Navigacija autonomnih vozila

Krajnović, Branka

Undergraduate thesis / Završni rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:523888

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

zir.nsk.hr

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Branka Krajnović

NAVIGACIJA AUTONOMNIH VOZILA

ZAVRŠNI RAD

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
ODBOR ZA ZAVRŠNI RAD

Zagreb, 24. travnja 2017.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Lokacijski i navigacijski sustavi**

ZAVRŠNI ZADATAK br. 4055

Pristupnik: **Branka Krajnović (0135231392)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Navigacija autonomnih vozila**

Opis zadatka:

Navesti i opisati senzorske tehnologije koje omogućavaju kretanje autonomnih vozila u prostoru. Objasniti parametre koji utječu na preciznost u pozicioniranju autonomnog vozila na kolničku traku. Opisati algoritme koji spadaju pod zajednički naziv "računalni vid" i navesti ograničenja u njegovoj primjeni koja dovode do potencijalnih opasnosti i pogrešnih zaključaka u navigaciji vozila. Objasniti potencijalne prednosti eksploatacije autonomnih vozila i navesti trenutno aktualnu zakonsku regulativu za njihovo prometovanje. Opisati trenutno aktualne projekte razvoja autonomnih vozila od strane vodećih proizvođača koji u ponudi imaju takva vozila ili vozila s određenim stupnjem autonomnosti.

Zadatak uručen pristupniku: 28. travnja 2017.

Mentor:

doc. dr. sc. Mario Muštra

Predsjednik povjerenstva za završni ispit:

Sveučilište u Zagrebu

Fakultet prometnih znanosti

ZAVRŠNI RAD

NAVIGACIJA AUTONOMNIH VOZILA

NAVIGATION OF AUTONOMOUS VEHICLES

Mentor: doc. dr. sc. Mario Muštra

Student: Branka Krajnović, 0135231392

Zagreb, rujan 2017.

NAVIGACIJA AUTONOMNIH VOZILA

SAŽETAK

U ovom završnom radu prikazane su senzorske tehnologije potrebne za navigaciju autonomnih vozila te je objašnjeno na koji način one rade i kakva je njihova preciznost. Navedene su prednosti kao i nedostaci uporabe ovakvih vozila te je prikazan trenutačni zakon koji se odnosi na Sjedinjene Američke Države i Europu. Detaljno su pojašnjeni zadaci koje obrađuje računalni vid te što je sam računalni vid. Opisani su trenutni projekti kroz auto-kompanije koje se bave izradom samih vozila ili unaprjeđenjem hardvera za poboljšanje senzora. Očekivani razvoj prikazan je do 2080. godine kao godina u kojoj će po svjetskim očekivanjima autonomna vozila preuzeti glavninu prometovanja na svim prometnicama.

KLJUČNE RIJEČI: navigacija; autonomna vozila; senzori; računalni vid; prednosti uporabe

SUMMARY

This paper shows which sensors technologies are used for navigation of autonomous vehicles. Also, it explains how it works and how accurate this navigation is. Both advantages and disadvantages are listed for the usage of autonomous vehicles as well as current legislation the US and European law. Tasks that computer vision does and also computer vision for itself are explained in detail. Current projects are shown through companies that develop vehicles or hardware technologies for their improvement. Expected development and evolution are stated until 2080 as a year in which all vehicles are going to be fully autonomous by the global expectations.

KEYWORDS: navigation; autonomous vehicles; sensors; computer vision; advantages of usage

SADRŽAJ

1. Uvod 1
2. Senzorske tehnologije potrebne za navigaciju autonomnih vozila 3
   2.1. Radar 3
   2.2. LIDAR 4
   2.3. GPS 5
3. Točnost u pozicioniranju kombinacijom senzorskih sustava 8
   3.1. Kalmanov filtar 9
   3.2. Markovljevi lanci 10
4. Računalni vid za autonomna vozila 11
   4.1. Zadaci računalnog vida 11
      4.1.1. Prepoznavanje 11
      4.1.2. Analiza pokreta 13
      4.1.3. Rekonstrukcija događaja 13
      4.1.4. Restauracija slike 13
   4.2. SIFT 14
5. Prednosti uporabe autonomnih vozila i zakonska regulativa 16
   5.1. Prednosti i nedostaci autonomnih vozila 16
   5.2. Zakonska regulativa 17
6. Trenutni projekti i očekivani razvoj u budućnosti 20
   6.1. Trenutni projekti 20
   6.2. Planirani razvoj 23
7. Zaključak 24

Literatura 25

Popis slika 26

1. Uvod

Tema ovog završnog rada je navigacija autonomnih vozila. Proučavanjem polja umjetne inteligencije te sve većim napretkom po pitanju istoga rodila su se razmišljanja kako će računalo jednog dana biti u mogućnosti zamijeniti čovjeka u bilo kojem poslu koji će trebati izvršiti. Tako se stvorila i ideja o autonomnim vozilima.

Autonomnim vozilom smatra se svako vozilo kojemu nije potrebno ljudsko upravljanje za prometovanje. Iako su već od početka 20. stoljeća postojali projekti vezani uz tadašnje vizije autonomnih vozila, primjer autonomnog vozila kakvo poznajemo danas prikazan je bio tek krajem 70-tih te početkom 80-tih godina. Ernst Dickmanns i njegov tim preuredili su 1980. godine Mercedesov kombi na način da je bilo moguće kontrolirati upravljač, mjenjač i kočnice preko računalnih naredbi baziranih na slikama dobivenim u stvarnom vremenu preko kamere. Svakim daljnjim napretkom sve se više približavalo današnjoj inačici autonomnog vozila.

Obzirom na veliku navalu u istraživanju i najavljenoj proizvodnji, u SAD-u je 2013. godine definirana klasifikacija razina autonomnih cestovnih motornih vozila te se ona danas primjenjuje u cijelome svijetu. Tako je *National Highway Traffic Safety Administration* postavio klasifikaciju u 5 razina:

1. RAZINA 0 – to je tzv. neautonomna razina; u ovoj razini vozač je jedini koji potpuno samostalno upravlja vozilom.
2. RAZINA 1 – autonomija na ovoj razini uključuje automatizaciju ponekih parametara vožnje; primjer može biti automatizacija elektronske kontrole stabilnosti ili elektronskih pomoćnih sustava kočenja.
3. RAZINA 2 – u ovoj razini vožnje barem dva elementa moraju biti automatizirana i oni rade kooperativno kako bi vozača oslobodili od upravljanja tim funkcijama.
4. RAZINA 3 – vozila ove razine autonomije trebaju preuzeti svu kontrolu od vozača; od vozača se u ovoj razini traži samo pravovremeno djelovanje u kritičnim situacijama.
5. RAZINA 4 – potpuno autonomno vozilo; vozilo je dizajnirano tako da samostalno izvršava sve operacije tijekom cijelog trajanja vožnje, od vozača se očekuje unos željene rute, ali s obzirom da nikakva druga interakcija nije potrebna – ovi automobili mogu prometovati i bez prisustva vozača.

Danas gotovo svi proizvođači proizvode vozila s barem prvom razinom autonomije, ali se ubrzo očekuju potpuno autonomna vozila koja će moći prometovati i bez prisustva čovjeka kao vozača, već samo kao putnika na željeno odredište.

Ovaj rad podijeljen je u 7 cjelina:

1) Uvod
2) Senzorske tehnologije potrebne za navigaciju autonomnih vozila
3) Točnost u pozicioniranju kombinacijom senzorskih sustava
4) Računalni vid za autonomna vozila
5) Prednosti uporabe autonomnih vozila i zakonska regulativa
6) Trenutni projekti i očekivani razvoj u budućnosti
7) Zaključak.

U prvome poglavlju opisana je povijest autonomnih vozila te što su takva vozila uopće. Navedena je klasifikacija po kojoj se danas rangiraju sva vozila kako bi se utvrdio njihov stupanj autonomnosti.

U poglavlju pod nazivom „Senzorske tehnologije potrebne za navigaciju autonomnih vozila" definirane su različite vrste senzora koje se mogu i koje se koriste pri navigaciji autonomnih vozila. Opisano je na koji način ti senzori rade i koja je njihova uloga u autonomnom vozilu.

Iduće poglavlje objašnjava važnost svih senzora i njihove kombinacije bez koje vozilo ne može u potpunosti točno funkcionirati ili ne može funkcionirati uopće. Također, prikazan je razmještaj svih senzora u jednome automobilu.

Četvrto poglavlje objašnjava što je računalni vid kao jedan od senzora potrebnih za navođenje autonomnog vozila. Objašnjeni su zadaci koje računalni vid provodi te je prikazan jedan od algoritama koji pomaže vozilima da prepoznaju neželjene objekte kao što im pomaže i pri navođenju.

Peto poglavlje prikazuje neke od nedostataka koje autonomna vozila mogu donijeti, ali su uglavnom prikazane njihove prednosti. Također, ovo poglavlje opisuje kakvo je trenutno stanje u svijetu po pitanju zakona vezanog uz ovu vrstu vozila. Prikazana je karta SAD-a uz navedene države sa provedenim zakonom za prometovanje ovakvih vozila.

U šestom poglavlju navedene su tvrtke koje trenutno rade na projektima te su i neki od tih projekata opisani. Objašnjen je očekivani razvoj u svijetu u nadolazećih 60 godina.

Posljednje poglavlje donosi zaključak ovoga rada.

2. Senzorske tehnologije potrebne za navigaciju autonomnih vozila

Kako bi se vozilo moglo kretati autonomno, bez vozača, ono mora biti opremljeno raznom senzorskom tehnologijom potrebnom za navigaciju, ispravno lociranje te prepoznavanje okoline u kojoj se vozilo nalazi.

Ovdje se nalaze primjeri nekih od njih:

- radar
- LIDAR/LADAR
- računalni vid
- GPS
- ultrazvučni senzori.

Senzori se mogu podijeliti u dvije kategorije, oni aktivni i pasivni. U aktivne senzore spadaju radar, LIDAR, ultrazvučni i radio valovi, dok u pasivne ubrajamo infracrveno zračenje te kamere. [1]

2.1. Radar

Dolazeći od engleskih riječi "*RAdio Detection And Ranging*", radar možemo definirati kao uređaj za detekciju ili mjerenje udaljenosti nekog objekta pomoću radiovalova. Na radar ne utječu vremenske nepogode i ima mogućnost otkrivanja objekta po mraku, magli ili drugim uvjetima smanjene vidljivosti. Radari se najčešće koriste u kontroli zračnog prometa iako su od velike važnosti i u astronomiji, oružanim snagama, meteorologiji, medicini i drugim poljima znanosti.

Na autonomnim vozilima radari su razmješteni po cijelome vozilu. Ako prilikom slanja elektromagnetskih valova ovaj senzor naiđe na prepreku, elektromagnetski val reflektira se od iste natrag i daje informaciju koliko je prepreka udaljena od radara i koliko brzo se ona kreće pa tako radar u vozilu može u stvarnom vremenu pratiti brzine drugih vozila koja ga okružuju. Trenutačni 2D radari nisu u mogućnosti prepoznati visinu nekog objekta pošto mogu samo horizontalno skenirati pa će taj problem riješiti 3D radari koji se trenutno razvijaju.

Kada ga koristimo kao vizualni senzor za autonomna vozila, radar obuhvaća frekvencijsko područje od 75 do 110 GHz, te valnu duljinu od 2,7 do 4 mm. [2]

2.2. LIDAR

LIDAR je skraćenica od engleskih riječi *LIght Detection And Ranging* ili *LAser Detection And Ranging* (LADAR) i koristi se u robotici za detektiranje objekata, kao i za opažanje životne okoline. Prvotno je razvijen kao sustav za upozorenja na daljinu, a sada se koristi i kod vozila u adaptivnoj kontroli kretanja (engl. *Adaptive Cruise Control - ACC*).

To su sustavi koji koriste lasersku svjetlost i šalju impulse van vidljivog spektra da bi otkrili udaljenost nekog objekta. Imaju posebnu važnost u navigaciji autonomnih vozila zato što standardne kamere nisu uvijek u mogućnosti raspoznati svoju okolinu. Imaju visoku preciznost pri prepoznavanju udaljenih predmeta i prilikom prepoznavanja nekog objekta stvaraju detaljnu 3D mapu terena koja omogućava vozilu da primijeti razliku između automobila i kamiona, bicikla i motocikla i dr. To je od iznimne važnosti zato što se svi ti objekti ponašaju drugačije pa tako i vozilo mora drugačije reagirati na svaki objekt koji susretne u prometu. [2]

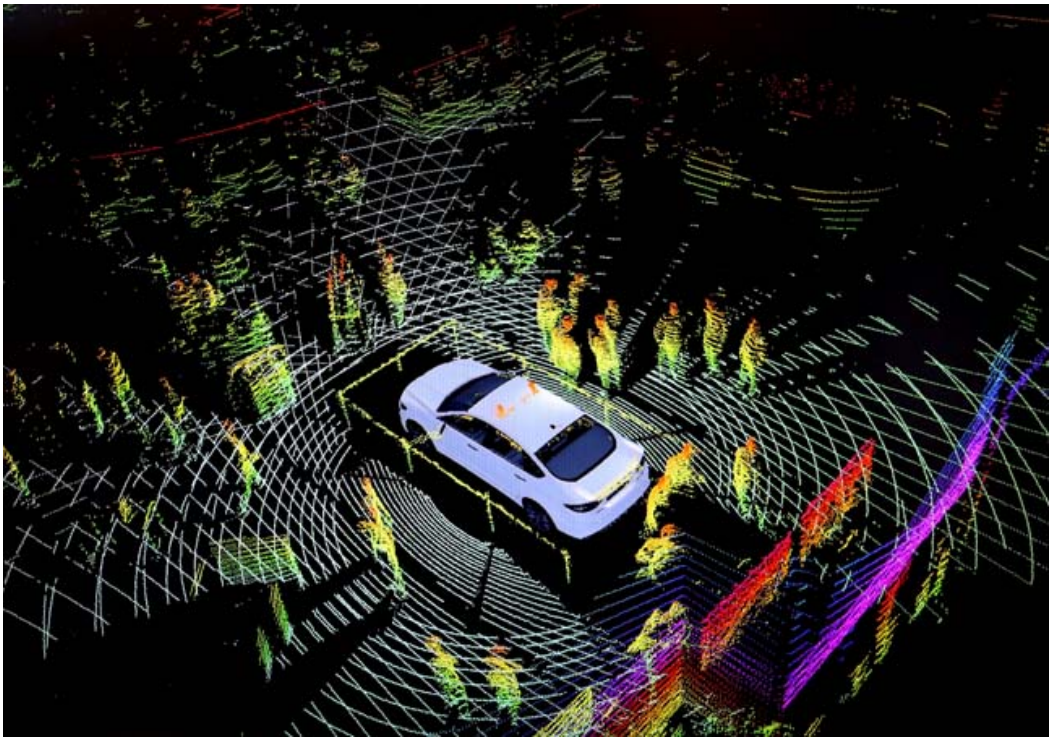

Slika 1. Snimanje okoline u stvarnom vremenu LIDAR senzorom, [1]

LIDAR tehnologija je trenutno preskupa za komercijalnu uporabu u automobilima i cijena im može ići do 80.000 $, ali neke tvrtke su već počele najavljivati ogromni pad u cijenama, čak i do 90%.

2.3. GPS

GNSS je internacionalni naziv za mrežu satelita namijenjenih navigaciji i pozicioniranju u koju spadaju GPS, GLONASS, Galileo i drugi. GPS ili Globalni pozicijski sustav (engl. *Global Positioning System*) temelji se na satelitima koji neprekidno kruže oko Zemlje te tako osiguravaju točnu lokaciju i poziciju u bilo koje doba dana. Potreban je u autonomnim vozilima zato što određuje rutu kojom će vozilo putovati od trenutka kada korisnik unese željenu lokaciju sve do dolaska na samo odredište. Sastoji se od svemirskog, kontrolnog i korisničkog segmenta. [3]

Svemirski segment GPS-a čine 32 satelita. Sateliti se gibaju oko Zemlje u kružnim orbitama na visini od oko 20 000 km što im omogućuje pokrivanje većeg područja. Globalna pokrivenost postigla se njihovim rasporedom u 6 orbitalnih ravnina. Ravnine imaju inklinaciju (nagib prema Zemljinu ekvatoru) od 55° te su razmaknute 60°. Sateliti se kreću brzinom od 11 000 km/h čime je njihovo ophodno vrijeme oko Zemlje 12 sati. U svakome trenutku se iznad horizonta nalazi barem pet satelita. Predviđeno je da svaki od satelita može raditi deset godina, a nakon toga ih je potrebno zamijeniti.

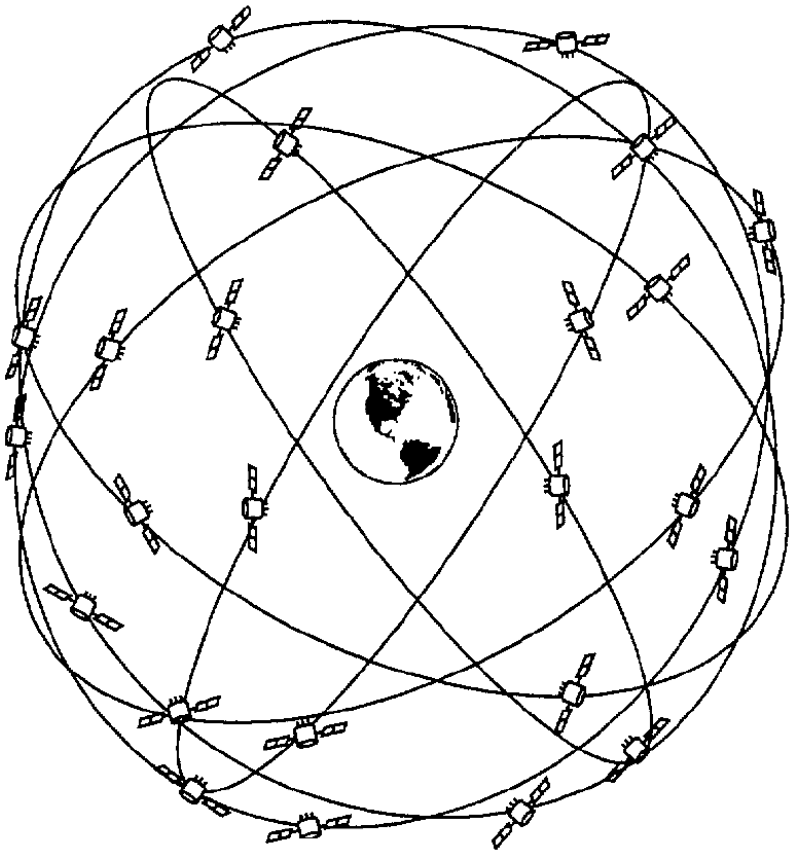

Slika 2. Konstelacija GPS satelita oko Zemlje, [2]

Kontrolni segment obavlja nadzor i upravlja satelitima prateći ih. Sastoji se od pet kontrolnih stanica diljem svijeta. U četiri kontrolne stanice ne nalaze se ljudi, već se sve dobivene informacije dobivene od satelita šalju glavnoj kontrolnoj stanici. U glavnoj kontrolnoj stanici, koja se nalazi u Colorado Springs-u, izračunavaju se odstupanja svakog satelita pa se korekcije šalju natrag satelitima nekoliko puta dnevno. Sateliti su u mogućnosti raditi nekoliko mjeseci bez kontakta sa kontrolnom sustavom.

Slika 3. Kontrolne stanice za praćenje GPS satelita, [3]

Korisnički segment čine dvije kategorije korisnika: autorizirani i neautorizirani korisnici. Autorizirane korisnike sačinjavaju američka vojska i državne službe, a neautorizirani korisnici su svi drugi korisnici diljem svijeta. Također, pozicioniranje s višom razinom točnosti namijenjeno je samo autoriziranim korisnicima.

Princip rada sustava temelji se na visokom stupnju stabilnosti atomskih „satova" ugrađenih na satelite i na iznimno visokoj točnosti mjerenja vremena. Sustav radi u vlastitom vremenu pa nije potrebna stalna sinkronizacija. Kako bi GPS prijemnik mogao odrediti svoju poziciju, treba izmjeriti udaljenost do satelita, znati poziciju satelita i znati podatke za uračunavanje korekcije. Mjerenje udaljenosti između prijamnika i satelita odvija se mjerenjem vremena protoka radiosignala od satelita do prijamnika preko formule:

$$R = c \cdot \Delta t = c \cdot (t_s - t_p), \tag{1}$$

gdje R označava satelit, c brzinu svjetlost, a t_s i t_p pokazivanje satelitskog sata i sata u prijemniku. U svakome radiosignalu koje šalje satelit nalaze se koordinate satelita. U idealnim uvjetima trebala bi tri mjerenja da prijamnik odredi svoju poziciju, ali s obzirom na to da satovi na satelitu i prijamniku nisu savršeni i da se radioval ne širi brzinom svjetlosti, prijamnik ne mjeri pravi razmak već tzv. pseudorazmak (R^*) :

$$R^* = R + c\left(\Delta t_p - \Delta t_{si}\right) + c \cdot \Delta t_{ai}, \tag{2}$$

gdje Δt_p, Δt_{si} predstavljaju odstupanje sata u prijamniku i na satelitu od stvarnog vremena sustava, a Δt_{ai} predstavlja pogrešku zbog utjecaja na širenje radiovalova. Odstupanje sata na satelitu sadržano je u radiosignalu sa satelita, pogreška zbog utjecaja na širenje uračunava se korekcijskim metodama i nju izračunava prijemnik, a odstupanje sata u prijamniku isto je za sve pseudorazmake. Kod trodimenzionalnog pozicioniranja zbog netočnosti sata u prijamniku trebalo bi mjeriti razmak do četiri satelita.

3. Točnost u pozicioniranju kombinacijom senzorskih sustava

Korištenje svih odgovarajućih senzora za navigaciju autonomnih vozila nema smisla ukoliko ti senzori nisu dovoljno stabilni i točni kako bi se navigiranje ispravno odvijalo. Kako je već i u prijašnjem poglavlju navedeno, senzorske tehnologije potrebne za navigaciju nisu u mogućnosti raditi samostalno, te se upotrebom više takvih postiže sve veća točnost u pozicioniranju.

Veliki problem stvaraju uvjeti smanjene vidljivosti koji mogu onemogućiti potpuno funkcioniranje nekog od senzora i zbog toga je potrebno imati drugi, pričuvni, koji je na takve uvjete otporan. Na primjer, LIDAR senzor može biti neprecizan prilikom zatrpavanja ceste snijegom pa su u tim situacijama važni radari i kamere. Radar i LIDAR u kombinaciji u vozilu imaju učinkovit raspon pregleda od oko 50 metara, ali se to može znatno smanjiti zbog kiše ili drugih loših vremenskih uvjeta. Također, komercijalni GPS sustavi u vozilima imaju preciznost od oko 5 metara, ali se u tunelima može dogoditi da znatno promaše svoju lokaciju ili da u potpunosti zakažu.

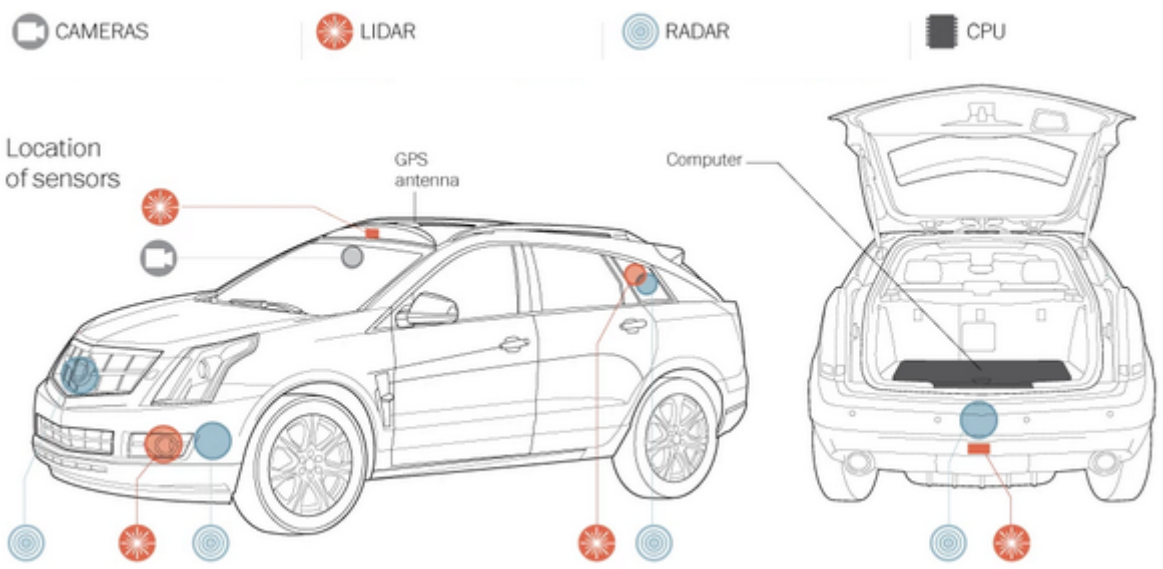

Slika 4. Razmještaj senzora u autonomnom vozilu, [4]

Vodeće kompanije za razvitak ovakvih vozila, poput Google-a, smatraju kako bi u skorije vrijeme s ovim senzorskim tehnologijama mogle postići točnost pozicioniranja u opsegu od 10 do 20 centimetara. Zbog visoke cijene LIDAR sustava pojavila su se razmišljanja kako bi se vožnja u autonomnim vozilima mogla odvijati i bez njega zamjenjujući ga visokokvalitetnim kamerama koje bi zbog svoje niske cijene sve više i više bile unaprijeđene kroz vrijeme.

Ipak, simulacije vožnje pokazale su da vozila najbolje funkcioniraju i pokazuju najveću točnost kada rade sa što većim brojem senzora tako da bi, zbog ljudske sigurnosti na prvome mjestu, bilo najbolje ostati pri razmišljanju da se koriste svi senzori iako je njihova cijena trenutačno možda previsoka.

3.1. Kalmanov filtar

Kombiniranje dobivenih podataka sa dva ili više senzora zove se fuzija senzora. S obzirom na pogreške u mjerenju, niti jedan od senzora neće nikada dati stopostotno točno mjerenje, pa se tako njihovom kombinacijom mogu dobiti dva različita mjerenja. Na primjer, mjerenje odrađeno radarom može pokazati da je drugo vozilo udaljeno 20 metara, dok nam LIDAR senzor u automobilu može izmjeriti udaljenost drugog vozila na 25 metara. Zato se koristi Kalmanov filtar. [4]

Kalmanov algoritam je optimalni algoritam korišten za računanje pozicije s minimalnom pogreškom i za filtriranje zašumljenih signala, a u navigaciji je poznat kao Kalmanov filtar. Zasniva se na činjenici da će kombinacija dvije vrijednosti, tj. dva mjerenja određene točnosti dati vrijednost veće točnosti. To je rekurzivni algoritam pa tako koristi sva mjerenja kako ona postaju raspoloživa, čime rezultate iz prethodnog koraka koristi za dobivanje rezultata u slijedećem koraku. Može se koristiti za interpolaciju prethodnih stanja, estimaciju trenutnog stanja, pa tako i za predviđanje budućeg stanja sustava. [4]

Kalmanov filtar opisan je ovim formulama:

- srednje kvadratno odstupanje

$$\frac{1}{\sigma^2} = \frac{1}{\sigma_A^2} + \frac{1}{\sigma_B^2}, \tag{3}$$

- rezultat procjene (srednja vrijednost)

$$\mu = \frac{\mu_A \sigma_B^2 + \mu_B \sigma_A^2}{\sigma_A^2 + \sigma_B^2}, \tag{4}$$

3.2. Markovljevi lanci

Markovljev lanac u matematici predstavlja niz stanja sustava. Ukoliko neki slijed stanja sadrži Markovljevo svojstvo, to znači da je svako buduće stanje neovisno o prethodnom. [5]

Primjer korištenja možemo naći u svakoj društvenoj igri gdje se igra odvija na ploči bacanjem kockice. U svakom trenutku kada igrač dolazi na red i baca kocku, prošlo stanje gdje se nalazio nije važno niti ono može utjecati na njegovu buduću poziciju zato što igrač baca kocku koja odlučuje o njegovu daljnjem pomaku.

U prometu i transportu primjer Markovljevog lanca možemo primijeniti također na točnost senzora koje autonomna vozila koriste. Ako u pet mjerenja LIDAR da točnija mjerenja u odnosu na radar, i dalje ne znači da će iduće mjerenje koje senzori provedu pokazati veću točnost kod LIDAR senzora, ali opet možemo izračunati njihovu srednju vrijednost korištenjem Kalmanovog filtra.

4. Računalni vid za autonomna vozila

Računalni vid je znanstvena i tehnološka disciplina koja spada u jedno od područja umjetne inteligencije. To je sustav kojime se pokušava percipirati ljudski vid te tako prepoznavati dvodimenzionalne i/ili trodimenzionalne objekte.

Ljudsko oko u stanju je prepoznati okolinu ili stvari na slici – bile one rotirane, umanjene, uvećane ili čak i ako dio predmeta na slici nedostaje. Taj zadatak za računalo još uvijek predstavlja problem, ali je računalni vid ipak našao svoju važnu primjenu u područjima poput medicine, automatike, zrakoplovstva i drugih disciplina. [6]

4.1. Zadaci računalnog vida

U uobičajene zadatke koje računalni vid obavlja možemo svrstati prepoznavanje, analizu pokreta, rekonstrukciju događaja te restauraciju slike.

4.1.1. Prepoznavanje

Prepoznavanje, kao zadatak računalnog vida, se odnosi na prepoznavanje objekata u prostoru, prepoznavanje znakova i prepoznavanje lica ili identifikaciju.

Prepoznavanje znakova ili kraće OCR[1] temelji se na otkrivanju zadanog rukom napisanog ili pisačem ispisanog teksta ili raznih simbola s neke podloge (papir, metal, plastika i dr.). U praksi se mnogo koristi prilikom digitalizacije starih knjiga ili neke druge literature kako bi se omogućilo njihovo pretraživanje na Internetu. Iz vozila mogu prepoznavati ograničenja brzine ili druge prometne znakove.

[1] OCR – engl. *Optical Character Recognition*

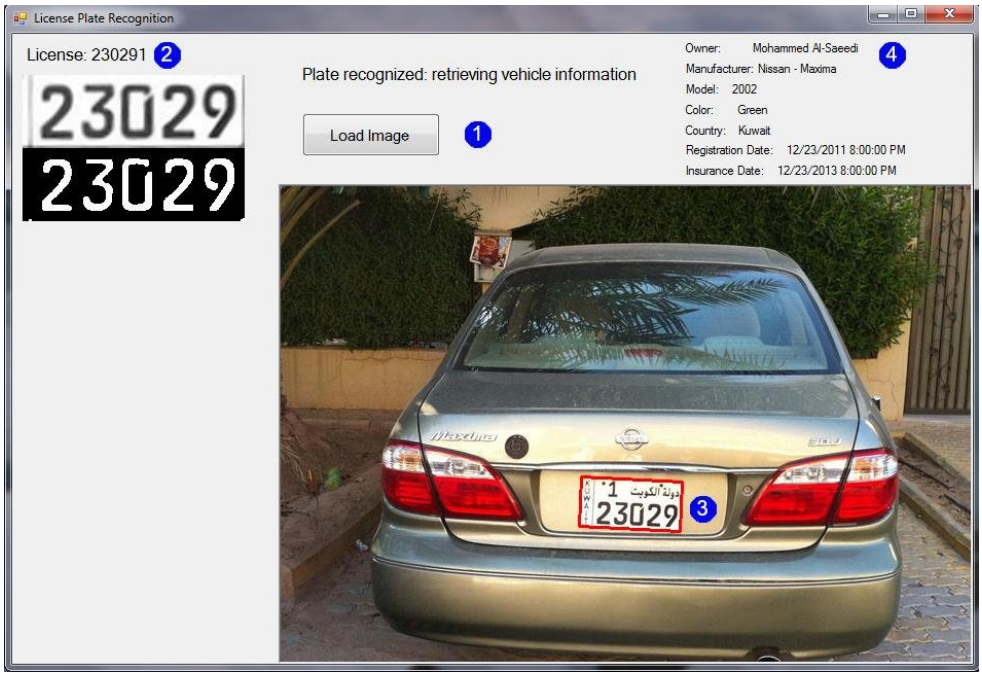

Slika 5. Primjer programa za prepoznavanje registracija korištenjem OCR-a, [5]

Prepoznavanje objekata u prostoru pokazalo se najučinkovitiji prilikom prepoznavanja određenih objekata na slici kao što su ljudska lica no i u tim situacijama dolazi do pogrešaka (poput označenog zida na slici dolje) pa se ovakvo prepoznavanje i dalje smatra prevelikim izazovom za računalni vid.

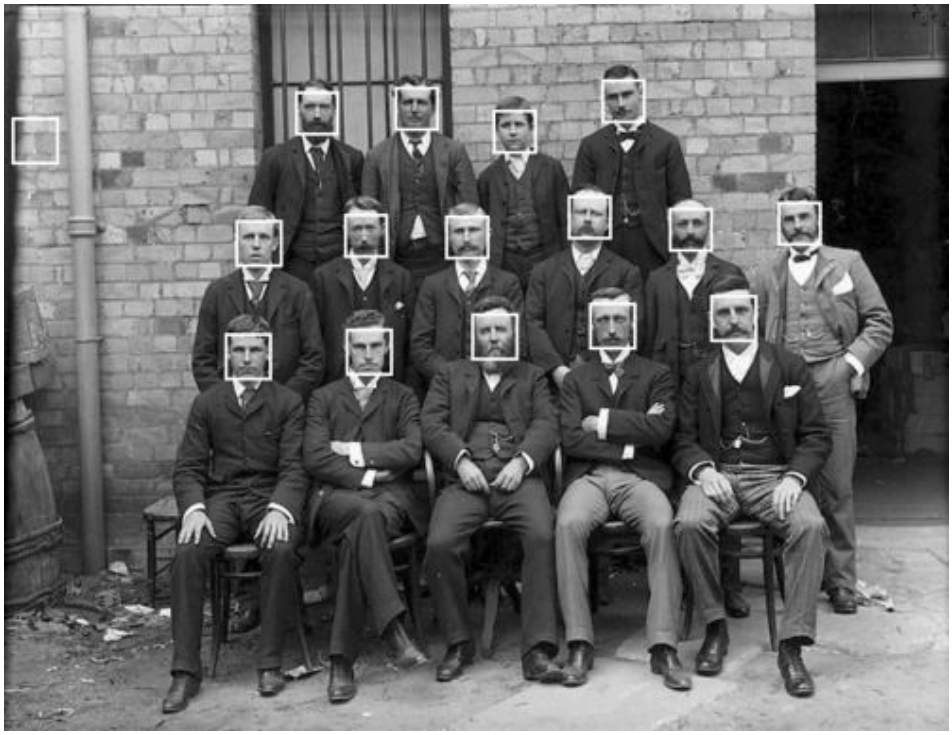

Slika 6. Prepoznavanje lica na slici korištenjem računalnog vida, [6]

Detekcija se u računalnom vidu najčešće koristi u sigurnosnim sustavima gdje možemo prepoznati osobu pomoću njenog otiska prsta ili skeniranjem njena lica, ili pak možemo identificirati određeno vozilo iz trenutnoga. Prepoznavanje lica može se odvijati kombinacijom višestrukih algoritama koji analiziraju određene dijelove lica poput veličine nosa, visine čela ili oblika očiju i nakon analize uspoređuju izmjerene elemente sa drugim slikama koje imaju jednake vrijednosti.

4.1.2. Analiza pokreta

Ovaj zadatak u računalnom vidu odnosi se na analizu pokreta u video snimci ili pak na obradu niza slika gdje se odvijaju promjene. Primjeri takvih zadataka u analizi pokreta su *egomotion*, *optical flow* i *tracking*.

Egomotion prepoznaje i određuje trodimenzionalni pokret iz niza fotografija uslikanih aparatom. Primjer uporabe *egomotion*-a bio bi procjena kretanja automobila iz samoga automobila uspoređujući prometne znakove ili uličnu traku kraj koje automobil prolazi.

Optical flow za svaku točku u ravnini neke slike određuje kako se ona kreće u odnosu na tu ravninu i zatim predstavlja to kretanje kao odnos kretanja odgovarajuće 3D točke i kretanja kamere u prostoru.

Tracking prati pokrete određenih zadanih točaka ili objekata (npr. ljudi ili vozila) iz slijeda fotografija.

4.1.3. Rekonstrukcija događaja

Cilj rekonstrukcije događaja je složiti što više točaka koji prikazuju sliku scene kako bi se omogućilo slaganje te izračunavanje 3D modela scene. Vremenskim razvijanjem došlo je do metoda koje mogu u potpunosti proizvesti 3D model plohe, kao i do unapređivanja algoritama da spajaju više slika u 3D modele.

4.1.4. Restauracija slike

Glavni zadatak restauracije slike je uklanjanje smetnji iz iste, uz zadržavanje dovoljne kvalitete i detalja koje slika sadrži. Te smetnje odnose se uglavnom na razna zamućenja, a najviše se rješavaju korištenjem raznih filtara poput niskopropusnih ili pojasnopropusnih pa je tako na slici prikazana kombinacija filtara do smanjena zamućenja dovoljnog za jasan pregled slike uz dovoljne detalje.

Slika 7. Uklanjanje smetnji iz slike korištenjem računalnog vida, [7]

4.2. SIFT

Scale-invariant feature transform ili kraće SIFT označava algoritam računalnog vida za prepoznavanje i opisivanje lokalnih značajki u slikama. Razvio ga je David Lowe 1999. godine, a poboljšan je te ponovno izdan 2004. godine.

Posebnu važnost ima zbog svoje nepromjenjivosti obzirom na rotaciju i veličinu slike (točnije njeno umanjenje ili uvećanje), a pokazao je i dobre rezultate prilikom testiranja otpornosti na svjetlost, zaklanjanja i promjene točke gledišta nekog objekta.

Postoje 4 osnovna koraka na osnovu kojih SIFT radi:

1. Detekcija ekstrema kroz niz skala – u ovome koraku algoritma traže se točke u slikama koje odgovaraju uvjetima stabilnosti, ponovljivosti i nepromjenjivosti. Koristi se Gauss-ov filtar na zamućenim slikama i tako se pronalaze ekstremi koji postaju interesne točke (engl. *interest keypoints*).
2. Lokalizacija interesnih točaka – s obzirom na to da je prvi korak rezultirao prevelikim brojem interesnih točaka, gdje su neke od njih ipak nestabilne, u ovome koraku se vrši izbor interesnih točaka ponovnom provjerom njihove stabilnosti.
3. Dodjela orijentacije – nakon konačnog odabira interesnih točaka, svakoj od njih dodjeljuje se orijentacija obzirom na lokalne značajke tog dijela slike.
4. Deskriptor interesnih točaka – u ovome koraku algoritma izrađuje se deskriptor u kojemu se dodjeljuje opisni vektor svakoj točki interesa kako bi se što bolje precizirala njena nepromjenjivost na osvjetljenje, promjene položaja kamere te druge faktore.

SIFT kao algoritam računalnog vida pronalazi svoju primjenu u mnogim poljima poput robotike, medicine i filmske industrije, a zbog mogućnosti vrlo brze i precizne usporedbe neke slike s mnogim velikim bazama podataka njegova primjena

može mnogo doprinijeti i navigaciji autonomnih vozila jer može poslužiti za detekciju neželjenih objekata, kao i za pomoć pri navođenju. [6]

Najveći nedostatak SIFT metode za izdvajanje značajki neke slike je njena matematička složenost i nedovoljna brzina izračuna tih značajki. Zbog sve većeg zahtjeva za brzinom izračuna, 2006. godine predstavljena je nova metodologija nazvana SURF[2] i koristi se kao detektor i opisnik. Detektor značajki kod SURF-a donosi rezultate brže zbog korištenja drugačije sheme. Algoritam koji SURF koristi četiri je puta brži u izvođenju u odnosu na SIFT algoritam, no broj povezanih točaka na slici ipak je veći pri korištenju SIFT algoritma.

Uz SIFT i SURF, neki od značajnijih deskriptora značajki su također i MOPS[3], PCA-SIFT[4] i GLOH[5].

[2] SURF – engl. *Speeded Up Robust Feature* (Ubrzane robusne značajke)
[3] MOPS – engl. *Multi-Scale Oriented Patches*
[4] PCA-SIFT – engl. *Principal Components Analysis-SIFT*
[5] GLOH – engl. *Gradient Location and Orientation Histogram*

5. Prednosti uporabe autonomnih vozila i zakonska regulativa

U ovome poglavlju navedene su prednosti i nedostaci korištenja autonomnih vozila kako bi se pokazalo da, iako trenutnih prednosti ima mnogo više, i dalje postoje mnogi nedostaci na koje treba obratiti pozornost. Uz to, u drugome dijelu poglavlja prikazani su trenutni zakoni koji se odnose na Sjedinjene Američke Države, te Europu.

5.1. Prednosti i nedostaci autonomnih vozila

Iako autonomna vozila još nisu u komercijalnoj uporabi, duže vrijeme se naveliko raspravlja o prednostima, ali i nedostacima koje bi takva vozila mogla donijeti.

Uz trenutno nepovjerenje ljudi prema ovoj vrsti umjetne inteligencije, jedan od problema je i smanjenje broja zaposlenih. Mnogo ljudi na poslu profesionalnog vozača javnog prijevoza izgubiti će posao u trenutku kada ova vozila uđu u komercijalnu uporabu pa tako vozači autobusa, tramvaja pa čak i taksija više neće biti potrebni. Također, jedan od važnih nedostataka svakako je i cijena, koja će zasigurno biti mnogo veća od trenutnih, a mnogi vozači, prvenstveno automobila, smatraju kako će se u potpunosti izgubiti sam čar vožnje bez samostalnog manevriranja vozilom. U svijetu se također razgovara o problemu samih prometnih nesreća tijekom korištenja autonomnih vozila. Iako se smatra da će ona značajno smanjiti broj nesreća na cestama, to i dalje ne znači da ih neće biti uopće. I dalje nije definirano tko bi trebao biti krivac kada do takvih nesreća dođe jer je inače za sve bio odgovoran vozač kojeg tada više neće biti. Predviđa se da će trošak morati snositi osiguravajuće kuće no niti to još nije točno definirano zakonom. Veliku moralnu dilemu stvara razmišljanje o potencijalnim nesrećama u kojima će samo vozilo u nekoj situaciji morati odabrati kako reagirati u pojedinim situacijama gdje može biti više kolateralnih posljedica od materijalnih šteta pa sve do više ljudskih žrtava od kojih neke moraju nastradati. Ovakvi iznimno važni problemi nisu još pronašli svoje rješenje, ali to i dalje ne zaustavlja napredak po pitanju samog razvoja autonomnih vozila.

Usprkos mogućim nedostacima koji se navode u tekstu iznad, ipak se mnogobrojnijima smatraju prednosti autonomnih vozila. Najvećom prednosti korištenja autonomnih vozila može se smatrati smanjenje broja prometnih nesreća koja bi dovela i do manjeg broja smrtno stradalih osoba. Ta prednost ostvarila bi se zbog veće pouzdanosti u autonomne sustave kao i zbog manjeg vremena potrebnog za reakciju na nezgodu nego kod ljudskih vozača kod kojih također može biti prisutan umor, djelovanje opijata i slično. Kada bi se smanjile nezgode na cestama bilo bi i manjeg zagušenja na cestama što bi uz smanjenje vremena putovanja dovelo i do značajnog smanjenja potrošnje goriva pa tako i do manjeg zagađenja okoliša.

Ukoliko bi sva vozila na cesti bila autonomna ne bi postojala potreba ni za održavanjem određenog razmaka između vozila zbog sigurnosti što bi omogućilo povećanje prometa. Smanjile bi se potrebe za prometnom kontrolom kao i ulaganja u unaprjeđenje infrastrukture na prometnicama po pitanju prometne signalizacije zato što će vozila biti u mogućnosti dobivati informacije elektroničkim putem. Korištenjem autonomnih taxi vozila gubi se i vrijeme pronalaženja parkirnih mjesta zato što vozilo može samostalno nastaviti tražiti mjesto za parkiranje nakon što odradi vožnju.

Autonomna vozila bi također omogućila korištenje istih osobama koje inače nisu sposobne ili su zakonski ograničene za upravljanje vozilom poput maloljetnih osoba ili osoba sa težim zdravstvenim oboljenjima. [7]

5.2. Zakonska regulativa

Od početka 21. stoljeća se, uz veliki razvitak tehnologije potrebne za autonomna vozila, razvila i problematika vezana uz pravnu regulativu.

Na prostorima Sjedinjenih Američkih Država, Nevada je bila prva država koja je u lipnju 2011. godine predložila zakon koji se odnosi na uporabu autonomnih vozila, a taj zakon je stupio na snagu u ožujku 2012. godine. Tako je u svibnju 2012. godine Nevadin DMV[6] izdao prvu dozvolu za samoupravljajuće vozilo, a radilo se o Toyoti Prius prilagođenoj od strane Google-a. Automobil je bio modificiran na način da je vozač u bilo kojem trenutku bio u mogućnosti preuzeti kontrolu nad vozilom pritiskom papučice kočnice ili okretanjem volana. Ovim zakonom država Nevada postala je odgovorna za uspostavljanje sigurnosti i određivanje područja gdje se autonomna vozila mogu testirati prije uporabe.

[6] DMV – Odjel za motorna vozila (engl. *Department of Motor Vehicles*)

Nakon Nevade, slijedeće država u kojima je stupio zakon vezan za autonomna vozila bile su Florida i Kalifornija također 2012. godine, a nakon toga zakon se nastavio predlagati diljem Sjedinjenih Američkih Država. [8]

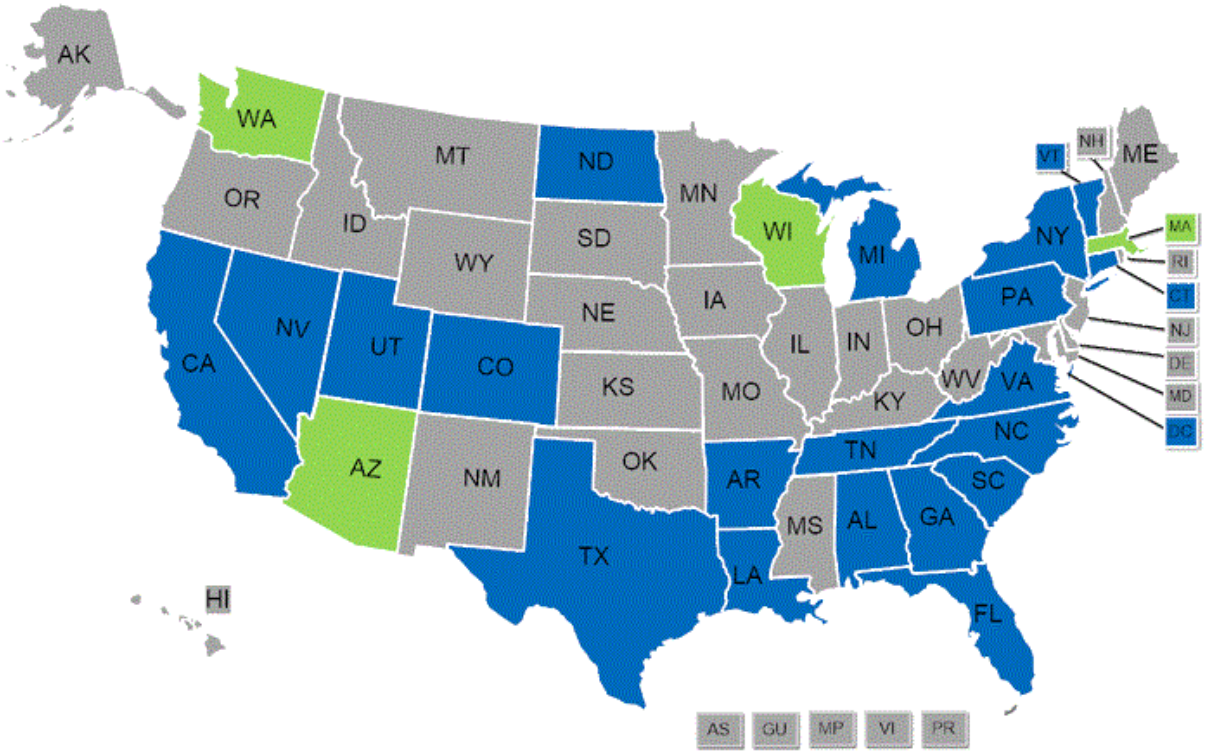

Slika 8. Države u SAD-u u kojima je implementiran zakon o autonomnim vozilima, [8]

(usvojen zakon – plavo, u procesu izvršenja – zeleno)

U travnju 2017. godine na konferenciji u Bruxelles-u razgovaralo se o implementaciji i uvođenju autonomnih vozila na prometnice Europske Unije. Smatra se da bi se autonomni kamioni mogli naći na autocestama Europe već kroz dvije godine, ali se trenutačno nikakva regulativa nije još primijenila na države Europske Unije.

U svibnju 2017. godine kancelarka Njemačke, Angela Merkel, i gornji dom parlamenta odobrili su zakon u kojemu se specificira na koji će se način i pod kojim uvjetima autonomna vozila moći naći na njemačkim prometnicama.

Naime, zakon nalaže da se vozač mora u svakome trenutku nalaziti u vozilu kako bi mogao preuzeti kontrolu u svakom trenutku ukoliko to bude potrebno. Također, svako vozilo mora imati tzv. „crnu kutiju" koja će zapisivati sve podatke s puta kao i podatke o tome da li vozilom upravlja čovjek ili se vozilo kreće „samostalno". U trenutkom stadiju zakona ističe se i da je vozač odgovaran za svaku moguću štetu koja se dogodi pod njegovim nadzorom. Predviđa se da će se zakon izmijeniti kroz dvije godine zbog tehnološkog napretka. [9]

6. Trenutni projekti i očekivani razvoj u budućnosti

6.1. Trenutni projekti

2005. godinu možemo navesti kao početak vala modernog razvoja autonomnih vozila. Agencija za obrambene napredne istraživačke projekte (*Defense Advanced Research Project Agency – DARPA*) organizirala je utrku u pustinji Mojave kojoj je cilj bio preći 212 kilometara autonomnim vozilom sa simuliranim uvjetima u roku od 10 sati. Do cilja je uspjelo doći 5 timova, a prvo mjesto te nagradu od 2 milijuna dolara osvojio je Volkswagen Touareg nazvan Stanley izrađen na Sveučilištu Stanford u kolaboraciji sa Volkswagenovim Laboratorijem za elektronička istraživanja. U idućoj utrci 2007. godine cilj je bio poštivati propise u gradskoj vožnji i tu je prvu nagradu uzelo Sveučilište Carnegie Mellon. [10]

Slika 9. Volkswagen Touareg nazvan Stanley, [9]

Održane utrke bile su uvertira za projekte koji su uslijedili od strane mnogih velikih svjetskih korporacija i u nastavku su navedeni neki od njih:

- Tesla – Izvršni direktor Elon Musk priopćio je krajem listopada 2016. godine da će se tri modela iz trenutne proizvodnje (Model S, Model X i Model 3) unaprijediti hardverom koji će omogućiti potpunu vožnju bez vozača. Demonstracija najavljene nove tehnologije trebala bi se održati do kraja 2017. godine jer se Musk obvezao da će do kraja 2018. godine imati potpuno spremno autonomno vozilo.
- Google – 2016. godine Google je osnovao podružnicu za razvijanje autonomne tehnologije pod nazivom Waymo. Cilj te kompanije je da surađuje sa proizvođačima automobila, pa tako Waymo u suradnji s Fiat Chryslerom testira njihove kombije na području Kalifornije. Iako se predviđa dovršetak Google-ovog autonomnog vozila do 2020. godine, kao njihov primarni cilj navodi se proizvodnja hardvera za proizvođače automobila.
- BMW – iNext najavljeni je projekt ove kompanije i to je potpuno autonomno vozilo najavljeno za 2021. godinu. Do sada su već prikazali neke njegove značajke poput samostalnog parkiranja i vraćanja po klijenta kada je spreman. Njihov BMW serije 7 dolazi s polu-autonomnim značajkama kao što su držanje kolničkog traka te zaštita od bočnog sudara.
- Toyota – Ova kompanija je u studenom 2016. godine uložila milijarda dolara u razvoj umjetne inteligencije i robotike kako bi i oni imali spremna autonomna vozila koja su najavili do kraja 2020. godine.
- Volvo – U planu ove kompanije za sada se nalaze samo polu-autonomne značajke u njihovim automobilima koje planiraju ugraditi u sve svoje automobile do kraja 2020. godine.
- Nissan – Na svojoj web-stranici, Nissan je napisao kako su dosegli adekvatne tehnološke mogućnosti potrebne za realiziranje autonomne vožnje na autocestama Japana, a širenje u Europu, Kinu i SAD nastaviti će se do 2020. godine.
- Audi – Direktor tvrtke NVidia najavio je suradnju sa Audijem koji 2018. godine planira ispitivanje vlastitih samovozećih automobila na javnim cestama.
- Apple – Poznato je kako je Apple zaposlio stručnjake za razvoj autonomnih vozila no ova tvrtka još nije službeno potvrdila planiraju li sami proizvodnju istih. U listopadu 2016. godine rečeno je da Apple prvenstveno radi na izradi softvera, a ne na stvaranju vozila od početka.

Uz još mnoge poznate tvrtke koje rade na autonomnim vozilima ili na razvijanju njihove tehnologije, istaknuo se i UBER najavivši suradnju s velikim brojem kompanija. Naime, iz tvrtke su najavili kupnju velikog broja vozila u trenutku kada ona budu potpuno autonomna i dostupna za prometovanje kako bi ih oni mogli koristiti u svome servisu za prijevoz putnika. Također, Uber je sa svoja četiri Ford Fusiona isprobao autonomno taksiranje na ulicama u Pittsburghu, u Pennsylvaniji. [11]

Slika 10. Uber-ovo autonomno taxi vozilo, [10]

6.2. Planirani razvoj

Autonomna vozila kao vozila budućnosti spominju se već desetljećima, ali dosadašnji razvitak tehnologije nije dozvolio njihovu potpunu implementaciju. Tako brojni prometni instituti smatraju da bi se u vremenskom periodu od 2015. godine do 2025. godine moglo potpuno ozakoniti testiranje te korištenje autonomnih vozila na javnim prometnicama ukoliko bi ta vozila zadovoljavala kriterije sigurnosti i funkcionalnosti. Time bi smo mogli označiti prvu fazu razvoja.

U drugoj fazi za koju se predviđa trajanje od 2020. do 2040. godine potrebno je upotpuniti trenutnu infrastrukturu prilagođenu vozilima s adaptivnom kontrolom kretanja kako bi se postiglo usklađeno odvijanje prometa za sva vozila. Unutar druge faze također se očekuje i dostupnost autonomnih vozila na tržištu što bi trebalo biti omogućeno do kraja 2030. godine.

Iako su neke svjetske kompanije već započele testiranje i upotrebu autonomnih taxi vozila, potpuna implementacija očekuje se u vremenskom periodu od 2030. do 2040. godine.

Potpuna neovisnost i mobilizacija takvih vozila očekuje se između 2040. i 2050. godine kada će ona biti dostupna široj javnosti na prodaju zbog očekivanog pada cijene. Samim time došlo bi do mnogih prednosti poput povećane sigurnosti, smanjenja emisije štetnih ispušnih plinova i povećane štednje u odnosu na prijašnja ulaganja u prometnu infrastrukturu.

Krajnjom fazom predviđenog razvoja u budućnosti smatra se period od 2050. do 2080. godine u kojoj bi gotova sva ili sva vozila bila autonomna, a u SAD-u se smatra da će 60% svih vozila sačinjavati ona autonomna već do 2030. godine. [12]

7. Zaključak

Autonomna vozila zbog nedovoljnog razvitka tehnologije još nisu ušla u komercijalnu uporabu. Senzori potrebni za njihovu navigaciju razvijaju se iz dana u dan sve više, ali se i dalje nisu razvili toliko da bi se autonomna vozila mogla kretati potpuno samostalno uz potpunu točnost. Također, cijene tih svih senzora još su previsoke za testiranja te implementaciju u sva postojeća ili nova vozila.

Razvoj računalnog vida, kao tehnologije potrebne za navigaciju autonomnih vozila, nailazi na probleme prilikom detaljnog prepoznavanja objekata ili analize istih zato što računalo još uvijek nije u mogućnosti sa stopostotnom točnošću rješavati zadatke koje obavlja čovjek.

Uz sve navedene prednosti koje autonomna vozila mogu donijeti i dalje postoje i mnogi nedostaci poput nepovjerenja ljudi u ovakvu vrstu umjetne inteligencije. Čovjek i dalje smatra kako ni jedan računalni sustav ne može u potpunosti zamijeniti njegovu sposobnost prosuđivanja, instinkte koji u većini slučajeva uspješno rješavaju krizne situacije kojih u prometu ne manjka. Također, postoji strah vezan uz kvarove istih.

Iako u Sjedinjenim Američkim Državama postoji mnogo država koje su već prihvatile zakon za testiranje i provedbu autonomnih vozila na prometnice, u Europi još uvijek nije u potpunosti prihvaćena ideja o ovakvim vozilima na našim prometnicama. Uz probleme sa zakonskom regulativom, u zemljama poput Hrvatske problem bi jednog dana mogao stvarati i ekonomski aspekt. Testiranja ovakvih sustava i dijelovi za iste su vrlo skupi zbog čega se može očekivati da će jednog dana i takvi automobili zbog svoje visoke cijene biti nedostupni širem tržištu.

Literatura

[1] Cheng. H: Autonomous Intelligent Vehicles; Springer-Verlag London Limited, 2011.

[2] Fossen T., Pettersen K. Y., Nijmeijer H. : Sensing and Control for Autonomous Vehicles; Springer International Publishing AG, 2017.

[3] http://e-student.fpz.hr/Predmeti/L/Lokacijski_i_navigacijski_sustavi/Materijali/05-Satelitski_pozicijski_sustavi.pdf; pristupljeno: 01.07.2017.

[4] http://e-student.fpz.hr/Predmeti/L/Lokacijski_i_navigacijski_sustavi/Materijali/06-Map_matching.pdf; pristupljeno: 04.09.2017.

[5] https://www.dartmouth.edu/~chance/teaching.../Chapter11.pdf; pristupljeno: 04.09.2017.

[6] Szeliski R.: Computer Vision, Alghorithms and Applications; Springer-Verlag London Limited, 2011.

[7] https://www.autoinsurancecenter.com/top-20-pros-and-cons-associated-with-self-driving-cars.htm; pristupljeno: 17.08.2017.

[8] http://www.ncsl.org/research/transportation/autonomous-vehicles-self-driving-vehicles-enacted-legislation.aspx; pristupljeno: 12.08.2017,

[9] http://www.racunalo.com/njemacka-prihvatila-zakon-o-autonomnim-vozilima/ ; pristupljeno: 12.08.2017.

[10] https://www.wired.com/2006/01/stanley/; pristupljeno: 12.08.2017.

[11] http://www.businessinsider.com/google-apple-tesla-race-to-develop-driverless-cars-by-2020-2016-7/#tesla-is-aiming-to-have-its-driverless-technology-ready-by-2018-1; pristupljeno: 15.08.2017.

[12] www.vtpi.org/avip.pdf; pristupljeno: 15.08.2017.

Popis slika

Slika 1. Snimanje okoline u stvarnom vremenu LIDAR senzorom, [1] 4
Slika 2. Konstelacija GPS satelita oko Zemlje, [2] 5
Slika 3. Kontrolne stanice za praćenje GPS satelita, [3] 6
Slika 4. Razmještaj senzora u autonomnom vozilu, [4] 8
Slika 5. Primjer programa za prepoznavanje registracija korištenjem OCR-a, [5] 12
Slika 6. Prepoznavanje lica na slici korištenjem računalnog vida, [6] 12
Slika 7. Uklanjanje smetnji iz slike korištenjem računalnog vida, [7] 14
Slika 8. Države u SAD-u u kojima je implementiran zakon o autonomnim vozilima, [8] 18
Slika 9. Volkswagen Touareg nazvan Stanley, [9] 20
Slika 10. Uber-ovo autonomno taxi vozilo, [10] 22

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj završni rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog rada pod naslovom **NAVIGACIJA AUTONOMNIH VOZILA** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student:

U Zagrebu, 6.9.2017.

Krajnović Branta

(potpis)