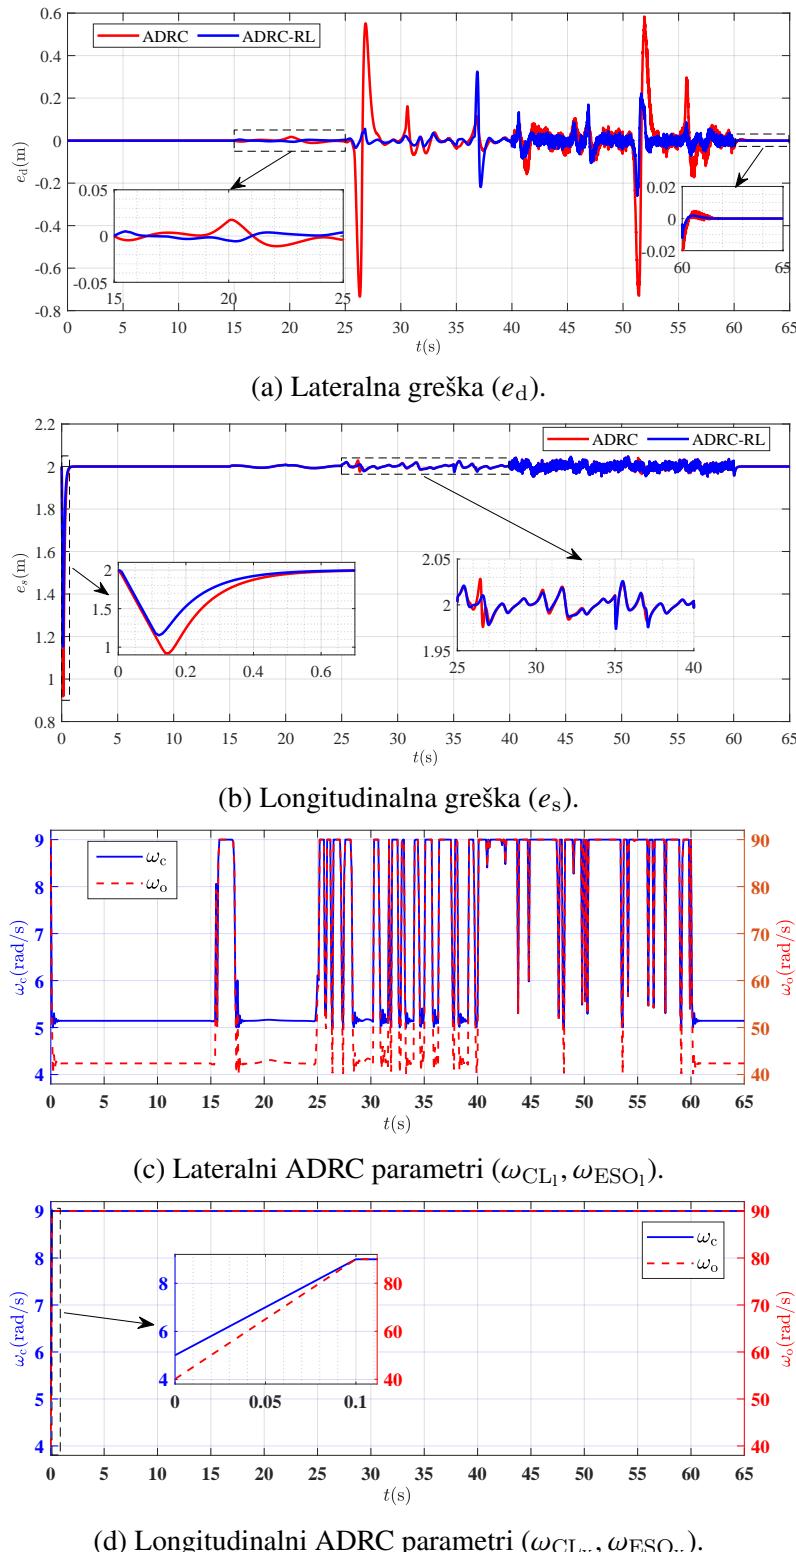
- Utrošena energija E, izračunata kao integral kvadrata lateralnog i longitudinalnog upravljačkog signala tokom vremena:

$$E = \int_{t_0}^{t_f} |y(t)|^2 dt.$$

- Ukupna varijacija upravljačkog signala TV, koja predstavlja integral apsolutnih razlika između uzastopnih vrednosti lateralnog i longitudinalnog upravljačkog signala:

$$TV = \int_{t_0}^{t_f} |y(t + \Delta t) - y(t)| dt,$$

gde je $e(t)$ greška upravljanja, $y(t)$ je izlazni upravljački signal sistema, sa $y(t) = \dot{\theta}(t)$ za lateralni upravljački kanal i $y(t) = v(t)$ za longitudinalni upravljački kanal, t_0 je početno vreme, t_f je krajnje vreme, a Δt je korak diskretizacije. Razmatrane vrednosti su izračunate za svaki interval simulacije i date su u tabeli 4.2. Da bi se procenile ukupne performanse sistema, izračunata je Euklidska norma (eng. Euclidean norm), označena sa χ , koja integriše predložene kvantitativne kriterijume lateralnog i longitudinalnog kanala. Ova kombinovana metrika pruža sveobuhvatnu procenu performansi sistema u oba kanala, obuhvatajući ukupnu procenu efikasnosti upravljanja i dobijena je na osnovu izraza



Slika 4.7: Rezultati simulacije: greške praćenja i evolucija ADRC parametara podešenih pomoću DDPG

$$\chi = \sqrt{M_{\text{lateralni}}^2 + M_{\text{longitudinalni}}^2},$$

gde je M jedna od prethodno razmatranih kvantitativnih kriterijuma (IAE, E ili TV).

Tabela 4.2: Kvantitativno poređenje sa konvencionalnim ADRC-om (plavom bojom) je označen dobitak ADRC-RL u poređenju sa ADRC, crvenom bojom je označen gubitak ADRC-RL u poređenju sa konvencionalnim ADRC-om).

Metrika	Regulator	Prvi interval (od 0 do 15 s)			Drugi interval (od 15 do 40 s)			Treći interval (od 40 do 60 s)			Četvrti interval (od 60 do 65 s)		
		e_d	e_s	χ	e_d	e_s	χ	e_d	e_s	χ	e_d	e_s	χ
IAE	ADRC	6.3606e-15	0.21706	0.21706	0.99943	0.14496	1.0099	1.2259	0.22614	1.2466	0.0050	0.0064	0.0082
	ADRC-RL	1.4687e-13	0.15675	0.15675	0.32095	0.13761	0.34921	0.46315	0.22328	0.51416	0.0024	0.0065	0.0069
	Dobitak/Gubitak	/	/	/	67.89%	5.07%	65.42%	62.22%	1.26%	58.76%	53.07%	-0.43%	15.90%
E	ADRC	1.9038e-25	73.968	73.968	108.07	247.75	270.29	157.75	278.36	319.95	0.1367	0.2065	0.2476
	ADRC-RL	3.1373e-19	70.656	70.656	76.515	239.83	251.74	188.74	275.57	334.01	0.1362	0.2175	0.2566
	Dobitak/Gubitak	/	/	/	29.20%	3.20%	6.86%	-19.65%	1.00%	-4.39%	0.36%	-5.32%	-3.63%
TV	ADRC	2.1126e-10	44.476	44.476	170.59	69.687	184.27	3090.8	964.73	3237.9	44.437	7.70	45.099
	ADRC-RL	1.9614e-08	41.276	41.276	166.66	65.344	179.01	3788.1	959.3	3907.7	8.858	7.86	11.842
	Dobitak/Gubitak	/	/	/	2.30%	6.23%	2.85%	-22.56%	0.56%	-20.69%	80.07%	-2.12%	73.74%

Analiza rezultata je sprovedena kroz četiri ključna aspekta: analiza greške praćenja, analiza adaptacije parametara, analiza kvantitativnih kriterijuma performansi i sumarna analiza.

4.4.2.1 Analiza greške praćenja

Analiza vremenskih odziva grešaka praćenja (slika 4.7) po intervalima pruža uvid u dinamičko ponašanje oba sistema upravljanja:

- Prvi interval (idealni uslovi, 0-15s):** kao što se i očekivalo, u odsustvu poremećaja proklizavanja i šuma merenja, oba sistema upravljanja (ADRC-RL i konstantni ADRC) efikasno prate trajektoriju lidera i pokazuju slične performanse, budući da su inicijalni parametri konstantnog ADRC odabrani na osnovu vrednosti koje je ADRC-RL usvojio u ovom intervalu. Međutim, pažljivijim posmatranjem (posebno longitudinalne greške e_s na slici 4.7b) može se uočiti da ADRC-RL pokazuje nešto bolji prelazni odziv na samom početku simulacije, brže postižući željenu distancu praćenja.
- Drugi interval (poremećaj proklizavanja, 15-40s):** ovaj interval demonstrira efikasnost ADRC-RL pristupa u prisustvu promenljivih poremećaja proklizavanja. U periodu od 15s do 25s, uprkos linearno rastućem (rampa) poremećaju proklizavanja, oba sistema održavaju visok nivo tačnosti praćenja uz male varijacije u obe greške. Ipak, ADRC-RL pokazuje manje varijacije u lateralnoj grešci (e_d) u poređenju sa konstantnim ADRC-om (slika 4.7a). U periodu od 25s do 40s, kada poremećaji postaju složeniji (sinusoidalni), ADRC-RL nastavlja da prati lidera sa visokim performansama, postižući vidno niže maksimalne vrednosti i manje oscilacije obe

greške (e_d i e_s), posebno lateralne, u poređenju sa konstantnim ADRC-om, što ukazuje na uspešnu adaptaciju ADRC-RL na promenljive poremećaje.

- **treći interval (poremećaj proklizavanja i šum merenja, 40-60s):** uvođenje Gaušovog šuma merenja dodatno testira robusnost sistema. ADRC-RL i dalje nadmašuje konstantni ADRC, održavajući zadovoljavajući nivo praćenja lidera. Međutim, primetne su povećane varijacije u obe greške (e_d i e_s) za oba sistema, što ukazuje na uticaj šuma. ADRC-RL i dalje održava generalno niže magnitude grešaka u poređenju sa konstantnim ADRC-om, potvrđujući svoju bolju robusnost u kombinovanim uslovima poremećaja i šuma.
- **Poslednji interval (zaustavljanje lidera, 60-65s):** kada se lider zaustavi, oba sistema uspešno održavaju zadatu longitudinalnu distancu ($e_{s(e)}$ teži nuli). Konstantni ADRC pokazuje blagu prednost u brzini smirivanja longitudinalne greške u ovom kratkom intervalu. Međutim, ADRC-RL pokazuje bolje performanse u smislu lateralne greške (e_d), brže konvergira ka nuli i sa manjim preskokom, što omogućava precizno pozicioniranje pri zaustavljanju.

4.4.2.2 Analiza adaptacije parametara

Ponašanje adaptivno podešenih parametara ADRC regulatora (ω_{CL} i ω_{ESO}) pruža uvid u mehanizam učenja DDPG agenata i prikazani su na slikama 4.7c i 4.7d.

- **Lateralni parametri ($\omega_{CL_l}, \omega_{ESO_l}$):** slika 4.7c pokazuje da DDPG agent aktivno prilagođava propusne opsege lateralnog ADRC regulatora, posebno tokom intervala 2 i 3 kada su prisutni poremećaji i šum. Uočava se tendencija povećanja vrednosti parametara (ω_{CL_l} i ω_{ESO_l}) kada sistem nailazi na veće poremećaje ili greške praćenja (npr. tokom perioda 25-40s i 40-60s). Ovo ukazuje na potrebu za bržim odzivom sistema i jačim potiskivanjem poremećaja. Suprotno tome, parametri se smanjuju kada su uslovi mirniji ili kada dominira šum, što može ukazivati na strategiju smanjenja osetljivosti na visokofrekventni šum i postizanje stabilnijeg upravljanja. Ove varijacije direktno odražavaju adaptivnu prirodu algoritma kao odgovor na promene u brzini lidera, dinamici proklizavanja i prisustvu šuma.
- **Longitudinalni parametri ($\omega_{CL_v}, \omega_{ESO_v}$):** zanimljivo je primetiti, kao što je prikazano na slici 4.7d, da longitudinalni parametri ostaju relativno stabilni tokom čitave simulacije nakon inicijalnog prelaznog perioda. Postoje dva moguća objašnjenja za ovo. Prvo, inicijalne vrednosti parametara konstantnog ADRC (koje su korišćene kao osnova) već su bile blizu optimalnih za longitudinalni kanal pod datim simulacionim uslovima. Drugo, moguće je da su efekti unakrsnih veza između longitudinalne i lateralne dinamike omogućili da adaptacija lateralnih parametara

dovoljno kompenzuje poremećaje koji utiču na oba kanala, čineći značajnu adaptaciju longitudinalnih parametara manje potrebnom za postizanje zadovoljavajućih performansi upravljanja.

4.4.2.3 Analiza kvantitativnih kriterijuma efikasnosti upravljanja

Tabela 4.2 pruža kvantitativno poređenje performansi koristeći metrike IAE, energija E i TV:

- **IAE:** ostvarene vrednosti IAE jasno pokazuju značajna poboljšanja sa ADRC-RL pristupom, posebno za lateralnu grešku (e_d) u intervalima sa poremećajima. U Intervalu 2, smanjenje IAE za e_d iznosi čak 67.9%, a u intervalu 3 62.2%. Ukupna metrika performansi χ za IAE takođe pokazuje značajne dobitke (65.4% u Intervalu 2 i 58.8% u Intervalu 3). Ovo kvantitativno potvrđuje visoku preciznost praćenja ADRC-RL sistema u izazovnim uslovima. U slučaju longitudinalne greške ADRC-RL pokazuje mala, ali konzistentna poboljšanja u IAE (osim u intervalu 4 gde je konvencionalni ADRC neznatno bolji).
- **E (Energija upravljanja):** kriterijum utrošene energije upravljanja pokazuje različite rezultate. ADRC-RL koristi manje energije (posebno lateralno) u intervalu 2, što ukazuje na efikasnije upravljanje pri uvođenju poremećaja proklizavanja. Međutim, u intervalu 3 (sa uticajem šuma merenja), ADRC-RL koristi nešto više energije, naročito u lateralnom kanalu (gubitak od -19.7%). Ovo može ukazivati da postizanje veće tačnosti praćenja u uslovima jakih poremećaja i šuma zahteva veći upravljački napor od strane adaptivnog sistema. U intervalu 4, potrošnja energije je slična za oba sistema.
- **TV (Izgled upravljačkog signala):** ukupna varijacija (TV) meri koliko se brzo menjaju upravljački signali. ADRC-RL pokazuje poboljšani izgled (glatkoću) u intervalu 2. Međutim, u intervalu 3, TV za lateralni kanal značajno raste (gubitak od -22.6%), što sugerise da adaptivni parametri dovode do bržih promena u upravljačkom signalu kada je prisutan šum. Ove brže promene su neophodne za održavanje tačnosti u prisustvu šuma, ali dolaze po cenu smanjene glatkoće signala. Vredno je pomenuti značajno smanjenje TV-a za lateralni upravljački signal ($\dot{\theta}$) u intervalu 4 (dubitak od 80.1%), što ukazuje na precizno zaustavljanje BGV-a.

4.4.2.4 Sumarna diskusija rezultata

Rezultati simulacije podržavaju postavljenu hipotezu da korišćenje DDPG algoritma za adaptivno podešavanje parametara ADRC regulatora unapređuje performanse i robu-snost sistema upravljanja. Pristup ADRC-RL pokazao je visoku tačnost praćenja (niži IAE) u poređenju sa konvencionalnim ADRC-om, naročito kada je suočen sa značajnim

poremećajima proklizavanja gusenica i šumom merenja. DDPG agenti su uspešno naučili da prilagođavaju propusne opsege ADRC regulatora online, adaptirajući karakteristike regulatora promenljivim uslovima. Iako su potrošnja energije i glatkoća upravljačkog signala pokazali mešovite rezultate u zavisnosti od intervala (što ukazuje na potencijalni kompromis između tačnosti i napora/glatkoće u prisustvu šuma), primarni zadatak minimizacije greške praćenja efikasnije je postignut adaptivnim pristupom. Stabilnost i konvergencija sistema potvrđene su i kroz testove sa slučajnim početnim uslovima. Ovi rezultati ukazuju da ADRC-RL predstavlja obećavajuću strategiju za poboljšanje autonomije i adaptibilnosti BGV sistema u dinamičkim realnim scenarijima.

Ovde treba napomenuti da je validacija adaptivnog ADRC-RL sistema sprovedena isključivo kroz računarske simulacije. Iako su simulacije obuhvatile realistične modele poremećaja, potvrda performansi u realnim uslovima na fizičkom BGV sistemu ostaje neophodan sledeći korak. Takođe, relativna stabilnost adaptiranih longitudinalnih parametara sugerije prostor za dalja istraživanja, bilo kroz modifikaciju funkcije nagrade, proširenje prostora stanja ili analizu uticaja sprege između kanala upravljanja. Budući pravci istraživanja proističu direktno iz ovih zapažanja. Primarni zadatak je implementacija i eksperimentalna validacija predloženog ADRC-RL sistema na realnoj guseničnoj platformi, kako bi se potvrdili simulacioni rezultati i ispitala robusnost u stvarnom svetu. Dodatno, moglo bi se istražiti korišćenje naprednijih DRL algoritama (npr. TD3, SAC) ili tehnika za poboljšanje efikasnosti učenja i robusnosti na šum. Proširenje primene adaptivnog podešavanja i na druge zadatke, poput autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka, takođe predstavlja interesantan pravac za dalji rad.

Poglavlje 5

Zaključak

Autonomija BV-a predstavlja oblast intenzivnog istraživanja i razvoja sa ogromnim potencijalom u brojnim vojnim i civilnim primenama. Izazovi upravljanja ovakvim sistemima u složenim i dinamičkim okruženjima, obeleženim nelinearnostima, nestacionarnostima i spoljašnjim poremećajima, poput proklizavanja pogonskih gusenica i točkova, zahtevaju primenu naprednih strategija upravljanja i vođenja. Ova doktorska disertacija sistematski je pristupila ovom problemu, fokusirajući se na razvoj, integraciju i validaciju robusnih i adaptivnih rešenja zasnovanih na tehnicu ADRC-a, algoritmima DL-a za vođenje, i RL za adaptivno upravljanje, čime je ostvaren značajan napredak u autonomiji vozila.

Ključni rezultati istraživanja direktno potvrđuju postavljene hipoteze. Eksperimentalnom validacijom na laboratorijskoj BGV platformi demonstrirano je da predloženi ADRC sistem upravljanja ostvaruje bolje performanse u odnosu na klasične regulatore, u zadaćima autonomnog praćenja zadate vozne trake sa izbegavanjem prepreka i autonomnog praćenja lidera. Konkretno, ADRC je pokazao bolju robusnost na poremećaje proklizavanja, preciznije praćenje referentne putanje/trajektorije i generisanje glatkijih upravljačkih signala. Navedeno je evidentno iz analiza grešaka praćenja i karakteristika upravljačkih komandi dobijenih tokom eksperimentalnih testiranja, što potvrđuje **prvu posebnu hipotezu** o prednostima ADRC-a.

Integracija savremenih DL algoritama (YOLOv8, YOLOPv2, MPP) sa podacima sa kamere i LiDAR senzora omogućila je razvoj efikasnog i modularnog sistema vođenja. Eksperimenti su pokazali da ovaj sistem pouzdano detektuje vozne trake, prepreke i ljudskog lidera, kao i da uspešno interpretira komande zadate pozom lidera. Uspešna realizacija autonomnog praćenja vozne trake, izbegavanja prepreka i interaktivnog praćenja lidera u realnim scenarijima potvrđuje **drugu posebnu hipotezu** o povećanju stepena autonomije i unapređenju interakcije čovek-vozilo.

Implementacija celokupnog sistema na laboratorijskom BGV vozilu i uspešna demonstracija njegovih funkcionalnosti u reprezentativnim zadacima potvrđuje **treću posebnu hipotezu**, pružajući konkretnu osnovu za dalji razvoj i potencijalnu primenu ovih tehnologija na operativnim besposadnim vozilima.

Pored toga, istraživanje potencijala adaptivnog ADRC sistema rezultiralo je predlogom ADRC-RL sistema upravljanja za zadatak praćenja lidera, gde DDPG algoritam dinamički podešava parametre ADRC regulatora. Simulaciona validacija pokazala je da ADRC-RL ostvaruje značajno poboljšanje performansi praćenja u poređenju sa ADRC-om sa konstantnim parametrima, posebno u prisustvu složenih poremećaja (promenljiva brzina lidera, proklizavanje, šum merenja). Ovo potvrđuje **četvrtu posebnu hipotezu** i ukazuje na zavidan potencijal RL pristupa za povećanje adaptivnosti i robusnosti BGV sistema. Svi ovi rezultati zajedno potvrđuju i **opštu hipotezu** disertacije: da projektovanje naprednih robusnih (ADRC) i adaptivnih (ADRC-RL) algoritama upravljanja, integrisanih sa sistemima vođenja zasnovanim na DL-u, omogućava postizanje visokih performansi autonomnog kretanja BGV-a u uslovima delovanja unutrašnjih i spoljašnjih poremećaja.

Ključni naučni doprinosi ove disertacije mogu se sagledati prema sledećem:

- Razvoj i primena kinematičkog modela BGV-a koji eksplicitno uključuje efekte proklizavanja gusenica.
- Projektovanje i eksperimentalna validacija efikasnosti robusnog ADRC sistema upravljanja BGV za zadatke praćenja vozne trake sa izbegavanjem prepreka i praćenja lidera u realnim uslovima.
- Integriranje naprednih DL algoritama (YOLOv8, YOLOPv2, MPP) u sistem percepcije i vođenja BGV-a, čime je demonstrirana njihova primenljivost za obavljanje složenih zadataka u realnom vremenu.
- Predlog nove strategije adaptivnog podešavanja parametara ADRC regulatora zasnovane na DDPG algoritmu u kontekstu praćenja lidera BGV-a, koja je pokazala značajno poboljšanje performansi i robusnosti u prisustvu dinamičkih poremećaja i šuma.
- Sveobuhvatna integracija projektovanih sistema vođenja i upravljanja i njihova evaluacija kroz simulacije i eksperimente na realnom BGV sistemu.

Iako su postignuti značajni rezultati, ovo istraživanje ima i određena ograničenja koja se mogu klasifikovati prema sledećem:

- **Praćenje vozne trake sa izbegavanjem prepreka:**
 - *Detekcija vozne trake:* iako je YOLOPv2 pokazao dobre rezultate, u uslovima loše vidljivosti, oštećenih ili nejasnih oznaka traka može doći do grešaka u detekciji. Performanse bi mogle zavisiti od specifičnosti okruženja.
 - *Detekcija prepreka:* korišćeni YOLOv8 detektor ograničen je na klase objekata na kojima je obučen. Nepoznati ili novi tipovi prepreka možda neće biti

detektovani. Fuzija sa drugim senzorima (npr. LiDAR) ili korišćenje metoda za detekciju nepoznatih prepreka moglo bi poboljšati robusnost sistema.

- *Efikasnost sistema vođenja:* algoritmi za obradu slike vozne trake i generisanje virtuelnih putanja, iako funkcionalni, mogli bi se dodatno optimizovati radi bržeg izvršavanja, posebno pri većim brzinama.
- *Validacija:* eksperimenti su sprovedeni samo na specifičnoj voznoj stazi u laboratorijskim uslovima.

- **Praćenje lidera:**

- *Identifikacija lidera:* sistem trenutno prepostavlja jednog lidera i bira osobu najbližu centru slike u slučaju višestrukih detekcija. Nedostaje robustan mehanizam za reidentifikaciju lidera nakon privremenog gubitka iz vidnog polja ili u prisustvu više osoba.
- *Komande pozom:* implementirani sistem prepoznavanja poza podržava ograničen skup komandi (stajanje, čučanj, podignuta ruka u čučnju). Proširenje na veći broj gestova ili složenije komande zahtevalo bi dodatni razvoj ovog sistema.
- *Prisustvo prepreka:* trenutni sistem za praćenje lidera ne uzima eksplisitno u obzir prisustvo statičkih ili dinamičkih prepreka između BGV-a i lidera, što je čest slučaj u realnim scenarijima.
- *Validacija:* eksperimentalna validacija praćenja lidera sprovedena je na ograničenom broju terena.

- **Adaptivno upravljanje (ADRC-RL):**

- *Validacija:* ključno ograničenje je nedostatak eksperimentalne validacije ADRC-RL sistema. Performanse naučene u simulaciji možda se neće direktno preneti na realni sistem zbog nestacionarnosti modela i nepredviđenih realnih efekata.
- *Obučavanje:* obučavanje DRL agenata direktno na laboratorijskom BGV-u je nepraktično zbog velikog broja potrebnih interakcija i potencijalnih rizika.
- *Algoritam:* testiran je samo DDPG algoritam. Drugi DRL algoritmi (npr. TD3, SAC) potencijalno bi mogli ponuditi bolju stabilnost učenja i/ili bolje performanse.

- **Opšta ograničenja:**

- *Model sistema:* simulacioni rezultati su sprovedeni na relativno jednostavnom modelu BGV, koji ne uključuje svu dinamiku realnog BGV. Iako je model

uključio efekte proklizavanja, on ne obuhvata sve kompleksne dinamičke interakcije (npr. inercija, uticaj nagiba terena, promene centra mase vozila, itd.). Korišćenje preciznijeg dinamičkog modela BGV moglo bi pružiti bolje početne pretpostavke pri projektovanju sistema upravljanja i simulacione rezultate bliže realnim.

- *Optimizacija brzine:* sistemi su testirani pri relativno konstantnim i manjim brzinama kretanja BGV. Optimizacija algoritama za rad pri većim brzinama i u realnom vremenu zahtevala bi dodatna istraživanja.

Na osnovu ovih ograničenja i postignutih rezultata, mogu se definisati pravci za budućih istraživanja koji bi imali više pravaca:

- **Unapređenje praćenja vozne trake sa izbegavanjem prepreka:**

- Istraživanje alternativnih ili komplementarnih metoda za *detekciju linija* (npr. fuzija sa drugim senzorima, napredniji modeli segmentacije) radi poboljšanja robusnosti u teškim uslovima vidljivosti.
- Unapređenje sistema za *detekciju prepreka* obučavanjem YOLOv8 na specifičnim klasama prepreka relevantnim za BGV primene, ili integracijom LiDAR senzora za detekciju nepoznatih objekata i preciznije merenje rastojanja.
- Optimizacija algoritama za *obradu traka i planiranje putanje* radi postizanja veće brzine izvršavanja i glatkijih manevara izbegavanja.
- *Proširena eksperimentalna validacija* na različitim tipovima staza (unutrašnjim i spoljašnjim) i sa raznovrsnijim preprekama.

- **Unapređenje praćenja lidera:**

- Razvoj i integracija modula za *reidentifikaciju lidera* kako bi se omogućilo robusno praćenje u prisustvu više osoba ili nakon privremenih gubitaka slike lidera.
- Proširenje sistema za *prepoznavanje poz* na veći broj gestova i složenijih komandi za intuitivniju interakciju čovek-vozilo.
- Integracija mehanizama za *detekciju i izbegavanje prepreka* unutar sistema za praćenje lidera, omogućavajući bezbedno vođenje u složenijim okruženjima.
- Sprovođenje *opsežnijih eksperimenata* u različitim spoljašnjim uslovima, na raznovrsnijim terenima.

- **Unapređenja adaptivnog ADRC upravljanja (ADRC-RL):**

- Prioritet je *eksperimentalna validacija* ADRC-RL sistema na laboratorijskoj BGV platformi. Ovo podrazumeva razvoj strategija za premoščavanje jaza između simulacionih i eksperimentalnih rešenja simulacija.
- Korišćenje naprednih simulacionih okruženja kao što su ROS2 (eng. Robot Operating System 2) i Gazebo za realističnije obučavanje i testiranje DRL agenata pre implementacije na hardver.
- Istraživanje i poređenje performansi drugih DRL algoritama (npr TD3, SAC) za zadatok adaptivnog podešavanja ADRC parametara.

- **Opšta unapređenja:**

- Razvoj i poređenje sistema upravljanja zasnovanih na složenijim modelima BGV-a sa predloženim sistemom, kako bi se kvantifikovale prednosti i nedostaci oba pristupa.
- Optimizacija celokupnog softverskog sistema (percepcija, vođenje, upravljanje) za izvršavanje u realnom vremenu pri *većim brzinama* kretanja BGV-a.
- Razmatranje integracije sistema sa višim nivoima *planiranja misija i autonomne vođenja* (npr. globalno planiranje putanje SLAM (eng. Simultaneous Localization and Mapping)).

Zaključno, ova disertacija je uspešno demonstrirala potencijal i efikasnost primene naprednih robusnih (ADRC) i adaptivnih (ADRC-RL) tehnika upravljanja, u kombinaciji sa savremenim metodama vođenja zasnovanim na DL-u, za rešavanje problema autonomog kretanja BGV-a. Postignuti rezultati i razvijene metodologije predstavljaju valjanu osnovu za dalji napredak u ovoj oblasti i doprinose razvoju autonomnih sistema sposobnih za pouzdan rad u izazovnim realnim uslovima.

Literatura

- [1] Google, “Mediapipe,” https://developers.google.com/mediapipe/solutions/vision/pose_landmarker/, 2023.
- [2] Y. Wang, C. Zheng, M. Sun, Z. Chen, and Q. Sun, “Reinforcement-learning-aided adaptive control for autonomous driving with combined lateral and longitudinal dynamics,” in *Proc. Data-Driven Control and Learning Systems Conference*, 2023, pp. 840–845.
- [3] I. K. Sethi, *Autonomous Vehicles and Systems: A Technological and Societal Perspective*. CRC Press, 2024.
- [4] J. Ni, J. Hu, and C. Xiang, “Unmanned ground vehicles: An introduction,” in *Design and Advanced Robust Chassis Dynamics Control for X-by-Wire Unmanned Ground Vehicle*. Springer, 2018, pp. 1–19.
- [5] B. Sebastian and P. Ben-Tzvi, “Physics based path planning for autonomous tracked vehicle in challenging terrain,” *Journal of Intelligent & Robotic Systems*, vol. 95, pp. 511–526, 2019.
- [6] S. Shafaei and H. Mousazadeh, “On the power characteristics of an unmanned tracked vehicle for autonomous transportation of agricultural payloads,” *Journal of Terramechanics*, vol. 109, pp. 21–36, 2023.
- [7] O. Alexa, T. Ciobotaru, L. c. Grigore, T. L. Grigorie, A. řtefan, I. Oncioiu, I. Priescu, and C. Vlădescu, “A review of mathematical models used to estimate wheeled and tracked unmanned ground vehicle kinematics and dynamics,” *Mathematics*, vol. 11, no. 17, p. 3735, 2023.
- [8] T. Zou, J. Angeles, and F. Hassani, “Dynamic modeling and trajectory tracking control of unmanned tracked vehicles,” *Robotics and Autonomous Systems*, vol. 110, pp. 102–111, 2018.
- [9] A. Al-Jarrah, M. Salah, and F. Almomani, “Controlling a skid-steered tracked mobile robot with slippage using various control schemes,” in *2019 20th International*

- Conference on Research and Education in Mechatronics (REM).* IEEE, 2019, pp. 1–7.
- [10] S. BaniHani, M. R. M. Hayajneh, A. Al-Jarrah, and S. Mutawe, “New control approaches for trajectory tracking and motion planning of unmanned tracked robot,” *Advances in Electrical and Electronic Engineering*, vol. 19, no. 1, pp. 42–56, 2021.
 - [11] E. Kayacan, H. Ramon, and W. Saeys, “Robust trajectory tracking error model-based predictive control for unmanned ground vehicles,” *IEEE/ASME Transactions on Mechatronics*, vol. 21, no. 2, pp. 806–814, 2015.
 - [12] H. Rizk, A. Chaibet, and A. Kribèche, “Model-based control and model-free control techniques for autonomous vehicles: A technical survey,” *Applied Sciences*, vol. 13, no. 11, p. 6700, 2023.
 - [13] J. Han, “From pid to active disturbance rejection control,” *IEEE transactions on Industrial Electronics*, vol. 56, no. 3, pp. 900–906, 2009.
 - [14] Z. Gao, “Active disturbance rejection control: a paradigm shift in feedback control system design,” in *2006 American control conference*. IEEE, 2006, pp. 7–pp.
 - [15] R. Fareh, S. Khadraoui, M. Y. Abdallah, M. Baziad, and M. Bettayeb, “Active disturbance rejection control for robotic systems: A review,” *Mechatronics*, vol. 80, p. 102671, 2021.
 - [16] Q. Zheng and Z. Gao, “On practical applications of active disturbance rejection control,” in *Proceedings of the 29th Chinese control conference*. IEEE, 2010, pp. 6095–6100.
 - [17] B. Sebastian and P. Ben-Tzvi, “Active disturbance rejection control for handling slip in tracked vehicle locomotion,” *Journal of Mechanisms and Robotics*, vol. 11, no. 2, p. 021003, 2019.
 - [18] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, “A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas,” *Machine learning and knowledge extraction*, vol. 5, no. 4, pp. 1680–1716, 2023.
 - [19] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
 - [20] D. Wu, M.-W. Liao, W.-T. Zhang, X.-G. Wang, X. Bai, W.-Q. Cheng, and W.-Y. Liu, “Yolop: You only look once for panoptic driving perception,” *Machine Intelligence Research*, vol. 19, no. 6, pp. 550–562, 2022.

- [21] J. Zhan, Y. Luo, C. Guo, Y. Wu, J. Meng, and J. Liu, “Yolopx: Anchor-free multi-task learning network for panoptic driving perception,” *Pattern Recognition*, vol. 148, p. 110152, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S003132032300849X>
- [22] D. Silver, G. Lever, N. Heess, T. Degris, D. Wierstra, and M. Riedmiller, “Deterministic policy gradient algorithms,” in *Proc. International Conference on Machine Learning*, 2014, pp. 387–395.
- [23] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. M. O. Heess, T. Erez, Y. Tassa, D. Silver, and D. Wierstra, “Continuous control with deep reinforcement learning,” in *4th International Conference on Learning Representations, ICLR 2016, San Juan, Puerto Rico, May 2-4, 2016, Conference Track Proceedings*, 2016.
- [24] S. Cao, Y. Jin, T. Trautmann, and K. Liu, “Design and experiments of autonomous path tracking based on dead reckoning,” *Applied sciences*, vol. 13, no. 1, p. 317, 2022.
- [25] Y. Yang, “A review of lane detection in autonomous vehicles,” *Journal of Advances in Engineering and Technology*, vol. 1, no. 4, pp. 30–36, 2024.
- [26] M. J. Islam, J. Hong, and J. Sattar, “Person-following by autonomous robots: A categorical overview,” *The International Journal of Robotics Research*, vol. 38, no. 14, pp. 1581–1618, 2019.
- [27] M. Stanković, R. Madonski, and S. Manojlović, “Systematic design of adrc-based unmanned tracked vehicle trajectory tracking with fpga-in-the-loop validation,” *Vojnotehnički glasnik*, vol. 72, no. 4, pp. 1700–1725, 2024.
- [28] S.-B. Amokrane, M. Z. Laidouni, T. Adli, R. Madonski, and M. Stanković, “Active disturbance rejection control for unmanned tracked vehicles in leader–follower scenarios: Discrete-time implementation and field test validation,” *Mechatronics*, vol. 97, p. 103114, 2024.
- [29] Z. Gao *et al.*, “Scaling and bandwidth-parameterization based controller tuning,” in *Acc*, vol. 4, 2003, pp. 4989–4996.
- [30] A. Gadekar, S. Fulsundar, P. Deshmukh, J. Aher, K. Kataria, V. Patel, and S. Barve, “Rakshak: A modular unmanned ground vehicle for surveillance and logistics operations,” *Cognitive Robotics*, vol. 3, pp. 23–33, 2023.
- [31] M. He, X. Yue, Y. Zheng, J. Chen, S. Wu, Z. Heng, X. Zhou, and Y. Cai, “State of the art and future trends in obstacle-surmounting unmanned ground vehicle configuration and dynamics,” *Robotica*, vol. 41, no. 9, pp. 2625–2647, 2023.

- [32] B. Paden, M. Čáp, S. Z. Yong, D. Yershov, and E. Frazzoli, “A survey of motion planning and control techniques for self-driving urban vehicles,” *IEEE Transactions on intelligent vehicles*, vol. 1, no. 1, pp. 33–55, 2016.
- [33] Z. Zuo, M. Yang, H. Wang, Y. Wang, L. Wang, and X. Luo, “A lateral control strategy for unmanned ground vehicles with model predictive control and active disturbance rejection control,” *Transactions of the Institute of Measurement and Control*, vol. 43, no. 15, pp. 3473–3482, 2021.
- [34] P. J. Durst, G. Monroe, C. L. Bethel, D. T. Anderson, and D. W. Carruth, “A history and overview of mobility modeling for autonomous unmanned ground vehicles,” in *Autonomous Systems: Sensors, Vehicles, Security, and the Internet of Everything*, vol. 10643. SPIE, 2018, pp. 103–113.
- [35] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann *et al.*, “Stanley: The robot that won the darpa grand challenge,” *Journal of field Robotics*, vol. 23, no. 9, pp. 661–692, 2006.
- [36] D. Tilbury and A. Ulsoy, “Reliable operations of unmanned ground vehicles: Research at the ground robotics reliability center,” in *Proceedings of IARP workshop on technical challenges for dependable robots in human environments*, 2010, pp. 27–32.
- [37] J. Ni, J. Hu, and C. Xiang, “A review for design and dynamics control of unmanned ground vehicle,” *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 235, no. 4, pp. 1084–1100, 2021.
- [38] J. Shin, D. Kwak, and T. Lee, “Robust path control for an autonomous ground vehicle in rough terrain,” *Control Engineering Practice*, vol. 98, p. 104384, 2020.
- [39] S. Zhu, G. Xiong, H. Chen, and J. Gong, “Guidance point generation-based cooperative ugv teleoperation in unstructured environment,” *Sensors*, vol. 21, no. 7, p. 2323, 2021.
- [40] X. Ao, L.-m. Wang, J.-x. Hou, Y.-Q. Xue, S.-j. Rao, Z.-Y. Zhou, F.-X. Jia, Z.-Y. Zhang, and L.-m. Li, “Road recognition and stability control for unmanned ground vehicles on complex terrain,” *IEEE Access*, 2023.
- [41] A. Mohamed, M. El-Gindy, and J. Ren, “Advanced control techniques for unmanned ground vehicle: literature survey,” *International journal of vehicle performance*, vol. 4, no. 1, pp. 46–73, 2018.

- [42] S. M. Zadeh, D. Powers, and R. B. Zadeh, “Autonomy and unmanned vehicles augmented reactive mission-motion planning architecture for autonomous vehicles,” *CoRR*, 2020.
- [43] S. G. Fernandez, K. Vijayakumar, R. Palanisamy, K. Selvakumar, D. Karthikayan, D. Selvabharathi, S. Vidyasagar, and V. Kalyanasundhram, “Unmanned and autonomous ground vehicle,” *International Journal of Electrical and Computer Engineering*, vol. 9, no. 5, p. 4466, 2019.
- [44] T. van der Sande and H. Nijmeijer, “From cooperative to autonomous vehicles,” *Sensing and Control for Autonomous Vehicles: Applications to Land, Water and Air Vehicles*, pp. 435–452, 2017.
- [45] V. Ahluwalia, J. Arents, A. Oraby, and M. Greitans, “Construction and benchmark of an autonomous tracked mobile robot system,” *Robotic Systems and Applications*, vol. 2, no. 1, pp. 15–28, 2022.
- [46] F. Rubio, F. Valero, and C. Llopis-Albert, “A review of mobile robots: Concepts, methods, theoretical framework, and applications,” *International Journal of Advanced Robotic Systems*, vol. 16, no. 2, p. 1729881419839596, 2019.
- [47] L. Tagliavini, G. Colucci, A. Botta, P. Cavallone, L. Baglieri, and G. Quaglia, “Wheeled mobile robots: state of the art overview and kinematic comparison among three omnidirectional locomotion strategies,” *Journal of intelligent & robotic systems*, vol. 106, no. 3, p. 57, 2022.
- [48] Y. Zhao, J. Wang, G. Cao, Y. Yuan, X. Yao, and L. Qi, “Intelligent control of multilegged robot smooth motion: a review,” *IEEE Access*, vol. 11, pp. 86 645–86 685, 2023.
- [49] M. D. Teji, T. Zou, and D. S. Zeleke, “A survey of off-road mobile robots: Slippage estimation, robot control, and sensing technology,” *Journal of Intelligent & Robotic Systems*, vol. 109, no. 2, p. 38, 2023.
- [50] C. K. Y. L. L. Man, Y. Koonjul, and L. Nagowah, “A low cost autonomous unmanned ground vehicle,” *Future Computing and Informatics Journal*, vol. 3, no. 2, pp. 304–320, 2018.
- [51] D. Li, S. Wu, Y. Zhao, Z. Li, and J. Gong, “A hierarchical path tracking method for high-speed unmanned tracked vehicle,” in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*. IEEE, 2021, pp. 38–43.

- [52] X. Wang, Y. Wang, Q. Sun, Y. Chen, and A. Al-Zahran, “Adaptive robust control of unmanned tracked vehicles for trajectory tracking based on constraint modeling and analysis,” *Nonlinear Dynamics*, vol. 112, no. 11, pp. 9117–9135, 2024.
- [53] M. Liu, Y. Xu, X. Lin, Y. Tan, Y. Pu, W. Li, and D. Oetomo, “On active disturbance rejection control for unmanned tracked ground vehicles with nonsmooth disturbances,” *Unmanned Systems*, vol. 12, no. 06, pp. 1023–1037, 2024.
- [54] D. Tian, J. Gao, C. Liu, and X. Shi, “Simulation of upward jump control for one-legged robot based on qp optimization,” *Sensors*, vol. 21, no. 5, p. 1893, 2021.
- [55] N. A. I. Ruslan, N. H. Amer, K. Hudha, Z. A. Kadir, S. A. F. M. Ishak, and S. M. F. S. Dardin, “Modelling and control strategies in path tracking control for autonomous tracked vehicles: A review of state of the art and challenges,” *Journal of Terramechanics*, vol. 105, pp. 67–79, 2023.
- [56] N. Hung, F. Rego, J. Quintas, J. Cruz, M. Jacinto, D. Souto, A. Potes, L. Sebastiao, and A. Pascoal, “A review of path following control strategies for autonomous robotic vehicles: Theory, simulations, and experiments,” *Journal of Field Robotics*, vol. 40, no. 3, pp. 747–779, 2023. [Online]. Available: <https://onlinelibrary.wiley.com/doi/abs/10.1002/rob.22142>
- [57] M. Sarcinelli-Filho and R. Carelli, *Control of Ground and Aerial Robots*. Springer, 2023.
- [58] A. P. Aguiar and J. P. Hespanha, “Trajectory-tracking and path-following of underactuated autonomous vehicles with parametric modeling uncertainty,” *IEEE transactions on automatic control*, vol. 52, no. 8, pp. 1362–1379, 2007.
- [59] Y. Xing, C. Lv, L. Chen, H. Wang, H. Wang, D. Cao, E. Velenis, and F.-Y. Wang, “Advances in vision-based lane detection: Algorithms, integration, assessment, and perspectives on acp-based parallel vision,” *IEEE/CAA Journal of Automatica Sinica*, vol. 5, no. 3, pp. 645–661, 2018.
- [60] N. B. Chetan, J. Gong, H. Zhou, D. Bi, J. Lan, and L. Qie, “An overview of recent progress of lane detection for autonomous driving,” in *2019 6th International conference on dependable systems and their applications (DSA)*. IEEE, 2020, pp. 341–346.
- [61] N. J. Zakaria, M. I. Shapiai, R. Abd Ghani, M. N. M. Yassin, M. Z. Ibrahim, and N. Wahid, “Lane detection in autonomous vehicles: A systematic review,” *IEEE access*, vol. 11, pp. 3729–3765, 2023.

- [62] A. Bar Hillel, R. Lerner, D. Levi, and G. Raz, “Recent progress in road and lane detection: a survey,” *Machine vision and applications*, vol. 25, no. 3, pp. 727–745, 2014.
- [63] S. Sultana, B. Ahmed, M. Paul, M. R. Islam, and S. Ahmad, “Vision-based robust lane detection and tracking in challenging conditions,” *IEEE Access*, vol. 11, pp. 67 938–67 955, 2023.
- [64] M. Aly, “Real time detection of lane markers in urban streets,” in *2008 IEEE intelligent vehicles symposium*. IEEE, 2008, pp. 7–12.
- [65] G. Kaur and D. Kumar, “Lane detection techniques: A review,” *International Journal of Computer Applications*, vol. 112, no. 10, 2015.
- [66] R. Zhang, Y. Wu, W. Gou, and J. Chen, “Rs-lane: A robust lane detection method based on resnest and self-attention distillation for challenging traffic situations,” *Journal of advanced transportation*, vol. 2021, no. 1, p. 7544355, 2021.
- [67] F. Munir, S. Azam, M. Jeon, B.-G. Lee, and W. Pedrycz, “Ldnet: End-to-end lane marking detection approach using a dynamic vision sensor,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 7, pp. 9318–9334, 2021.
- [68] S. Ghanem, P. Kanungo, G. Panda, S. C. Satapathy, and R. Sharma, “Lane detection under artificial colored light in tunnels and on highways: an iot-based framework for smart city infrastructure,” *Complex & Intelligent Systems*, vol. 9, no. 4, pp. 3601–3612, 2023.
- [69] C. Lee and J.-H. Moon, “Robust lane detection and tracking for real-time applications,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 12, pp. 4043–4048, 2018.
- [70] D. Kavitha and S. Ravikumar, “Retracted article: Designing an iot based autonomous vehicle meant for detecting speed bumps and lanes on roads,” *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, no. 7, pp. 7417–7426, 2021.
- [71] B. Akbari, J. Thiyyagalingam, R. Lee, and K. Thia, “A multilane tracking algorithm using ipda with intensity feature,” *Sensors*, vol. 21, no. 2, p. 461, 2021.
- [72] R. R. Dhanakshirur, P. Pillai, R. A. Tabib, U. Patil, and U. Mudenagudi, “A framework for lane prediction on unstructured roads,” in *Advances in Signal Processing and Intelligent Recognition Systems: 4th International Symposium SIRS 2018, Bangalore, India, September 19–22, 2018, Revised Selected Papers 4*. Springer, 2019, pp. 178–189.

- [73] Z. Feng, S. Zhang, M. Kunert, and W. Wiesbeck, “Applying neural networks with a high-resolution automotive radar for lane detection,” in *AmE 2019-Automotive meets Electronics; 10th GMM-Symposium*. VDE, 2019, pp. 1–6.
- [74] M. Fakhfakh, L. Chaari, and N. Fakhfakh, “Bayesian curved lane estimation for autonomous driving,” *Journal of Ambient Intelligence and Humanized Computing*, vol. 11, no. 10, pp. 4133–4143, 2020.
- [75] Y. Sun, L. Wang, Y. Chen, and M. Liu, “Accurate lane detection with atrous convolution and spatial pyramid pooling for autonomous driving,” in *2019 IEEE International Conference on Robotics and Biomimetics (ROBIO)*. IEEE, 2019, pp. 642–647.
- [76] J. Philion, “Fastdraw: Addressing the long tail of lane detection by adapting a sequential prediction network,” in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 2019, pp. 11 582–11 591.
- [77] D. K. Dewangan, S. P. Sahu, B. Sairam, and A. Agrawal, “Vldnet: Vision-based lane region detection network for intelligent vehicle system using semantic segmentation,” *Computing*, vol. 103, no. 12, pp. 2867–2892, 2021.
- [78] E. S. Dawam and X. Feng, “Smart city lane detection for autonomous vehicle,” in *2020 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCom/CyberSciTech)*. IEEE, 2020, pp. 334–338.
- [79] Z. Wu, K. Qiu, T. Yuan, and H. Chen, “A method to keep autonomous vehicles steadily drive based on lane detection,” *International Journal of Advanced Robotic Systems*, vol. 18, no. 2, p. 17298814211002974, 2021.
- [80] L. Zhang, F. Jiang, B. Kong, J. Yang, and C. Wang, “Real-time lane detection by using biologically inspired attention mechanism to learn contextual information,” *Cognitive Computation*, vol. 13, pp. 1333–1344, 2021.
- [81] L. Liu, X. Chen, S. Zhu, and P. Tan, “Condlanenet: a top-to-down lane detection framework based on conditional convolution,” in *Proceedings of the IEEE/CVF international conference on computer vision*, 2021, pp. 3773–3782.
- [82] S.-W. Baek, M.-J. Kim, U. Suddamalla, A. Wong, B.-H. Lee, and J.-H. Kim, “Real-time lane detection based on deep learning,” *Journal of Electrical Engineering & Technology*, vol. 17, no. 1, pp. 655–664, 2022.

- [83] E. Oğuz, A. Küçükmanisa, R. Duvar, and O. Urhan, “A deep learning based fast lane detection approach,” *Chaos, Solitons & Fractals*, vol. 155, p. 111722, 2022.
- [84] J. Ni, Y. Chen, Y. Chen, J. Zhu, D. Ali, and W. Cao, “A survey on theories and applications for self-driving cars based on deep learning methods,” *Applied Sciences*, vol. 10, no. 8, p. 2749, 2020.
- [85] C. S. Dima, N. Vandapel, and M. Hebert, “Classifier fusion for outdoor obstacle detection,” in *IEEE International Conference on Robotics and Automation, 2004. Proceedings. ICRA'04. 2004*, vol. 1. IEEE, 2004, pp. 665–671.
- [86] X. Zhang, M. Zhou, P. Qiu, Y. Huang, and J. Li, “Radar and vision fusion for the real-time obstacle detection and identification,” *Industrial Robot: the international journal of robotics research and application*, vol. 46, no. 3, pp. 391–395, 2019.
- [87] J.-w. Hu, B.-y. Zheng, C. Wang, C.-h. Zhao, X.-l. Hou, Q. Pan, and Z. Xu, “A survey on multi-sensor fusion based obstacle detection for intelligent ground vehicles in off-road environments,” *Frontiers of Information Technology & Electronic Engineering*, vol. 21, no. 5, pp. 675–692, 2020.
- [88] F. Islam, M. Nabi, and J. E. Ball, “Off-road detection analysis for autonomous ground vehicles: A review,” *Sensors*, vol. 22, no. 21, p. 8463, 2022.
- [89] X. Yu and M. Marinov, “A study on recent developments and issues with obstacle detection systems for automated vehicles,” *Sustainability*, vol. 12, no. 8, p. 3281, 2020.
- [90] D. Vera-Yanez, A. Pereira, N. Rodrigues, J. P. Molina, A. S. García, and A. Fernández-Caballero, “Optical flow-based obstacle detection for mid-air collision avoidance,” *Sensors*, vol. 24, no. 10, p. 3016, 2024.
- [91] S. Badrloo, M. Varshosaz, S. Pirasteh, and J. Li, “Image-based obstacle detection methods for the safe navigation of unmanned vehicles: A review,” *Remote Sensing*, vol. 14, no. 15, p. 3824, 2022.
- [92] Y. Parmar, S. Natarajan, and G. Sobha, “Deeprange: deep-learning-based object detection and ranging in autonomous driving,” *IET Intelligent Transport Systems*, vol. 13, no. 8, pp. 1256–1264, 2019.
- [93] M. Hussain, “Yolov1 to v8: Unveiling each variant—a comprehensive review of yolo,” *IEEE access*, vol. 12, pp. 42 816–42 833, 2024.
- [94] A. Vijayakumar and S. Vairavasundaram, “Yolo-based object detection models: A review and its applications,” *Multimedia Tools and Applications*, vol. 83, no. 35, pp. 83 535–83 574, 2024.

- [95] R. Marino, S. Scalzi, G. Orlando, and M. Netto, “A nested pid steering control for lane keeping in vision based autonomous vehicles,” in *2009 American Control Conference*. IEEE, 2009, pp. 2885–2890.
- [96] B.-C. Chen, B.-C. Luan, and K. Lee, “Design of lane keeping system using adaptive model predictive control,” in *2014 IEEE International conference on automation science and engineering (CASE)*. IEEE, 2014, pp. 922–926.
- [97] Z. Chu, C. Wu, and N. Sepehri, “Automated steering controller design for vehicle lane keeping combining linear active disturbance rejection control and quantitative feedback theory,” *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, vol. 232, no. 7, pp. 937–948, 2018.
- [98] A. Singhal, V. Mohta, A. Jha, Y. Khandelwal, D. Agrawal, S. Kowshik, S. Agarwal, S. Shrivastava, V. Lodhi, and D. Chakravarty, “Real-time lane detection, fitting and navigation for unstructured environments,” in *2019 International Conference on Image and Video Processing, and Artificial Intelligence*, vol. 11321. SPIE, 2019, pp. 146–151.
- [99] P. Amaradi, N. Sriramoju, L. Dang, G. S. Tewolde, and J. Kwon, “Lane following and obstacle detection techniques in autonomous driving vehicles,” in *2016 IEEE International Conference on Electro Information Technology (EIT)*. IEEE, 2016, pp. 0674–0679.
- [100] M. Liu, X. Deng, Z. Lei, C. Jiang, and C. Piao, “Autonomous lane keeping system: Lane detection, tracking and control on embedded system,” *Journal of Electrical Engineering & Technology*, vol. 16, no. 1, pp. 569–578, 2021.
- [101] T. S. Abd Al-Zaher, A. M. Bayoumy, A.-H. M. Sharaf, and Y. H. H. El-din, “Lane tracking and obstacle avoidance for autonomous ground vehicles,” in *2012 9th France-Japan & 7th Europe-Asia Congress on Mechatronics (MECATRONICS)/13th Int'l Workshop on Research and Education in Mechatronics (REM)*. IEEE, 2012, pp. 264–271.
- [102] Z. Chu, Y. Sun, C. Wu, and N. Sepehri, “Active disturbance rejection control applied to automated steering for lane keeping in autonomous vehicles,” *Control Engineering Practice*, vol. 74, pp. 13–21, 2018.
- [103] P. Zahradníček, L. Rak, J. Nohel, B. Rýznar *et al.*, “Combat unmanned ground vehicles: Perspectives for implementation into operational application,” *Security & Future*, vol. 5, no. 3, pp. 108–111, 2021.

- [104] E. Chen, ““folo”: A vision-based human-following robot,” in *2018 3rd International Conference on Automation, Mechanical Control and Computational Engineering (AMCCE 2018)*. Atlantis Press, 2018, pp. 224–232.
- [105] M. Cao, J. Wang, and L. Ming, “Multi-templates based robust tracking for robot person-following tasks,” *Applied Sciences*, vol. 11, no. 18, p. 8698, 2021.
- [106] M. G. Burke and W. Brink, “Estimating target orientation with a single camera for use in a human-following robot,” in *21st Annual Symposium of the Pattern Recognition Association of South Africa (PRASA)*. South Africa: Pattern Recognition Association of South Africa, 2010, p. 6.
- [107] W. Chung, H. Kim, Y. Yoo, C.-B. Moon, and J. Park, “The detection and following of human legs through inductive approaches for a mobile robot with a single laser range finder,” *IEEE transactions on industrial electronics*, vol. 59, no. 8, pp. 3156–3166, 2011.
- [108] M. Ramírez-Neria, J. González-Sierra, R. Madonski, R. Ramírez-Juárez, E. G. Hernandez-Martinez, and G. Fernández-Anaya, “Leader–follower formation and disturbance rejection control for omnidirectional mobile robots,” *Robotics*, vol. 12, no. 5, p. 122, 2023.
- [109] Y. Chen, “Autonomous unmanned ground vehicle (ugv) follower design,” Master’s thesis, Ohio University, 2016.
- [110] J. Fan, P. Yan, R. Li, Y. Liu, F. Wang, Y. Liu, and C. Chen, “Decoupled adaptive motion control for unmanned tracked vehicles in the leader-following task,” *World Electric Vehicle Journal*, vol. 15, no. 6, p. 239, 2024.
- [111] H. Sira-Ramírez, R. Castro-Linares, and G. Puriel-Gil, “An active disturbance rejection approach to leader-follower controlled formation,” *Asian Journal of Control*, vol. 16, no. 2, pp. 382–395, 2014.
- [112] M. Ramirez-Neria, A. Luviano-Juárez, R. Madonski, R. Ramírez-Juárez, N. Lozada-Castillo, and Z. Gao, “Leader-follower adrc strategy for omnidirectional mobile robots without time-derivatives in the tracking controller,” in *2023 American Control Conference (ACC)*. IEEE, 2023, pp. 405–410.
- [113] C. V. Samak, T. V. Samak, and S. Kandhasamy, “Control strategies for autonomous vehicles,” in *Autonomous driving and advanced driver-assistance systems (ADAS)*. CRC Press, 2021, pp. 37–86.

- [114] Q. Yao, Y. Tian, Q. Wang, and S. Wang, “Control strategies on path tracking for autonomous vehicle: State of the art and future challenges,” *IEEE Access*, vol. 8, pp. 161 211–161 222, 2020.
- [115] J. Zhang, X. Yang, W. Wang, J. Guan, L. Ding, and V. C. Lee, “Automated guided vehicles and autonomous mobile robots for recognition and tracking in civil engineering,” *Automation in Construction*, vol. 146, p. 104699, 2023.
- [116] D. C. Guastella and G. Muscato, “Learning-based methods of perception and navigation for ground vehicles in unstructured environments: A review,” *Sensors*, vol. 21, no. 1, p. 73, 2020.
- [117] J. Cao, C. Song, S. Peng, S. Song, X. Zhang, and F. Xiao, “Trajectory tracking control algorithm for autonomous vehicle considering cornering characteristics,” *IEEE Access*, vol. 8, pp. 59 470–59 484, 2020.
- [118] A. Finn and S. Scheding, “Developments and challenges for autonomous unmanned vehicles,” *Intelligent Systems Reference Library*, vol. 3, pp. 128–154, 2010.
- [119] Z. Wang, “A survey on convex optimization for guidance and control of vehicular systems,” *Annual Reviews in Control*, vol. 57, p. 100957, 2024.
- [120] J. Schulte, M. Kocherovsky, N. Paul, M. Pleune, and C.-J. Chung, “Autonomous human-vehicle leader-follower control using deep-learning-driven gesture recognition,” *Vehicles*, vol. 4, no. 1, pp. 243–258, 2022.
- [121] N. Horri, W. Holderbaum, and F. Giulietti, “Challenges in the guidance, navigation and control of autonomous and transport vehicles,” <https://www.mdpi.com/2076-3417/14/15/6635>, p. 6635, 2024.
- [122] Z. Gao, S. Hu, and F. Jiang, “A novel motion control design approach based on active disturbance rejection,” in *Proceedings of the 40th IEEE conference on decision and control (Cat. No. 01Ch37228)*, vol. 5. IEEE, 2001, pp. 4877–4882.
- [123] A. Balasubramaniam and S. Pasricha, “Object detection in autonomous vehicles: Status and open challenges,” *arXiv preprint arXiv:2201.07706*, 2022.
- [124] Q. Liu, Z. Li, S. Yuan, Y. Zhu, and X. Li, “Review on vehicle detection technology for unmanned ground vehicles,” *Sensors*, vol. 21, no. 4, p. 1354, 2021.
- [125] E. Balestrieri, P. Daponte, L. De Vito, and F. Lamonaca, “Sensors and measurements for unmanned systems: An overview,” *Sensors*, vol. 21, no. 4, p. 1518, 2021.

- [126] P. Soviany and R. T. Ionescu, “Optimizing the trade-off between single-stage and two-stage deep object detectors using image difficulty prediction,” in *2018 20th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing (SYNASC)*. IEEE, 2018, pp. 209–214.
- [127] Z. Qiu, N. Zhao, L. Zhou, M. Wang, L. Yang, H. Fang, Y. He, and Y. Liu, “Vision-based moving obstacle detection and tracking in paddy field using improved yolov3 and deep sort,” *Sensors*, vol. 20, no. 15, p. 4082, 2020.
- [128] Y. Li and L. Xu, “Panoptic perception for autonomous driving: A survey,” *arXiv preprint arXiv:2408.15388*, 2024.
- [129] Q.-H. Che, D.-T. Le, M.-Q. Pham, V.-T. Nguyen, and D.-K. Lam, “Twinlitenetplus: a stronger model for real-time drivable area and lane segmentation,” *arXiv preprint arXiv:2403.16958*, 2024.
- [130] X. Yumeng, N. B. Manshor, N. A. Husin, and L. Chengzhi, “Improving yolopx using yolop and yolov8 for panoptic driving perception,” *JOIV: International Journal on Informatics Visualization*, vol. 9, no. 1, pp. 248–257, 2025.
- [131] M. Sridevi and M. Harish, “Computer vision based panoptic driving perception under various weather conditions,” *Procedia Computer Science*, vol. 237, pp. 803–810, 2024.
- [132] C. Han, Q. Zhao, S. Zhang, Y. Chen, Z. Zhang, and J. Yuan, “Yolopv2: Better, faster, stronger for panoptic driving perception,” *arXiv preprint arXiv:2208.11434*, 2022.
- [133] J. Zhan, J. Liu, Y. Wu, and C. Guo, “Multi-task visual perception for object detection and semantic segmentation in intelligent driving,” *Remote Sensing*, vol. 16, no. 10, p. 1774, 2024.
- [134] S. Kulkarni, S. Deshmukh, F. Fernandes, A. Patil, and V. Jabade, “Poseanalyser: A survey on human pose estimation,” *SN Computer Science*, vol. 4, no. 2, p. 136, 2023.
- [135] C. Zheng, W. Wu, C. Chen, T. Yang, S. Zhu, J. Shen, N. Kehtarnavaz, and M. Shah, “Deep learning-based human pose estimation: A survey,” *ACM Computing Surveys*, vol. 56, no. 1, pp. 1–37, 2023.
- [136] S. Dubey and M. Dixit, “A comprehensive survey on human pose estimation approaches,” *Multimedia Systems*, vol. 29, no. 1, pp. 167–195, 2023.
- [137] H. Chen, R. Feng, S. Wu, H. Xu, F. Zhou, and Z. Liu, “2d human pose estimation: A survey,” *Multimedia systems*, vol. 29, no. 5, pp. 3115–3138, 2023.

- [138] R. Josyula and S. Ostadabbas, “A review on human pose estimation,” *arXiv preprint arXiv:2110.06877*, 2021.
- [139] Z. Li, *Guidance, control and estimation of autonomous vehicle systems*. University of Illinois at Urbana-Champaign, 2013.
- [140] A. Artuñedo, M. Moreno-Gonzalez, and J. Villagra, “Lateral control for autonomous vehicles: A comparative evaluation,” *Annual Reviews in Control*, vol. 57, p. 100910, 2024.
- [141] D. C. Andrade, F. Bueno, F. R. Franco, R. A. Silva, J. H. Z. Neme, E. Margraf, W. T. Omoto, F. A. Farinelli, A. M. Tusset, S. Okida *et al.*, “A novel strategy for road lane detection and tracking based on a vehicle’s forward monocular camera,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 20, no. 4, pp. 1497–1507, 2018.
- [142] X. Yan, S. Wang, Y. He, A. Ma, and S. Zhao, “Autonomous tracked vehicle trajectory tracking control based on disturbance observation and sliding mode control,” in *Actuators*, vol. 14, no. 2. MDPI, 2025, p. 51.
- [143] H. Wang, Z. Zuo, W. Xue, Y. Wang, and H. Yang, “Switching longitudinal and lateral semi-decoupled active disturbance rejection control for unmanned ground vehicles,” *IEEE Transactions on Industrial Electronics*, vol. 71, no. 3, pp. 3034–3043, 2023.
- [144] N. H. Amer, H. Zamzuri, K. Hudha, and Z. A. Kadir, “Modelling and control strategies in path tracking control for autonomous ground vehicles: A review of state of the art and challenges,” *Journal of intelligent & robotic systems*, vol. 86, pp. 225–254, 2017.
- [145] Y. Zhang, F. Gao, Y. Sun, N. Hovakimyan, and Z. Fang, “Guest editorial: Autonomous systems: Navigation, learning, and control,” *IET Cyber-systems and Robotics*, vol. 3, no. 4, pp. 279–280, 2021.
- [146] M. Breivik and T. I. Fossen, “Guidance laws for planar motion control,” in *2008 47th IEEE Conference on Decision and Control*. IEEE, 2008, pp. 570–577.
- [147] M. Bibuli, O. Parodi, L. Lapierre, G. Bruzzone, and M. Caccia, “Vehicle-following guidance for unmanned marine vehicles,” *IFAC Proceedings Volumes*, vol. 42, no. 18, pp. 103–108, 2009.
- [148] A. D. Sabiha, M. A. Kamel, E. Said, and W. M. Hussein, “Ros-based trajectory tracking control for autonomous tracked vehicle using optimized backstepping and

- sliding mode control,” *Robotics and Autonomous Systems*, vol. 152, p. 104058, 2022.
- [149] H. Lu, G. Xiong, and K. Guo, “Motion predicting of autonomous tracked vehicles with online slip model identification,” *Mathematical Problems in Engineering*, vol. 2016, no. 1, p. 6375652, 2016.
- [150] H. Gao, H. Yang, X. Zhang, X. Ren, F. Liang, R. Yan, Q. Liu, M. Hu, F. Zhang, J. Gao *et al.*, “Longitudinal velocity control of autonomous driving based on extended state observer,” *CAAI Transactions on Intelligence Technology*, 2025.
- [151] Y. Xia, F. Pu, S. Li, and Y. Gao, “Lateral path tracking control of autonomous land vehicle based on adrc and differential flatness,” *IEEE Transactions on Industrial Electronics*, vol. 63, no. 5, pp. 3091–3099, 2016.
- [152] H. Wang, Z. Zuo, Y. Wang, H. Yang, and S. Chang, “Composite nonlinear extended state observer and its application to unmanned ground vehicles,” *Control Engineering Practice*, vol. 109, p. 104731, 2021.
- [153] S. Azam, F. Munir, and M. Jeon, “Dynamic control system design for autonomous car.” in *VEHITS*, 2020, pp. 456–463.
- [154] A. M. Annaswamy and A. L. Fradkov, “A historical perspective of adaptive control and learning,” *Annual Reviews in Control*, vol. 52, pp. 18–41, 2021.
- [155] Z. Tang, H. Liu, Z. Zhao, J. Lu, H. Guan, and H. Chen, “Trajectory tracking of unmanned tracked vehicle based on model-free algorithm for off-road driving conditions,” in *2021 IEEE International Conference on Unmanned Systems (ICUS)*. IEEE, 2021, pp. 870–877.
- [156] T. Hiramatsu, S. Morita, M. Pencelli, M. Niccolini, M. Ragaglia, and A. Argiolas, “Path-tracking controller for tracked mobile robot on rough terrain,” *International Journal of Electrical and Computer Engineering*, vol. 13, no. 2, pp. 59–64, 2019.
- [157] F. Santoso, M. A. Garratt, and S. G. Anavatti, “State-of-the-art integrated guidance and control systems in unmanned vehicles: A review,” *IEEE Systems Journal*, vol. 15, no. 3, pp. 3312–3323, 2020.
- [158] Y. Kebbati, N. Ait-Oufroukh, D. Ichalal, and V. Vigneron, “Lateral control for autonomous wheeled vehicles: A technical review,” *Asian Journal of Control*, vol. 25, no. 4, pp. 2539–2563, 2023.
- [159] T. Mitsuhashi, Y. Chida, and M. Tanemura, “Autonomous travel of lettuce harvester using model predictive control,” *IFAC-PapersOnLine*, vol. 52, no. 30, pp. 155–160, 2019.

- [160] H. Wang, Z. Zuo, Y. Wang, H. Yang, and C. Hu, “Longitudinal velocity regulation of ugvs: A composite control approach for acceleration and deceleration,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 24, no. 10, pp. 11 096–11 106, 2023.
- [161] J. Kong, M. Pfeiffer, G. Schildbach, and F. Borrelli, “Kinematic and dynamic vehicle models for autonomous driving control design,” in *2015 IEEE intelligent vehicles symposium (IV)*. IEEE, 2015, pp. 1094–1099.
- [162] X. Zhang, X. Zhang, W. Xue, and B. Xin, “An overview on recent progress of extended state observers for uncertain systems: Methods, theory, and applications,” *Advanced Control for Applications: Engineering and Industrial Systems*, vol. 3, no. 2, p. e89, 2021.
- [163] G. Herbst and R. Madonski, “Active disturbance rejection control: From principles to practice,” 2025.
- [164] W.-H. Chen, J. Yang, L. Guo, and S. Li, “Disturbance-observer-based control and related methods—an overview,” *IEEE Transactions on industrial electronics*, vol. 63, no. 2, pp. 1083–1095, 2015.
- [165] A. Radke and Z. Gao, “A survey of state and disturbance observers for practitioners,” in *2006 American Control Conference*. IEEE, 2006, pp. 6–pp.
- [166] Q. Zheng, L. Q. Gao, and Z. Gao, “On validation of extended state observer through analysis and experimentation,” *Journal of Dynamic Systems, Measurement, and Control*, 2012.
- [167] Q. Zheng and Z. Gao, “Active disturbance rejection control: between the formulation in time and the understanding in frequency,” *Control Theory and Technology*, vol. 14, pp. 250–259, 2016.
- [168] C. Sen, X. Wenchao, L. Zhiyun, and Y. Huang, “On active disturbance rejection control for path following of automated guided vehicle with uncertain velocities,” in *2019 American Control Conference (ACC)*. IEEE, 2019, pp. 2446–2451.
- [169] H. Yi, X. Wen-Chao, and Z. Chun-Zhe, “Active disturbance rejection control: methodology and theoretical analysis,” *Journal of Systems Science and Mathematical Sciences*, vol. 31, no. 9, p. 1111, 2011.
- [170] Y. Long, Z. Du, L. Cong, W. Wang, Z. Zhang, and W. Dong, “Active disturbance rejection control based human gait tracking for lower extremity rehabilitation exoskeleton,” *ISA transactions*, vol. 67, pp. 389–397, 2017.

- [171] B. Ye, X. Yao, and Y. Yang, “Speed control of mobile robot based on ladr,” in *2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, vol. 1. IEEE, 2016, pp. 310–313.
- [172] B.-Z. Guo and Z.-L. Zhao, “Active disturbance rejection control: Theoretical perspectives,” *Communications in Information and Systems*, vol. 15, no. 3, pp. 361–421, 2015.
- [173] Z. Gao, Y. Huang, and J. Han, “An alternative paradigm for control system design,” in *Proceedings of the 40th IEEE conference on decision and control (Cat. No. 01CH37228)*, vol. 5. IEEE, 2001, pp. 4578–4585.
- [174] X. Jin, H. Lv, Z. He, Z. Li, Z. Wang, and N. V. O. Ikiela, “Design of active disturbance rejection controller for trajectory-following of autonomous ground electric vehicles,” *Symmetry*, vol. 15, no. 9, p. 1786, 2023.
- [175] N. Kang, Y. Han, T. Guan, and S. Wang, “Improved adrc-based autonomous vehicle path-tracking control study considering lateral stability,” *Applied Sciences*, vol. 12, no. 9, p. 4660, 2022.
- [176] N. Sang and L. Chen, “Design of an active front steering system for a vehicle using an active disturbance rejection control method,” *Science Progress*, vol. 103, no. 1, p. 0036850419883565, 2020.
- [177] H. Wang, Z. Zuo, Y. Wang, H. Yang, and C. Hu, “Estimator-based turning control for unmanned ground vehicles: An anti-peak extended state observer approach,” *IEEE Transactions on Vehicular Technology*, vol. 71, no. 12, pp. 12 489–12 498, 2022.
- [178] G. Herbst and R. Madonski, “Tuning and implementation variants of discrete-time ADRC,” *Control Theory and Technology*, vol. 21, pp. 72–88, 2023.
- [179] G. A. Kumar, J. H. Lee, J. Hwang, J. Park, S. H. Youn, and S. Kwon, “Lidar and camera fusion approach for object distance estimation in self-driving vehicles,” *Symmetry*, vol. 12, no. 2, p. 324, 2020.
- [180] D. Robot, “All-terrain autonomous navigation robot with GPS-IMU Jaguar lite user guide,” <https://www.DrRobot.com/>, 2001, accessed: 2024-07-25.
- [181] P. Zhao and R. Nagamune, “Switching linear parameter-varying control with improved local performance and optimized switching surfaces,” *International Journal of Robust and Nonlinear Control*, vol. 28, no. 10, pp. 3403–3421, 2018.

- [182] Y. Li, M. Jia, X. Han, and X.-S. Bai, “Towards a comprehensive optimization of engine efficiency and emissions by coupling artificial neural network (ANN) with genetic algorithm (GA),” *Energy*, vol. 225, p. 120331, 2021.
- [183] Y. Zheng, J. Tao, Q. Sun, X. Zeng, H. Sun, M. Sun, and Z. Chen, “Ddpg-based active disturbance rejection 3d path-following control for powered parafoil under wind disturbances,” *Nonlinear Dynamics*, vol. 111, no. 12, pp. 11 205–11 221, 2023.
- [184] S. Wang, H. Zhu, M. Wu, and W. Zhang, “Active disturbance rejection decoupling control for three-degree-of-freedom six-pole active magnetic bearing based on bp neural network,” *IEEE Transactions on Applied Superconductivity*, vol. 30, no. 4, pp. 1–5, 2020.
- [185] R.-C. Roman, R.-E. Precup, and E. M. Petriu, “Hybrid data-driven fuzzy active disturbance rejection control for tower crane systems,” *European Journal of Control*, vol. 58, pp. 373–387, 2021.
- [186] L. Zhao, W. He, F. Lv, and W. Xiaoguang, “Trajectory tracking control for parafoil systems based on the model-free adaptive control method,” *IEEE Access*, vol. 8, pp. 152 620–152 636, 2020.
- [187] X. Kong and Y. Xia, “Reinforcement learning-based active disturbance rejection control for nonlinear systems with disturbance,” in *Proc. Conference on Fully Actuated System Theory and Applications*, 2023, pp. 799–804.
- [188] Y. Zheng, J. Tao, J. Hartikainen, F. Duan, H. Sun, M. Sun, Q. Sun, X. Zeng, Z. Chen, and G. Xie, “Ddpg based ladrc trajectory tracking control for underactuated unmanned ship under environmental disturbances,” *Ocean Engineering*, vol. 271, p. 113667, 2023.
- [189] J. Shin, T. A. Badgwell, K.-H. Liu, and J. H. Lee, “Reinforcement learning—overview of recent progress and implications for process control,” *Computers & Chemical Engineering*, vol. 127, pp. 282–294, 2019.
- [190] R. Nian, J. Liu, and B. Huang, “A review on reinforcement learning: Introduction and applications in industrial process control,” *Computers & Chemical Engineering*, vol. 139, p. 106886, 2020.
- [191] M. Zhu, Y. Wang, Z. Pu, J. Hu, X. Wang, and R. Ke, “Safe, efficient, and comfortable velocity control based on reinforcement learning for autonomous driving,” *Transportation Research Part C: Emerging Technologies*, vol. 117, p. 102662, 2020.

- [192] Y. Zhang, L. Guo, B. Gao, T. Qu, and H. Chen, “Deterministic promotion reinforcement learning applied to longitudinal velocity control for automated vehicles,” *IEEE Transactions on Vehicular Technology*, vol. 69, no. 1, pp. 338–348, 2019.
- [193] J. Liao, T. Liu, X. Tang, X. Mu, B. Huang, and D. Cao, “Decision-making strategy on highway for autonomous vehicles using deep reinforcement learning,” *IEEE Access*, vol. 8, pp. 177 804–177 814, 2020.
- [194] Ó. Pérez-Gil, R. Barea, E. López-Guillén, L. M. Bergasa, C. Gómez-Huélamo, R. Gutiérrez, and A. Díaz-Díaz, “Deep reinforcement learning based control for autonomous vehicles in carla,” *Multimedia Tools and Applications*, vol. 81, no. 3, pp. 3553–3576, 2022.
- [195] A. Dosovitskiy, G. Ros, F. Codevilla, A. Lopez, and V. Koltun, “CARLA: An open urban driving simulator,” in *Proc. of the 1st Annual Conference on Robot Learning*, vol. 78, 2017, pp. 1–16.
- [196] V. François-Lavet, P. Henderson, R. Islam, M. G. Bellemare, J. Pineau *et al.*, “An introduction to deep reinforcement learning,” *Foundations and Trends in Machine Learning*, vol. 11, no. 3-4, pp. 219–354, 2018.
- [197] S. Aradi, “Survey of deep reinforcement learning for motion planning of autonomous vehicles,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, no. 2, pp. 740–759, 2020.
- [198] L. Wu, C. Wang, P. Zhang, and C. Wei, “Deep reinforcement learning with corrective feedback for autonomous UAV landing on a mobile platform,” *Drones*, vol. 6, no. 9, p. 238, 2022.
- [199] M. Wei, S. Wang, J. Zheng, and D. Chen, “UGV navigation optimization aided by reinforcement learning-based path tracking,” *IEEE Access*, vol. 6, pp. 57 814–57 825, 2018.

Lista publikacija autora disertacije

1. Amokrane, S-B., Andrić, M., *Fuzija vizuelnih i termalnih slika u vojnim primenama pomoću faze logike*, VojNa 2023, Beograd (M63).
2. Adli, T., Amokrane, S-B., Pavlović, B., Laidouni, M., Benyahia, A., *Anomaly network intrusion detection system based on NetFlow using machine/deep learning*, Vojnotehnički glasnik, Vol. 71 Br. 4 (2023), str. 941-969, DOI: 10.5937/vojtehg71-46058 (M51).
3. Laidouni, M., Benyahia, A., Pavlović, B., Amokrane, S-B., Adli, T., *Deep learning channel estimation for 5G wireless communications*, Vojnotehnički glasnik, Vol. 71 Br. 4 (2023), str. 911-940, DOI: 10.5937/vojtehg71-46057 (M51).
4. Amokrane, S-B., Laidouni, M., Adli, T., Madonski, R., Stanković, M., *Active disturbance rejection control for unmanned tracked vehicles in leader–follower scenarios: Discrete-time implementation and field test validation*, Mechatronics 97 (2024): 103114. DOI: 10.1016/j.mechatronics.2023.103114 (M22).
5. Amokrane, S-B., Stanković, M., Benyahia, A., *Projektovanje upravljanja bespadsnog vozila sa aktivnim potiskivanjem poremećaja na bazi dubokog učenja sa podrškom: studija slučaja praćenje lidera*, YUINFO 2024 (M63).
6. Benyahia, A., Stanković, M., Amokrane, S-B., *Adaptive Control of a 5-DOF Upper Limb Exoskeleton for Passive Rehabilitation: ADRC with Online Model Parameter Estimation*, ICIST 2024 (M63).
7. Amokrane, S-B., Bujaković, D., Pavlović, B., Andrić, M., Adli, T., *Enhancing Intrusion Detection System Performance through Feature Selection*, Acta Polytechnica Hungarica 22 (2025). DOI: 10.12700/APH.22.1.2025.1.10 (M23).
8. Amokrane, S-B., Stanković, M., Madonski, R., Benyahia, A., Fareh, R., *Adaptive Tuning of Active Disturbance Rejection Control Based on Deep Reinforcement Learning: Case of Leader-Following in Unmanned Tracked Vehicles*, Proc IMechE Part I: J Systems and Control Engineering (Rad je u postupku recenzije) (M22).