

Autonomna vozila

Pribisalić, Iva

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of Mathematics / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:126:701039>

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

Download date / Datum preuzimanja: **2024-04-18**



Repository / Repozitorij:

[Repository of School of Applied Mathematics and Computer Science](#)



Sveučilište Josipa Jurja Strossmayera u Osijeku
Odjel za matematiku
Sveučilišni diplomski studij Matematika i računarstvo

Iva Pribisalić

Autonomna vozila

Diplomski rad

Osijek, 2021

Sveučilište Josipa Jurja Strossmayera u Osijeku
Odjel za matematiku
Sveučilišni diplomski studij Matematika i računarstvo

Iva Pribisalić

Autonomna vozila

Diplomski rad

Mentorica: izv. prof. dr. sc. Darija Marković

Osijek, 2021

Sadržaj

1	Uvod	1
2	Povijest	2
3	Senzori	4
3.1	Radar	4
3.2	Lidar	5
3.3	Ultrazvučni senzor	6
3.4	Kamera	6
3.5	GPS	7
3.6	IMU	7
3.7	Odometrijski senzor	8
4	Percepcija	9
4.1	Lokalizacija	9
4.2	Mapiranje	9
4.3	SLAM	10
4.4	Detektiranje objekata	11
4.4.1	Izdvajanje značajki	12
4.4.2	Klasifikacija	16
5	Planiranje	19
5.1	Planiranje rute	19
5.2	Bihevioralno planiranje	20
5.3	Planiranje kretanja	21
6	Kontrola	22
7	V2X	24
7.1	V2V	24
7.2	V2I	26
7.3	V2P	27
8	Primjeri	28
8.1	Tesla	28
8.2	Waymo	29
8.3	Olimpijsko selo	30
9	Budućnost	31
	Literatura	32
	Sažetak	34
	Summary	35
	Životopis	36

1 Uvod

Autonomna vozila ubrzano se razvijaju unazad nekoliko godina. Ulaže se u njihov razvoj jer se smatra da će doprinijeti smanjenju zagađenja zraka, poboljšati protok prometa i smanjiti broj nesreća na cestama. Pod autonomnim vozilima smatramo vozila koja su sposobna percipirati okolinu i kretati se uz nikakvu ili minimalnu pomoć čovjeka [2].

Svako vozilo pripada određenoj razini koja opisuje stupanj automatiziranosti vozila. Te razine navedene su u sljedećoj tablici (vidi [14]).

Razina	Naziv	Upravljanje volanom i ubrzavanje/usporavanje	Promatranje okoline	Kontrola u slučaju greške	Sposobnosti sustava
0	Bez automatizacije	čovjek	čovjek	čovjek	-
1	Pomoć vozača	čovjek i sustav	čovjek	čovjek	neke
2	Djelomična automatizacija	sustav	čovjek	čovjek	neke
3	Uvjetna automatizacija	sustav	sustav	čovjek	neke
4	Velika automatizacija	sustav	sustav	sustav	neke
5	Potpuna automatizacija	sustav	sustav	sustav	sve

Tablica 1: Razine automatiziranosti vožnje.

Razina 0 označava vozila koja nemaju nikakvu automatizaciju, odnosno vozač obavlja sve funkcije i nadzire okolinu, dok sustav samo daje određena upozorenja. Razina 1 predstavlja najnižu razinu automatizacije. Sustav je u mogućnosti preuzeti kontrolu nad volanom ili samostalno ubrzavati/usporavati (ne može i jedno i drugo). Vozač odlučuje kada bi se to trebalo dogoditi i potreban je stalan nadzor nad vozilom. Razinu 2 imaju vozila koja se mogu samostalno kretati i istovremeno preuzeti obje kontrole navedene na prethodnoj razini. Vozač još uvijek mora sve nadzirati i biti spreman preuzeti kontrolu nad sustavom. Razina 3 predstavlja veliki tehnološki napredak u odnosu na prethodnu razinu. Sustav promatra okolinu i donosi odluke poput ubrzavanja pored vozila koje se sporo kreće. Vozač mora biti spreman preuzeti kontrolu ukoliko vozilo ne može izvršiti zadatak. Vozila razine 4 mogu djelovati ukoliko se dogodi greška u sustavu. U tom smislu vozač nije potreban u većini slučajeva. Vozila mogu sama donositi odluke i kretati se, ali samo na određenim područjima i u određenim uvjetima. Razina 5 predstavlja najvišu razinu automatizacije i ona označava da vozilo može odreagirati u svim slučajevima i sposobno je voziti od početne do završne točke bez ljudske intervencije.

Kada bi većina ili sva vozila dostigla razinu 5, promet bi bio sigurniji za sve. Autonomna vozila se ne umaraju, ništa im ne odvraća pozornost, ne konzumiraju alkohol i ne krše prometne propise. U usporedbi s ljudima brže razmišljaju. Svi ovi faktori mogli bi utjecati na smanjenje prometnih nesreća. No, autonomna vozila imaju i negativne strane. Skupa su zbog sustava i opreme koju koriste, a upravo pad sustava ili greške mogu dovesti do ozbiljnih posljedica. Postoji i mogućnost hakiranja podataka poput lokacije vozila.

Kako bi se postigla autonomija vozila, određeni proces mora se izvršiti. Prvo senzori određuju okolinu i detektiraju objekte. Zatim se pronalazi lokacija vozila radi daljnjeg planiranja puta i kretanja. Potom se izračuna željena ruta i donesene odluke šalju se kontroli vozila. Kontrola te odluke prevodi u naredbe koje prosljeđuje do aktuatora koji brine da se vozilo kreće na odgovarajući način. Ovim postupkom detaljnije ćemo se baviti u nastavku rada.

2 Povijest

Autonomna vozila počela su se istraživati još 1920-ih godina i tada su ih nazivali „fantomska vozila”. Razvoj takvih vozila predstavljao je veliki napredak u tehnologiji. U početku se upravljalo na daljinu pomoću radio signala. Ljudi su u tome vidjeli budućnost sigurne vožnje.

Povijesni pregled razvoja autonomnih vozila dan je u nastavku (vidi [12]).

- 1925. godine Francis P. Houdina razvio je vozilo upravljano radio kontrolom.
- 1926. godine na vozilo je postavljena antena koja je odašiljala i primala radio signale, a iz drugog vozila koje ga je pratilo slali su se signali.
- 1939. godine General Motors predstavio je ideju električnih automobila kojima se upravljalo uz pomoć elektromagnetskih polja.
- 1953. godine Radio Corporation of America proizveo je automobil kojim se upravljalo žicama položenim na laboratorijskom podu.
- 1960-ih godina razvijena su eksperimentalna vozila koja su vozila bez vozača, a upravljalo se električnim uređajima.
- 1970-ih godina Bendix Corporation razvio je i testirao automobil kojim se upravljalo zakopanim kablovima i komunikatorima bez prisustva vozača.
- 1980-ih godina Mercedes-Benz razvio je robotski kombi i testirao ga pri brzini od 63 km/h na cesti bez prometa. Prvi put je testiran lidar pri brzini od 31 km/h. Carnegie Mellon University koristilo je tehnologiju neuronskih mreža za kontrolu autonomnih vozila.
- 1994. godine dva robotska vozila testirana su na više od 1000 km autoceste u gustom prometu pri brzini od 130 km/h, uz ljudsku intervenciju.
- 1995. godine Carnegie Mellon University razvilo je vozilo koje je od 5000 km čak 98.2% vozilo autonomno. Koristili su tehnologiju neuronskih mreža za upravljanje volanom, no gas i kočnicu kontrolirao je čovjek.
- 2000. godine američka vlada financirala je autonomna vozila za vojne svrhe.
- 2004. godine Defense Advanced Research Projects Agency (DARPA) organizirala je DARPA Grand Challenge zbog kojeg su se autonomna vozila počela ubrzano razvijati. Cilj izazova bio je voziti autonomno 240 km kroz Mojave Desert Region, a pobjednik bi dobio 1 000 000 USD. Nitko od sudionika nije uspio u tome.
- 2005. godine 5 sudionika DARPA Grand Challenge-a uspjelo je postići cilj.
- 2007. godine održao se DARPA Urban Challenge u urbanom okruženju. Carnegie Mellon University osvojilo je prvo mjesto.
- 2009. godine Google je započeo privatno istraživanje o autonomnim vozilima.
- 2010. godine ista istraživanja započele su i ostale veće automobilske kompanije kao što su Ford, Mercedes-Benz, Volkswagen, Audi, Nissan, Toyota, BMW i Volvo.

- 2012. godine Volkswagen je razvio privremeni autopilot (temporary autopilot - TAP) i testirao ga na autocesti pri brzini od 130 km/h.
- 2013. godine Toyota je razvila autonomno vozilo sa senzorima i sustavom za komuniciranje.
- 2014. godine mogao se kupiti Mercedes S klase koji je imao dosta autonomnih opcija, a na autoputu je dostizao brzinu od 200 km/h. Tesla je razvila prvu verziju autopilota, a kasnije je softver ažuriran i lansiran je novi model. SAE International objavio je 6 standardnih razina automatiziranosti vozila.
- 2015. godine Volvo je razvio autonomno vozilo razine 3.
- 2017. godine Audi je započeo razvoj modela A8 sa svim autonomnim opcijama.
- 2020. godine sve automobilske kompanije pokušavaju razviti autonomno vozilo razine 5.


Neka od poznatijih autonomnih vozila danas su Tesla, Waymo, Zoox i Aptiv. Još uvijek nije razvijeno vozilo razine 5 automatiziranosti.

3 Senzori

Prvi korak u autonomiji vozila je da ono postane svjesno okoline u kojoj se nalazi, a senzori su najvažniji dio tog procesa. Senzori su hardverske komponente koje prikupljaju podatke o okolini. Na osnovu rezultata koje daju, donose se odluke poput promjene trake, usporavanja i ubrzavanja. Zbog toga je jako bitno razumjeti na koji način radi koji tip senzora. Nakon odabira senzora, treba ih implementirati u sustav da rade što optimalnije.

Razlikujemo aktivne i pasivne senzore. Aktivni senzori emitiraju nekakav oblik energije u okolinu te primaju i mjere reflektirani signal. Za razliku od njih, pasivni senzori samo upijaju energiju okoline. Primjerice, kamere su pasivni senzori, dok su radar i lidar aktivni senzori. Osim njih, senzori koji se najviše koriste u autonomnim vozilima su još i ultrazvučni senzori, GPS (Global Positioning System), IMU (Inertial Measurement Unit) i odometrijski senzori.

Samo jedan senzor ne može dati sve potrebne informacije za potpunu autonomiju vozila. Stoga se koristi više senzora i informacije koje pružaju kombiniraju se za najbolje rezultate. Primjerice, kamera je bitna kako bi vozilo promatralo okolinu na način na koji ju čovjek promatra, ali informacija o udaljenosti objekata najbolje se dobije korištenjem senzora poput lidara ili radara.




Slika 1: Konfiguracija senzora autonomnog vozila [14].

3.1 Radar

Radar je glavni senzor za prepoznavanje udaljenih objekata. Radi na način da odašilje radiovalove kako bi prepoznao i pratio objekte. Radiovalovi se reflektiraju od okolnih objekata i pri povratku daju informacije o smjeru, udaljenosti i procijenjenoj veličini svakog objekta. Dok drugi senzori rade na način da uspoređuju dva očitavanja, neki tipovi radara koriste Dopplerov efekt da izmjere brzinu kretanja objekata.

Neke od prednosti radara su što se može koristiti u bilo kakvim svjetlosnim okruženjima kao što su izravna sunčeva svjetlost te potpuni mrak, u različitim vremenskim uvjetima kao

i pri velikim brzinama. Od svih senzora na vozilu, radar najbolje radi u uvjetima kiše ili magle. Nedostatci su što ima ili uzak kut djelovanja i dalek domet (preko 200 m) ili širok kut djelovanja (oko 150 stupnjeva) i kratak domet što se može vidjeti na Slici 2.




Slika 2: Kut djelovanja radara za daleki (a) i kratki (b) domet [14].

3.2 Lidar

Lidar koristi infracrvene laserske zrake za određivanje udaljenosti između senzora i objekata u blizini. Laserske zrake pulsiraju te se reflektiraju od objekata. Te refleksije stvaraju oblak točaka (point cloud) koji reprezentira objekte iz okoline što možemo vidjeti na Slici 3. Svaki piksel predstavlja izračunatu udaljenost do objekta koja se dobije mjereći vrijeme potrebno laserskoj zruci da se reflektira. Moderniji lidari imaju mogućnost odašiljanja vertikalnih zraka što služi za mjerenje visine objekta.

Lidar se zbog velikog dometa i male širine zraka koristi za 3D mapiranje visokih rezolucija. Uvelike se koristi i za pozicioniranje unutar prostorija i u područjima gdje satelitski signal nije dostupan. Nedostatak je što su dosta skupi, no zbog ubrzanog razvoja autonomnih vozila očekuje se da će im se cijena znatno smanjiti. Nije pouzdan u lošim vremenskim uvjetima poput kiše, snijega i magle. Razlog tomu je što se laserske zrake odbijaju od malih čestica. Isto tako ne daje točne rezultate ukoliko se blato ili snijeg nađu na samom senzoru.




Slika 3: 3D oblak točaka [14].

3.3 Ultrazvučni senzor

Ultrazvučni senzor odašilje akustične valove koji su izvan ljudskog čujnog dometa i pomoću njih mjeri udaljenost do objekta. Ovi senzori krenuli su se upotrebljavati u autoindustriji tek 1980-ih godina nakon što je Toyota predstavila ultrazvučni sustav koji pomaže u parkiranju automobila. Danas ovi senzori imaju široku upotrebu. Osim za parkiranje, koriste se za prepoznavanje gesta koje omogućava korisnicima da bez dodira koriste sučelje (hands free).

Prednosti ultrazvučnih senzora su pristupačnost i neovisnost o svjetlu. Najjeftiniji su od svih senzora. Funkcioniraju u svim vremenskim uvjetima dokle god nisu prekriveni snijegom, ledom, blatom i sličnim. Nedostatak je što imaju mali domet djelovanja. Osim toga, na njihov rad utječe zvuk visoke frekvencije iz okoline. Krivi izračuni mogu uzrokovati krive procjene udaljenosti objekata. Zbog velikog kuta djelovanja ultrazvučnih valova, moguće je odrediti točnu poziciju detektiranih objekata koristeći trilateraciju kao što je prikazano na Slici 4.



Slika 4: Ultrazvučna trilateracija [14].

3.4 Kamera

Kamera je jedan od prvih senzora koji su se koristili u autonomnim vozilima na početku njihovog razvoja. Današnja vozila imaju jako puno kamera. One, za razliku od dosad navedenih senzora, pasivno primaju svjetlosne valove, ali ne odašilju nikakav oblik energije. Kamera je jeftiniji senzor od radara i lidara, ali u nekim situacijama može dati bolje rezultate. Primjerice, kada je zgrada prepoznatljivija po teksturi, nego po strukturi, kamerom ćemo to prije uočiti. No, kamera je osjetljiva na svjetlost i vremenske uvjete. Ne daje dobre rezultate na direktnoj sunčevoj svjetlosti kao ni za vrijeme snijega, magle ili jake kiše. Zbog toga su se u zadnje vrijeme počele koristiti hiperspektralne kamere (vidi [4]). Na Slici 5 vidimo da daju dobre informacije po magli, a i manje su osjetljive na sunčevu svjetlost te mrak. Negativna strana kamera je što im je potrebno puno energije da procesiraju podatke.



(a) mrak

(b) sunčeva svjetlost



(c) sjena


(d) magla

Slika 5: Rezultati hiperspektralne kamere u različitim uvjetima [4].

3.5 GPS

GPS služi za određivanje lokacije vozila, izračunavanje ruta i navigiranje vozača do odredišta. Sustav je podijeljen na tri segmenta koja uključuju konstelaciju 24 satelita, stanice koje komuniciraju i kontroliraju satelite pomoću radara te GPS prijemnik preko kojeg se dobije lokacija. Prijemniku je potreban signal od barem 4 različita satelita kako bi se dobila lokacija vozila. Tri satelita koriste se za određivanje dužine, širine i visine, a četvrti za točniji izračun. Lokacija će biti preciznije određena ukoliko je više satelita u vidnom polju. Kao i kod ultrazvučnih senzora, lokacija se određuje trilateracijom.

GPS prijemnici danas su pristupačni i dostupni skoro svugdje zahvaljujući njihovoj prisutnosti u pametnim telefonima. Najveći problem kod GPS-a je što za pouzdanost zahtijeva neprekinutu putanju signala između prijemnika i satelita. Signal često može biti prekinut visokim zgradama, drvećem ili tunelima. Zbog toga GPS najbolje funkcionira na otvorenim područjima, a loše u prostorima poput garaža. Još jedan problem je što GPS koji je javno dostupan postiže točnost s odstupanjem do tri metra, što nije dovoljno dobro za autonomna vozila. Jedan takav primjer odstupanja možemo vidjeti na Slici 6.



Slika 6: GPS daje grešku veću od jednog metra [3].

3.6 IMU

IMU je uređaj koji se koristi na mjestima gdje satelitski signal nije dostupan. Pomaže u određivanju položaja i smjera u kojem je vozilo okrenuto. Oslanja se na parametre koji se mogu izmjeriti u svim uvjetima zbog čega autonomna vozila u svakom trenutku mogu dobiti informacije od ovih senzora. Negativna strana je što se greške mogu dogoditi zbog proklizavanja ili nailaska na rupe na cesti.

3.7 Odometrijski senzor

Odometrijski senzori mjere udaljenost koju vozilo prijeđe na način da pomnože broj okretaja kotača i opseg gume. Također daju informaciju o brzini kotača na koju se jako oslanja ABS. Ovi senzori su prilično jeftini, a danas mogu detektirati brzinu kotača od 0.1 km/h. No, prilično su osjetljivi na greške koje se događaju zbog proklizavanja ili neravnih površina. Zbog toga se očitavanja kombiniraju s drugim sensorima poput GPS-a ili IMU-a i koriste razni algoritmi da bi se odredila pozicija kotača.

4 Percepcija

Percepcija za autonomno vozilo predstavlja sposobnost da bude svjesno okoline. Podatci koje dobijemo od senzora trebaju se obraditi kako bi se dobila slika okoline. Dobra percepcija ključna je za glatke i sigurne operacije koje obavlja autonomno vozilo. Problem percepcije može se podijeliti u dvije podfunkcije, a to su istovremena lokalizacija i mapiranje (Simultaneous Localization and Mapping - SLAM) te detektiranje i praćenje objekata u pokretu (Detection and Tracking of Moving Objects - DATMO). U ovom poglavlju reći ćemo nešto više o navedenim funkcijama.

4.1 Lokalizacija

Lokalizacija je proces određivanja pozicije i orijentacije vozila s obzirom na kartu. Ta karta može biti globalna za vožnju po javnim cestama ili može biti ograničenija za vozila koja se kreću unutar nekakvih granica poput vožnje u tvornici. Autonomna vozila uglavnom se kreću u okruženjima koja su već točno mapirana što pojednostavljuje proces lokalizacije.

Razlikujemo dva pristupa lokalizaciji, a to su lokalni ili relativni koji uspoređuje trenutnu lokaciju s prijašnjom te globalni ili apsolutni koji za određivanje trenutne lokacije koristi vanjske reference poput satelita. Relativni pristup je brži i zahtijeva manje resursa u usporedbi s globalnim pristupom. No, zbog toga su podložniji greškama. Također može doći do problema otetog robota (robot kidnapping problem) kada robot, odnosno vozilo dođe na novu lokaciju. Zbog toga se koriste oba pristupa. Uglavnom se relativni pristup koristi za praćenje trenutne lokacije, a globalni pristup za ispravljanje rezultata ili nakon resetiranja sustava.


4.2 Mapiranje

Lokalizacija funkcionira uz pretpostavku da su precizne karte već dostupne. Međutim, takve precizne i detaljne karte većinom nisu javno dostupne stoga trebaju biti generirane. Mapiranje je proces stvaranja tih karata. Izbor tipa karte koja se koristi ovisi o korištenim senzorima, memoriji i procesorskoj snazi računalne platforme, algoritmima i slično. Senzori koji se uglavnom koriste su lidar, radar i kamera. Navest ćemo karte koje se najčešće koriste u autonomnim vozilima. One se uglavnom integriraju s Google Maps kartama kako bi se identificirala točna lokacija vozila.

Najpoznatija karta koja se koristi u robotici i autonomnim vozilima je **karta mreže zauzeća** (occupancy grid maps). Okolina je prikazana kao mreža, a svaka ćelija sadrži vjerojatnost zauzeća. Negativna strana je što prikazuju mnoge nepotrebne dijelove poput praznih prostora do kojih se ne može doći. Nisu pogodne za prikazivanje dinamičke okoline pa se kombiniraju s raznim pristupima. Primjerice, koriste se pristupi dubokog učenja kojima se detektiraju objekti u pokretu te se filtriranjem dobije statična okolina. Međutim, potrebne su velike količine memorije što može usporiti rad sustava. Karte zauzeća koristile su se i u prošlosti posebice za sustave za izbjegavanje sudara ili gužvi, procjenu granica prometnih traka, detekciju slobodnog parkirnog mjesta i slično.

Karte značajki (feature maps) prikazuju okolinu točkama, linijama ili geometrijskim oblicima zbog čega se koriste u jednostavnijim okruženjima. Ove karte su kompaktnije u odnosu na mrežu zauzeća, no problem može predstavljati odabir značajki koje će najbolje odgovarati

okruženju u kojem se vozilo nalazi. Negativna strana ovih karata je što ne mogu prikazati prazan prostor. Za autonomna vozila to može predstavljati problem jer moraju moći razlikovati područja koja još nisu istražena i ona koja imaju praznog prostora. To im pomaže u planiranju sigurnih pokreta. Ono što je pozitivno je što jako dobro prikazuju objekte u obliku kružnice, trokuta, kvadrata i ostalih jednostavnijih geometrijskih oblika. Zbog navedenih nedostataka najčešće se kombiniraju s drugim kartama za najbolje rezultate.




Slika 7: Karta značajki [14].

Koriste se i druge vrste karata poput **karte slobodnog prostora** (free space map) koja prikazuje informacije o nezauzetom prostoru. Slobodan prostor može se prikazati geometrijskim oblicima. Još jedna popularna vrsta karte je **karta intervala** (interval map) koja diskretizira prostor oko vozila uzdužno, dok su bočne komponente spremljene kao neprekidne vrijednosti u obliku intervala. Više o navedenim kartama može se pronaći u [13].

4.3 SLAM

Stvaranje precizne karte moguće je samo kada je točna lokacija vozila poznata. U stvarnosti je to težak zadatak zbog greški koje mogu nastati prilikom rada senzora. Stoga se najčešće koristi tehnika istovremene lokalizacije i mapiranja (SLAM) koja nastoji izgraditi preciznu kartu okoline dok u isto vrijeme lokalizira vozilo na toj karti. Koristi se i u slučajevima kada se vozilo nalazi u nepoznatoj okolini.

Problem koji nastaje je što značajke promatrane karte, kao i lokacija vozila, sadrže određene greške koje se povećavaju što je vozilo dalje od zadnje poznate lokacije. Navedeni problem prikazan je na Slici 8. Procijenjena lokacija x_{k+1} izračunata je primjenom kontrole vozila u_{k+1} na prethodno procijenjenu lokaciju x_k . Oznaka $z_{k,j}$ označava izmjerenu udaljenost između vozila na poziciji x_k i promatranog orijentira m_j . Međutim, nakon što se cijela ruta odvozi u petlji barem jednom, SLAM generira preciznu kartu. Rezultirajuća karta tada se koristi za određivanje točne lokacije vozila primjenjujući isti algoritam lokalizacije, ali bez mapiranja.



Slika 8: SLAM problem [14].

Najčešće se navedeni problem dijeli na potpune i online SLAM probleme. Potpuni SLAM procjenjuje cijeli put i kartu, dok online SLAM procjenjuje samo zadnju poznatu lokaciju i kartu. Označimo s $X_T = \{x_0, x_1, \dots, x_t\}$ put ili niz proputovanih lokacija gdje je x_0 početna točka, m kartu okoline, $Z_T = \{z_1, z_2, \dots, z_t\}$ niz mjerenja te $U_T = \{u_1, u_2, \dots, u_t\}$ niz ulaza. Sada potpuni SLAM problem možemo zapisati kao

$$p(X_T, m | Z_T, U_T) = p(x_{0:t}, m | z_{1:t}, u_{1:t}),$$

dok je online SLAM formuliran sljedećim zapisom


$$p(x_t, m | z_{1:t}, u_{1:t}) = \int_{x_0} \int_{x_1} \dots \int_{x_{t-1}} p(x_{0:t}, m | z_{1:t}, u_{1:t}) dx_{t-1} \dots dx_1 dx_0.$$

4.4 Detektiranje objekata

Osim što je detektiranje objekata nužno za sigurnu vožnju, važno je za dobro razumijevanje okoline kako bi vozilo moglo donijeti najbolju odluku u trenutnoj situaciji. Jako je bitno razlikovati objekte u pokretu poput automobila i pješaka, ali i statične objekte poput prometnih znakova, granica prometnih traka i semafora.

Detektiranje objekata najčešće je podijeljeno u sljedeće potprobleme prikazane na Slici 9:

1. lokalizacija objekata, odnosno određivanje granica detektiranih objekata,
2. klasifikacija objekata, odnosno kategoriziranje detektiranih objekata u već definirane klase,
3. semantička segmentacija, odnosno particioniranje slike u semantički smislene dijelove i klasificiranje svakog dijela u već definirane semantičke regije.



Slika 9: Detektiranje objekata. (a) pokazuje lokalizaciju i klasifikaciju, a (b) semantičku segmentaciju [14].

Ovaj problem istražuje se još od sredine 1960-ih i predloženo je mnogo rješenja za isti. Tri koraka koja se najčešće provode su predobrada, izdvajanje značajki i klasifikacija.

Predobrada uključuje normalizaciju slike, odnosno rade se određene izmjene tako da slika odgovara očekivanom ulazu za sljedeći korak. Ovo može uključivati rotaciju i promjenu veličine slike ili podešavanje intenziteta, ovisno o primjeni. Neki od pristupa preskaču ovaj korak. O druga dva koraka i tehnologiji koju koriste reći ćemo više u nastavku.

4.4.1 Izdvajanje značajki

Izdvajanje značajki predstavlja najveći izazov u detektiranju objekata jer je potrebno dizajnirati deskriptore značajki koji će svaku klasu moći razlikovati od svih ostalih. Primjerice, zamislimo da želimo napraviti klasifikaciju za stolove, odnosno želimo da računalo vrati izlaz „stol” ukoliko je ulazni podatak slika stola i „nije stol” u suprotnom. Vrlo jednostavan deskriptor značajki može biti funkcija koja opisuje „Stol ima četiri noge”. Na osnovu ovog deskriptora, izdvajamo samo bitne informacije o dijelovima slike koji izgledaju kao noge, a sve ostale informacije odbacujemo. U koraku klasifikacije, odredit će se broj dijelova slike koji izgledaju kao noge i na osnovu toga donijet će se odluka. Korištenje ovakvog jednostavnog i nedovoljno preciznog deskriptora svakako će dovesti do netočnih rezultata klasifikacije, bez obzira koliko dobar klasifikator koristili. Postoji mnogo stolova koji nemaju četiri noge, a isto tako postoji mnogo objekata koji imaju četiri noge, a nisu stolovi.

Srećom, dosad je definirano mnogo općenitih algoritama za deskriptore značajki te su pomoću njih riješeni razni problemi detekcije objekata. Navest ćemo neke od najpoznatijih.

Histogram orijentiranih gradijenata (Histogram of Oriented Gradients - HOG) je deskriptor koji koristi intenzitete i orijentacije gradijenata za karakterizaciju izgleda i oblika objekta. Algoritam dijeli sliku u manje ćelije te se za svaku ćeliju računa histogram orijentiranih gradijenata.

Svaki piksel u ćeliji na poziciji (x, y) ima vrijednost $I \in [0, 255]$ koja predstavlja intenzitet. Za svaki piksel računaju se iznos i orijentacija gradijenata na sljedeći način:

$$\begin{aligned} G_x(x, y) &= I(x + 1, y) - I(x - 1, y), \\ G_y(x, y) &= I(x, y - 1) - I(x, y + 1), \\ m(x, y) &= \sqrt{G_x(x, y)^2 + G_y(x, y)^2}, \end{aligned} \quad (4.1)$$


$$\theta(x, y) = \arctan \left(\frac{G_y(x, y)}{G_x(x, y)} \right). \quad (4.2)$$

Ova metoda bazira se na tome da se iznos gradijenta povećava na dijelovima gdje je velika promjena u intenzitetu, a to je najčešće na rubovima objekta.

Za svaku ćeliju dalje se računa histogram na način da se izračunati iznos gradijenta svakog piksela pridružuje stupcu s obzirom na izračunatu orijentaciju. Primjerice, zamislimo da imamo histogram sa stupcima 0, 20, 40... i piksel čiji je iznos gradijenta 40, a orijentacija 15° . Tada se stupcu 20 pridružuje iznos 30, a stupcu 0 iznos 10.

Budući da je gradijent jako osjetljiv na osvjetljenje, u sljedećem koraku radi se normalizacija. Uglavnom se koristi L_1 ili L_2 norma.

Slika 10 pokazuje kako algoritam funkcionira, a više o tome može se pronaći u [11].



Slika 10: HOG algoritam. (a) predstavlja originalnu sliku, (b) odgovarajuće HOG značajke, a (c) detektirane objekte u pravokutnicima [14].

Transformacija značajke invarijantne skale (Scale-Invariant Feature Transformation - SIFT) je algoritam koji pronalazi značajke slike invarijantne na rotaciju, translaciju i skaliranje.

Prvi korak algoritma je detektirati ključne točke. Ulazna slika reprezentirana je u različitim skalama i različitom razinom zamućenja. Svaka točka uspoređuje se s 8 susjeda u trenutnoj slici i 9 susjeda u skali iznad i ispod. Odabire se samo ako je veća ili manja od svih navedenih susjeda. Na taj način pronalazi se najbolja skala i slika postaje invarijantna na skaliranje. Nakon što su pronađeni kandidati za lokacije ključnih točaka, pokušava se dobiti točniji rezultat. Neke ključne točke leže na rubu slike pa one ne mogu puno pridonijeti usporedbi objekata. Takve točke zanemarujemo. Potom se za svaku ključnu točku računa iznos i orijentacija kao što je prikazano u (4.1) i (4.2). Napravi se histogram u kojem najviši stupac predstavlja dominantnu orijentaciju. Uzimaju se u obzir i stupci višji od 80%. Tako se dobiju ključne točke iste lokacije i skale, ali različite orijentacije. To pridonosi stabilnosti u uspoređivanju slika. Sada imamo ključne točke koje su invarijantne i na rotaciju. Konačno se svaka točka predstavlja kao vektor značajki.

Uspoređivanje objekata radi se na način da se uspoređuju pronađene značajke sa značajkama već prepoznatih objekata spremljenih u bazi. Kandidati se odabiru računanjem Euklidske udaljenosti između vektora značajki. Deskriptori ključnih točaka jako su karakteristični što omogućava pronalazak ispravnog podudaranja s velikom vjerojatnošću.

Primjer rada SIFT algoritma može se vidjeti na Slici 11, a više o algoritmu u [10].



(a)




(b)



(c)



(d)



(e)

Slika 11: SIFT algoritam. Uspoređivanjem značajki (b) i (d) izračunatih iz originalnih slika (a) i (c) dobijemo podudaranje slika (e) [14].

Maksimalno stabilne ekstremne regije (Maximally Stable Extremal Regions - MSER) metoda je koja detektira promjene u nekoj regiji (ili skupu povezanih piksela) u odnosu na okolinu. Ova metoda opisuje sliku kao skup regija koje su maksimalno stabilne unatoč promjenama u intenzitetu. Drugim rječima, pokušava pronaći regiju koja će ostati vidljiva u širokom rasponu svjetline. Pronađene regije često se označavaju elipsama. U usporedbi sa SIFT-om, MSER je brži i invarijantan na transformacije poput iskrivljenja. Opširnije o ovoj metodi kao i definicija maksimalno stabilnih ekstremnih regija može se pronaći u [5].

MSER se često koristi za detektiranje teksta, a jedan takav primjer može se vidjeti na Slici 12.



(a)




(b)

Slika 12: MSER metoda. (a) pokazuje originalnu sliku, a (b) pronađene maksimalno stabilne regije [14].

4.4.2 Klasifikacija

Posljednji korak u detekciji objekata je raspoređivanje značajki dobivenih iz prethodnog koraka u skup klasa poput „auto”, „pješač” i slično. Neki od poznatijih algoritama klasificiranja koji se koriste su metoda potpornih vektora, slučajne šume i umjetne neuronske mreže.

Metoda potpornih vektora (Support Vector Machine - SVM) jedan je od najpoznatijih algoritama klasificiranja. Radi na način da pokušava pronaći hiperravninu koja što optimalnije razdvaja skupove različitih klasnih oznaka. Ovaj algoritam zahtijeva da su svi trening podatci dostupni, odnosno spremljeni u memoriji tijekom treninga podataka. Nakon toga daljnje predikcije ovise samo o potpornim vektorima. Oni definiraju margine hiperravnine. Više o ovoj metodi može se pronaći u [1].



Slika 13: SVM algoritam pronalazi optimalnu hiperravninu koja maksimizira geometrijsku marginu [1].

Model funkcija dana je s

$$h_{\theta}(x) = \begin{cases} 1, & \text{za } \theta^T x \geq 0 \\ -1, & \text{za } \theta^T x < 0 \end{cases},$$

za $x = [1 \ x_1 \ \dots \ x_n]^T$, $\theta = [\theta_0 \ \theta_1 \ \dots \ \theta_n]^T$. Označimo $\bar{\theta} = [\theta_1 \ \dots \ \theta_n]^T$. Problem maksimiziranja geometrijske margine svodi se na

$$\min \frac{1}{2} \|\bar{\theta}\|^2 \quad \text{uz uvjete } y^{(i)} \theta^T x^{(i)} \geq 1, \quad \forall i = 1, \dots, m. \quad (4.3)$$

Kada podatci nisu linearno separabilni, uvode se *slack* varijable ξ_i . Tada SVM klasificira većinu podataka ispravno. Problem (4.3) sada se može zapisati kao

$$\begin{aligned} \min \quad & \frac{1}{2} \|\bar{\theta}\|^2 + C \sum_{i=1}^m \xi_i \\ \text{uz uvjete} \quad & y^{(i)} \theta^T x^{(i)} \geq 1 - \xi_i, \quad \forall i = 1, \dots, m, \\ & \xi_i \geq 0, \quad \forall i = 1, \dots, m. \end{aligned}$$

Slučajna šuma (Random forest) skup je stabala odluke koji su automatski generirani nasumičnim odabirom podataka i podskupova značajki. Rezultat klasifikacije određen je glasanjem većine, odnosno uzima se najfrekventniji rezultat među rezultatima svih stabala. Što više stabala ima u slučajnoj šumi, veća je točnost i manja vjerojatnost da dođe do prenaučivosti (overfitting).

Algoritam 1 ALGORITAM SLUČAJNE ŠUME

Ulaz: trening podatci $D = \{(x_1, y_1), \dots, (x_N, y_N)\}$, $x_i = [x_1^i \dots x_p^i]^T$, broj stabala J , testni podatak d

Izlaz: klasa za testni podatak d

for $j = 1, \dots, J$ **do**

a) uzmi bootstrap uzorak (uzorak s vraćanjem) D_j iz D veličine N

b) izgradi stablo slučajne šume koristeći uzorak D_j kao trening podatke, rekursivno ponavljajući sljedeće korake za svaki čvor u stablu:

i) slučajno izaberi m varijabli od p mogućih

ii) pronađi najbolju binarnu podjelu među svim binarnim podjelama m varijabli


iii) podijeli čvor na lijevi i desni prema ii)

end for

return najfrekventniju klasu svih J stabala


Dodatno o slučajnim šumama može se pronaći u [7].

Algoritam slučajne šume prikazan je na Slici 14.



Slika 14: Algoritam slučajne šume [14].

Umjetne neuronske mreže predstavljaju višeslojni sustav koji se sastoji od međusobno povezanih čvorova (neurona). Nelinearna klasifikacija spada pod dio neuronskih mreža zvan višeslojni perceptron (multi-layer perceptron - MLP). MLP sastoji se od barem tri sloja (ulazni, skriveni, izlazni) gdje je svaka varijabla prezentirana jednim čvorom u ulaznom sloju. Svaki neuron u skrivenom sloju transformira izlazne vrijednosti prethodnog sloja korištenjem težina i pripadne nelinearne aktivacijske funkcije. Nakon što izlazni sloj vrati konačni rezultat, računa se greška između stvarnog i očekivanog rezultata. Greška se smanjuje algoritmom povratne propagacije na način da se težina svakog čvora popravljaju počevši od izlaznog pa sve do ulaznog sloja.



Slika 15: Višeslojni perceptron [14].

5 Planiranje

Planiranje podrazumijeva odgovor na pitanje „Kako da stignem do odredišta?”. Sastoji se od planiranja rute, bihevioralnog planiranja i planiranja kretanja (vidi [8]).

5.1 Planiranje rute

Planiranje rute određuje najbolju rutu od trenutne lokacije do odredišta na osnovu informacija o cestovnoj mreži koje pruža karta. Pronalazak najbolje rute može zahtijevati i dodatne vanjske faktore poput trenutnih informacija o prometu, potrošnje energije (posebice za električna vozila), korisnikove želje npr. želi li izbjeći cestarinu i slično. Ovakvo planiranje provodi se i u ugrađenim navigacijskim sustavima automobila te mobilnim aplikacijama poput Google Maps-a.

Cestovna mreža može se prikazati pomoću usmjerenog grafa gdje težina svakog brida predstavlja cijenu prolazanja tim dijelom ceste. Za pronalazak najbolje rute koriste se algoritmi za rješavanje poznatog problema iz teorije grafova zvanog problem najkraćeg puta. Jedan od najpoznatijih algoritama za rješavanje tog problema je Dijkstrin algoritam (vidi [6]). Algoritam započinje inicijalizirajući udaljenost svih čvorova na beskonačno. Za sve čvorove u koje se može direktno doći iz trenutnog čvora, računa se nova udaljenost i vrijednost se ažurira ukoliko je izračunata udaljenost manja od dosadašnje. Postupak se ponavlja dok svi čvorovi nisu posjećeni.


Algoritam 2 DIJKSTRIN ALGORITAM

Ulaz: graf $G = (V, E)$, težine w i početni vrh s

Izlaz: najkraći put od vrha s do svakog preostalog vrha

```
for svaki vrh  $v \in V$  do
     $d[v] \leftarrow \infty$ 
     $\pi[v] \leftarrow NIL$ 
end for
 $d[s] \leftarrow 0$ 
 $S \leftarrow \emptyset$ 
 $Q \leftarrow V$ 
while  $Q \neq \emptyset$  do
     $u \leftarrow \text{EXTRACT-MIN}(Q)$ 
     $S \leftarrow S \cup \{u\}$ 
    for svaki vrh  $v \in \text{Adj}[u]$  do
        if  $d[v] > d[u] + w(u, v)$  then
             $d[v] \leftarrow d[u] + w(u, v)$ 
             $\pi[v] \leftarrow u$ 
        end if
    end for
end while
```

Na sljedećoj slici možemo vidjeti primjer Dijkstrinog algoritma.



Slika 16: Dijkstrin algoritam [14].

Kao poboljšanu verziju Dijkstrinog algoritma, ponekad se koristi i A* algoritam. Umjesto analiziranja svih mogućih puteva, prati se put s najmanjom cijenom. Ovo se postiže korištenjem heuristike koja procjenjuje cijenu puta od nekog stanja do cilja. Ukoliko je heuristika u svakom vrhu 0, A* je upravo Dijkstrin algoritam.

5.2 Bihevioralno planiranje

Bihevioralno planiranje pronalazi najbolji način kojim se može doći do sljedeće točke puta (koja je poznata iz prethodnog planiranja rute) uzimajući u obzir kakvo je stanje na cestama. To uključuje druge sudionike u prometu, prepreke, ograničenja brzine i ostalo. Rezultat ovog planiranja su odluke poput mijenjanja prometne trake ili praćenja granica prometnih traka. Primjerice, nailaskom na znak stop, vozilo će se zaustaviti, proučiti ponašanje drugih vozila i pješaka te nastaviti kada je sigurno.

Najveći izazov u ovom planiranju je predvidjeti kako će se drugi objekti u pokretu ponašati. Jedno od rješenja ovog problema je pristup baziran na predikciji i funkciji pogreške (Prediction and Cost-function Based - PCB) koji generira nekoliko mogućih kretanja. Uzima u obzir sve moguće reakcije okolnih vozila i izabire najbolju odluku na osnovu ukupnog troška, udobnosti, sigurnosti i potrošnje goriva. Rezultat ovog planiranja je skup naredbi za kontrolu kao što su kut okreta volana te jačina gasa i kočnice.

5.3 Planiranje kretanja

Kada se bihevioralni sloj odluči za izvršavanje određenog ponašanja poput promjene trake ili skretanja udesno, ono se mora prevesti u put ili trajektoriju. Rezultirajući put ili trajektorija mora biti dinamički izvodiva, udobna za putnika i mora izbjegavati detektirane objekte. Planiranje puta pronalazi najkraći geometrijski put na kojem nema zastoja, dok planiranje trajektorija treba odrediti niz pokreta kao funkciju vremena s kojom bi se postigla glatka vožnja. Kako bi se pronašao najbolji geometrijski put, informacije koje pruža karta trebaju se povezati s informacijama koje daju senzori.

6 Kontrola


Zadatak kontrole vozila je izvršiti odluke donesene u prethodnim koracima. Uglavnom se prevode izračunate trajektorije u skup naredbi za aktuatore pazeći na stabilnost vozila. Pri tome treba paziti i na sigurnost vozila i minimizirati utjecaj neočekivanih događaja. Ovo je nužno jer vjerojatnost da se dogodi greška u hardveru, prilikom mjerenja ili implementacije nikada nije nula. Zbog toga se moduli kontrole implementiraju odvojeno od svih ostalih funkcionalnosti. Neke od mogućnosti kontrole navedene su u nastavku.

Ostajanje unutar trake (lane keeping) nastoji da vozilo ostane unutar granica vlastite trake. To uglavnom znači držati vozilo na sredini prometne trake. Za ovu funkcionalnost najbitnija je kamera. Mnoga vozila danas imaju slične funkcionalnosti koje upozoravaju vozača kada vozilo krene izlaziti iz granica svoje prometne trake.




Slika 17: Detekcija prometne trake [14].

Prilagodljivi tempomat (Adaptive Cruise Control - ACC) radi na način da automatski prilagođava brzinu vozila kako bi zadržalo sigurnu udaljenost od vozila ispred. Za to koristi prednje radar senzore i kameru.



Slika 18: Prilagodljivi tempomat [14].

Promjena trake (lane changing) omogućava vozilu da na siguran način prijeđe iz jedne trake u drugu. Ovo je najkompleksnija funkcija od navedenih jer se oslanja na puno više senzora i drugih funkcija poput detektiranja objekata u susjednim trakama.



Slika 19: Automatizirana promjena trake [14].

Zadnje dvije funkcije za svoj rad trebaju poznavati brzinu i položaj ostalih vozila. To je moguće zbog komunikacije između vozila poznate kao V2V komunikacija. To je samo jedan dio V2X komunikacije o kojoj ćemo reći nešto više u sljedećem poglavlju.

7 V2X


Komunikacija s *backend* serverima pomaže autonomnom vozilu da bude pouzdan i u situacijama koje su izvan okvira njegove percepcije. Međutim, globalne informacije od tih servera nekada nisu dovoljne pa autonomno vozilo treba dodatne lokalne informacije. Nadalje, *backend* komunikacija obično se odvija između vozila istog proizvođača. Zbog toga se razvila V2X (Vehicle-to-Everything) komunikacija.

V2X odnosi se na komunikaciju između vozila i ostalih sudionika, mobitela ili stanica. Glavni cilj je poboljšanje sigurnosti prometa pomažući vozilima i ostalim sudionicima u prometu da izbjegnu nesreće. Informacije koje daje ova komunikacija mogu se procesirati i prikazati kao upozorenja vozačima ili se može pokrenuti sigurnosni mehanizam vozila. V2X pomaže autonomnom vozilu da bude svjesno kritičnih situacija. To može uključivati privremene promjene smjera u prometnim trakama, zatvorene ceste zbog obnove ili prometne nesreće. Također može biti od velike koristi u lošim vremenskim uvjetima kada je sposobnost percepcije privremeno ograničena. Važan cilj V2X komunikacije je smanjenje gužve na prometnicama. Uz pomoć točnih i lokalno važnih informacija, vozila mogu biti obaviještena da krenu alternativnim rutama ili da prilagode brzinu kako bi izbjegla zastoje u prometu. Neke tipove V2X komunikacije opisat ćemo u nastavku.

7.1 V2V

V2V (Vehicle-to-Vehicle) odnosi se na izmjenu informacija između vozila u neposrednoj blizini. Navest ćemo nekoliko primjera takve komunikacije.

Upozorenje pri kretanju na raskrižju (Intersection movement assist warning) pomaže u sprječavanju nesreća zbog otežanog pregleda raskrižja. Ovo upozorenje pruža informacije o svim sudionicima na raskrižju i time povećava sposobnost percepcije vozila. Smatra se da bez ovih upozorenja autonomno vozilo zbog ograničenog vidnog kruga ne bi doprinijelo smanjenju prometnih nesreća koje se događaju na raskrižjima.



Slika 20: Primjer upozorenja pri kretanju na raskrižju [14].

Upozorenje o krivom smjeru (Wrong way driver warning) odnosi se na situaciju kada vozilo vozi suprotnim smjerom u traci u kojoj se nalazi. To je posebno opasno na autocestama kada se vozila kreću jako velikim brzinama čime se povećava zaustavni put. Slanjem ovakvog upozorenja daje drugim vozilima priliku da reagiraju na vrijeme i izbjegnu nesreću.



Slika 21: Primjer upozorenja o krivom smjeru [14].

Upozorenje o pretjecanju (Do-not-pass warning) je od velike važnosti za autonomna vozila jer pružaju puno više informacija o okolini od senzora. Pretjecanje predstavlja problem i čovjeku jer zahtijeva jako dobru procjenu kao i koordinirane pokrete.



Slika 22: Primjer upozorenja o pretjecanju [14].

7.2 V2I

V2I (Vehicle-to-Infrastructure) uključuje komunikaciju između vozila i objekata pored ceste (Road Side Units - RSU). Navest ćemo nekoliko primjera takve komunikacije.

Upozorenje o radovima na cesti (Road work warning) svakako predstavlja jedno od najtežih scenarija za autonomno vozilo. Ono se ne može osloniti na informacije spremljene u memoriji u slučaju zatvorenja cesta, promjene smjera u trakama, slabo vidljivih granica prometnih traka, promjena ograničenja brzine, novih prometnih znakova i slično. Stoga je upozorenje da vozilo nailazi na radove na cesti vrlo korisno kako bi se stiglo pripremiti na nove uvjete ili izračunati alternativnu rutu da potpuno izbjegne radove.




Slika 23: Primjer upozorenja o radovima na cesti [14].

Upozorenje o opasnosti na cesti i nesreći (Road hazard and accident warning) daje upozorenje o bilo kakvim površinama ili objektima na cesti koji mogu ugroziti vožnju. To mogu biti krhotine, životinje, led i ostalo. Rana upozorenja uz pomoć DENM poruka (Decentralized Environmental Notification Message) daju vozilu mogućnost da na vrijeme krene drugom rutom kako bi izbjeglo gužvu ili potencijalnu nesreću.



Slika 24: Primjer upozorenja o opasnosti na cesti [14].

Upozorenje o fazama semafora (Traffic light phase event) pomaže poboljšati sigurnost i efikasnost. Senzori poput kamera nisu pouzdani u svim vremenskim uvjetima i prometnim situacijama pa ovakva upozorenja mogu pomoći da se upotpuni percepcija vozila. Vozilo dobiva informacije o trenutnoj fazi semafora svake prometne trake te preostalo vrijeme trenutne faze.



Slika 25: Primjer upozorenja o fazama semafora [14].

7.3 V2P

V2P (Vehicle-to-Pedestrian) obuhvaća komunikaciju između vozila i mobilnih uređaja koje nose pješaci ili biciklisti.


Upozorenje o ranjivom sudioniku u prometu (Vulnerable road user warning) upozorava vozila da pješak ili biciklist namjerava prijeći cestu ili se nalazi na cesti. Ovo je posebice bitno kada se radi o pješacima sa smanjenom pokretljivošću ili oslabljenim sluhom. Isto tako upozorenje može dati informacije o biciklistima posebice po noći kada su teže uočljivi.

Primjer gdje ovakvo upozorenje može biti jako korisno je kada vozilo nailazi na pješački prijelaz, a zbog vozila u susjednoj traci koje se zaustavilo ne može senzorima detektirati pješaka koji je već krenio prelaziti cestu.

8 Primjeri

8.1 Tesla

Tvrtka Tesla je među poznatijima kada se govori o autonomnim vozilima. Tesla autopilot napredni je sustav koji pomaže vozaču na način da poboljšava sigurnost i udobnost. Tesla vozila opremljena su s 8 vanjskih kamera, 12 ultrazvučnih senzora i snažnim putnim računalom koje pruža dodatnu sigurnost. Neki od modela opremljeni su i radarom. Sustav je razine 2 automatiziranosti stoga je namijenjeno vožnji uz potpunu prisutnost vozača. On mora biti spreman preuzeti kontrolu u svakom trenutku.



Slika 26: Senzori na Tesli [15].

Ovisno o vozilu, sustav može imati autopilot ili potpunu sposobnost samostalne vožnje (Full Self-Driving Capability). Razlikuju se u funkcionalnostima koje su dostupne (vidi [15]).

Autopilot ima sljedeće funkcije:

- prilagodljivi tempomat (Traffic-Aware Cruise Control) koji prilagođava brzinu vozila s obzirom na promet i uvjete na cesti,
- automatsko upravljanje (Autosteer) koje samostalno upravlja unutar jasno označenih prometnih traka.

Potpuna sposobnost samostalne vožnje sadrži funkcije koje ima i autopilot uz dodatno:

- navigacija na autopilotu (Navigate on Autopilot) koja navigira vozilo na autocesti uključujući sugeriranje promjene trake, uključivanje pokazivača smjera i skretanje na ispravan izlaz,
- automatska promjena trake (Auto Lane Change) pomaže u prelasku u susjednu traku na autocesti,
- automatsko parkiranje (Autopark) pomaže bočno ili okomito parkirati vozilo,

- poziv (Summon) parkira vozilo na usko mjesto ili ga isparkirava pomoću aplikacije ili ključa,
- pametan poziv (Smart Summon) poziva vozilo u kompleksnijoj okolini i parkiralištima koji zaobilazeći objekte pronalazi vlasnika,
- kontrola prometa i znakova zaustavljanja (Traffic and Stop Sign Control) identificira znakove zaustavljanja i semafore te automatski usporava vozilo pri nailasku na njih.

Trenutno rade na automatskom upravljanju u gradovima.

Video u kojem su prikazane neke od navedenih funkcija može se pogledati na sljedećoj poveznici: <https://www.tesla.com/autopilot>.

8.2 Waymo

Waymo je prva tvrtka koja je odvozila potpuno autonomnu vožnju na javnim cestama 2015. godine. Razvili su Waymo Driver sustav razine 4 automatiziranosti. Ta tehnologija ima mogućnost bez vozačeve pomoći sigurno zaustaviti vozilo ukoliko dođe do pada u sustavu ili se nađe u uvjetima koji su izvan domene njegovih senzora.

Waymo je razvio i koristi razne senzore kao što su lidar, radar, kamera, IMU, GPS i dodatne senzore poput sustava za detekciju zvuka koji na velikim udaljenostima prepoznaje zvuk sirene vozila hitne pomoći i policije.



Slika 27: Waymo Driver senzori [18].

Sustav prepoznaje i klasificira objekte na cesti te procjenjuje njihovu brzinu i smjer. Razlikuje pješake, bicikliste, motocikliste, vozila i drugo. Također razlikuje boje statičnih objekata. Sustav je svjestan okoline poput konstrukcijske zone ili blokirane ceste. Ukoliko nailazi na blokiranu cestu, a ispred vozila se nalazi drugi objekt u pokretu, vozilo će usporiti i napraviti mjesta ukoliko predvidi da će objekt prijeći u susjednu traku.

Waymo Driver testiran je na preko 30 milijuna kilometara javne vožnje zbog čega je razvijen model velike točnosti koji predviđa kako se različiti objekti ponašaju. Sustav je svjestan da se pješaci, biciklisti i motociklisti ponašaju dosta različito, iako samom vozilu izgledaju

slično. Pješaci su možda sporiji od navedenih, ali mogu naglo promijeniti smjer kretanja.

Waymo One usluga je prijevoza koja pruža potpuno autonomne vožnje na određenom području Arizone. Početkom 2020. godine bilo je između 1000 i 2000 Waymo One vožnji tijekom jednog tjedna. Kako usluga funkcionira? Korisnici ne mogu zatražiti autonomnu vožnju, ali ukoliko se autonomno vozilo nađe u blizini, mogu se probati povezati s jednim. Ukoliko uspiju, dobiju obavijest kroz aplikaciju. Vozilo stiže potpuno prazno, bez vozača ili drugih sudionika i vozi korisnike do određene lokacije. Razvijen je sustav Rider Support koji daje odgovore na eventualna pitanja korisnika. Više o funkcionalnostima može se pogledati u [18].

Video korištenja Waymo One usluge može se pogledati na sljedećoj poveznici: <https://waymo.com/waymo-one/>.

8.3 Olimpijsko selo

Tvrtka Toyota dizajnirala je autonomna vozila, točnije autobuse, za olimpijsko selo tijekom olimpijskih i paraolimpijskih igara u Tokiju 2020. godine održanih godinu dana kasnije. 20-ak vozila trebalo je omogućiti lakše kretanje sportašima. Vozila su razine 4 automatiziranosti tako da nije potreban vozač koji bi nadzirao sustav, no u svakom vozilu nalazi se barem jedna osoba radi sigurnosti. Također imaju ograničenu brzinu od 20 km/h. Od senzora koristi kameru i lidar. Vozila su udobna i imaju puno prostora - stane 20 osoba ili 4 osobe u kolicima i 7 osoba koje stoje. Opremljena su rampama koje omogućavaju osobama u kolicima da brzo i lako uđu i izađu iz vozila.



Slika 28: Toyotin autonomni autobus [16].


Međutim, Toyota je obustavila rad ovih autobusa zbog nesreće u kojoj je autobus udario paraolimpijskog sportaša (vidi [17]). Autobus je skretao na raskrižju, a slabovidni sportaš krenuo je prelaziti pješački prijelaz. Iako su se u autobusu nalazile osobe koje su nadzirale vožnju, autobus je udario u sportaša. Zadobio je nekoliko masnica i porezotina i morao je propustiti natjecanje.

9 Budućnost

Predviđa se da će do 2025. godine autonomna vozila biti prilično pouzdana i sigurna (vidi [9]). Budući da je za komercijalnu upotrebu potrebno puno testiranja koja mogu trajati i nekoliko godina, do 2030. godine bi autonomna vozila trebala biti dostupna i dopuštena u većini zemalja. Vozila moraju raditi bez greške u prometu gdje se nalaze vozila koja nisu autonomna, kao i za vrijeme jakih nevremena te na putovima koja nisu označena na karti.

Do 2030. godine zajednička autonomna vozila trebala bi postati svakodnevica. Ona bi predstavljala taksije koji sami voze. Trebali bi biti jeftiniji od današnjih taksija, ali će pružati usluge manje kvalitete jer neće biti vozača koji će pomoći putnicima ili očistiti vozilo. U budućnosti možemo očekivati i autobuse koji sami voze zbog određenih ruta kojima putuju. Zbog mogućnosti uništavanja vozila i ostavljanja smeća, unutrašnjost će najvjerojatnije biti od tvrdog metala i plastike, a bit će ugrađene i kamere. Očekuje se da će većina vozila biti električna, što već i danas možemo vidjeti.

U početku će autonomna vozila biti relativno skupa tako da će većina nastaviti koristiti vozila kojima sami upravljaju. Slika 29 pokazuje predviđanja da će tek iza 2060. godine 50% vozila biti autonomno, odnosno tada će ih moći kupiti gotovo svi.



Slika 29: Predikcija prodaje, voznog parka, putovanja i koristi autonomnih vozila [9].

Moguće je da će autoceste trebati urediti, dodati nove oznake na cesti i znakove koji će se moći pročitati elektronički. U tunele će trebati postaviti uređaje koji će omogućavati pristup internetu. Zbog takvih promjena, autonomna vozila bit će sigurnija i pristupačnija. Vrijeme putovanja će se smanjiti, no promet će se najvjerojatnije povećati za 10 – 30%.

Literatura

- [1] M. Awad, R. Khanna, *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*, Apress, 2015.
- [2] J. Barry, G. Velasco-Hernandez, J. Walsh, D. J. Yeong, *Sensor and Sensor Fusion Technology in Autonomous Vehicles: A Review*, MDPI, 21.6, 2021.
- [3] O. Brock, W. Burgard, C. Stachniss, *Robotics: Science and Systems III*, The MIT Press, 2008.
- [4] B. Brown, J. Kho, P. Liu, B. Meister, C. Mrutyunjaya, V. Narayanan, V. Vaidyanathan, *HyperSpectral Technology for Autonomous Vehicles*, Sutardja Center for Entrepreneurship & Technology, Berkeley Engineering, <https://scet.berkeley.edu/wp-content/uploads/UCB-ELPP-Report-Hyperspectral-Technology-for-Autonomous-Vehicles-FINAL.pdf>, zadnje posjećeno 17.8.2021.
- [5] O. Chum, J. Matas, T. Pajdla, M. Urban, *Robust Wide Baseline Stereo from Maximally Stable Extremal Regions*, British Machine Vision Conference, 2002.
- [6] T. H. Cormen, C. E. Leiserson, R. L. Rivest, C. Stein, *Introduction to Algorithms: Third Edition*, The MIT Press, 2009.
- [7] A. Cutler, D. R. Cutler, J. R. Stevens, *Random Forests*, Machine Learning, 45.1, 2011.
- [8] M. Čáp, E. Frazzoli, B. Paden, D. Yershov, S. Z. Yong, *A Survey of Motion Planning and Control Techniques for Self-driving Urban Vehicles*, IEEE Transactions on Intelligent Vehicles, 1.1, 2016.
- [9] T. Litman, *Autonomous Vehicle Implementation Predictions: Implications for Transport Planning*, Victoria Transport Policy Institute, 2021. <https://www.vtpi.org/avip.pdf>, zadnje posjećeno 21.8.2021.
- [10] D. G. Lowe, *Distinctive Image Features from Scale-Invariant Keypoints*, International Journal of Computer Vision, 60.2, 2004.
- [11] I. S. Na, *Fast Pedestrian Detection Using Histogram of Oriented Gradients and Principal Components Analysis*, International Journal of Contents, 9.3, 2013.
- [12] T. Raviteja, R. Vedaraj LS, *An Introduction Of Autonomous Vehicles And A Brief Survey*, Journal of Critical Reviews, 7.13, 2020.
- [13] M. Schreier, *Environment Representations for Automated On-Road Vehicles*, at-Automatisierungstechnik, 66.2, 2018.
- [14] H. Sjafrie, *Introduction to Self-Driving Vehicle Technology*, CRC Press, Taylor & Francis Group, 2020.
- [15] Tesla, *Autopilot and Full Self-Driving Capability*, <https://www.tesla.com/support/autopilot>, zadnje posjećeno 16.8.2021.
- [16] Toyota, *Toyota autonomous busses*, <https://global.toyota/en/newsroom/corporate/29933371.html>, zadnje posjećeno 30.8.2021.

- [17] *Toyota accident*, <https://www.businessinsider.com/toyota-suspends-self-driving-buses-after-paralympic-accident-2021-8>, zadnje posjećeno 30.8.2021.
- [18] WaymoLLC, *Waymo Safety Report*, 2021., <https://storage.googleapis.com/waymo-uploads/files/documents/safety/2021-03-waymo-safety-report.pdf>, zadnje posjećeno 16.8.2021.

Sažetak

Cilj ovog rada je upoznati se s autonomnim vozilima. Nakon povijesnog pregleda razvoja autonomnih vozila, objašnjen je proces kojim vozila postižu autonomiju.

Sve započinje radom senzora koji skeniraju okolinu i detektiraju objekte. Neki od poznatijih senzora koji se koriste su radar, lidar, kamera, GPS, IMU te ultrazvučni i odometrijski senzori.

Na osnovu podataka koje daju senzori, potrebno je stvoriti percepciju okoline. To se postiže lokalizacijom i mapiranjem te detektiranjem objekata. Problem detektiranja objekata rješava se metodama poput histograma orijentiranih gradijenata, transformacije značajke invarijantne skale, maksimalno stabilnim ekstremnim regijama, metode potpornih vektora, slučajnih šuma i umjetnih neuronskih mreža.

Nakon što je vozilo svjesno svoje okoline, treba planirati kako doći do svog odredišta. Najpoznatiji algoritmi koji se koriste za pronalazak najkraće rute su Dijkstrin i A* algoritam. Osim toga, vozilo treba moći predvidjeti kako će se drugi objekti u prometu ponašati.

Nakon što su odluke donesene, prosljeđuju se kontroli vozila koja te odluke prevodi u naredbe za aktuator. Aktuator konačno upravlja vozilom prema donesenim odlukama.

Vozila dodatno koriste V2X komunikaciju kako bi komunicirala s drugim vozilima, mobitelima, stanicama i drugim objektima. To poboljšava percepciju vozila jer ima uvid u situacije izvan dometa njegovih senzora.

Među najpoznatijim autonomnim vozilima svakako su Tesla i Waymo. Tesla je autonomno vozilo razine 2, a Waymo razine 4 automatiziranosti i u skladu s time imaju određene funkcionalnosti. Toyota je razvila autonomne autobuse razine 4 automatiziranosti za olimpijske i paraolimpijske igre u Tokiju 2020. godine.

Na kraju je ukratko navedeno što možemo očekivati u budućnosti kada je riječ o autonomnim vozilima.

Ključne riječi autonomna vozila, senzori, percepcija, planiranje, kontrola, V2X

Autonomous vehicles

Summary

The goal of this paper is to learn about autonomous vehicles. We will begin with the definition and history of autonomous vehicles and move on to the autonomy process.

Sensors are the basic of vehicle autonomy. This is how vehicle gets information about the environment. Some of the most popular sensors include lidar, radar, camera, GPS, IMU, ultrasonic and odometry sensors.

Vehicle perception is created based on the data from sensors with the use of localization, mapping and object detection. Object detection problem is solved using methods such as histogram of oriented gradients, scale-invariant feature transformation, maximally stable extremal regions, support vector machine, random forest and artificial neural networks.

After perception, planning takes place. Vehicle must plan how to get to its destination and this is accomplished by finding the shortest path using Dijkstra's or A* algorithm. When traveling to chosen location, vehicle should be able to predict how will other objects behave.

All decisions that were made are forwarded to the vehicle control. Decisions are translated into commands for the actuators which finally manage mechanical motion.

Vehicles use V2X communication to exchange information with other vehicles, mobile phones etc. This is how vehicle becomes more aware of the environment.

Tesla and Waymo are among the most famous autonomous vehicles nowadays. Tesla is level 2 and Waymo is level 4 automation. Each has certain functionalities based on the automation level. Toyota developed level 4 automation bus for olympic and paralympic games in Tokyo 2020.

Finally, the paper summarizes what we can expect in the future when it comes to autonomous vehicles.

Keywords autonomous vehicles, sensors, perception, planning, control

Životopis

Zovem se Iva Pribisalić i rođena sam 8. studenog 1997. godine u Osijeku. Pohađala sam Osnovnu školu Vladimira Becića i III. gimnaziju u Osijeku. 2016. godine upisala sam pred-diplomski studij Matematike na Odjelu za Matematiku u Osijeku. Preddiplomski studij završila sam 2019. godine s temom završnog rada *Horadamovi polinomi* pod mentorstvom izv. prof. dr. sc. Mihaele Ribičić-Penave. Za preddiplomski studij dodijeljena mi je pohvala *cum laude*. Iste godine upisala sam diplomski studij, smjer: Matematika i računarstvo. Tijekom diplomskog studija bila sam demonstratorica iz kolegija Elementarna matematika. Sudjelovala sam u pripremama za srednjoškolska natjecanja organizirana od strane Udruge matematičara Osijek. Također sam članica Studentskog zbora. Tijekom obrazovanja primala sam razne stipendije uključujući STEM, gradsku i županijsku stipendiju te privatnu stipendiju od tvrtke Kod savjetovanje d.o.o. U istoj firmi radim već dvije godine preko studentskog ugovora.