Sigurnost i pouzdanost autonomnih vozila

Barać, Ante

Master's thesis / Diplomski rad

2021

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:119:447154

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU

FAKULTET PROMETNIH ZNANOSTI

Ante Barać

SIGURNOST I POUZDANOST AUTONOMNIH VOZILA

DIPLOMSKI RAD

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 28. travnja 2021.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Računalna sigurnost**

DIPLOMSKI ZADATAK br. 6262

Pristupnik: **Ante Barać (0135238832)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Inteligentni transportni sustavi

Zadatak: **Sigurnost i pouzdanost autonomnih vozila**

Opis zadatka:

Sigurnost i pouzdanost jedna je od značajnijih tema kada su u pitanju autonomna vozila. Napredak tehnologije rezultirao je sve većim brojem vozila koja imaju mogućnost autonomne vožnje. Pojavom novih autonomnih funkcionalnosti, istodobno su se otvorili i novi aspekti sigurnosti i pouzdanosti koji do sada nisu postojali. U diplomskom radu je potrebno opisati problemsko područje manualnog upravljanja vozilima, pregled razvoja autonomnih vozila te principe rada autonomnih vozila. Također, u diplomskom je radu potrebno provesti analizu sigurnosti i pouzdanosti autonomnih prema razinama autonomnosti te opisati trendove razvoja autonomnih vozila.

Mentor:

doc. dr. sc. Pero Škorput

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu

Fakultet prometnih znanosti

DIPLOMSKI RAD

SIGURNOST I POUZDANOST AUTONOMNIH VOZILA

SAFETY AND RELIABILITY OF AUTONOMOUS VEHICLES

Mentor: doc.dr. sc. Pero Škorput

Student: Ante Barać, JMBAG: 0135238832

Zagreb, rujan 2021.

SAŽETAK

Naslov: Sigurnost i pouzdanost autonomnih vozila

U zadnjih nekoliko desetljeća zamjetan je porast broja stanovnika koji žive u urbanim sredinama u odnosu na ruralne sredine. Ukoliko se navedenoj činjenici pridoda i povećanje stupnja motorizacije, dolazimo do održivog problema mobilnosti čovjeka u većim gradovima. Čovjek kao pojedinac ima u genetskom kodu da u svojim odlukama čini greške odnosno odstupa od savršenosti. Potreba za razvojem autonomnih vozila upravo dolazi iz činjenice o velikom broju stradalih osoba i nesreća u prometu. Razvoj do potpuno autonomnog vozila je jedan od najvećih pothvata i projekata današnjice trenutno vodećih auto industrija u svijetu. Sigurnost u prometnom sustavu je na prvom mjestu prioriteta prilikom izrade prometne mreže, prijevoznih sredstva i mobilnosti čovjeka u svakodnevnom životu. Autonomna vozila od kojih se očekuje da će u potpunosti zamijeniti čovjekovu ulogu u vozilu još su daleko od potpuno funkcionalnog i automatiziranog samostalno odlučujućeg prijevoznog sredstva koje se razvija postepeno kroz šest razina autonomije kako bi se ostvario konačni cilj, a to je potpuno autonomno funkcionalno komercijalno vozilo. Provedbom značajnog broja istraživanja velik broj ljudi još uvijek se ne bi odlučilo na prijevoz od točke A do točke B u potpuno autonomnom vozilu, a kao glavni faktor je navedena sigurnost i pouzdanost. U ovom diplomskom radu izvršit će se istraživanje na tu temu, svi aspekti koji mogu pripomoći u povećanju sigurnosti prilikom prijevoza autonomnim vozilom i ulijevanja pouzdanosti pri donošenju odluka.

Ključne riječi: Autonomna vozila, pouzdanost, sigurnost, predviđanja

SUMMARY

Title: Safety and reliability of autonomous vehicles

In the last few decades, there has been a noticeable increase in the number of inhabitants living in urban areas compared to rural areas. If this fact is added and the degree of motorization is increased, we come to a sustainable problem of human mobility in larger cities. Man as an individual has in the genetic code that he makes mistakes in his decisions or deviates from perfection. The need for the development of autonomous vehicles comes precisely from the facts about the large number of fatalities and traffic accidents. Development to a fully autonomous vehicle is one of the largest ventures and projects of today's leading automotive industries in the world. Safety in the transport system is a priority in the creation of transport networks, means of transport and human mobility in everyday life. Autonomous vehicles that are expected to fully replace the human role in driving are still far from a fully functional and automated self-determining vehicle that develops gradually through six levels of autonomy to achieve the ultimate goal, which is a fully autonomous functional commercial vehicle. Proven significant number of studies A large number of people still do not decide to transport from point A to point B in fully autonomous transport, and safety and reliability are mentioned as the main factor. In the diploma thesis will be conducted research on this topic, all aspects that can help increase safety during transport by autonomous vehicle and instill reliability in decision making.

Keywords: Autonomous vehicles, reliability, security, predictions

SADRŽAJ

1. Uvod 1

2. Problematika manualnog upravljanja vozilom u prometu 4

2.1. Ljudski faktor u prometnom sustavu 4

2.2. Podaci o nesrećama i gubicima uzrokovanih ljudskom pogreškom 7

3. Povijesni pregled razvoja autonomnih vozila 14

3.1. Prvi pokušaji autonomne vožnje 14

3.2. Tvrtke nositelji razvoja u području autonomne vožnje 19

4. Princip rada autonomne vožnje 23

4.1. Razine autonomije vozila 24

4.2. Senzorski sustav autonomnih vozila 27

4.3. Kooperativna komunikacija između vozila i infrastrukture 34

4.4. Komunikacija između vozila i vozila (V2V) 38

4.5. Primjena umjetne inteligencije i neuronskih mreža 41

5. Razine autonomije i sigurnosni zahtjevi 46

5.1. Kibernetička sigurnost i zaštita vozila 47

5.2. Rast sigurnosti proporcionalno rastu razini autonomije 52

6. Pregled istraživanja i razvoja autonomnih vozila 57

6.1. Prednosti autonomnih vozila 58

6.2. Tehničko tehnološki izazovi u području autonomne vožnje 61

6.3. Zahtjevi potpuno autonomne vožnje 63

7. Zaključak 66

Literatura 68

Popis slika 70

Popis tablica 71

1. Uvod

U ovom diplomskom radu prikazan je koncept autonomnih vozila kroz šest razina autonomnosti. Radi se usporedba između vozila kojim upravlja čovjek i autonomnog vozila koji samostalno donosi odluke. Čovjek u svojim odlukama donosi greške odnosno odstupa od savršenosti, te uz današnju tehnologiju postoji velika potreba za ispravkom toga i poboljšanjem trenutnog stanja situacije u prometu. Razvoj do potpuno autonomnog vozila je dug i skup proces u koji je uključeno veliki broj tvrtki i industrijskih grana. Gotovo svaka vodeća autoindustrija ima svoj razvojni centar autonomnih vozila. Autonomni koncept je prije svega predodređen za rutinske zadaće, što sigurno vožnja osobnog vozila u najvećem broju slučajeva nije.

Još od kraja devedesetih godina postala je zanimljiva ideja o autonomnim odnosno tada je češće korišten naziv bio samovozeći automobili. Sjetite se samo filmova u kojima su se pojavljivala autonomna vozila. Izgledalo je kao daleka budućnost i teško bi tada bilo zamisliti da je već 2020. godine jedna od vodećih autokompanija izradila potpuno autonomno vozilo koje još uvijek nije pušteno u komercijalnu uporabu iz zakonskih, sigurnosnih i tehničkih razloga. Postepeno se sve veći broj kompanija kako automobilskih tako i tehnoloških poput Google-a, Uber-a itd. uključilo u razvoj i istraživanje autonomnih vozila. Danas je to postala jedna zanimljiva utrka između jednih od najbogatijih kompanija svijeta.

Da bi autonomno vozilo na današnjoj cestovnoj infrastrukturi moglo stići od polazišta do odredišta, kompleksan je proces koji zahtjeva poboljšanja i usavršavanje da bi takav koncept zaživio. Postoji šest razina autonomije kroz koje se može jasno opisati način i princip rada te količina potrebe za ljudskom intervencijom i nadgledanjem prilikom vožnje.

Sigurnost u prometnom sustavu je na prvom mjestu prioriteta prilikom izrade prometne mreže, prijevoznih sredstva i mobilnosti čovjeka u svakodnevnom životu. Autonomna vozila od kojih se očekuje da će u potpunosti zamijeniti čovjekovu ulogu u vozilu još su daleko od potpuno funkcionalnog i automatiziranog samostalno odlučujućeg prijevoznog sredstva iako su predviđanja optimistična od pojedinih proizvođača i kompanija. Provedbom značajnog broja istraživanja velik broj ljudi još uvijek se ne bi odlučilo na prijevoz od točke A do točke B u potpuno autonomnom vozilu, a kao glavni faktor je

navedena sigurnost i pouzdanost. Radi se istraživanje na tu temu, svi aspekti koji mogu pripomoći u povećanju sigurnosti prilikom prijevoza autonomnim vozilom i ulijevanja pouzdanosti pri donošenju odluka.

Budućnost, možda i ne tako skora zasigurno nam donosi uporabu i primjenu autonomnih vozila. Veliko je pitanje koliko će potrajati razvoj i skok iz pojedinih razina autonomije dok se ne dostigne zadnja razina odnosno potpuno autonomno i samostalno vozilo. Postoje razna predviđanja ali kroz povijest znamo da predviđanja nisu uvijek toliko točna pogotovo kod tematike kao što je autonomno vozilo koje uključuje mnoštvo elemenata, različitih grana industrije, zakonskih regulativa i raznih tehnologija.

Diplomski rad se sastoji od sljedećih poglavlja:

1. Uvod

2. Problematika manualnog upravljanja vozilom u prometu

3. Povijesni pregled razvoja autonomnih vozila

4. Princip rada autonomne vožnje

5. Razine autonomije i sigurnosni zahtjevi

6. Pregled istraživanja i razvoja autonomnih vozila

7. Zaključak

U prvom poglavlju završnog rada je *Uvod* u kojem se opisuje predmet rada, problematika, te cilj i svrha razvoja sigurnosti i pouzdanosti autonomnih vozila.

Drugo poglavlje *Problematika manualnog upravljanja vozilom u prometu* iznosi problematiku vozila kojim upravlja čovjek i krucijalnu važnost donošenja brzih odluka. Iznesene su činjenice i podatci o broju stradalih i unesrećenih osoba uzrokovanih ljudskom pogreškom.

U trećem poglavlju rada pod nazivom *Povijesni pregled razvoja autonomnih vozila* prikazani su početci u razvoju autonomne vožnje i koncepti vozila. Predstavljena je dinamika

kojom se razvija stupanj autonomije u vozilima te važnost pojedinih perioda koji vode do ove današnje razine autonomnih vozila.

Kroz četvrto poglavlje *Princip rada autonomne vožnje* opisana je krucijalna važnost raznih oblika senzora, kamera, detektora u samom načinu rada. Prikazano je 6 razina autonomne vožnje, u rasponu od razine 0 (potpuno ručno) do razine 5 (potpuno autonomno). Predstavljeni su načini komuniciranja u međuodnosu vozila i infrastrukture te primjena umjetne inteligencije i neuronskih mreža.

U petom poglavlju *Razine autonomije i sigurnosni zahtjevi* predstavljeni su oblici zaštite protiv kibernetskih napada na vozilo i računalnog sustava vozila. Opisani su sigurnosni zahtjevi kroz 6 razina autonomne vožnje. Napravljeno je istraživanje na široj populaciji da bi se dobio uvid koliko ljudi vjeruju i imaju pouzdanja u ovakav oblik prijevoza trenutno.

Šesto poglavlje *Pregled istraživanja i razvoja autonomnih vozila* jasno definira prednosti koje autonomna vožnja donosi, brojni izazovi s kojima se susreće te pogled u budućnost kako bi mogli predvidjeti koliko smo daleko od uporabe potpuno autonomnog vozila na tržištu.

U završnom poglavlju rada je *Zaključak* koji je donesen na temelju proučavanja i vlastitih istraživanja na problematici velikog broja motornih vozila koji su upravljani čovjekom. Povučena je usporedba između današnjeg oblika prijevoza i putem potpuno autonomnog vozila. Jasno su ustanovljene prednosti koje nam takav način transporta donosi i dobitci za ljude i čovječanstvo.

2. Problematika manualnog upravljanja vozilom u prometu

Čovjek. Nesavršeno biće koje je sklono pogreškama odnosno odstupanju od nečega idealnog. Čovjek naravno teži idealu, ali to je jednostavno nemoguće te od tuda polazi izraz to nas čini čovjekom. Čovjekova reakcija ovisno o pojedincu odstupa od idealne odnosno mora proći određeno vrijeme kako bi mozak registrirao informaciju koju oči vide pred sobom, zvuk koji uši registriraju, te tijelo da prenese tu informaciju na vozilo kojim čovjek upravlja.

Prometni sustav kao što znamo nije idealan, međutim, u bilo kojem planiranju grada i prometnica teži se tome. Isto tako, čovjek teži istoj stvari no kako znamo da to nije slučaj dešavaju se pogreške što dovodi do prometnih nesreća, prometnih zagušenja, zastoja, povećane potrošnje energije, goriva, resursa itd. Način na koji pojedina osoba prima određenu informaciju nije isti kod svakoga što dovodi do primjerice sporije reakcije i uočavanja objekata, a tu se dešavaju pogrešne procjene i greške koje dovode do nesreća.

2.1. Ljudski faktor u prometnom sustavu

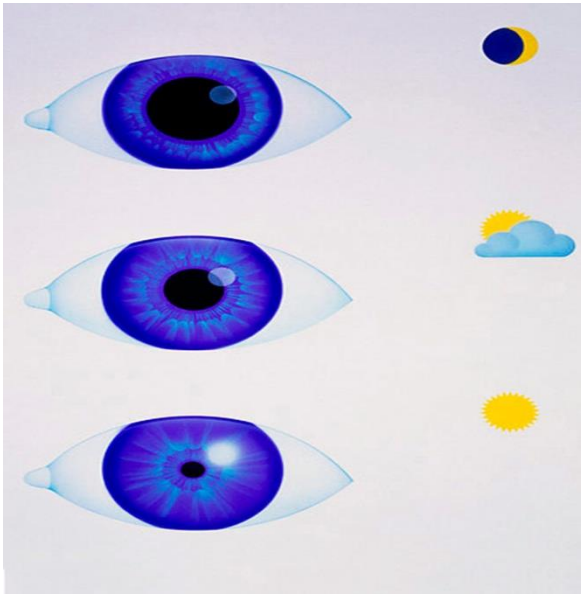
S obzirom na to da svaka osoba upravlja svojim vozilom, možemo gledati svako vozilo kao pokretni objekt koji prima i daje informaciju u prometni sustav, i svako to vozilo reagira različito na pojedine situacije odnosno na sličan ali svojstven način. Ako pridodamo toj činjenici još i prometnu infrastrukturu koja isto tako u većini slučajeva nije u idealnom stanju, primjerice: oštećen kolnik, slaba vidljivost prometnog znaka, loša optimizacija semaforiziranog raskrižja i slično, možemo reći da puno faktora otežava i utječe na sami ishod, a to je težnja idealnom prometnom sustavu kao cjelini.

Gledajući ljudsko tijelo s biološke strane čovjek koristi "glavno računalo" koje donosi sve odluke i prima informacije, a to je mozak. Također, sastoji se i od raznih senzora odnosno osjetila, a to su oči (vid), uši (sluh), taktilni osjet odnosno osjet dodira te zadnja dva osjetila i najmanje bitna za vožnju, a to je nos (njuh) i jezik (okus).

Mozak je najviši dio središnjega živčanog sustava i središte usklađivanja živčane aktivnosti. Mozak prima informacije iz osjetnih organa, obrađuje ih i šalje upute izvršnim

organima (npr. mišićima, žlijezdama). Mozak je i sjedište inteligencije i pamćenja. Kod čovjeka živčani sustav čini mreža živčanih vlakana, međusobno povezanih dugim izdancima, a funkcija im je primanje podražaja iz okoline i predavanje impulsa izvršnim organima. [18].

Oči odnosno vid je najbitnije osjetilo/senzor koji čovjek koristi prilikom vožnje vozila i pomoću tog osjetila prima većinu potrebnih informacija. Pomoću vida primjećujemo, razaznajemo svjetlo, boje, oblike i udaljenosti. Kada svjetlost prolazi kroz leću i zjenicu, dolazi do mrežnice koja reflektira obrnutu sliku onog čega gledamo. Mozak iz oba oka dobiva obrnutu sliku nego što ona zapravo jest, pa je on usklađuje u sliku kakva je u stvarnosti. Slikom 1. prikazana je zjenica oka te prilikom ulaska određene razine svjetlosti se skuplja i širi. Ako je manja razina svjetlosti šarenica se širi, ako je visoka razina svjetlosti sjenica se skuplja.



Slika 1. Širenje i skupljanje zjenica pri izlaganju različitoj razini svjetlosti [15]

Prilikom vožnje, često se desi da tijekom određene rute od točke A do točke B oko bude izloženo različitim jačinama svjetlosti. Primjerice: prolazak u tunel, te izlazak iz tunela usred sunčanog dana. Nastaje taj efekt da oku treba određeno vrijeme da se prilagodi novoj razini svjetlosti te taj kratki period vid je otežan pri čemu mogu nastati krive procjene i reakcije prilikom vožnje vozila. Drugi primjer je tijekom noćne vožnje i u kišnim uvjetima. Ulična rasvjeta kreira odsjaj odnosno mokar kolnik i asfalt reflektira svjetlost nazad u čovjekovo oko te znatno otežava vid. Kada tome još pridodamo vozila koja prolaze u

suprotnom smjeru odnosno traku kolnika desi se to da čovjek teško može primijetiti pojedine objekte sve dok ne dođe na udaljenost od kojih 10-ak metara od objekta. Štoviše, ne mogu se svi pohvaliti savršenim vidom. Sve je veći broj ljudi koji koristi pomagala pomoću kojih korigira vid (primjerice: dioptrijske naočale ili kontaktne leće).

Ljudske faktore u prometnom sustavu koji bi mogli izdvojiti bi bili nepredvidivost i individualno donošenje odluka, reakcija na okolinu i sama sposobnost vožnje i upravljanje vozilom te brzina registriranja informacija. S obzirom na to da svaki čovjek ima koristeći programerski žargon latenciju, odnosno vrijeme koje protekne od registriranja informacije do reakcije i djelovanja, dešava se to da se stvaraju repovi čekanja u prometu, gužve, veća potrošnja goriva, nesreće itd.

Uzmimo za primjer semaforizirano raskrižje. Za jedan smjer upali se zelena faza odnosno faza prolaska tog prometnog toka te se vozila počnu kretati i prolaziti kroz raskrižje. Prosječna reakcija čovjeka je oko 0.6 sekundi od registriranja informacije da treba krenuti do samog djelovanja odnosno akcije. Ako je 10 vozila u prometnom toku to znači da će svako vozilo nakon prvog krenuti podosta kasnije nego li se faza prolaska s obzirom na to da se akumuliraju reakcije vozača tih 10 vozila. Samim time protok vozila je manji. To se zove stacionarni frontalni šok val. Može se primijetiti na ovom primjeru koji je jedan od mnogih da dolazi do repova čekanja, gužvi i povećane potrošnje goriva s obzirom na povećano vrijeme čekanja.

Povećanje prosječne brzine izravno je povezano kako s vjerojatnosti sudara, tako i s težinom posljedica sudara. Osoba koja upravlja vozilom i prekoračuje ograničenje brzine povećava vjerojatnost nastanka sudara odnosno nesreće. Što je veće prekoračenje samim time je otežana reakcija i normalno upravljanje vozilom te se mogućnost nesreće drastično povećava.

Jedan od faktora koji također znatno utječe je vožnja u alkoholiziranom stanju ili pod određenim opijatima i psihodeličnim drogama. Činjenica je da osoba koja je u takvom stanju ima usporeno i otežano donošenje odluka, te je reakcija znatno usporena. Percepcija brzine i udaljenosti je također dezorijentirana.

2.2. Podaci o nesrećama i gubicima uzrokovanih ljudskom pogreškom

Sigurnost je glavni prioritet odnosno primarni fokus u razvoju prometnog sustava. Kao što je već spomenuto zbog same nepredvidivosti i spore reakcije čovjeka te brojnih drugih sekundarnih razloga dolazi do nesreća u prometu. Preko 90% nesreća danas je uzrokovano pogreškom vozača. Procijenjeno je da jedan ljudski život u državi u kojoj ta osoba radi i doprinosi zajednici ima vrijednost oko 2.000.000 eura. Tako da gubitak ljudskog života ne samo što je tragičan već i utječe s ekonomske i financijske strane tu državu/grad u kojoj ta osoba živi.

Tabelom 1. prikazana je lista odnosno poredak 10 glavnih uzroka izgubljenih zdravih godina života zbog invaliditeta. Prometne nesreće nalaze se na 3. mjestu iz podataka 2020. godine dok su 1998. godine prometne nesreće bile na 9. mjestu. Time se da zaključiti da je znatno veći broj prometnih nesreća nego li prije. Uzrok tome je i sve veći broj vozila po kućanstvu.

Tabela 1. Poredak 10 glavnih uzroka izgubljenih zdravih godina zbog invaliditeta [3]

1998 Disease or Injury	2020 Disease or Injury
1. Lower respiratory infections	1. Ischaemic heart disease
2. HIV/AIDS	2. Unipolar major depression
3. Perinatal conditions	3. ***Road traffic injuries***
4. Diarrhoeal diseases	4. Cerebrovascular disease
5. Unipolar major depression	5. Chronic obstructive pulmonary diseases
6. Ischaemic heart disease	6. Lower respiratory infections
7. Cerebrosvascular disease	7. Tuberculosis
8. Malaria	8. War
9. ***Road traffic injuries***	9. Diarrhoeal diseases
10. Chronic obstructive pulmonary diseases	10. HIV/AIDS

***DALYs: Disability-Adjusted Life Years**

Ključne i bitne činjenice su:

- godišnje u prometnim nesrećama umre približno 1,3 milijuna ljudi,
- generalna skupština Ujedinjenih naroda postavila je ambiciozan cilj da do 2030. prepolovi globalni broj smrtnih slučajeva i ozljeda uslijed prometnih nesreća,
- nesreće u cestovnom prometu većinu zemalja koštaju 3% njihovog BDP-a (bruto domaćeg proizvoda),
- više od polovice svih smrtnih slučajeva u cestovnom prometu događa se među ugroženim sudionicima u prometu: pješacima, biciklistima i motociklistima,
- 93% smrtnih slučajeva na cestama u svijetu događa se u zemljama s niskim i srednjim prihodima, iako te zemlje imaju približno 60% svjetskih vozila,
- ozljede na cestama vodeći su uzrok smrti djece i mladih u dobi od 5 do 29 godina [16].

Prometne nesreće su trenutno jedan od vodećih uzročnika smrtnosti i ozljeda (invaliditeta) ljudi. Svake godine oko 1,3 milijuna života je oduzeto prometnim nesrećama. Između 20 i 50 milijuna ljudi pretrpi neki oblik ozljede, a mnogi su doživjeli teže ozljede ili invaliditet. Ozljede u cestovnom prometu uzrokuju značajne ekonomske gubitke pojedincima, njihovim obiteljima i nacijama u cjelovitosti. Ovi gubici proizlaze direktno iz troškova liječenja, kao i zbog gubitka produktivnosti za one koji su preminuli ili onesposobljeni zbog njihovih ozljeda, te za članove obitelji koji trebaju uzeti slobodno vrijeme s posla ili u školi kako bi se brinuli o ozlijeđenima.

Više od 90% smrtnih slučajeva u cestovnom prometu događa se u zemljama s niskim i srednjim prihodima. Zanimljivo je to da su Sjedinjene Američke Države prve na listi s najvećim brojem nesreća u jednoj godini (2,21 milijun nesreća, smrtnost oko 38 tisuća ljudi i 3,14 milijuna ozlijeđenih). Stope smrtnosti od prometnih ozljeda najveće su u afričkoj regiji. Čak i u zemljama s visokim prihodima, ljudi s nižim društveno-ekonomskim slojem vjerojatnije će biti uključeni u prometne nesreće.

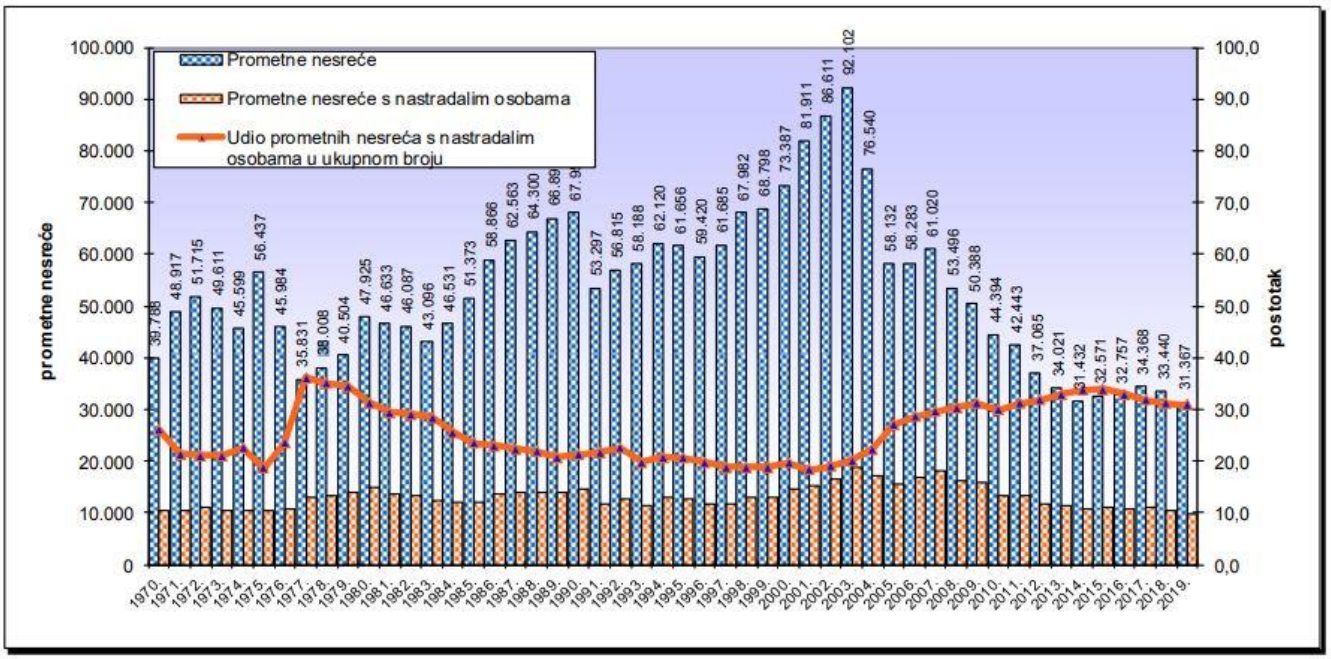
Ozljede na cestama vodeći su uzrok smrti djece i mladih u dobi od 5 do 29 godina. Razlog tome je neiskustvo vozača i nepredvidivost djece i mladih (izlijetanje pred auto, prebrza vožnja, nesigurna vožnja itd.). Od malih nogu veća je vjerojatnost da će muškarci sudjelovati u prometnim nesrećama nego žene. Oko 73% svih smrtnih slučajeva u cestovnom

prometu događa se među mladim muškarcima mlađim od 25 godina koji imaju gotovo 3 puta veću vjerojatnost da će poginuti u sudaru u prometu kao mlade žene.

U Republici Hrvatskoj je materijalna šteta uzrokovana prometnim nesrećama, prema procjenama stručnjaka za osiguranja i ekonomskih analitičara, prelazi osam milijardi kuna, odnosno 2,3 posto hrvatskog BDP-a, dok su posredni gubici višestruki. Na hrvatskim se cestama posljednjih deset godina prosječno dogodilo 35 386 prometnih nesreća. U 31,9 posto nesreća stradavale su osobe. Godišnje su u prometu prosječno stradale 15 652 osobe [17]. Od tog broja 79,4 posto prošlo je s lakšim tjelesnim ozljedama. Teške tjelesne ozljede zadobilo je 18,4 posto osoba, dok je 2,2 posto osoba godišnje pogibalo, što je prosječno godišnje 351 osoba [17].

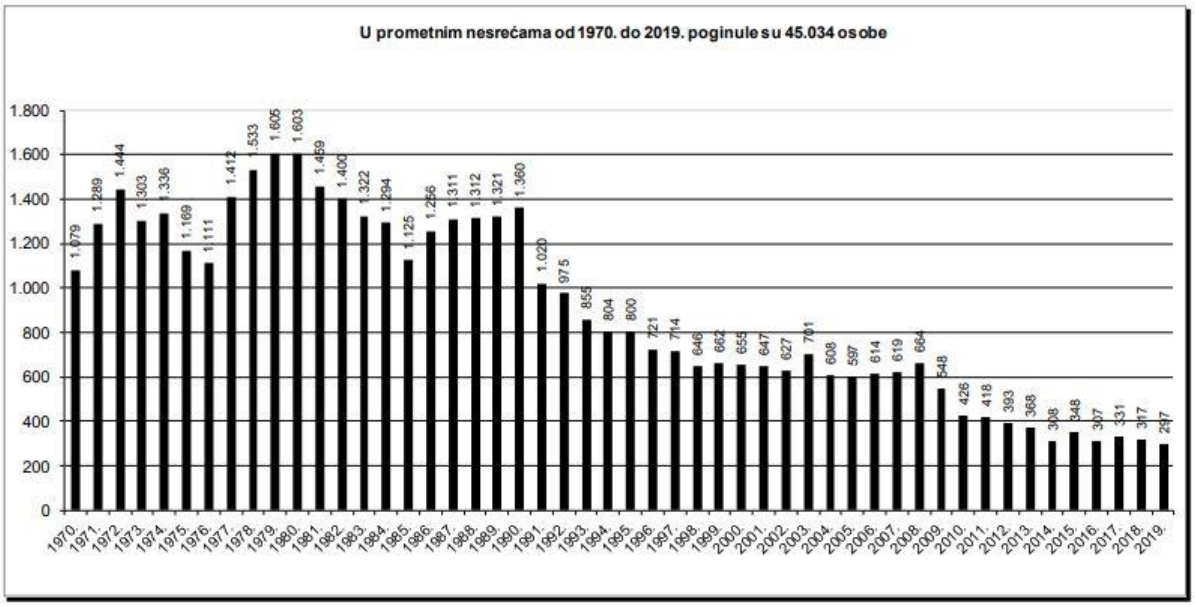
Tabela 2. prikazuje prometne nesreće i posljedice od 1970. do 2019. godine. Možemo vidjeti da je trenutni broj prometnih nesreća podosta manji naspram početka 20. stoljeća ali udio prometnih nesreća s nastradalim osobama prema ukupnom broju nesreća je znatno veći što je zabrinjavajuć faktor.

Tabela 2. Prometne nesreće i posljedice kroz godine u RH od 1970. do 2019. godine [17]



Broj poginulih osoba je znatno manji u usporedbi sa zadnjih 30-ak godina što se može vidjeti na Tabeli 3. To je ohrabrujuć podatak jer u konačnici najlošiji i najnepoželjniji ishod prometne nesreće je smrt. Može se vidjeti da je 2019. godine broj poginulih 297 što je čak 45% manje nego li 2000. godine.

Tabela 3. Poginule osobe u prometu u RH od 1970. do 2019. godine [17]



Na hrvatskim se cestama od 2010. do 2019. godine dogodilo 353 858 prometnih nesreća. U tim je nesrećama nastradalo 156 519 osoba: poginulo je 3513 osoba, teško je ozlijeđeno 28 714 osoba, a 124 292 osobe su lakše ozlijeđene. U istom razdoblju broj prometnih nesreća s nastradalim osobama smanjio se s 13 272 u 2010. godini na 9695 (27,0 posto) u 2019. godini, lakše ozlijeđenih osoba s 15 151 na 10 393 (31,4 posto), teško ozlijeđenih osoba s 3182 na 2492 (21,7 posto) i broj poginulih u prometnim nesrećama smanjio se s 426 na 297 poginulih (30,3 posto) [17] .

Povećanje prosječne brzine izravno je povezano kako s vjerojatnosti sudara, tako i s težinom posljedica sudara. Na primjer, svako povećanje srednje brzine od 1% proizvodi 4% povećanje rizika od smrtonosnog sudara i 3% povećanje rizika ozbiljnog sudara.

Opasnost od smrti pješaka pogođenih frontama automobila brzo raste (4,5 puta s 50 km/h na 65 km/h). Kod utjecaja od auta do auta rizik od smrtnog ishoda za putnike iznosi 85% pri 65 km/h. Vožnja pod utjecajem alkohola i bilo koje psihoaktivne tvari ili droge povećava rizik od sudara koji za posljedicu ima smrt ili teške ozljede. U slučaju vožnje u alkoholiziranom stanju rizik od prometne nesreće počinje na niskim razinama koncentracije

alkohola u krvi (BAC) i značajno se povećava kada je BAC vozača ≥ 0,04 g/dl. U slučaju upravljanja drogama, rizik od sudara na cestovnom prometu povećava se u različitim stupnjevima ovisno o korištenoj psihoaktivnoj drogi. Na primjer, rizik od smrtonosnog sudara među onima koji su koristili amfetamine je oko 5 puta veći od rizika od nekoga tko nije.

Pravilna uporaba kacige može dovesti do smanjenja rizika od smrtnih ozljeda za 42%, a do ozljede glave do 69%.Vezanje pojasa smanjuje rizik od smrti među vozačima i putnicima na prednjim sjedalima za 45-50%, a rizik od smrti i teških ozljeda među putnicima na stražnjim sjedalima za 25%. Korištenje sigurnosnih sustava za dijete može dovesti do smanjenja smrtnosti za 60%. Postoje mnoge vrste smetnji koje mogu dovesti do otežane vožnje [16].

Smetnje uzrokovane mobitelima sve su veća briga za sigurnost na cestama. Vozači koji koriste mobilne telefone imaju otprilike 4 puta veću vjerojatnost da će biti uključeni u sudar od vozača koji ne koriste mobilni telefon. Korištenje telefona tijekom vožnje usporava vrijeme reakcije (osobito vrijeme kočenja, ali i reakciju na prometne signale), te otežava zadržavanje u ispravnoj traci i pridržavanje ispravnih sljedećih udaljenosti. Telefoni bez upotrebe ruku nisu mnogo sigurniji od ručnih telefonskih aparata, a slanje poruka značajno povećava rizik od sudara.

Na Tabeli 4. može se vidjeti kojim oblicima pogrešaka se dešavaju nesreće u prometu. Najveći postotak i broj pogreški koje uzrokuju nesreće su vožnja i brzina neprimjerena uvjetima na cesti, u 2019. je to bilo čak 5837 nesreća odnosno 18,6% svih nesreća. Iznenađujuće je da nepoštivanje prednosti prolaza je druga po redu s čak 3885 nesreća (12,4% od ukupnog broja nesreća).

Tabela 4. Prometne nesreće nastale zbog pogreške vozača, pješaka i ostalih uzroka u 2019. godini [17]

Pogreške		Prometne nesreće					
		ukupno	%	s poginulima	%	s ozlijeđenima	%
Pogreške vozača	Nepropisna brzina	875	2,8	18	6,5	360	3,8
	Brzina neprimjerena uvjetima	5.837	18,6	111	39,8	2.575	27,3
	Vožnja na nedovoljnoj udaljenosti	2.225	7,1	9	3,2	793	8,4
	Zakašnjelo uočavanje opasnosti	213	0,7	4	1,4	97	1,0
	Nepropisno pretjecanje	642	2,0	6	2,2	256	2,7
	Nepropisno obilaženje	554	1,8			71	0,8
	Nepropisno mimoilaženje	602	1,9	2	0,7	62	0,7
	Nepropisno uključenje u promet	1.572	5,0	6	2,2	503	5,3
	Nepropisno skretanje	1.536	4,9	5	1,8	395	4,2
	Nepropisno okretanje	207	0,7			35	0,4
	Nepropisna vožnja unazad	2.853	9,1	1	0,4	180	1,9
	Nepropisno prestrojavanje	676	2,2			131	1,4
	Nepoštivanje prednosti prolaza	3.885	12,4	19	6,8	1.521	16,2
	Nepropisno parkiranje	172	0,5			4	0,0
	Naglo usporavanje-kočenje	41	0,1			22	0,2
	Nepoštivanje svjetlosnog znaka	516	1,6	4	1,4	180	1,9
	Neosiguran teret na vozilu	76	0,2			7	0,1
	Nemarno postupanje s vozilom	436	1,4	1	0,4	58	0,6
	Ostale pogreške vozača	4.161	13,3	45	16,1	982	10,4
	Nepropisno kretanje vozila na kolniku	2.890	9,2	36	12,9	865	9,2
	UKUPNO	**29.969**	**95,5**	**267**	**95,7**	**9.097**	**96,6**
Pogreške pješaka	Nepoštivanje svjetlosnog znaka	80	0,3	1	0,4	50	0,5
	Nekorište.obilježenog pješ.prijel.	77	0,2	2	0,7	72	0,8
	Nekorištenje pothodnika	3	0,0			2	0,0
	Ostale pogreške pješaka	146	0,5	7	2,5	122	1,3
	UKUPNO	**306**	**1,0**	**10**	**3,6**	**246**	**2,6**
Ostali uzroci	Neočekivana pojava opasnosti	1.031	3,3	2	0,7	61	0,6
	Iznenadni kvar vozila	61	0,2			12	0,1
	UKUPNO	**1.092**	**3,5**	**2**	**0,7**	**73**	**0,8**
SVEUKUPNO		**31.367**	**100,0**	**279**	**100,0**	**9.416**	**100,0**

Projektiranje cesta može imati značajan utjecaj na njihovu sigurnost. U idealnom slučaju, ceste bi trebale biti projektirane imajući na umu sigurnost svih sudionika u prometu. To bi značilo pobrinuti se da postoje odgovarajući sadržaji za pješake, bicikliste i motocikliste. Mjere poput pješačkih staza, biciklističkih staza, sigurnih prijelaza i druge mjere smirivanja prometa mogu biti ključne za smanjenje rizika od ozljeda ovih sudionika u prometu.

Sigurna vozila igraju ključnu ulogu u sprječavanju sudara i smanjenju vjerojatnosti ozbiljnih ozljeda. Postoje brojni propisi UN -a o sigurnosti vozila koji bi, ako se primijene na proizvođačke i proizvodne standarde zemalja, potencijalno spasili mnoge živote. To uključuje zahtijevanje od proizvođača vozila da poštuju propise o prednjim i bočnim udarima, da uključuju elektroničku kontrolu stabilnosti (kako bi se spriječilo prekomjerno upravljanje) i da osiguraju da su zračni jastuci i pojasevi pričvršćeni u svim vozilima [16]. Bez ovih osnovnih standarda, rizik od prometnih ozljeda,kako za one u vozilu, tako i za one izvan njega, znatno se povećava.

Kašnjenja u otkrivanju i pružanju skrbi za one koji su uključeni u prometnu nesreću povećavaju težinu ozljeda. Njega ozljeda nakon sudara iznimno je osjetljiva na vrijeme: kašnjenja u minutama mogu napraviti razliku između života i smrti. Poboljšanje skrbi nakon sudara zahtijeva osiguravanje pristupa pravovremenoj skrbi i poboljšanje kvalitete prehospitalne i bolničke njege, primjerice putem specijaliziranih programa osposobljavanja.

Ako se ne poštuju prometni zakoni o vožnji u alkoholiziranom stanju, vezivanju pojaseva, ograničenjima brzine, kacigama i sustavima za držanje djece, oni ne mogu dovesti do očekivanog smanjenja smrtnih slučajeva i ozljeda u cestovnom prometu povezanih s posebnim ponašanjem. Stoga, ako se prometni zakoni ne provode ili se smatra da se ne provode, vjerojatno se neće poštivati i stoga će imati vrlo male šanse utjecati na ponašanje. Učinkovita provedba uključuje uspostavljanje, redovito ažuriranje i provedbu zakona na nacionalnoj, općinskoj i lokalnoj razini koji se bave gore navedenim čimbenicima rizika. Uključuje i definiciju odgovarajućih kazni.

3. Povijesni pregled razvoja autonomnih vozila

27. studenoga 2019. godine, službeni list Europske unije objavio je Uredbu 2019/2144 Parlamenta i Vijeća Europske unije vezano za zahtjeve za homologaciju tipova motornih vozila i njihove prikolice te za dijelove, sustave i zasebne tehničke jedinice koje su namijenjene za takva vozila. Tiče se njihove opće sigurnosti i zaštite osoba u vozilima i nezaštićenih sudionika u cestovnom prometu. U istoj toj uredbi definira se automatizirano vozilo i potpuno autonomno vozilo. Definicija je da automatizirano vozilo znači motorno vozilo konstruirano i izrađeno kako bi se kretalo autonomno tijekom određenog razdoblja bez stalnog nadzora vozača, ali u odnosu na koje se intervencija vozača ipak očekuje ili je potrebna [10]. Druga definicija je da potpuno automatizirano vozilo znači motorno vozilo koje je konstruirano i izrađeno kako bi se kretalo autonomno bez ikakva nadzora vozača.

Bez obzira na definicije iz Službenog lista Europske unije, koristi se i prihvaćen je termin autonomno vozilo. Autonomija odnosno autonomno znači samostalno ili neovisno. Pojmom autonomna kontrola podrazumijevaju se zadovoljavajuće performanse vozila u nesigurnim i nenadanim uvjetima i događajima koji se mogu pojaviti u okolini vozila [10]. Danas većina koncepata vozila (za koje se trenutno zna) ima osobu na mjestu vozača, te se koristi komunikacijskom vezom putem oblaka ili drugih vozila, i nesamostalno odabire odredište ili rutu za dostizanje tog odredišta tako da pojam automatiziran preciznije opisuje takve koncepte vozila.

Ideje o autonomnim vozilima počinju još 1930-tih, bez da su ljudi tada bili svjesni da takve ideje i koncepti će se danas nazivati autonomnim vozilima i biti od tolike važnosti, te jedno od glavnih fokusa danas u prometnom svijetu.

3.1. Prvi pokušaji autonomne vožnje

Rani prikaz automatiziranih automobila s vodičem bila je izložba Futurama Normana Bel Geddesa, sponzorirana od strane General Motors-a na Svjetskom sajmu 1939. godine, koja je prikazivala radioupravljane električne automobile koji se pokreću putem elektromagnetskih polja osiguranih sklopovima ugrađenim u kolnik.

Bel Geddes kasnije je izložio svoju viziju u svojoj knjizi Čarobne autoceste 1940. godine, promičući napredak u projektiranju i prijevozu autocesta, nagovještavajući međudržavni sustav autocesta i tvrdeći da ljude treba ukloniti iz procesa vožnje. Njegovo predviđanje je bilo da će ovaj napredak postani stvarnost 1960. godine [1, 2].

Godine 1953. , RCA Labs (Radio Corporation of America) uspješno je stvorio sustav s minijaturnim automobilom vođenim i kontroliranim žicama postavljenim po uzorku na podu laboratorija. Sustav je potaknuo maštu Lelanda M. Hancocka, prometnog inženjera u Odjelu za ceste u Nebraski, i njegovog direktora, L. N. Ressa, državnog inženjera. Donesena je odluka o eksperimentiranju sa sustavom u stvarnim instalacijama autocesta.

Godine 1957. , RCA Labs i država Nebraska uspješno su demonstrirali sustav pune veličine na 400 metara širokoj traci javne autoceste na križanju američke ceste 77 i autoceste Nebraska 2, tada neposredno izvan Lincolna, Nebraska. Niz eksperimentalnih krugova detektora zakopanih u kolnik bio je uparen s nizom svjetala uz rub ceste. Krugovi detektora mogli su slati impulse kako bi usmjerili automobil i odredili prisutnost i brzinu bilo kojeg metalnog vozila na njegovoj površini. Prethodna probna instalacija sustava u rujnu 1954. duž američke ceste 73 i američke ceste 75 u okrugu Cass, Nebraska, korištena je kao eksperimentalni brojač prometa . Razvijen je u suradnji s General Motors-om, koji je dva standardna modela automobila opremio opremom koja se sastoji od posebnih radio prijemnika i zvučnih i vizualnih upozoravajućih uređaja koji su mogli simulirati automatsko upravljanje, ubrzanje i kontrolu kočnica [20].

Dalje je demonstrirano 5. lipnja 1960. u sjedištu RCA Laba u Princetonu u New Jerseyju, gdje je novinarima bilo dopušteno voziti automobile. Komercijalizacija sustava trebala se dogoditi do 1975. Osim toga, tijekom 1950-ih i 1960-ih, General Motors je predstavio svoje Firebirds, seriju eksperimentalnih automobila za koje je opisano da imaju sustav elektroničkog navođenja koji ga može prevesti preko automatske autoceste dok se vozač opušta i uživa.

Godine 1960. Laboratorij komunikacijskih i upravljačkih sustava Sveučilišta Ohio State pokrenuo je projekt razvoja automobila bez vozača koji su aktivirani elektroničkim uređajima ugrađenim u kolnik. Voditelj projekta, dr. Robert L. Cosgriff, tvrdio je 1966. godine da bi sustav mogao biti spreman za ugradnju na javnu cestu za 15 godina što je za to vrijeme više nego optimistična izjava, čak i vizionarska [3].

Početkom 1960-ih, Zavod za javne ceste razmatrao je izgradnju eksperimentalne elektronički kontrolirane autoceste. Četiri države, a to su Ohio, Massachusetts, New York i Kalifornija natjecale su se za izgradnju. U kolovozu 1961. Popular Science je izvijestio o Aeromobileu 35B, vozilu na zračnom jastuku (ACV) koje je izumio William Bertelsen i zamišljeno je da revolucionira transportni sustav, s osobnim samovozećim lebdećim automobilima koji mogu ubrzati do 240 km/h.

Tijekom šezdesetih godina prošlog stoljeća, transportni i cestovni laboratorij Ujedinjenog Kraljevstva testirao je Citroen DS bez vozača koji je bio u interakciji s magnetskim kablovima koji su bili ugrađeni u cestu. Na Slici 2. može se vidjeti modificirani Citroen DS19 koji se nalazi u Muzeju znanosti u Londonu . Prošao je testnu stazu brzinom od 130 km/h bez odstupanja brzine ili smjera u bilo kojim vremenskim uvjetima, i na daleko učinkovitiji način nego ljudskom kontrolom. Istraživanja su se nastavila 1970-ih s uređajima za tempomat koji su se aktivirali signalima u kablovima ispod kolosijeka. Prema napravljenim analizama isplativosti, usvajanje sustava na britanskim autocestama otplatilo bi se do kraja stoljeća, povećalo cestovni kapacitet za najmanje 50% i spriječilo oko 40% nesreća [3]. Sredstva za te pokuse povučena su sredinom 1970-ih.



Slika 2. Modificirani Citroen DS19 iz 1960. godine [20]

Također, tijekom 1960-ih i 1970-ih, Bendix Corporation je razvila i testirala automobile bez vozača koji su se napajali i kontrolirali zakopanim kablovima, s komunikatorima na putu koji su prenosili računalne poruke. Stanford je demonstrirao svoje laboratorijsko kolica za umjetnu inteligenciju, mali robot na kotačima koji je jednom slučajno izašao na obližnju cestu. Prethodna istraživanja inteligentne automatizirane logike potrebne za autonomne automobile provedena su u Koordiniranom znanstvenom laboratoriju Sveučilišta Illinois početkom do sredine 1970-ih.

Osamdesetih godina prošlog stoljeća robotski kombi vođen vizijom Mercedes-Benz, koji su dizajnirali Ernst Dickmanns i njegov tim na Sveučilištu Bundeswehr u Münchenu, u Njemačkoj, postigao je brzinu od 63 km/h na ulicama bez prometa. Nakon toga, EUREKA je od 1987. do 1995. godine provela 749,000,000 € Prometheus projekt na autonomnim vozilima. Tako da tada su se počela već ulagati jako velika sredstva u razvoj automatiziranih vozila.

U istom desetljeću, projekt Autonomna vozila na kopneni pogon (ALV) koji je financirao DARPA u Sjedinjenim Državama koristio je nove tehnologije koje su razvile Sveučilište Maryland, Sveučilište Carnegie Mellon, Institut za istraživanje okoliša u Michiganu, Martin Marietta i SRI International. Projekt ALV postigao je prvu demonstraciju nakon ceste koja je koristila LIDAR, računalni vid i autonomnu robotsku kontrolu za usmjeravanje robotskog vozila brzinom do 31 km/h. Godine 1987. HRL Laboratories (Hughes Research Labs) demonstrirali su prvu terensku kartu i autonomnu navigaciju temeljenu na senzorima na ALV-u [20]. Vozilo je putovalo više od 610 m brzinom od 3,1 km/h po kompleksnom terenu sa strmim padinama, gudurama, velikim stijenama i raslinjem. Do 1989. godine Sveučilište Carnegie Mellon postao je vodeći u korištenju neuronskih mreža za upravljanje i na drugi način upravljanje autonomnim vozilima čineći osnovu suvremenih strategija upravljanja.

Kongres Sjedinjenih Država usvojio je 1991. godine prijedlog zakona o autorizaciji prijevoza, te da demonstrira automatizirani sustav vozila i autocesta do 1997. godine. Federalna uprava za autoceste preuzela je ovaj zadatak, prvo s nizom Analiza sustava prekursora, a zatim uspostavom Nacionalnog konzorcija za automatizirane sustave autocesta (NAHSC). Ovaj projekt s podjelom troškova vodili su FHWA i General Motors, a Caltrans, Delco, Parsons Brinkerhoff, Bechtel, UC-Berkeley, Sveučilište Carnegie Mellon i Lockheed Martin kao dodatni partneri. Opsežni rad i istraživanje sistemskog inženjeringa održali su

demonstracijom 1997. godine u San Diegu u Kaliforniji, u kojoj je oko 20 automatiziranih vozila, uključujući automobile, autobuse i kamione, demonstrirano tisućama promatrača, što je privuklo veliku medijsku pokrivenost [20]. Demonstracije su uključivale uvođenje vodova u blizinu namijenjenih za rad u odvojenom prometu, kao i vozila "slobodnih agenata" namijenjena za rad u mješovitom prometu. Drugi proizvođači automobila bili su pozvani da demonstriraju svoje sustave, pa su tako sudjelovale i Toyota i Honda. Dok je sljedeći cilj bio izraditi dizajn sustava koji bi pomogao komercijalizaciju, program je otkazan krajem 1990 -ih zbog pooštravanja proračuna za istraživanje. Ukupna sredstva za program kretala su se u rasponu od 90 milijuna američkih dolara.

Vrijedan spomena je i ParkShuttle koji je prikazan Slikom 3. , koji se smatra prvim vozilom na svijetu bez vozača. On je automatiziran prijevoznik ljudi koji koristi umjetne referentne točke (magnete) ugrađene u površinu ceste za provjeru svog položaja. Dva pilot projekta započela su u Nizozemskoj, na aerodromu Schiphol 1997. godine i poslovnom parku Rivium 1999. godine.



Slika 3. ParkShuttle u Nizozemskoj [20]

Oba pilot projekta su nosili članove opće javnosti i kao takvi polažu pravo na prva vozila bez vozača. Vozila su autonomna, nemaju upravljač ili pedale, niti imaju sigurnosnog vozača ili stjuarda u vozilu. Voze se u razredu, namjenskom trakom na kojoj se nalaze raskrižja s pješacima, biciklistima i automobilima.

3.2. Tvrtke nositelji razvoja u području autonomne vožnje

Gotovo sve tvrtke koje su u automobilskoj industriji trenutno se bave razvojem autonomnih vozila. Mnogi veliki proizvođači automobila, uključujući General Motors, Ford, Mercedes Benz, Volkswagen, Audi, Nissan, Toyota, BMW i Volvo, u procesu su testiranja automobilskih sustava bez vozača.

Tesla, Inc. je američka tvrtka za električna vozila i čistu energiju sa sjedištem u Kaliforniji u SAD-u. Tesla dizajnira i proizvodi električne automobile, akumulatorsku bateriju za skladištenje energije od kuće do mreže, solarne ploče i solarne crjepove te slične proizvode i usluge. U veljači 2004. godine, putem ulaganja od 6,5 milijuna USD, suosnivač X.com Elon Musk postao je najveći dioničar tvrtke i njezin predsjednik. On je bio izvršni direktor od 2008. Prema Musku, svrha Tesle je pomoći ubrzati prelazak na održivi transport i energiju, dobivenu električnim vozilima i solarnom energijom. Tesla je 2009. godine započela proizvodnju svog prvog modela automobila Roadster. Nakon toga uslijedila je Tesla Model S sedan 2012., Tesla Model X SUV 2015., Tesla Model 3 limuzina 2017. i Tesla Model Y crossover godine. 2020.



Slika 4. Teslin Model [3]

Slikom 4. prikazan je Tesla Model 3 i to je najprodavaniji priključni električni automobil svih vremena u svijetu, a u lipnju 2021. postao je prvi električni automobil koji je prodao 1 milijun jedinica na globalnoj razini. Kao što se može vidjeti sa slike domet modela 3 je 560 km s punim punjenjem što je zapravo jedini odbojni faktor kod kupnje takvog automobila s obzirom na to da današnji automobili s Diesel motorima mogu dosegnuti čak i do 1000 km s punim spremnikom goriva. Trenutno Tesla trenutno ima oko 70.000 zaposlenih ljudi.

Argo AI je autonomna tvrtka za tehnologiju vožnje sa sjedištem u Pittsburghu, Pennsylvania. Tvrtku su 2016. osnovali Bryan Salesky i Peter Rander, veterani programa Google i Uber za automatiziranu vožnju. Argo AI je neovisna tvrtka koja izrađuje softver, hardver, karte i infrastrukturu za podršku u oblaku za pogon samovozećih vozila. Argo trenutno broji više od 1000 zaposlenika. U Argo ulažu jedne od najvećih autokompanija, a to su Ford Motor Co. i Volkswagen group. Argo tvrdi da će njihova tehnologija isporučiti sustave za samostalnu vožnju s najvišom razinom autonomije u skorijoj budućnosti. Tehnologija koju je razvio Argo obuhvaća cijeli sustav za autonomnu vožnju, uključujući softverske i hardverske računalne platforme, senzore, kamere, radar i radar za detekciju svjetla i dometa (LIDAR). Argo je predstavio svoje testno vozilo treće generacije, temeljeno na Ford Fusion Hybridu, koje uključuje kamere veće razlučivosti sa širim dinamičkim rasponima, povećanom računalnom procesorskom snagom i poboljšanjima sustava grijanja i hlađenja.

Vodeća svjetska tehnološka tvrtka za izradu komponenti je Aptiv, američko-irska kompanija. Izrađuju električna, sigurnosna i elektronička tehnološka rješenja za tržište autonomnih vozila i dostavnih vozila. Aptiv broji velik broj zaposlenika, oko 141.000. Tvrtka Lyft se u 2018. godini udružila s Aptivom, te su pokrenuli uslugu robotaksija na modificiranom BMW-u. Vozilo koristi aplikaciju Lyft za vožnju autonomnih vozila i opremljeno je softverom, senzorima, računalom i ostalim tehnologijama. U kolovozu 2020. godine, Aptiv i Hyundai Motor Group počeli su razvijati projekt zvan Motional. To je projekt vezan za razvoj vozila za autonomnu vožnju, te kasnije u siječnju 2021. godine Aptiv je objavio da su kreirali platformu za autonomnu vožnju, primjenjiva na različite tipove vozila, te svaki proizvođač može bežično nadograditi prema svojim potrebama. Aptiv trenutno radi na proširenju autonomnog centra u Shanghaiu. Surađuju s General Motorsom, Volkswagen Groupom, Fiatom i Hyundaijem.

Google (Alphabet) je 2009. godine pokrenuo bez saznanja javnosti svoj projekt Google X u razvoju autonomnih vozila naziva Pribot. Pribot je bio prvi automobil koji se sam vozio javnim cestama. Toyotu Prius su modificirali i doradili svojom tehnologijom za automatiziranu vožnju te im je država Nevada izdala dozvolu. U prosincu 2016. projekt je preimenovan u Waymo i postao nova start-up tvrtka koja je dio Alphabeta. Naziv Waymo izveden je iz njegove misije, novi put prema naprijed u mobilnosti. Waymo je nakon odvajanja od Googlea prošao daljnja ispitivanja na svojim automobilima na javnim cestama. Waymo je postigao prvo svjetsko potpuno autonomno putovanje na javim cestama u 2015. godini u vozilu bez papučice i gasa bez ikakve ljudske interferencije. Vozilo Waymo One prikazan Slikom 5. , testiran je kao autonomni taksi.



Slika 5. Waymo autonomno vozilo [24]

Waymo djeluje na nekim od svojih tržišta za testiranje, poput Chandlera u Arizoni, na autonomiji razine 4, a nitko ne sjedi za upravljačem, dijeleći ceste s drugim vozačima i pješacima. Međutim, potrebna su dodatna testiranja. Waymova ranija ispitivanja usredotočila su se na područja bez teških vremenskih uvjeta, ekstremne gustoće ili kompliciranih cestovnih sustava, ali su prešli na testiranje u novim uvjetima. Kao rezultat toga, Waymo je započeo testiranje u područjima sa surovijim uvjetima, poput zimskih ispitivanja u Michigan. Waymo vozilo se koristi LIDAR-om, RADAR-om, senzorima, mikrofonima sve u svrhu postizanja potpune autonomnosti. Waymo projekt trenutno broji oko 1500 zaposlenika,

Veliko ime u razvoju autonomnih vozila je isto tako i General Motors, koji sa svojim GM Cruise autonomnim vozilom sadrži drugu po veličini autonomnu flotu na svijetu s čak 180 vozila koja se testiraju. Dosad je zabilježen prelazak više od 2 milijuna kilometra s testiranim vozilima. Pozornost javnosti je tvrtka privukla kada je 2016. godine uložila 500 milijuna dolara u Lyft. 2018. godine su pustili poluautonomno vozilo Super Cruise modela Cadillac CT6. Nedavno je USPTO (engl. United States Patent and Trademark Office) odnosno Ured za patente i žigove Sjedinjenih Država objavio patentnu prijavu GM-a, koja otkriva izum koji se odnosi na decentraliziranu distribuiranu kartu pomoću blockchaina [10]. Blockchain je relativno nova tehnologija poznatija u kripto svijetu odnosno kriptovalutama. Blockchain je sustav bilježenja informacija na način koji otežava ili onemogućuje promjenu, hakiranje ili varanje sustava. Blockchain je u biti digitalna knjiga transakcija koja se duplicira i distribuira po cijeloj mreži računalnih sustava na blockchainu.

Nissan je 2016. godine je razvio ProPilot, svoj sustav autonomnosti i tehnologije inteligentne mobilnosti koji koristi napredni sustav za pomoć vozaču. Danas je to jednostavna tehnologija koja se bazira na stani-kreni tehnologiji. Trenutno Nissan koristi ProPilot 2.0 i ima 3D navigaciju, s naprednim senzorima i kamerama koji imaju mogućnost prepoznavanja lica i pješaka. Nissan je velika automobilska tvrtka koja broji oko 137.000 zaposlenika. Također, razvio je i Nissan Leaf uslugu koja ima djelomične mogućnosti automatske vožnje poput ubrzavanja, kočenja i parkiranja na pritisak gumba.

Još jedna tvrtka koja je specijalizirana za usluge i proizvode povezane s internetom i umjetnom inteligencijom je Baidu, Inc. Sjedište tvrtke je u pekinškom okrugu Haidian. Jedna je od najvećih svjetskih AI i internetskih tvrtki. Također, Baidu trenutno razvija i projekt pod nazivom Apolong odnosno Apollo. 2013. godine Baidu je započeo razvoj autonomnih vozila bez vozača, putem istraživačkog instituta Baidu. Ovaj se projekt postupno proširio na 10.000 programera koji rade na otvorenoj platformi i više od 50 partnera širom svijeta, uključujući Intel, BMW, Benz, Kinglong i XTE. To je projekt za razvoj autonomne vožnje. Započeli su masovnu proizvodnju autonomnog autobusa visoke razine autonomnosti. Autobus bez vozača nema upravljač, gas ili kočnicu, vozi brzinom od 20 do 40 km/h i može osjetiti i predvidjeti kretanje pješaka i vozila u njegovoj blizini. Koristi Apollo 3.0, Baiduovu otvorenu operativnu platformu bez upravljačkih programa. Baidu kao kompanija trenutno broji oko 46. 000 zaposlenika.

4. Princip rada autonomne vožnje

Tri su glavne tehnologije uključene u projektiranje autonomnih automobila, a to su senzori, povezanost između vozila i povezanost s infrastrukturom, te zadnje, algoritam softvera i upravljanja. Kao što čovjek ima svoje senzore i osjetila pomoću kojih vidi, čuje i donosi odluke tako i autonomno vozilo ima velik broj senzora i tehnologija koji se ponašaju poput ljudskih osjetila. Kamere, infracrveni senzori, LIDAR (Light Detection and Ranging) senzori, RADAR (Radio Detection and Ranging), računalni vid, magnetski senzori, fotoelektrični, bluetooth tehnologija, NFC (Near Field Communication) itd. Također, računalo vozila posjeduje kompleksan programski kod od preko 100 milijuna linija koda i algoritme koji su u jednu ruku mozak autonomnog vozila i pomoću kojih vozilo samostalno donosi odluke. Umjetna inteligencija i neuronske mreže bitan su faktor na temelju kojih vozilo samostalno uči i razvija svoju inteligenciju odnosno uči u predviđanju situacija iako današnja razina autonomije još nije na toj razini u komercijalnoj uporabi što će se prikazati i opisati dalje u radu.

Pod pojmom povezanost vozila misli se da automobili imaju pristup najnovijim prometnim informacijama, vremenskim prilikama, površinskim uvjetima, konstrukciji, kartama, susjednim automobilima i cestovnoj infrastrukturi. Ovo su podaci koji se koriste za praćenje okolnog radnog okruženja automobila radi predviđanja loma ili izbjegavanja opasnih uvjeta. Omogućuju se sveukupne veze između različitih dijelova automobila i pomaže u navigaciji u odgovarajućem smjeru i prema odgovarajućem odredištu.

Algoritmi upravljanja potrebni su za prikupljanje podataka sa senzora i povezivanja te za donošenje odluka o upravljanju, kočenju, brzini i rutinskom navođenju. Daleko najkompleksniji dio automobila za samoupravljanje je donošenje odluka algoritama koji moraju biti u stanju besprijekorno rješavati mnoštvo jednostavnih i složenih situacija u vožnji. Softver koji se koristi za implementaciju ovih algoritama mora biti otporan na greške i robustan.

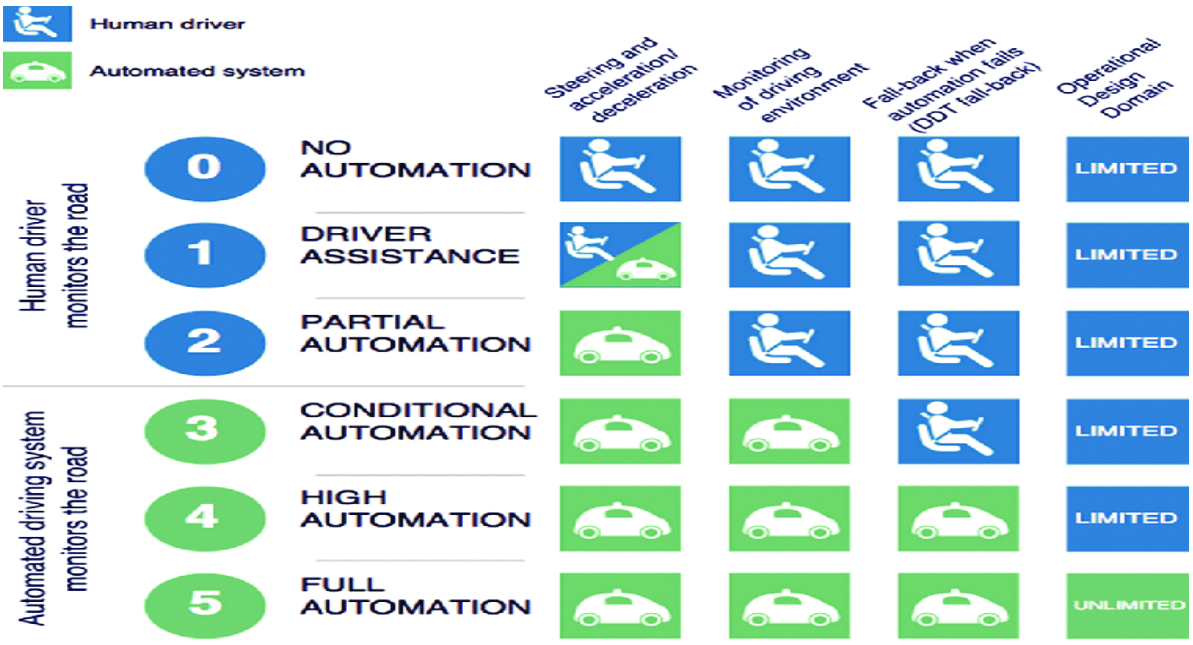
Autonomna vozila oslanjaju se na senzore, aktuatore, složene algoritme, sustav strojnog učenja i moćne procesore za izvršavanje softvera. Signale koje primaju senzori elektronička upravljačka jedinica koristi za donošenje odluka pomoću programskog koda, a zatim upravljačka jedinica šalje signal prema aktuatoru čiji je glavni cilj upravljanje vozilom.

Ovakva vozila stvaraju vlastitu kartu okruženja na temelju različitih senzora koji se nalaze na različitim njezinim dijelovima. Zatim se primljene informacije s karte šalju na korisničko sučelje koje se nalazi unutar vozila. Čvrsta pravila, algoritmi za izbjegavanje prepreka, prediktivno modeliranje i prepoznavanje objekata pomažu softveru da slijedi prometna pravila i snalazi se u preprekama.

4.1. Razine autonomije vozila

Društvo automobilskih inženjera (SAE) trenutno definira 6 razina automatizacije vožnje, u rasponu od razine 0 (potpuno ručno) do razine 5 (potpuno autonomno). Ove razine usvojilo je Ministarstvo prometa SAD-a. SAE koristi izraz automatiziran umjesto autonomno. Jedan od razloga je taj što riječ autonomija ima implikacije izvan elektromehaničkog. Potpuno autonomni automobil bio bi samosvjestan i sposoban donijeti vlastiti izbor.Primjerice, vozilo dobije glasovnu naredbu da odvede putnika na posao, ali automobil umjesto toga odluči odvesti putnika na plažu. Potpuno automatizirano vozilo bi slijedilo naredbe, a zatim se sam vozio odnosno odvezao bi putnika na posao s obzirom na to da je primio glasovnu naredbu.

Slikom 6. prikazane su razine automatizacije od nulte do pete razine. Primjetno je da do druge razine i dalje je čovjek u većinskoj kontroli nad vozilom dok od treće razine automatizacije pa na dalje vozilo preuzima većinu odluka i komandi nad vozilom.



Slika 6. Razine autonomije vozila [10]

Izraz samovožnja često se koristi naizmjenično s autonomnim. Međutim, to je ipak drugačija stvar. Samovozeći automobil može se sam voziti u nekim ili čak u svim situacijama, ali ljudski putnik mora uvijek biti prisutan i spreman preuzeti kontrolu. Samovozeći automobili spadali bi u razinu 3 (uvjetna automatizacija vožnje) ili razinu 4 (visoka automatizacija vožnje). Podložni su georeferenciranju, za razliku od potpuno autonomnog vozila razine 5 koji bi mogao ići bilo gdje.

Razina 0 odnosno nulta razina autonomije nema automatizaciju vožnje. Nulta razina odnosi se na vozilo koje nema tehnologiju automatizacije vožnje. U tom slučaju vozač je u potpunosti zadužen za upravljanje kretanjem vozila, uključujući upravljanje, ubrzavanje, kočenje, parkiranje i sve druge potrebne manevre za pomicanje automobila u bilo kojem smjeru [1]. Međutim, na razini 0 mogu biti prisutni sustavi podrške vozaču koji mogu privremeno intervenirati tijekom vožnje. Primjeri uključuju kontrolu stabilnosti, upozorenje na sudar naprijed, automatsko kočenje u nuždi odnosno ABS (engl. Automatic Breaking System), upozorenje na mrtvi kut i pomoć pri održavanju prometne trake. Ove se tehnologije smatraju razinom 0 jer ne upravljaju vozilom, već nude upozorenja ili trenutne radnje u posebnim situacijama. Većina vozila na cestama danas je razine 0.

Na razini 1 automatizacija vožnje pomaže vozaču. Prva razina je najniža stepenica automatizacije, vozilo ima najmanje jedan sustav podrške vozaču koji pruža pomoć pri upravljanju ili pomoć pri kočenju i ubrzanju [2]. Vozač ostaje odgovoran za upravljanje vozilom i mora biti spreman preuzeti kontrolu u bilo koje vrijeme i iz bilo kojeg razloga. Prilagodljivi tempomat odnosno ACC (engl. Adaptive Cruise Control) primjer je tehnologije koja pomaže vozaču vozila razine 1. Održava sigurnu udaljenost između vašeg vozila i prometa ispred vas bez ikakve intervencije vozača. Značajka pomoći pri upravljanju, poput pomoći pri centriranju trake ili pomoć pri praćenju trake, također bi se kvalificirala kao autonomija razine 1. Međutim, vozilo s obje ove značajke koje rade zajedno kvalificira se kao automatizacija vožnje razine 2.

Automatizacija vožnje razine 2 odnosno djelomična automatizacija vožnje primjenjuje se na vozila s naprednim sustavima pomoći u vožnji ADAS (engl. Advanced Driving Assistance Systems) koji mogu preuzeti upravljanje, ubrzanje i kočenje u posebnim scenarijima i slučajevima. No, iako podrška vozača razine 2 može kontrolirati ove primarne vozačke zadatke, vozač mora ostati budan i dužan je u svakom trenutku aktivno nadzirati tehnologiju, vozilo i okolinu. Primjer automatizacije vožnje razine 2 je pomoć pri vožnji na

autocesti, instalirana u vozilima poput Genesis, Hyundai i Kia. Vozač mora imati ruke na upravljaču, ali aktivno upravlja, ubrzava i koči vozilo tijekom vožnje po autocestama. BlueCruise je nova Fordova tehnologija automatizacije djelomične vožnje bez upotrebe ruku. Sofisticiraniji je od Highway Driving Assist, koji vozaču omogućuje da skine ruke s upravljača na određenim, odobrenim autocestama u SAD-u i Kanadi. Oba ova primjera automatizacije vožnje razine 2 zahtijevaju od vozača da ostane upozoren, angažiran i spreman preuzeti kontrolu u svakom trenutku. Teslin autopilot bi isto tako bio primjer druge razine autonomije vozila.

Skok s automatizacije razine 2 na razinu 3 je značajan, te trenutno skoro pa nijedan sustav razine 3 nije legalan za upotrebu na cestama. Razina 3 poznata je kao automatizacija uvjetne vožnje. Koristi različite sustave pomoći vozaču i umjetnu inteligenciju za donošenje odluka na temelju mijenjanja situacija u vožnji oko vozila. Ljudi u vozilu ne moraju nadzirati tehnologiju, što znači da se mogu baviti drugim aktivnostima. Međutim, ljudski vozač mora biti prisutan, upozoren i sposoban preuzeti kontrolu nad vozilom u bilo kojem trenutku, osobito u slučaju nužde zbog kvara sustava. Audi je za svoju vodeću limuzinu A8 2019. razvio tehnologiju pomoći u prometu 3. razine, ali nikada nije dobio regulatorno odobrenje za sustav u Njemačkoj i od tada je odložio napore. To je otvorilo vrata Hondi da postane prvi proizvođač automobila na svijetu koji je potrošačima prodao odobreni sustav pomoći 3. razine prometnih gužvi. U prodaju je stigao kao nadogradnja legendarne limuzine tvrtke Legend početkom 2021. , ponuđen u malim količinama i samo za uporabu na domaćem tržištu proizvođača automobila. Ostala vozila opremljena automatizacijom razine 3 vožnje koja čekaju regulatorno odobrenje uključuju redizajniranu Mercedes-Benz S-klasu 2021. i potpuno novo električno vozilo Mercedes-Benz EQS 2022. godine. Mercedesova tehnologija naziva se Drive Pilot.

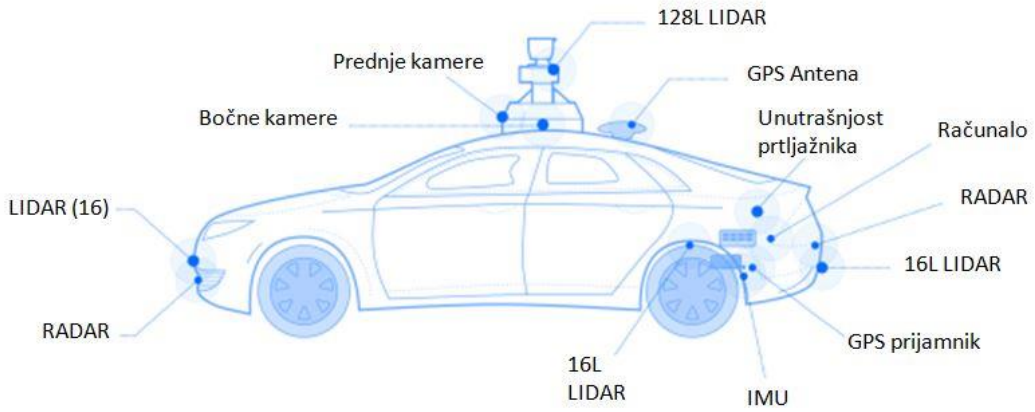
Četvrta razina spada pod visoku razinu automatizacije vožnje. Nazvana automatizacijom visoke razine, autonomija razine 4 ne zahtijeva nikakvu ljudsku interakciju i intervenciju u radu vozila jer je programirana da se zaustavi u slučaju kvara sustava. Budući da ljudski vozač nikada nije potreban, vozilo razine 4 može ne imati upravljač, komande i pedale. Sustav u vozilu razine 4 sposoban je samostalno voziti, prepoznati situaciju u okolini i samostalno odlučivati u različitim prometnim situacijama, poput iznenadne pojave pješaka na kolniku ili oduzimanje prednosti prolaza od drugog vozila. Tehnologija automatizacije vožnje razine 4 koristi se u taksijima bez vozača i uslugama javnog prijevoza. Takva vozila bit će

programirana za putovanje između točke A i točke B te će biti ograničena na određene geografske granice tehnologijom geografske ograde. Određeni uvjeti mogu ograničiti ili otkazati autonomni rad razine 4, poput loših vremenskih uvjeta. Primjeri takvih vozila bili bi Googleov Waymo te Volvo koji za Baidu proizvodi taksi četvrte razine autonomije za kinesko tržište.

Potpuna automatizacija vožnje odnosno potpuno autonomno vozilo bi bilo vozilo razine 5. Kao najviša klasifikacija automatizacije vožnje, razina 5 znači da se vozilo može voziti posvuda u svim uvjetima bez ikakve ljudske interakcije. Vozilo razine 5 nije limitirano geografskim ograđivanjem niti je pod utjecajem vremenskih uvjeta te udobno i učinkovito prevozi putnike bez potrebe za vozačem. Jedini ljudski napor odnosno interakcija bit će određivanje odredišta. Takva vozila, koja su u stanju sama prijeći bilo koji put odnosno doći od polazišta do odredišta, u različitim vremenskim uvjetima neovisno o dobu dana i stanju u prometu testiraju se diljem svijeta. Trenutno ne postoji niti jedan oblik takvog vozila u funkciji niti ih je moguće kupiti ili pribaviti.

4.2. Senzorski sustav autonomnih vozila

Različiti senzori i računalni sustavi potrebni su da bi vozilo repliciralo tradicionalni ljudski proces razumijevanja njegovog trenutnog položaja, željenog položaja i načina sigurne navigacije rutama i opasnostima između njih [21]. Među trenutno dostupnim senzorima niti jedna jedinica nije sposobna dešifrirati svoje okruženje na način koji pruža dovoljno informacija za autonomnu vožnju. Umjesto toga, dizajniran je sustav koji uključuje kombinaciju senzora, strateški iskorištavajući specifične sposobnosti jednog sustava, dok se njegovi nedostaci rješavaju korištenjem drugih. Pomoću tih senzora prikuplja podatke iz okoline u stvarnom vremenu i ti isti podaci koji se prikupe koriste se za percepciju, planiranje putovanja i rute, izračunavanje trenutnog i željenog položaja, te navigaciju.Senzori autonomnih vozila spadaju pod senzore kratkog i dugog dometa. Senzori kratkog dometa su ultrazvučni senzori, kapacitivni senzori ili infracrveni senzori, a senzori dugog dometa su LIDAR, RADAR, računalni vid i GPS odnosno GNSS. [10]



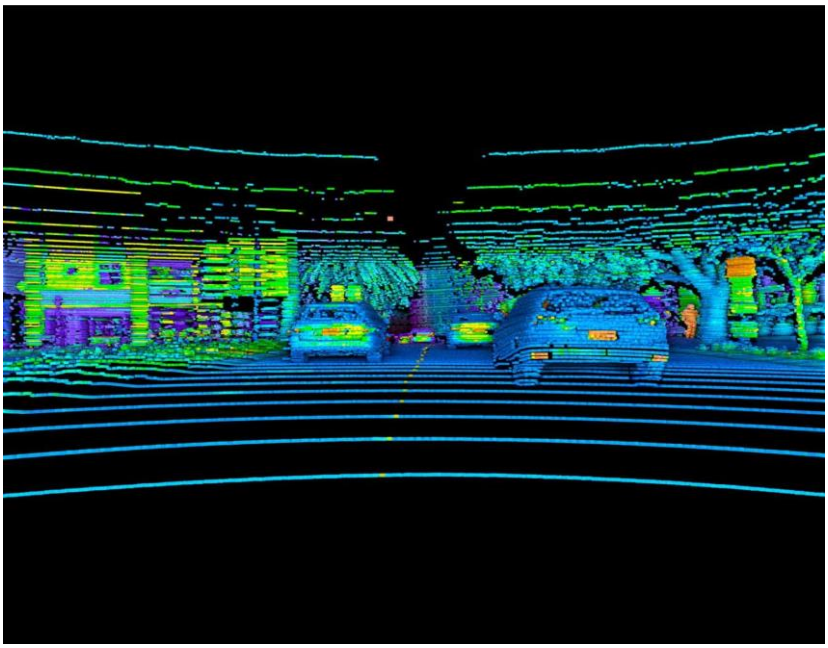
Slika 7. Senzorski sustav autonomnog vozila [21]

Kao što se može primijetiti na Slici 7. , velik broj kamera na autonomnom vozilu pomaže u detekciji objekta na blizinu i daljinu te u registriranju bilo kakve aktivnosti ostalih vozila, pješaka i prometnih signala i znakova. LIDAR sustav stvara 3D mapu, u rasponu od 360 stupnjeva koristeći lasere u okolini u kojoj se vozilo trenutno nalazi. Također, vozilo je opremljeno RADAR-om i GPS-om za pozicioniranje i lociranje vozila.

RADAR (engl. Radio Detecting and Ranging) je senzor koji se koristi za otkrivanje opasnih objekata na putu vozila koji su udaljeni više od 100 metara, a najbolje djeluje pri otkrivanju metalnih predmeta. Točno može odrediti i reći udaljenost otkrivenog i promatranog objekta. Automobilski radar obično se nalazi u 2 oblika, a to je 77GHz i 24GHz gdje se 24GHz koristi za aplikacije kratkog dometa, a 77GHz za otkrivanje na daljinu. Radar djeluje između 10 i 11 GHz tijekom razdoblja od 5 milisekundi, odašiljajući radarski signal iz središnje postavljenog antenskog sustava. Dva prijemnika primaju reflektirani radarski val odnosno energiju. To je tehnologija koja uglavnom radi na prilagodljivom tempomatu i automatskom kočenju u nuždi u autonomnim automobilima. Može vidjeti 100 metara i može odabrati brzinu svih objekata koje opaža [21]. Nije ni približno dovoljno precizno da računalo prepozna biciklista umjesto pješaka, ali trebalo bi moći otkriti činjenicu da se upravljano vozilo kreće brzinom i smjerom, a to je korisno za samostalno upravljanje vozilom.

LIDAR (engl. Light Detection and Ranging), koji se obično koristi kao skraćenica za otkrivanje i mjerenje svjetlosti, u osnovi je sonar koji koristi impulsne laserske valove za

mapiranje udaljenosti od okolnih objekata. Koristi ga velik broj autonomnih vozila za navigaciju okruženjima u stvarnom vremenu [1]. Njegove prednosti uključuju impresivno preciznu percepciju dubine, što omogućava LIDAR-u da zna udaljenost od objekta na udaljenosti od nekoliko centimetara, do 60 metara. Također je vrlo pogodan za 3D mapiranje, što znači da se vozila koja se vraćaju mogu tada predvidljivo kretati okolišem što je značajna prednost za većinu tehnologija samovožnje.



Slika 8. Prikaz LIDAR-ove detekcije okoline putem laserskih impulsa [8]

Jedna od ključnih prednosti LIDAR-a je broj područja koja pokazuju potencijal za poboljšanje. Tu se ubrajaju solid-state senzori koji bi mogli deseterostruko smanjiti troškove, povećati domet senzora do 200 m i četverodimenzionalni LIDAR koji prepoznaje brzinu objekta kao i njegov položaj u 3D prostoru. Međutim, unatoč tim uzbudljivim napredcima, LIDAR još uvijek ometa ključni čimbenik, a to je njegov značajan trošak. Izgled LIDAR-ove detekcije okoline putem laserskih impulsa prikazan je Slikom 8.

LIDAR nije jedina tehnologija koju koriste autonomna vozila, čiji su glavni suparnici kamere, a Tesla ih zagovara kao najbolji put prema naprijed. Elon Musk, CEO Tesle, tvrdi da je LIDAR nepotreban trošak i gubitak resursa. Postoji argument da ljudi voze samo na temelju vidljive okoline, pa bi i roboti trebali biti u mogućnosti. Kamera je znatno manja i jeftinija od LIDAR-a (iako ih je potrebno više), a ima prednost u boljoj rezoluciji i u boji, što znači da može čitati semafore i znakove. Međutim, kamere imaju širok niz karakteristika zbog

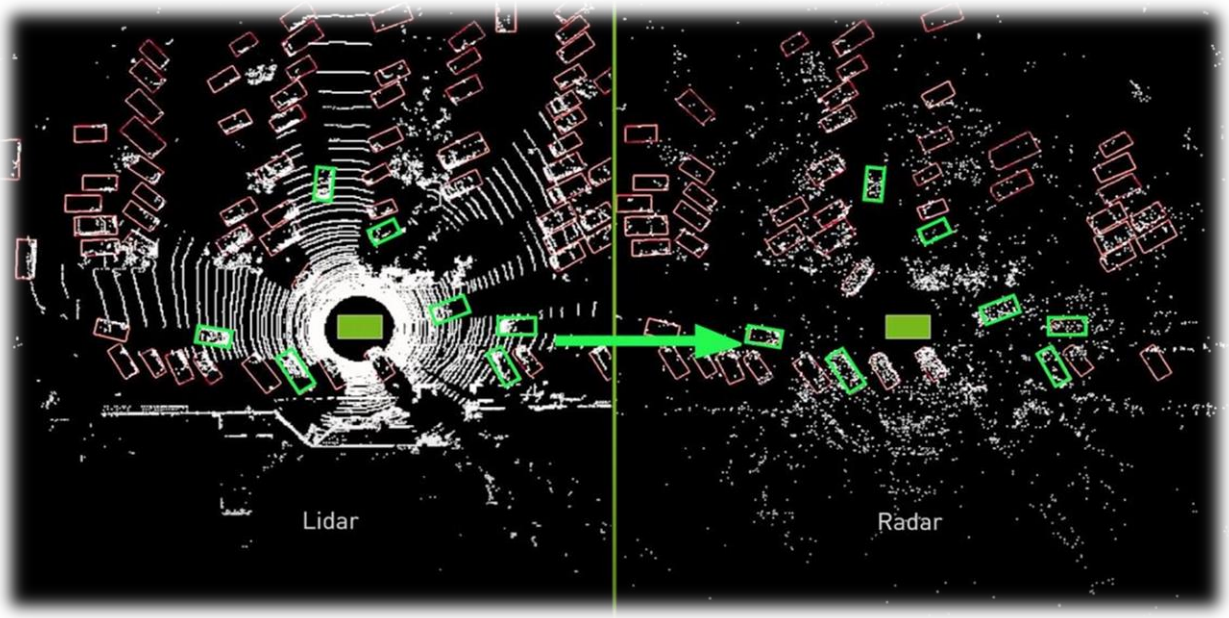
kojih ih je vrlo teško koristiti u uobičajenim uvjetima vožnje. Dok LIDAR koristi gotovo infracrveno svjetlo, fotoaparati koriste vidljivo svjetlo i stoga su osjetljiviji na probleme kada se suoče s kišom, maglom, lošijim vremenskim uvjetima ili čak nekim teksturama. Osim toga, LIDAR ne ovisi o ambijentalnom svjetlu, generirajući vlastite svjetlosne impulse, dok su kamere osjetljivije na nagle promjene svjetlosti, izravnu sunčevu svjetlost, pa čak i kišne kapi.

Tradicionalna RADAR obrada odbija RADAR signale od objekata u okolišu i analizira snagu i gustoću refleksija koje se vraćaju. Ako se vrati dovoljno jaka i gusta nakupina refleksija, klasična RADAR obrada može utvrditi da je to vjerojatno neka vrsta velikog objekta. Ako se slučajno i ta točka kreće s vremenom, tada je taj objekt vjerojatno automobil.

Iako ovaj pristup može dobro poslužiti za zaključivanje vozila u pokretu, isto možda ne vrijedi i za stacionarno vozilo. U ovom slučaju, objekt stvara gustu skupinu refleksija, ali se ne pomiče. Prema klasičnoj RADAR obradi, to znači da bi objekt mogao biti ograda, pokvareni automobil, nadvožnjak autoceste ili neki drugi objekt. Pristup često ne može razlikovati o kojem se objektu radi [8].

Jedan od načina za prevladavanje ograničenja ovog pristupa je pomoću AI u obliku duboke neuronske mreže (DNN). Za obuku DNN-a prvo je potrebno prevladati probleme s rijetkošću RADAR podataka. Budući da radarski odsjaji mogu biti prilično rijetki, ljudima je praktički nemoguće vizualno identificirati i označiti vozila samo na osnovu RADAR podataka.

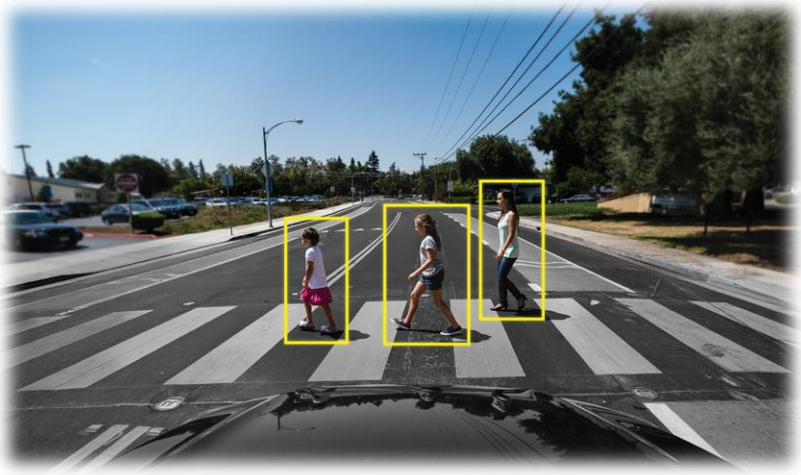
LIDAR, međutim, laserskim impulsima može stvoriti 3D sliku okolnih predmeta. Dakle, podaci o zemaljskoj istini za DNN stvoreni su širenjem naljepnica ograničavajućih okvira iz odgovarajućeg skupa podataka lidara na radarske podatke kao što je prikazano na Slici 9. Na taj način je sposobnost ljudskog etiketiranja da vizualno identificira i označi automobile iz LIDAR podataka efektivno prebačen u RADAR područje [8]. Štoviše, kroz ovaj postupak RADAR DNN ne uči samo otkrivati automobile, već i njihov 3D oblik, dimenzije i orijentaciju, što klasične metode ne mogu lako učiniti.



Slika 9. Širenje naljepnica graničnih okvira za automobile iz domene podataka LIDAR u domenu podataka RADAR [8]

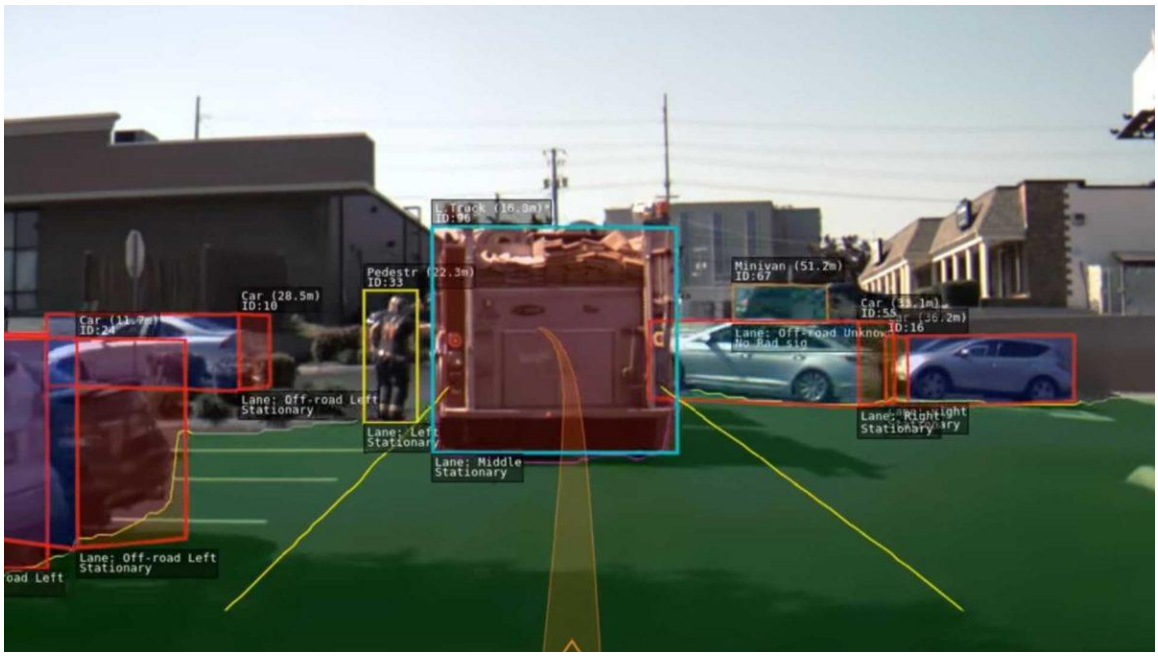
Veća pouzdanost 3D percepcije iz RADAR-a, DNN omogućuje autonomnom vozilu u predviđanju, planiranju i upravljačkom softveru donošenje boljih odluka u vožnji, posebno u izazovnim scenarijima. Za RADAR klasično teški problemi poput točne procjene oblika i orijentacije, otkrivanje stacionarnih vozila kao i vozila ispod nadvožnjaka autoceste postaju izvedivi s mnogo manje kvarova.

Stvaranjem 3D mape točaka, LIDAR je daleko bolji u procjenjivanju udaljenosti od kamera, kao i nepropustan za površine koje su reflektirajuće, teksturirane ili bez teksture. Kamere zahtijevaju značajan računalni napor, poput složenih neuronskih mreža, da bi se izmjerila udaljenost između objekata, skupljanjem različitih povratnih informacija kamere ili jedne informacije tijekom vremena detekcije. 2D slike također mogu prevariti kamere, čineći ih otvorenijima za zlonamjerne i cyber napade.



Slika 10. Opažanje pješaka putem kamere na pješačkom prijelazu [8]

U autonomnim vozilima koristi se čak 8 ili više kamera za detekciju raznih informacija i podataka iz okoline. Detekcija pješaka na Slici 10. obavlja se putem prednje kamere koja kada uoči na određenoj udaljenosti javlja računalu da je detektiralo pješaka (stacionarnog ili u kretanju) te procjeni i prilagođava brzinu s obzirom na udaljenost od pješaka i pješačkog prijelaza. Ukoliko pješaci i dalje prelaze pješaci prijelaz vozilo se zaustavlja ispred i jednom kada više ne detektira pješake ispred sebe ili u okolini vozilo krene akcelerirati i nastavlja svoj put. Kamere samostalno u posebnim vanjskim uvjetima ne funkcioniraju kao ljudsko oko, i bez obzira na napredne algoritme koji obrađuju podatke s kamera, vjerojatno nikad neće moći percipirati vizualne informacije kao ljudsko oko.



Slika 11. Prikaz percepcije okoline Teslinog autonomnog vozila [8]

Slikom 11. prikazana je detekcija vozila putem senzorskog sustava unutar Teslinih autonomnih vozila. Sustav razlikuje stacionarna vozila i vozila u pokretu te može razlikovati radi li se o pješaku, vozilu ili objektu infrastrukture. Također, razlikuje i klasificira tipove vozila. Ultrazvučni senzori mogu pružiti precizne podatke kratkoga dometa, a infracrveni senzorski sustavi mogu otkrivati oznake traka bez osvjetljenja, i pješake u noćnim uvjetima.

Računalni vid (engl. computer vision) u autonomnim vozilima može dovesti do projektiranja i razvoja naprednih vozila nove generacije koja mogu prevladati prepreke u vožnji, a pritom čuvati putnike. Takvi automobili mogu prevoziti putnike od polazišta do odredišta eliminirajući ljudsku intervenciju. Budući da čak i manji nedostatak u projektiranju ili razvoju ovog vozila može uzrokovati nesreće sa smrtnim ishodom i opasnost po život, istraživači i stručnjaci primjenjuju tehnologiju računalnog vida na autonomna vozila kako bi bila sigurnija i za putnike i pješake. Omogućit će samovozećim vozilima snimanje vizualnih podataka u stvarnom vremenu. Kamere povezane s takvim vozilima mogu snimati snimke uživo i omogućiti računalnom vidu stvaranje 3D karata. Pomoću ovih karata autonomna vozila mogu bolje razumjeti svoju okolinu uočavajući prepreke na svom putu i odlučiti se za zamjenske rute s 3D mapama. Autonomna vozila mogu predvidjeti nesreće pomoću 3D karata i mogu odmah aktivirati zračne jastuke za zaštitu putnika. Ovakvo rješenje čini autonomna vozila sigurnijim i pouzdanijim. Tehnologija računalnog vida može prikupiti velike skupove

podataka pomoću kamera i senzora, uključujući podatke o lokaciji, prometne uvjete, održavanje cesta, gužve i druge. Ovi detaljni podaci mogu pomoći samovozećim vozilima u korištenju svjesnosti o situaciji i donošenju vitalnih odluka što je prije moguće. Ti se detalji mogu dalje koristiti u obuci modela dubinskog učenja. Na primjer, tisuću slika prometnih signala prikupljenih računalnim vidom može se koristiti za obuku dubokog učenja modela za otkrivanje prometnih signala tijekom vožnje. Osim toga, može pomoći autonomnim vozilima u klasifikaciji različitih vrsta objekata. Kako bi obrađivali slike i videozapise pri slabom osvjetljenju, autonomna vozila koriste drugačije algoritme od onih za dnevno svjetlo. Slike snimljene pri slabom osvjetljenju mogu biti mutne i takvi podaci možda nisu dovoljno točni za ova vozila. Čim računalni vid otkrije stanje slabog osvjetljenja, može se prebaciti u način rada pri slabom osvjetljenju.

4.3. Kooperativna komunikacija između vozila i infrastrukture

Prije nikada nije bilo moguće osjetiti stvarni svijet, analizirati podatke, donijeti informirane odluke i djelovati na način kao što je to danas. Kako se granice između fizičkog i cyber svijeta zamagljuju, inovacije se ostvaruju iz dana u dan. To je osobito evidentno u posljednjih nekoliko godina na području transportnog sustava. Konkretno, vidimo pojavu povezanih vozila koja imaju impresivan niz senzora i ugrađenih jedinica za donošenje odluka za povećanje pomoći vozačima pružajući, na primjer, tempomat, parkiranje, upozorenje na sudar, upozorenje o promjeni trake, pješake otkrivanje, povezivanje i koordinacija suradnje [25]. Osim toga, vozilo se sve više smatra povezanim vozilom, koje je putem različitih komunikacijskih tehnologija trajno povezano s internetom, a također može komunicirati s infrastrukturom putem usluga između vozila i infrastrukture (V2I, engl. Vehicle to Infrastructure) i druga vozila putem usluga od vozila do vozila (V2V, engl. Vehicle to Vehicle). Tipični scenariji daljinske dijagnostike i izvještavanja o zdravlju vozila datiraju već 10-ak godina. Trenutno se pojavljuje trend prema hiperpovezanim vozilima, tj. komunikacija od vozila prema svemu (V2X, engl. Vehicle to Everything), gdje vozilo izvan V2I i V2V također stupa u interakciju i razmjenjuje informacije s bilo kojim subjektom sposobnim za to, npr. vozilo prema pješaku (V2P, engl. Vehicle to Passenger), vozilo prema uređaju (V2D, engl. Vehicle to Device), vozilo prema mreži (V2G, engl. Vehicle to Grid) itd. Štoviše, svjedoci smo primjene umjetne inteligencije, koja zajedno sa sofisticiranim senzorima dovodi

do pojave autonomnih vozila koja se sami upravljaju, i gdje bi vozač mogao biti opcionalan u sljedećim desetljećima.

V2I ili tehnologija od vozila do infrastrukture, bilježi podatke kao što su gužve u prometu, vremenske napomene, razine razmaka mostova, stanje semafora, a zatim ih bežično prenosi kako bi obavijestio vozače o uvjetima koja moraju biti svjesna koja pomažu u sigurnosti. Pametni prometni signali koje pokreće V2I pomažu vozačima da bolje razumiju prometne uvjete, pomažući u procjeni točnog vremena dolaska što može poboljšati komunikaciju između vozača i korisnika.

V2I dio je programa ITS-a koji je osmišljen kako bi se olakšalo usvajanje tehnologije u autonomnim vozilima. Budućnost V2I mogla bi dovesti do boljih sustava za pomoć vozaču, poput pametnog parkiranja i vozila za autonomnu vožnju, što bi moglo poboljšati buduće gradsko planiranje prometnih traka, parkirališta te brojnih drugih aspekata prometne infrastrukture.

Kako bi se izvršila klasifikacija tipova prometnih znakova, radi se hijerarhijska klasifikacija vrste prometnih znakova za veliki broj prometnih znakova širom svijeta. U ravnom DNN (duboka neuronska mreža, engl. Deep Neural Network) modelu osposobljenom za klasifikaciju, sve različite klase potencijalnih izlaza morale bi se unaprijed definirati, a za svaki okvir bi se trebao izabrati jedan izlaz klasifikacije [8]. S obzirom na složenost tipova prometnih znakova koji se nalaze u cijelom svijetu, skaliranje takvog modela za pokrivanje svih mogućih klasa s velikom preciznošću i performansama bilo bi izuzetno teško. Slikom 12. prikazan je način na koji vozilo klasificira i prepoznaje različite tipove prometnih znakova i potrebnih informacija koje sadrži prometna infrastruktura.



Slika 12. Prepoznavanje znakova ograničenja brzine [8]

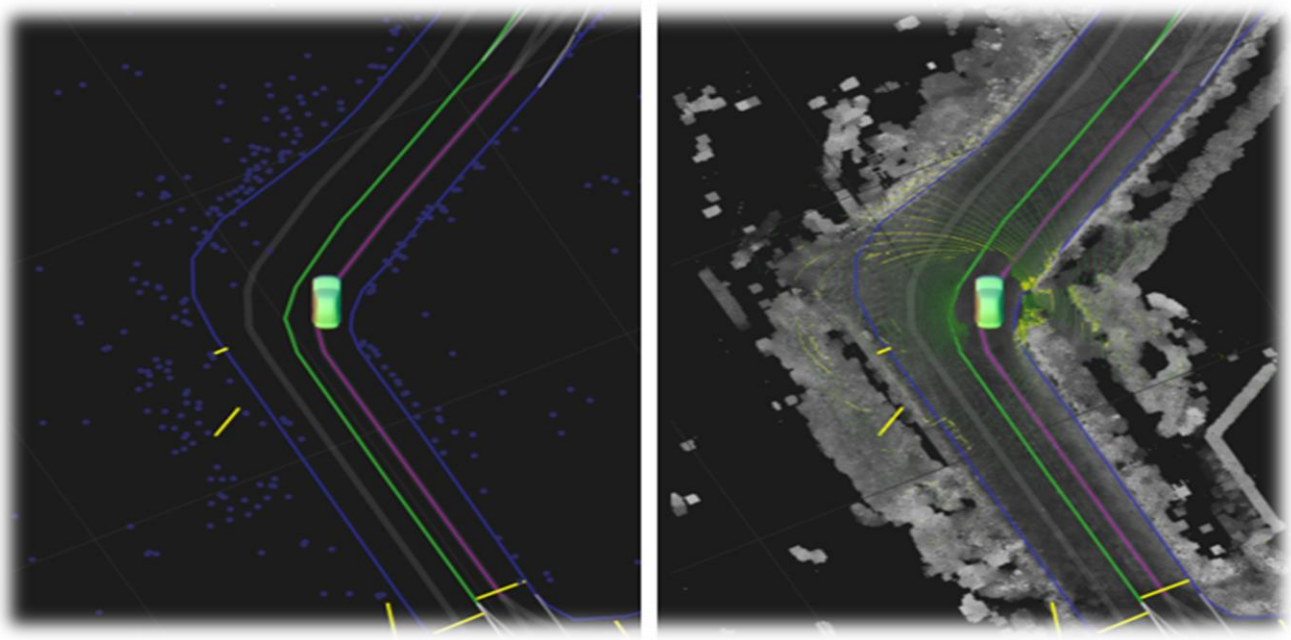
Da bismo upravljali ovom složenošću i optimizirali performanse, koristimo hijerarhijski DNN model, u kojem točne izlazne klase nisu unaprijed definirane. Vozilo se osposobljava za samostalno otkrivanje ključnih značajki koje se zatim kombiniraju u izlazne klase na temelju analize izlaznih rezultata. Dizajniranjem izlaznih klasa putem iterativne analize, postaje moguće skalirati na veliki broj klasa uz održavanje snažnih performansi klasifikacije.



Slika 13. Vizualizacija Velodyne LIDAR senzora [8]

Softver ovaj postupak izvodi dok se automobil vozi, tako da uvijek ima cjelovitu, ažurnu sliku okoline što je prikazano Slikom 13. To znači da za razliku od ljudskih vozača, autonomna vozila nemaju fleke i uvijek budno prate svijet oko sebe koji se kreće i mijenja.

Lokalizacija je kritična sposobnost autonomnih vozila, što omogućuje točno određivanje njihove lokacije unutar centimetara unutar karte. Ova visoka razina točnosti omogućuje automobilu koji samostalno vozi da razumije svoju okolinu i stvori osjećaj ceste i traka. S lokalizacijom, vozilo može otkriti kada se traka račva ili spaja, planirati promjene trake i odrediti putove trake čak i kada oznake nisu jasne.



Slika 14. Lokalizacija autonomnog vozila [8]

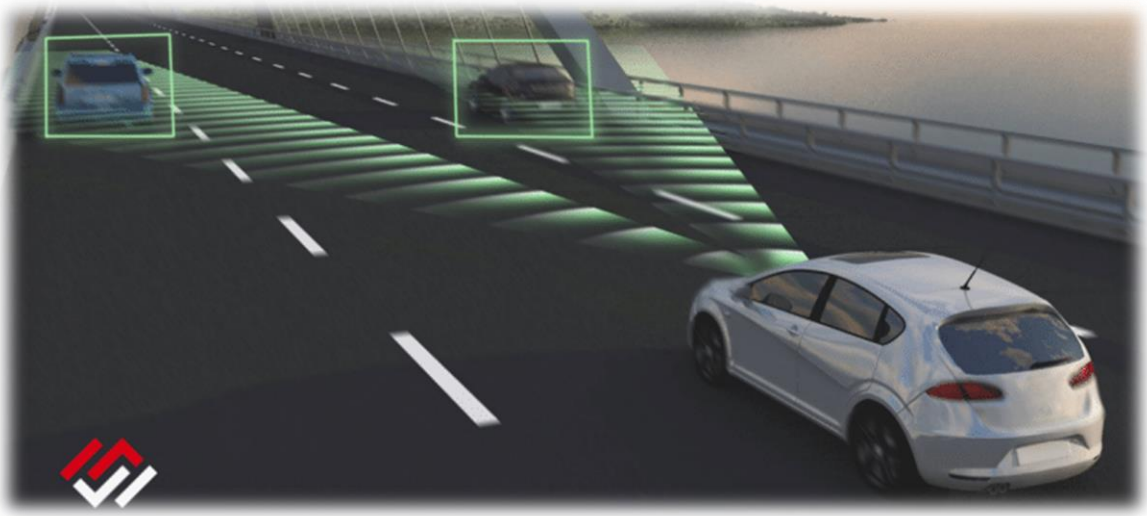
Osim lokalizacije kamere, lokalizacija se može koristiti i s RADAR-om (lijevo) i LIDAR-om (desno) kao što je prikazano Slikom 14. Na lijevoj slici plave točke su RADAR odzivi uživo. Desna slika prikazuje sliku refleksije LIDAR-a i žive točke odnosno uživo prikaz LIDAR-a (zelena).

4.4. Komunikacija između vozila i vozila (V2V)

V2V odnosno komunikacija između vozila i vozila, je komunikacija koja omogućuje autonomnim vozilima pristup podacima o brzini i položaju drugih vozila s omogućenim V2V okruženjem koristeći bežični komunikacijski protokol sličan onom kod WIFI-a. Ti se podaci zatim koriste za upozoravanje vozača na potencijalne opasnosti, pomažući u smanjenju nesreća i gužvi u prometu. V2V može otkriti opasne prometne i cestovne uvjete, probleme s terenom i vremenske prijetnje u rasponu od 300 metara. V2V ima mogućnost učiniti vožnju predvidljivijom i sigurnijom aktivnošću za sve na sudionike u prometu.

U Europi je za isključivo sigurnosne ITS aplikacije određen frekvencijski pojas od 5.875 do 5.905 MHz [10]. Također, predložena je bežična komunikacijska tehnologija kratkog dometa, takozvani ITS-G5 (evolucija standarda 802.11. ITS-G5 koristi ad hoc mrežnu topologiju bez fiksne strukture, a to znači da svi opremljeni agenti, kao što su vozila, motocikli i pješaci, imaju mogućnost izravne međusobne komunikacije, bez potrebe za razmjenu podataka kroz pristupnu točku ili baznu stanicu) [2]. U Europi se također radi na provedbi decentralizirane kontrole zagušenja komunikacija, skraćeno DCC (engl. Decentralized Communication congestion Control) mreži. DCC je zajednički naziv za razne tehnike kojima je cilj izbjeći preopterećenje mrežnog kanala. 5G mobilne mreže mogle bi podržavati dodatne usluge, istodobno održavajući kvalitetu i sigurnost V2X komunikacije.

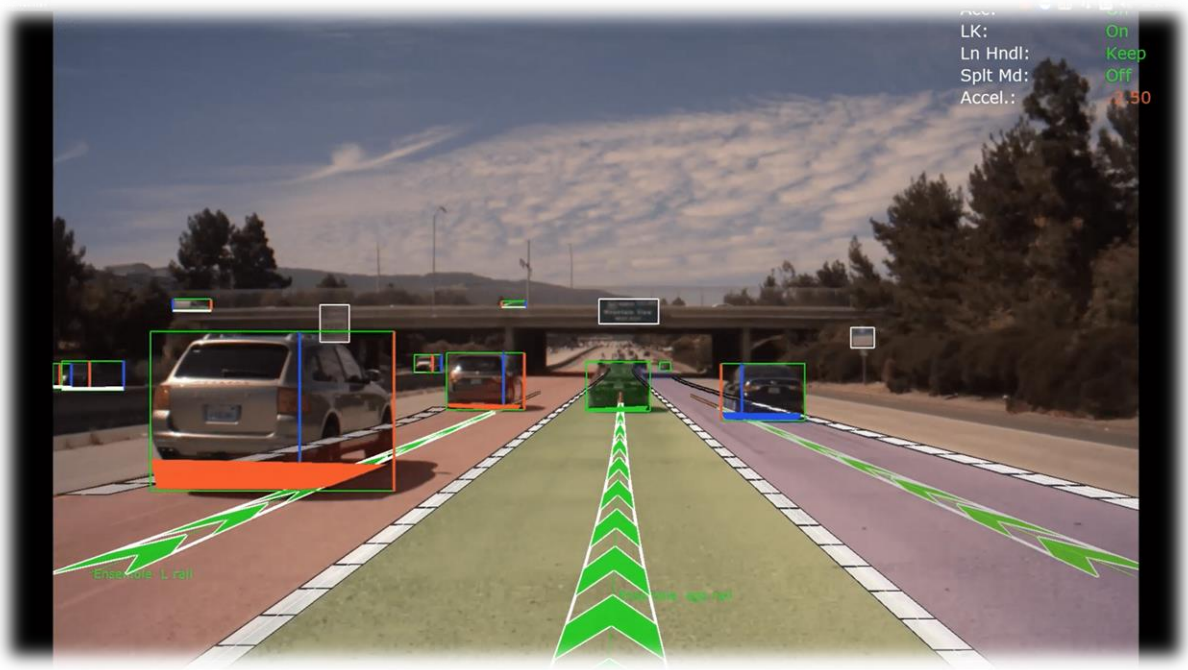
Za razliku od Europe SAD-u su se najviše orijentirali prema namjenskoj komunikaciji kratkog dometa (DSRC, engl. Dedicated Short-Range Communication). To je dvosmjerna bežična komunikacija koja koristi tehnologiju kratkog do srednjeg dometa i zasnovana je na IEEE 802.11p standardu. Također, na protokolu WAVE - Bežični pristup u okruženju vozila odnosno (engl. Wireless Access in Vehicular Environment), te TC-ITS europskom standardu [1]. U Sjedinjenim Američkim Državama dodijeljen je frekvencijski pojas 75MHz u spektru od 5.9GHz koji će se koristiti u svrhu sigurnosti vozila i raznih aplikacija za mobilnost.



Slika 15. Detekcija i komunikacija između vozila [8]

Senzori kamere, radara i lidara pružaju bogate podatke o okolišu automobila. Međutim, kao što se može primijetiti na Slici 15. , slično kao što ljudski mozak obrađuje vizualne podatke koje primaju oči, autonomno vozilo mora biti sposobno razumjeti taj stalni protok informacija. Autonomna vozila to rade pomoću postupka koji se naziva fuzija senzora. Ulazi senzora ulažu se u centralizirano računalo s inteligencijom visokih performansi koja kombinira relevantne dijelove podataka za vozilo kako bi donosilo odluke o vožnji. Umjesto da se u određenim trenucima oslanja samo na jednu vrstu podataka senzora, fuzija senzora omogućuje spajanje različitih podataka iz paketa senzora, poput oblika, brzine i udaljenosti kako bi se osigurala pouzdanost. Kada se odlučite za promjenu prometne trake, primanje podataka i sa senzora kamere i radara prije prelaska u sljedeću traku uvelike poboljšava sigurnost manevra, baš kao što trenutna upozorenja na mrtvu točku služe kao rezerva za vozače.

Slika 16. prikazuje rezultate percepcije putanje s visokim pouzdanjem za lijeve, ego vozila (srednje trake) i desne središnje trake. Rezultat visoke pouzdanosti vizualiziran je debelim zelenim središnjim linijama. Pune bijele linije označavaju predviđanja linija trake, a također ih izračunava skupina za percepciju i detekciju.



Slika 16. Prikaz smjera kretanja na kolniku i detekcija vozila i infrastrukture [8]

Kombiniraju se različiti izlazi percepcije puta tehnike cjeline. To je metoda strojnog učenja koja kombinira nekoliko osnovnih modela i proizvodi optimalan model predviđanja. Analizom slaganja i neslaganja različitih signala percepcije puta, izgradili smo i mjerili samopouzdanje percepcije puta uživo u automobilu, te smo dobili kvalitetniji ukupni rezultat. Ova analiza je prikazana u ovoj vizualizaciji na Slici 16. Kad se komponente signala jako slažu, debela linija koja označava predviđanje središnje staze za datu traku je zelena; kad se ne slažu, postaje crveno.Budući da se pristup temelji na različitosti, kvar na razini sustava bio bi manje statistički vjerojatan, što je iznimno korisno sa sigurnosne perspektive.

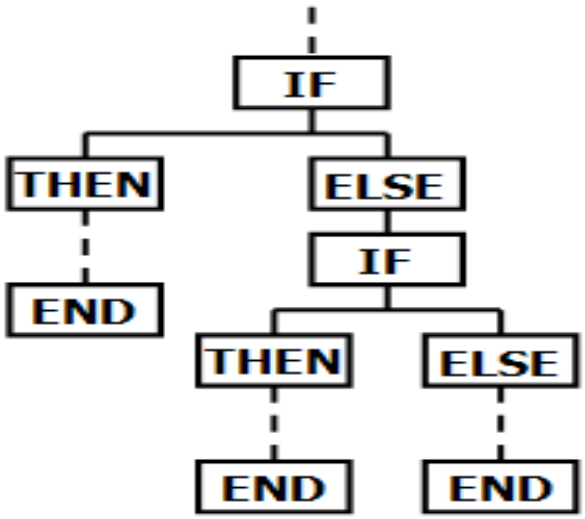
4.5. Primjena umjetne inteligencije i neuronskih mreža

Izvrsna percepcija okoline koju senzori detektiraju i iz nje prikupljaju podatke, uz sofisticirane algoritme umjetne inteligencije koja ih tumači, dopuštaju autonomnim vozilima kvalitetno planiranje i visoku pouzdanost vožnje. Sama ideja razvoja autonomnih vozila temelji se na činjenicama da se takva vozila nikad ne umaraju, kako njihovi algoritmi planiranja mogu izabrati optimalno ponašanje u prometu, i njihovo izvršavanje može biti brzo i besprijekorno, jer im se ni u jednoj situaciji ne povećava vrijeme reagiranja, niti mogu pogriješiti u izvršavanju naredbe kao vozač. Ljudski vid prikuplja sve podatke koje autonomnom vozilu pružaju skupovi senzora. Ljudske kognitivne sposobnosti značajno nadilaze sposobnosti autonomnih vozila [2]. Ljudi također puno bolje tumače i razumijevaju dobivene vizualne informacije. No ipak, ljudski vid i percepcija vizualnih informacija mogu biti ograničeni u određenim situacijama, poput nepovoljnih vanjskih uvjeta, umora, neuroloških problema, ili pod utjecajem različitih opijata. [10]

Autonomno vozilo koristi se raznim metodama i algoritmima kako bi donijelo ispravnu i brzu odluku. Jedno od tih metoda je primjena umjetne inteligencije, metoda zaključivanja i hibridnih neuronskih mreža.

Jedno od osnovnih metoda zaključivanja je metoda AKO-ONDA odnosno IF-THEN. Primjerice, ako se pješak nalazi na pješačkom prijelazu onda zaustavi vozilo ispred pješačkog prijelaza. Naravno, ovo je pojednostavljen primjer, gdje u stvarnosti je to mnogo kompleksnije i znatno je veći broj naredbi i parametara kako bi došlo do donošenja takve odluke.

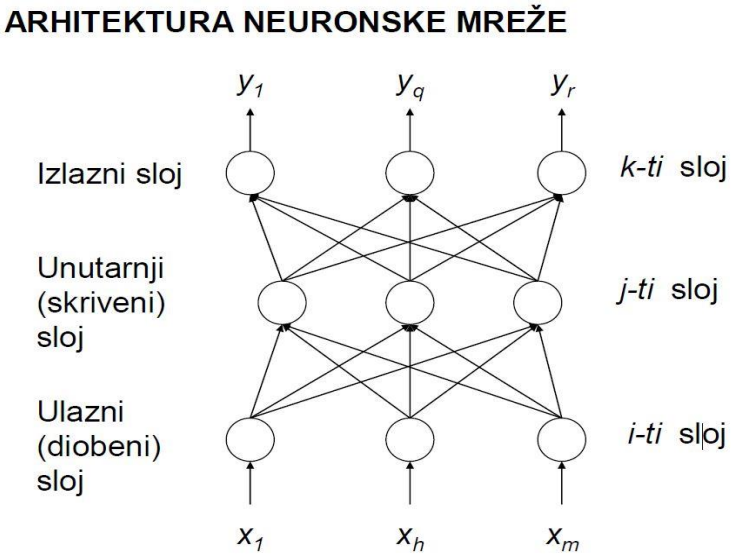
Stupanj više ali i dalje poprilično jednostavan u usporedbi s odlukama koje donosi autonomno vozilo AKO-ONDA zaključivanja bi bilo kada bi ubacili još i uvjet OSIM AKO odnosno izuzetak u zaključivanju prikazano Slikom 17. Primjer bi bio, ako se pješak nalazi na pješačkom prijelazu onda zaustavi vozilo ispred pješačkog prijelaza osim ako se pješak nalazi na drugom kraju pješačkog prijelaza.



Slika 17. Prošireniji oblik AKO-ONDA zaključivanja

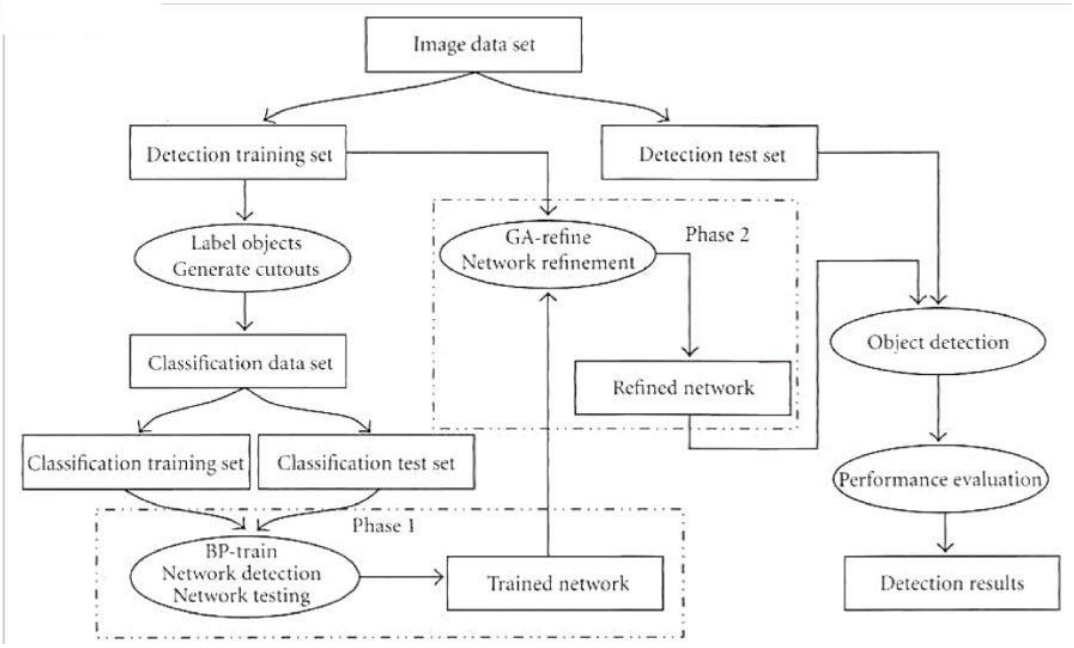
Umjetne neuronske mreže su mreže međusobno povezanih procesnih elemenata čije je ponašanje slično ponašanju biološkog neurona [6]. Neuronske mreže mogu istovremeno obrađivati podatke te imaju mogućnost samostalnog učenja, učenja na temelju iskustva, poopćavanja, odjeljivanje bitnog od nebitnog, prepoznavanje uzoraka itd. Sustav za obradu podataka sastavljen je po uzoru na strukturu mozga, od velikog broja jednostavnih vrlo povezanih procesnih elemenata (umjetnih neurona).

Slikom 18. prikaza je arhitektura neuronske mreže koja se sastoji od ulaznog (diobenog) sloja koje predaje podatke iz okoline neuronskoj mreži, unutarnjeg (skrivenog) sloja koji nije povezan s okolinom i obrađuje ulazne signale, te konačno izlaznog sloja koji predaje obrađene rezultate neuronske mreže okolini.



Slika 18. Arhitektura neuronske mreže [6]

Kombinirana i složena primjena neuronskih mreža i genetskog algoritma u autonomnom vozilu za detekciju objekata i okoline prikazana je Slikom 19. Prvo se primaju ulazni podaci set slika, te se radi trening (učenje) i test nad tim podacima. Treningom se označavaju objekti i generiraju izrezi, te se klasificira taj set podataka. Nad tim setom podataka se opet radi trening (učenje) i test te se otkriva i testira neuronska mreža. Ta testirana neuronska mreža zatim ide na usavršavanje u spoju s genetskim algoritmom. Testirani ulazni podaci i usavršena mreža odlaze na detekciju objekta te se ocijeni performansa i detektira konačni rezultat.



Slika 19. Slijed koraka u detekciji objekta neuronske mreže i genetskog algoritama [6]

Hibridnim inteligentnim sustavima se nazivaju sustavi koji su sastavljeni od više inteligentnih tehnologija popust vjerojatnosti zaključivanja (neizvjesnost), neizrazite fuzzy logike (približno računanje), neuronskih mreža (učenje, prilagođenje), te evolucijskih odnosno genetskih algoritama (optimizacija). Slikom 20. prikazana je primjena hibridnog inteligentnog sustava kao što je autonomno vozilo koje ima mogućnost predvidjeti buduću poziciju nekog objekta ili vozila pomoću detekcije trenutne pozicije i zapažanja brzine kojom se to vozilo kreće, te na temelju same okoline (primjerice: ako se vozilo vozi kroz zagušeno semaforizirano raskrižje sustav to detektira i prilagodi predikciju sukladno tome).



Slika 20. Prikaz trenutne i predviđanje buduće pozicije vozila/objekta [8]

Kombinacija označavanja podataka i prikupljanja podataka predstavlja veliki izazov za autonomni razvoj vozila. Primjenom umjetne inteligencije u ovaj proces moguće je smanjiti vrijeme i troškove utrošene na obuku, a istovremeno povećati točnost mreža.Postoje tri uobičajene metode za odabir DNN (Duboka neuronska mreža) podataka o obuci za autonomnu vožnju. Slučajnim uzorkovanjem izdvajaju se okviri iz baze podataka u jednakim intervalima, hvatajući najčešće scenarije, ali vjerojatno izostavljajući rijetke uzorke. Uzorkovanje temeljeno na metapodacima koristi osnovne oznake (na primjer, kiša, noć) za odabir podataka, što olakšava pronalaženje uobičajenih teških situacija, ali nedostaju jedinstveni okviri koji se ne mogu lako klasificirati, poput prikolice za traktor ili čovjeka na stupovima koji prelaze cestu [8].

Duboke neuronske mreže odgovorne za funkcije samoupravljanja zahtijevaju iscrpnu obuku. U situacijama na koje će se vjerojatno susresti tijekom svakodnevnih putovanja, kao i u neuobičajenim koje se pokušava izbjeći. Ključ uspjeha je osigurati da su obučene za prave podatke. Ti pravi podaci bi bile situacije koje su nove ili neizvjesne odnosno bez ponavljanja istih scenarija iznova.

Aktivno učenje metoda je odabira podataka o obuci za strojno učenje koja automatski pronalazi te raznolike podatke. On gradi bolje skupove podataka u djeliću vremena koje je potrebno ljudima za obradu. Radi tako što koristi obučeni model za pregledavanje prikupljenih podataka, označavajući okvire koje ima problema s prepoznavanjem. Ljudi tada te okvire označavaju, a onda se dodaju podacima o obuci. Takva metoda povećava točnost modela u situacijama poput opažanja objekata u otežanim uvjetima kao što je kiša, magla itd.

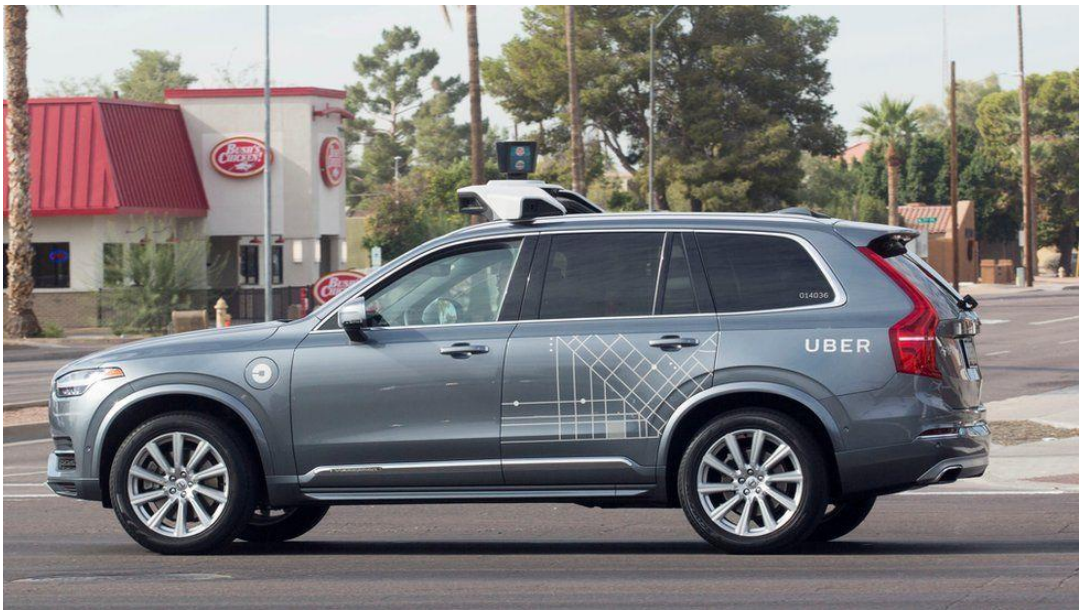
Količina podataka potrebna za osposobljavanje autonomnog vozila je ogromna. Stručnjaci iz RAND -a procjenjuju da je vozilima potrebno 17 milijardi kilometara vožnje da bi radili samo 20 posto bolje od čovjeka. To bi značilo više od 500 godina neprekidne vožnje u stvarnom svijetu s flotom od 100 automobila. Učinkoviti podaci o obuci moraju sadržavati različite i izazovne uvjete kako bi se osiguralo da automobil može sigurno voziti.

Kada bi ljudi zabilježili ove podatke o provjeri valjanosti kako bi pronašli ove scenarije, floti od 100 automobila koja vozi samo osam sati dnevno bilo bi potrebno više od milijun nadzornika za upravljanje kadrovima sa svih kamera na vozilu što je ogroman napor [1]. Uz troškove rada, računski i skladišni resursi potrebni za osposobljavanje DNN -a na tim podacima bili bi neizvodljivi.

5. Razine autonomije i sigurnosni zahtjevi

Kako bi se postigla određena razina sigurnosti prije puštanja vozila na cestu odnosno u promet, mora se napraviti izuzetno velik broj simulacija sa svim mogućim i zamislivim scenarijima koji se mogu desiti u prometu. Tako nešto iziskuje mukotrpan broj sati proveden u simulacijskim programima kako bi se došlo do željene razine sigurnosti i pouzdanosti.

Prva zabilježena nesreća na kameri koja uključuje autonomno vozilo dogodila se u mjestu Tempe u Arizoni (SAD) 2018. godine. Uberovo vozilo koje je u tom trenutku bilo u autonomnom modu te vozač nije bio pri komandama naletjelo je na pješaka koje je guralo bicikl uz sebe prelazeći preko kolnika (nepropisno jer nije bilo pješačkog prijelaza). Postoji i video zabilježen kamerom iz vozila te je vidljivo da je osvjetljenje bilo zaista loše i tek kada je vozilo došlo na par metara od pješaka se isti mogao primijetiti. Uber je objavio da prekida testiranje autonomnih vozila nakon nesreće i da prekida sve vožnje autonomnih vozila diljem SAD-a i Kanade. Na Slici 21. se nalazi Uberovo vozilo koje je počinilo nesreću.



Slika 21. Autonomno Uber vozilo marke Volvo [22]

Uber nije snosio nikakve kaznene prijave s objašnjenjem da nema osnova za kaznenu odgovornost s obzirom da je vozilo bilo u autonomnom modu [22]. Nakon ovakve nesreće pristupalo se s puno većim oprezom i mjerama u razvoju autonomnih vozila te je dana maksimalna važnost na sigurnost i pouzdanost autonomnih vozila. Također, ovom nesrećom i svakom pogreškom autonomnog vozila koja je bila javno eksponirana usporio se razvoj s

obzirom na to da je ovim slučajem stavljeno dosta upitnika poput tko snosi odgovornost prilikom nesreće, je li autonomno vozilo zaista toliko sigurno koliko se pretpostavljalo itd.

5.1. Kibernetička sigurnost i zaštita vozila

Prijetnje kibernetičkoj sigurnosti konvencionalnim vozilima s automatiziranim značajkama već postoje. U istraživanju na 5000 ispitanika u 109 zemalja u istraživanju 2015. godine otkrilo se da su ljudi najviše zabrinuti zbog hakiranja softvera i zloupotrebe vozila sa svim razinama automatizacije. Hakeri bi mogli preuzeti kontrolu nad vozilom putem bežičnih mreža poput Bluetootha, sustava za unos bez ključa, mobilnih aplikacija ili drugih veza, dok se automobil povezuje s okolinom. Svojom sposobnošću pohrane i prijenosa podataka o transakcijama i načinu života, autonomna vozila su privlačna meta hakerima jer se takve informacije mogu prodati radi financijske dobiti ili se ti sustavi mogu koristiti za nanošenje fizičke štete od strane ekstremista ili za prodaju u nezakonite svrhe od strane trgovaca drogom [12]. U studiji 2015. godine pokazali su da su zlonamjerni napadi na autonomna vozila prilično jednostavni u usporedbi s time kakvu štetu mogu nanijeti jer su u toj studiji odnosno istraživanju hakirali Chryslerov Jeep putem njegove internetske veze i preuzeli kontrolu nad njegovim motorima i kočnicama.

S obzirom na to da su vozila s povezivanjem u velikoj mjeri i autonomna vožnja relativno novi, aspekti sigurnosti, povjerenja i privatnosti nisu dobro riješeni. Sigurnost se često promatra kao naknadna misao, a vidljivija je zbog visokoprofilnih napada s različitim motivima, poput zabave, publiciteta, krađe, ometanja operacija itd. Međutim, sigurnost, a posebno privatnost i integritet, kada uključuju interakcije s više dionika , još su u razvoju. Integritet sprječava neovlaštene korisnike da mijenjaju ili krivotvore podatke i jamči da su svi podaci pouzdani, točni, dosljedni i provjerljive kvalitete. Neuspjeh u postizanju integriteta može imati ozbiljne sigurnosne posljedice u cyber-fizičkim sustavima (CPS) jer se podacima i ovisnim uslugama više ne može vjerovati ili se njima može zlonamjerno manipulirati, što dovodi do strašnih odluka i potencijalnih radnji koje ugrožavaju život. Privatnost jamči da se stečeni podaci na odgovarajući način koriste prema namjeni, a iako ih treće strane mogu obraditi, ne smiju iz njih izvlačiti obavještajne podatke. Integritet i privatnost ključni su aspekti koji se odnose na ključne scenarije u hiperpovezanim autonomnim vozilima, ali kako

se povećava složenost, osiguravaju se komponente unutar vozila, kao i pružaju realna rješenja za interakciju vozila s vrijednošću treće strane dodatne usluge smatraju se izazovima [25].

Različite studije analizirale su moguće prijetnje cybersigurnosti na autonomnim vozilima, jer računala imaju veću kontrolu nad kretanjem vozila te su autonomna vozila ranjiviji na hakiranje od konvencionalnih vozila, a vozač je manje sposoban intervenirati tijekom napada. Bez dovoljne sigurnosti, komunikacijski kanali V2V i V2I mogu se hakirati, što može dovesti do ozbiljnih nesreća. Ubrizgavanje lažnih poruka i lažiranje globalnih navigacijskih satelitskih sustava (GNSS) neke su od glavnih prijetnji s kojima će se autonomna vozila suočiti, jer se podacima GNSS-a može manipulirati kako bi se komprimirale sigurnosne kritične funkcije autonomnog vozila. Druge prijetnje uključuju upotrebu senzorne manipulacije za dezorijentiranje sustava vozila, jaka svjetla za slijepe kamere i ultrazvučne ili radarske smetnje za zasljepljivanje vozila od ulaznih prepreka. Iako se mogu instalirati sustavi za otkrivanje takvih kvarova, oni zahtijevaju ažuriranje softvera, kao i promjenu postojećih standardiziranih sigurnosnih arhitektura [9].

Većina vlada razvila je neobavezne smjernice o najboljoj praksi kibernetičke sigurnosti i u svrhu kako bi istražila implikacije autonomnog vozila na kibernetičku sigurnost. Vlade u SAD-u, Kini, EU-u i Singapuru usvojile su strategiju usmjerenu na kontrolu te su uvele ili donijele nove zakone za rješavanje rizika kibernetičke sigurnosti.

U SAD-u, dobrovoljne smjernice NHTSA-e preporučuju proizvođačima i softverskim tvrtkama da dizajniraju AV sustave prema postojećim međunarodnim standard ima, poput onih koje su objavili Nacionalni institut za standarde i tehnologiju, NHTSA, SAE, Savez proizvođača automobila i drugi u 2017. godini. Uspostavljeni su novi odjeli za istraživanje sigurnosti elektroničkih sustava za procjenu i praćenje potencijalnih kibernetičkih ranjivosti, a uspostavljena je i radna skupina unutarnje agencije, vijeće za elektroniku radi poboljšanja suradnje u pogledu istraživanja elektronike i kibernetičke sigurnosti. Ove promjene predstavljaju pokušaje stjecanja veće svijesti i podizanja svijesti o rizicima kibernetičke sigurnosti za proizvođače automobila i softverske tvrtke. Zakon o špijunskim automobilima također je uveden kako bi se poboljšala kontrola kibernetičke sigurnosti i privatnosti za sva vozila. Prema ovom zakonu, kritični i nekritični softverski sustavi u svakom vozilu moraju se odvojiti, a sva vozila će se ocjenjivati primjenom najboljih praksi. Uvode se specifikacije kako bi se osigurala sigurnost prikupljenih podataka u elektroničkim sustavima vozila dok su podaci u vozilu ili u prijevozu iz vozila na drugo mjesto. Također zahtijeva da vozila mogu

trenutačno otkriti, zaustaviti i prijaviti pokušaje hakiranja podataka o vožnji ili preuzeti kontrolu nad vozilom, a od autonomnog vozila mora vidjeti u kojoj mjeri vozilo štiti privatnost i kibernetičku sigurnost potrošača odnosno korisnika.

Kibernetička sigurnost nije nova briga u EU-u. U posljednjih nekoliko godina poduzeli su postupne korake za kontrolu rizika kibernetičke sigurnosti, iako oni nisu specifični za AV. Strategija EU -a za kibernetičku sigurnost uvedena je 2013. godine, a zatim je 2016. uslijedila Direktiva o sigurnosti mrežnih i informacijskih sustava. To je bio prvi zakon o kibernetičkoj sigurnosti u cijeloj EU. Razne organizacije EU -a uložile su daljnje napore u podizanje svijesti i davanje preporuka o tome kako riješiti pitanja kibernetičke sigurnosti. Nezavisno savjetodavno tijelo EU -a za zaštitu podataka i privatnost, Radna skupina za zaštitu podataka, 2016. objavilo je svoje stavove radi podizanja svijesti o razvoju u IoT -u i povezanim sigurnosnim pitanjima.

Kao i europska Opća uredba o zaštiti osobnih podataka, skraćeno GDPR, najnoviji kineski zakon o kibernetičkoj sigurnosti predstavlja strategiju usmjerenu na kontrolu. Ključne odredbe zakona su zaštita osobnih podataka, zaštita kritične informacijske infrastrukture, odgovornosti mrežnih operatora za osiguravanje sigurnosti, očuvanje osjetljivih podataka u Kini, certificiranje sigurnosnih proizvoda i kazne za prekršaje. Jedan primjer odgovornosti operatora mreže uključuje zahtjev da operatori kritične informacijske infrastrukture pohranjuju osobne podatke u Kini i da tvrtke dobiju odobrenje i prođu nacionalne preglede prije premještanja podataka u inozemstvo. Kritična kibernetička oprema i posebni proizvodi za kibernetičku sigurnost mogu se prodati tek nakon dobivanja sigurnosnih certifikata [12]. Vlada Singapura također je izmijenila postojeće zakonodavstvo radi kontrole različitih aspekata rizika kibernetičke sigurnosti. Singapurski zakon o zlouporabi računala i kibernetičkoj sigurnosti izmijenjen je u travnju 2017. kako bi se pojačao odgovor poduzeća na prekršaje povezane s računalom. Poduzeti su i drugi koraci za podizanje svijesti o kibernetičkoj sigurnosti, primjerice putem lokalnih instituta za visoko obrazovanje i stvaranja partnerstva između akademske zajednice i privatnog sektora [9]. Time vlada namjerava to iskoristiti kao priliku da Singapur postane vodeći pružatelj usluga kibernetičke sigurnosti, pokazujući strategiju usmjerenu na prilagodbu; a u planu je i osnivanje nacionalne obrambene cyber organizacije.

Vlada Velike Britanije još nije izvršila pravnu kontrolu nad rizicima kibernetičke sigurnosti autonomnih vozila, ali poduzima korake za povećanje svijesti i jačanje otpornosti

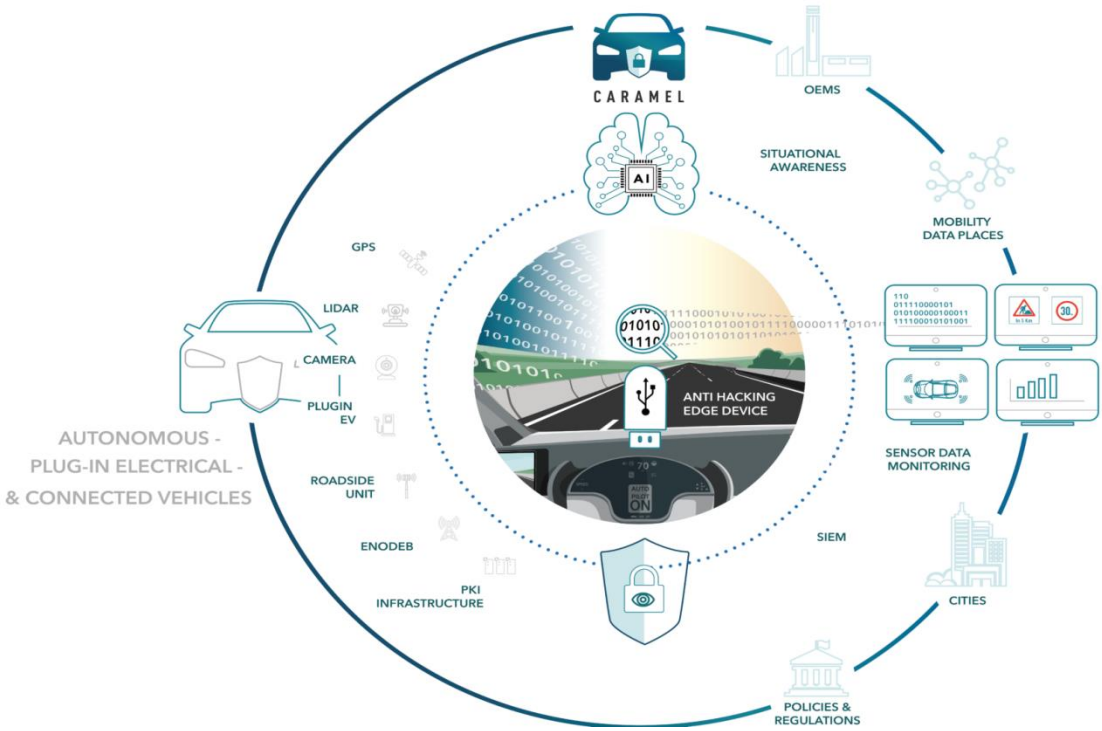
autonomnih vozila na takve rizike. Proveo je dvije strategije kibernetičke sigurnosti koje se primjenjuju na sve cyber sustave u Velikoj Britaniji.

Automatizacija i povezivanje pokreću transformaciju mobilnosti i sve više pretvaraju vozila u računala na kotačima. Kao što su računala meta cyber kriminalaca, tako su i moderna vozila. Automobili se danas sastoje od preko 100 milijuna redaka programskog koda, a broj raste. U nekoliko godina to bi moglo biti više od 300 milijuna linija koda. Za usporedbu, putnički zrakoplov ima procijenjenih 15 milijuna redaka koda, a operativni sustav računala za masovno tržište blizu 40 milijuna. Ova ogromna količina koda u vozilima nudi hakerima brojne mogućnosti za kibernetičke napade [11].

Studija koju su sproveli SAE International i Synopsis pokazala je da je 84% od gotovo 16.000 IT stručnjaka ispitanih u automobilskoj industriji zabrinuto da prakse kibernetičke sigurnosti ne idu u korak s tehnologijama koje se razvijaju. Ipak, 30% ispitanika reklo je da njihova organizacija nema program ili tim za kibernetičku sigurnost, a 63% je testiralo manje od polovice svojih tehnologija na ranjivosti što su poražavajući rezultati [11].

CARAMEL projekt je projekt koji ima za cilj proaktivno rješavanje izazova kibernetičke sigurnosti suvremenih vozila primjenom naprednih tehnika umjetne inteligencije (AI) i strojnog učenja (ML), kao i kontinuirano traženje metoda za ublažavanje povezanih sigurnosnih rizika.

Kako bi se riješila pitanja kibernetičke sigurnosti za već autonomna i povezana vozila, usvajaju se dobro uspostavljene metodologije koje dolaze iz informacijsko komunikacijskog sektora, dopuštajući procjenu ranjivosti i potencijalne učinke kibernetičkog napada [13]. Iako su prošle inicijative i projekti kibernetičke sigurnosti vezani uz automobilsku industriju dosegli okvire osiguranja sigurnosti za umrežena vozila, nekoliko novo uvedenih tehnoloških dimenzija poput 5G -a, autopilota i pametnog punjenja električnih vozila unose praznine u kibernetičkoj sigurnosti, koje još uvijek nisu riješene na zadovoljavajući način.



Slika 22. Arhitektura CARAMEL projekta cyber sigurnosti [13]

Slikom 22. prikazan je ciklus odnosno proces u zaštiti autonomnog vozila protiv hakiranja i napada na vozilu. Autonomno vozilo koje ima razne senzore, kamere i sustave spojene putem interneta, GPS-a te ostalih usluga koristi se enkripcijom odnosno zaštitom putem kriptiranja podataka koje vozilo prima i odašilje. Sustav se koristi umjetnom inteligencijom za prepoznavanje cyber napada te putem kriptografije se zaštićuje protiv takvih napada, jer su to složeni kodovi i načini zaštite koje je skoro pa nemoguće razotkriti i provaliti.

Na elektroničkoj upravljačkoj jedinici (ECU) nema dovoljno računalnih kapaciteta za enkripciju koja bi se inače koristila. To je potencijalna ranjivost te kako bi se zatvorio ovaj pristup, proizvođači i dobavljači sve više koriste fizičke hardverske sigurnosne module (HSM). To su fizički moduli na kojima je ključ izravno pohranjen i koji ga štite i njime upravljaju. Takvi hardverski sigurnosni moduli uskoro će biti sastavni dio svakog ECU -a.

Još jedan od načina zaštite kreiran je putem projekta ADOPT, odnosno tehnologija otvorene platforme za autonomnu vožnju. ADOPT je projekt spreman za kibernetičku sigurnost u svojim ranim fazama inovacija. On prevodi upute za vožnju iz virtualnih aplikacija za vozača (umjetna inteligencija za autonomnu vožnju) u stvarne naredbe o

kretanju vozila i omogućuje kontrolu svih relevantnih sustava za aktiviranje vozila. Rezultirajuća kontrola kretanja vozila izvodi se u skladu s načelima sigurnosti i učinkovitosti [13].

Automobilske tehnologije do sada nisu imale pristup zasnovan na sigurnosti. Industrija sada prepoznaje važnost kibernetičke sigurnosti; međutim, usvajanje sigurnosnih mjera bilo je sporo. Bilježe se dvije trenutne inicijative za standardizaciju zahtjeva koje su posebno vodili UNECE i ISO/SAE.

Radna skupina UN-a za kibernetičku sigurnost i bežični prijenos (OTA), osnovana 2016. godine, radi na uredbi o kibernetičkoj sigurnosti automobila zvana UNECE. Prijedlog uključuje zahtjeve za vozila (poput arhitektonskog dizajna, procjene rizika i ublažavanja sigurnosti) i za sustave upravljanja kibernetičkom sigurnošću (uključujući upravljanje i procese, kulturu i politike kibernetičke sigurnosti te upravljanje i reagiranje na incidente).

Zajednički projekt ISO i SAE započeo je u listopadu 2016. radi standardizacije inženjeringa automobilske kibernetičke sigurnosti. Glavni principi ISO/SAE 21434 usredotočeni su na pristup usmjeren na rizik, kao i procese kibernetičke sigurnosti za sve faze životnog ciklusa vozila: projektiranje i inženjering, proizvodnju, rad, održavanje i servis te stavljanje van pogona. Standard je u obliku nacrta, a još uvijek se očekuje njegov konačni oblik odnosno standard još uvijek nije kompletno završen.

5.2. Rast sigurnosti proporcionalno rastu razini autonomije

Kako bi tehnologija autonomne vožnje napredovala izvan automatizirane potpomognute vožnje, ona mora imati pouzdanu percepciju okružujućih prepreka od 360 stupnjeva. Sposobnost otkrivanja i reagiranja na predmete i objekte svuda po vozilu i oko vozila omogućuje udobno i sigurno iskustvo vožnje.

Zbog pažljivije automatske vožnje, očekuje se da će autonomnim vozilima trebati manje održavanja tradicionalnih dijelova automobila. Međutim, budući da se može očekivati da sami novi senzori trebaju povremeno održavanje, ne pretpostavljamo različite brojke troškova za ukupne troškove održavanja. Na temelju ranijih istraživanja pretpostavljalo se da

će sigurnija vožnja smanjiti stope osiguranja za 50%. Ovo se smatra konzervativnim, jer se izvještava da je današnji Tesla Autopilot već smanjio stope nesreća za 40%.

Još jedan potencijalni ulaz za hakere je sve veća povezanost vozila sa svojim okruženjem. Vozila će biti sve više povezana s drugim vozilima, s prometnom infrastrukturom i s oblakom. V2X komunikacija znatno će rasti s povećanjem automatizacije. Vozila će češće komunicirati sa semaforima, prometnim znakovima, sa stanicama za punjenje i s mobitelima. A upravo su ti infrastrukturni dijelovi uglavnom još uvijek jako loše osigurani. Zbog toga je utoliko važnije zaštititi vozilo od cyber napada izvana, na primjer, vatrozidom.

Tabela 5. prikazuje prioritet različitih pitanja vezanih uz istraživanje ljudskog faktora u kibernetičkoj sigurnosti autonomnih vozila na različitim razinama automatizacije.

Tabela 5. Ljudski faktor u kibernetičkoj sigurnosti po razinama automatizacije [14]

SAE level of automation	(0) No automation	(1) Driver assistance	(2) Partial automation	(3) Conditional automation	(4) High automation	(5) Full automation
Research issue:						
Cybersecurity failure prone people's characteristics	Small	Small	Middle	High	High	Middle
Ways to increase cybersecurity performance	Small	Small	Small	High	High	High
Overtrust to AV	Small	Middle	Middle	High	High	High
Laypeople education	Middle	Middle	Middle	Middle	Middle	Middle
Multitasking acceptability	Small	Middle	Middle	High	High	Small
Cybersecurity defense capability decrease	Small	Small	Middle	High	High	High
Behavior during cyberattacks	Small	Small	High	High	High	High
AV infrastructure companies job requirements	Small	Small	Small	High	High	High
Characteristics of AV cyberattackers	Small	Small	Middle	High	High	High

Kao što je već opisano u radu postoje 6 razina automatizacije vozila od nulte do pete odnosno vozila kojim upravlja čovjek do potpuno automatiziranog vozila. Različita istraživačka pitanja bit će važna u različitim fazama automatizacije autonomnih vozila. Istraživanje ljudskog ponašanja kada se radi o autonomnim vozilima mora istražiti iskustvo autonomne vožnje na običnim ljudima. Potpuno autonomna vozila još nisu rasprostranjena, pa je teško pronaći sudionike u istraživanju. Istraživanja o kibernetičkoj sigurnosti autonomnih vozila bit će prikladnija u budućnosti kada će ljudi redovito koristiti autonomna vozila [14]. Ipak, istraživači bi trebali dati sve od sebe da pronađu ono što je sada moguće, jer vlade i tvrtke trebaju biti pripremljene za budućnost.

U nultoj razini automatizacije gdje vozilom upravlja čovjek i gdje ne postoji nikakva automatizacija vožnje (većina vozila danas u svijetu i dalje) fokus je na sigurnost (ispravnost)

samog automobila i udobnost (doživljaj) vožnje. Primjenjuju se sustavi poput ABS, ECS, kočenja u slučaju nužde i slične tehnologije i uvijek se pokušava da vozilo bude maksimalno ispravno. Sve odluke donosi čovjek i on je odgovoran za cijelu vožnju te bilo kakav udes, iako navedene tehnologije mogu povećavati sigurnost i ugodnost vožnje. U nultoj razini bitno je educiranje ljudi o prometnoj infrastrukturi, znakovima i općenito vožnji i ponašanju (kulturi) u prometu te se time povećava sigurnost vožnje.

Prva razina automatizacije vozila je gdje vozilo samo pomaže vozaču u upravljanju, a sastoji se od nekih funkcionalnosti poput adaptivne kontrole brzine (ACC) gdje vozilo pomaže održavati razmak s vozilom ispred sebe ali vozač i dalje upravlja vozilom i nadgleda okolinu. Tako da prva razina ima veću razinu sigurnosti i pouzdanosti nego li nulta razina jer ima sve funkcionalnosti nulte razine s pojedinim poboljšanjima koje jedino mogu povećati sigurnost i udobnost vožnje, a nikako smanjiti.

Druga razina je djelomična automatizacija vožnje i ona predstavlja do 25 pojedinačnih funkcija koje povećavaju sigurnost, udobnost i učinkovitost vožnje poput pomoći pri upravljanju i zadržavanju traka, usporavanju i ubrzavanju, kako bi se osigurao sigurnosni razmak između vozila, pomoć pri gužvi u prometu i raspoznavanje semafora. Vozač u svakom trenutku može preuzeti kontrolu nad vožnjom. Teslin autopilot je primjer L2 razine autonomije gdje je čovjek i dalje u većinskoj kontroli nad vozilom. U ovoj razini s obzirom na to da je vozilo spojeno na internet i cloud se dolazi do problema kibernetičke sigurnosti i zaštite protiv hakiranja vozila odnosno preuzimanja kontrole.

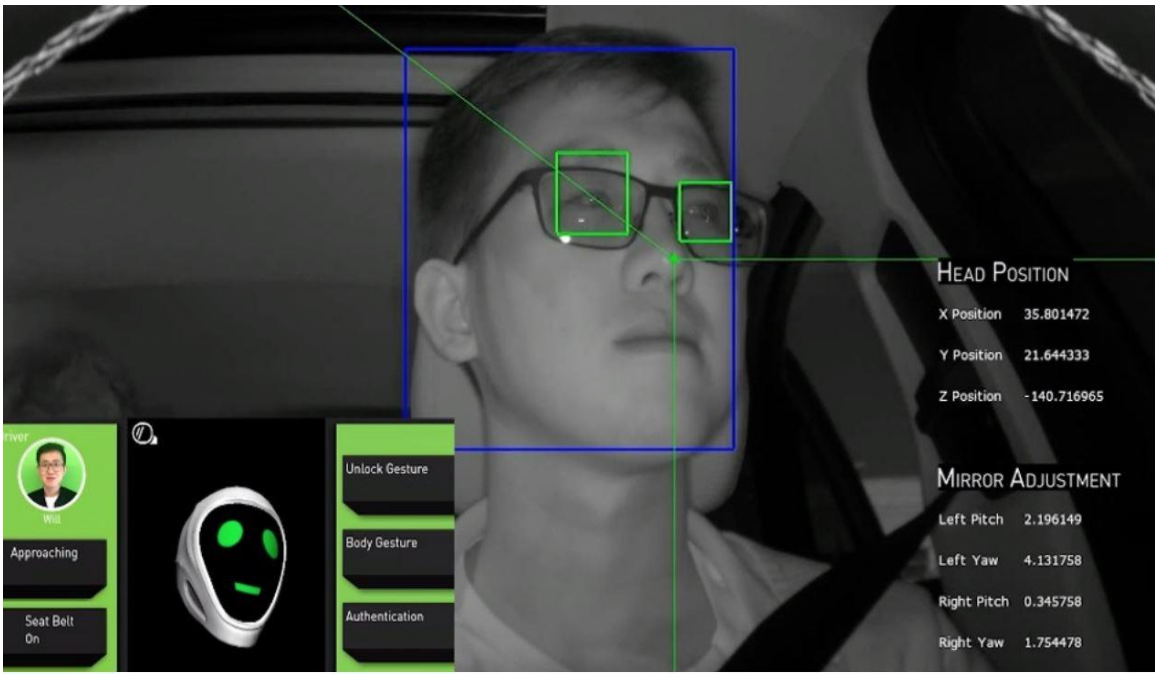
Kod treće razine automatski sustavi svjesni su okoline u kojoj se automobil nalazi, poput prometnica, drugih vozila i objekata. Vozilo je u stanju je preuzeti kontrolu i pretećи i zaobići vozilo koje se kreće usporeno. Vozač u svakom trenutku može preuzeti kontrolu ali vozilo je u većinskoj kontroli. U trećoj razini vozila postaju predmet mogućih cyber napada te je potrebno implementirati i instalirati spomenute sustave protiv zaštite hakiranja i napada na vozilo. Sama udobnost vožnje je povećana jer čovjek ima manju ulogu u vožnji te je samo iskustvo vožnje ugodnije.

Vozila četvrte razine imaju implementiranu visoku razinu autonomnosti. S obzirom na to da vozilo upravlja vožnjom udobnost vožnje je visoka za korisnika jer može za vrijeme vožnje obavljati druge stvari poput čitanja knjige, gledanja na mobitel, obavljanja razgovora i video poziva itd. Vozila četvrte razine koriste aplikacije koje pomažu vozilu (i vozaču)

ekstrahirati, kreirati, pohraniti i konzumirati sadržaj, s obzirom na pohranjenu povijest vožnje vozila, prometne gužve, odabir rute vožnje ili načina parkiranja. Sve te mogućnosti i funkcionalnosti donose velike prednosti ali i potencijalne rizike poput cyber napada. Vozilo i dalje sadrži upravljač i pričuvne kontrole protiv nenadanog otkazivanja sustava ili jednostavno želje vozača u tom trenutku. Sigurnost je drastično povećana jer vozilo prilagođava brzinu prema svom okruženju i predviđa situacije koje se mogu desiti.

Čak i s naprednim sustavima za pomoć vozaču koji automatiziraju više funkcija vožnje, ljudski vozači moraju zadržati pažnju za upravljačem i izgraditi povjerenje u AI sustav. Tradicionalni sustavi za nadzor vozača obično ne razumiju suptilne znakove poput kognitivnog stanja, ponašanja ili druge aktivnosti vozača koja ukazuje na to jesu li spremni preuzeti kontrole vožnje.

Percepcija vozača ključni je aspekt platforme koja autonomnom vozilu omogućuje da vozač bude oprezan i obraća pažnju na cestu. Omogućuje i AI sustavu da izvodi funkcije kokpita koje su intuitivnije i inteligentnije. Sustav primjećuje pažnju, aktivnost, emocije, ponašanje, držanje, govor, geste i raspoloženje vozača s različitim mogućnostima otkrivanja. Izrazi lica složeni su signali za tumačenje. Jednostavna bora na čelu ili pomicanje pogleda mogu imati različita značenja.



Slika 23. Detekcija lica i gestura vozača [8]

Na Slici 23. prikazan je sustav DNN-a koji prati poglede otkrivajući vektor vozačevih očiju i preslikavajući ga na cestu kako bi provjerio jesu li u stanju vidjeti prepreke ispred sebe. Također, nadzire pospanost, klasificirajući jesu li oči otvorene ili zatvorene kako bi odredio razinu iscrpljenosti. Sustav prati i aktivnosti vozača kao što su upotreba telefona, ruke uključene / isključene s kotača i pažnja vozača na događaje na cesti. Isto tako, sustav može otkriti da li vozač pravilno sjedi na svom mjestu kako bi se usredotočio na događaje na cesti. Ovakav sustav idealan je za primjenu u trećoj i četvrtoj razini autonomnosti o povećava sigurnost vožnje.

Peta razina su potpuno autonomna vozila, gdje je vozilo sposobno posve samo obavljati sve funkcije, bez ikakvog sudjelovanja vozača, odnosno, takvo vozilo nema potrebe ni za vozačem niti ima pričuvne ručne kontrole te je vozač u biti suputnik, a ne vozač. Implementacija konačne verzije potpuno autonomnog vozila dovesti će ogromne benefite po pitanju sigurnost i pouzdanosti. Eliminirat će se ljudska pogreška kompletno, ali najveći fokus će biti na zaštiti vozila od napada (jer vozač nije u mogućnosti preuzeti kontrolu u niti jednom trenutku) i samom povjerenju putnika u vozilo.

6. Pregled istraživanja i razvoja autonomnih vozila

Iako optimisti i mnogi analitičari predviđaju da će većina vozila raditi autonomno do 2030. godine većina njih ima financijske interese u autonomnoj industriji vozila, a svoja predviđanja temelje na iskustvu s elektroničkim tehnologijama, kao što su digitalne kamere, pametne telefone i osobna računala, a ne inovacije u motornim vozilima. Motorna vozila su izdržljiva i skupa i korisnici rijetko kupuju nova vozila samo radi stjecanja nove tehnologije, pa je inovacijama općenito potrebno desetljeća za potpuni prodor na komercijalno tržište vozila. Optimisti tvrde da će koristi biti dovoljno velike da opravdaju prerano ukidanje vozila kojima nedostaju sposobnosti autonomne vožnje, ali to se čini malo vjerojatnim pod realnim pretpostavkama o njihovim prednostima i troškovima. Većina objektivnih stručnjaka priznaje da će automatizaciji razine 5 biti potrebno mnogo više godina za razvoj i testiranje. Dosta stručnjaka i inženjera tvrdi da mogu proći čak i desetljeća prije nego što se vozilo može sigurno voziti bilo kojom brzinom na bilo kojoj cesti po bilo kojem vremenu [24]. Trenutno nitko nema rješenje za autonomna vozila koje je dovoljno pouzdano i sigurno da rade u komercijalnoj uporabi.

Toyota i Uber, koji je vodeća globalna kompanija za dijeljenje vožnje, zaostaju u razvoju autonomnih vozila za konkurentima, dok tvrtke poput Wayma i Tesle već u tome području idu punom parom naprijed. Mnogi analitičari smatraju da će privatno vlasništvo nad automobilima u budućnosti dramatično biti smanjeno upravo zbog autonomnih vozila i dijeljenja vožnje.

Velik je broj prepreka i mogućih poteškoća u predviđanju razvoja autonomnih vozila te sama predikcija kao što se može primijetiti je dosta širokog vremenskog razdoblja te najmanje sitnice mogu znatno usporiti i otežati razvoj i konačni cilj autonomnih vozila, a to je komercijalna upotreba i potpuna autonomija.

6.1. Prednosti autonomnih vozila

Brojne su prednosti koje donose autonomna vozila naspram tradicionalnog oblika prijevoza. Smanjen je stres vozača i povećana produktivnost. Vozači se mogu odmarati, igrati i raditi tijekom putovanja. Mobilnost za vozače je povećana, a neovisnija mobilnost za vozače može smanjiti vozačeva opterećenja i potrebe za subvencijama za tranzit. Smanjeni su plaćeni troškovi vozača. Smanjuju se troškovi usluga taksija i vozača komercijalnog prijevoza.Znatno je povećana sigurnost jer potpuno ispravno i funkcionalno autonomno vozilo smanjuje postotak pogreške praktički na nulu. Može se smanjiti rizik od sudara i samim time troškovi osiguranja. Može smanjiti vožnju s visokim rizikom poput prebrze vožnje. Autonomna vozila donose i povećan kapacitet prometa i uštedu troškova. Isto tako, učinkovitiji promet vozila može smanjiti gužve i troškove na cesti. Što se tiče parkiranja, znatno su smanjeni troškovi jer se ujedno smanjuje i potražnja za parkiranjem na odredištima. Uvelike je smanjena potrošnja energije i zagađenje jer se u isto vrijeme i povećava učinkovitost goriva (energije) i time smanjuju emisije. Dolaskom autonomnih vozila znatno bi se povećalo dijeljenje vozila, i ne samo što bi se olakšalo već bi i dijeljenje automobila i dijeljenje vožnje, smanjilo ukupno vlasništvo nad vozilom i putovanja. Pogodnosti i poboljšanja kvalitete života su neograničeni s autonomnim vozilima. Stariji i tjelesni invalidi imali bi neovisnost u mobilnosti.

Prema studiji Sveučilišta u Kaliforniji, ako su automatizirana vozila elektrificirana i u masovnoj uporabi, emisija stakleničkih plinova do 2050. godine bi se mogla smanjiti za čak 80%. Osim toga, kada vozači postanu putnici, putnici će moći produktivno koristiti vrijeme vožnje. Iako je teško argumentirati ovu korist autonomnog vozila, vjerojatni učinak je da će se tolerancija na duge vožnje povećati, uključujući i dnevne vožnje. S obzirom na praktičnost sličnu osobnom vozaču od polazišta do odredišta, nešto što je prije bilo nedostupno za veliku većinu vlasnika automobila, pojedinci mogu jednostavno izabrati da posjeduju automobil bez vozača, a ne ili uz tradicionalni automobil, što znači vlasništvo automobila i korištenje mogli bi nastaviti rasti, a ne padati.

Brzi napredak u tehnologiji autonomne vožnje pokreće pitanje prikladnih operativnih modela za buduća autonomna vozila. Ključna odrednica održivosti takvih operativnih modela je konkurentnost njihovih struktura troškova [5]. Privatni automobili su u vlasništvu privatnih osoba a koriste ih isključivo oni sami, ili njihova obitelj i prijatelji.

Iako su troškovi proizvodnje relevantni za operatore flote kako bi najučinkovitije zadovoljili potražnju, može se pretpostaviti da su cijena i sigurnost ključni atribut izbora načina kupca. Dva pokazatelja mogu se međusobno pretvoriti uzimajući u obzir poreze, naknade za plaćanje i marže. Slično tome, operater može planirati kilometre vozila, dok putnički kilometri uzimaju u obzir reakciju potražnje na uslugu (primjerice popunjenost, prazno putovanje itd.). Također, izravni trošak putovanja operativni je trošak za vožnju od točke B do točke C, dok puni trošak putovanja uključuje i moguće prazno putovanje od točke A do B. Dok prva mjera određuje spremnost kupca da bi platio, operator mora pokriti pune troškove putovanja [5]. Baterija je jedan od glavnih pokretača troškova električnih vozila. Ipak, treba naglasiti da će cijene baterija vjerojatno pasti u budućnosti.

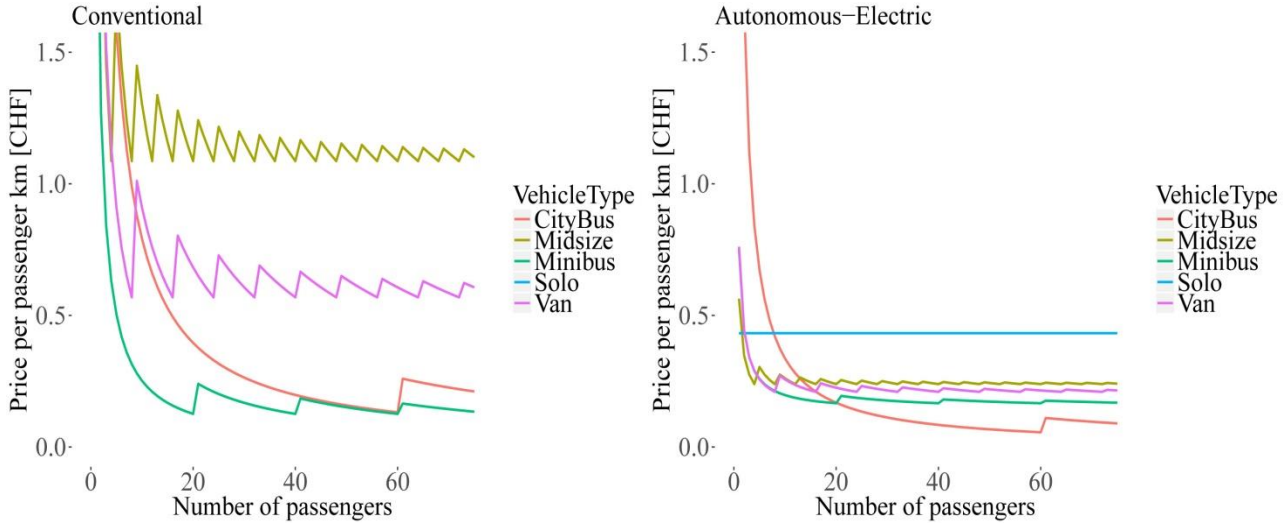
Zbog pažljivije automatske vožnje, očekuje se da će autonomnim vozilima trebati manje održavanja tradicionalnih dijelova automobila. Međutim, budući da se može očekivati da sami novi senzori trebaju povremeno održavanje, ne pretpostavljaju se različite brojke troškova za ukupne troškove održavanja. Na temelju ranijih istraživanja pretpostavljalo se da će sigurnija vožnja smanjiti stope osiguranja za 50%. Ovakav pristup se smatra konzervativnim, jer se izvještava da je današnji Tesla Autopilot već smanjio stope nesreća za 40% [5].

Ne očekuje se da tehnologija automatizacije i električni pogon imaju značajne utjecaje na fiksne i promjenjive troškove javnih autobusnih i željezničkih usluga, jer je tehnologija automatizacije već unaprijed instalirana (u vlakovima) ili ne bi predstavljala značajan rast nabavne cijene vozila (za autobuse). Štoviše, pretpostavlja se da će sustavi i dalje raditi na isti način kao danas, tako da će utjecaj na administrativne troškove biti minimalan. Prosječni trošak po korisniku ovisi ne samo o karakteristikama vozila, već i o učinkovitosti usluge, tj. o iskorištenosti vozila, praznom putovanju i troškovima. Rađeno je istraživanje 2020. godine u Švicarskoj gdje je utvrđeno da prosječni privatni automobil u Švicarskoj košta 0,71 CHF odnosno 5 KN po kilometru.

Automatizacija vozila drastično mijenja strukturu troškova različitih usluga. Općenito djeluju tri učinka: autonomne tehnologije vozila podižu cijenu kupnje vozila, ali s druge strane smanjuju operativne troškove nižim naknadama za osiguranje, održavanjem i troškovima goriva. Uz to, omogućuju taksi flotama da rade bez vozača, smanjujući tako svoju glavnu komponentu troškova.

Podaci pokazuju da su autonomna samostalna vozila najjeftiniji način rada samo za relacije izvor-odredište s niskom potražnjom. Zapravo, kupnja autonomnog vozila mogla bi se smatrati ulaganjem u privatnog robota za mobilnost, koji se može koristiti i za usluge vozača i za obavljanje poslova; ovaj će pothvat stoga biti još privlačniji od konvencionalnog vozila. Stoga se može očekivati da će značajan broj ljudi cijeniti privatnu upotrebu robota za mobilnost i pristat će platiti pripadajuću premiju.

Slikom 24. prikazana je usporedba između tradicionalnog/konvencionalnog oblika prijevoza po broju putnika te autonomnog/električnog oblika prijevoza po broju putnika. Odmah postaje jasno da tehnologije električnog pogona i samoupravljanja omogućuju znatno smanjenje cijena za sve načine rada. Zapravo, najznačajniji dobici postižu se kod dijeljenih vozila srednje veličine, kojima cijena po putničkom kilometru naglo pada za 78%. Zanimljivo je da autonomni električni kombiji (1,47 KN / km) i minibusevi (1,19 KN / km) nisu znatno jeftiniji od vozila srednje veličine kada se rade s punim opterećenjem. Primjerice, podaci pokazuju da su autonomna samostalna vozila najjeftiniji način rada samo za relacije izvor-odredište s niskom potražnjom. S prosječnom zauzetošću dvije osobe na ovoj relaciji, srednji automobil već bi bio učinkovitiji.



Slika 24. Cijene po putničkom kilometru u odnosu na broj putnika [5]

6.2. Tehničko tehnološki izazovi u području autonomne vožnje

U svijetu je dosad napravljen velik broj istraživanja po pitanju autonomnih vozila. Ljudi i javnost još uvijek nisu dovoljno upoznati s autonomnom tehnologijom i samim pojmom autonomnosti. Prilikom provedbe istraživanja i anketa nad ispitanicima, primjećuje se da su ljudi u najvećoj mjeri zabrinuti za posljedice kvara sustava, opreme, ali i same vožnje u potpuno autonomnom vozilu, te za sve vrste prijevoza koje ne bi imale vozača (taksi, javni prijevoz, prijevoz tereta itd.) [10]. U istraživanju većina ljudi je iznijela kako ne bi posjedovala potpuno autonomno vozilo zbog zabrinutosti i straha od hakerskih napada, pravne odgovornosti, moralne upitnosti, privatnosti i sigurnosti.

Neki od nedostataka autonomnih naspram tradicionalnih vozila:

- povećani troškovi vozila,
- zahtijevanje dodatne opreme vozila, usluge i naknade,
- dodatni rizici za korisnike (nenadani pad sustava),
- osjetljivost na zlouporabu podataka (hakiranje),
- smanjena sigurnost i privatnost (praćenje lokacije i dijeljenje podataka),
- povećanje ukupnog putovanja vozilom (veći broj vozila na prometnicama),
- povećani troškovi infrastrukture i zahtijevanje većeg standarda prometnica,
- Smanjenje broja poslova i masovni otkazi (taksisti, vozači kamiona, buseva itd) [2].

LIDAR sustav je i dalje skup i još uvijek pokušava postići pravu ravnotežu između dometa i razlučivosti. Vremenski uvjeti također znatno otežavaju rad autonomnog vozila, primjerice, ako je na cesti sloj snijega, traka postaju gotovo nevidljive. Znatno je otežana orijentacija vozila u takvim uvjetima.

Kako bi se poboljšalo društveno prihvaćanje i tehnologije autonomne vožnje i njezina uporaba u javnosti ceste, bitno je razjasniti sadržaj i pripisivanje pravne odgovornosti u slučaju nesreće kada se koristila autonomna vožnja. S ovog stajališta, pitanje je li vozilo radilo unutar svog ODD-a (u statusu autonomne vožnje) ili ne. Vozilo koje radi unutar ODD-a smatra se autonomnim vozilom razine 4 ili više. Njegov vozač ili sustav je zadužen za same zadatke vožnje ili je upravitelj takvog sustava. Kada autonomno vozilo napusti ODD, ovlaštenje za vožnju mora se vratiti čovjeku odnosno vozaču. Nakon preuzimanja, način

vožnje je na razini 2 ili nižoj, a ako se nakon toga dogodi nesreća, odgovornost pada na operatera koji se klasificira kao vozač u konvencionalnom značenju [19].

Osobu u autonomnom vozilu razine 3 zaista ne treba smatrati vozačem, već kao stanara (putnika) prije nego što se dogodilo preuzimanje. Status putnika trebao bi se promijeniti kada se zatraži preuzimanje kontrole vožnje i kontrola se prenese s autonomnog sustava vožnje na putnika. Iako stalni nadzor uređaja za autonomnu vožnju od strane putnika olakšava prihvaćanje zahtjeva za preuzimanjem, to ne može proizaći iz koncepta putnika na razini 3. Razlog zašto revidirani zakon smatra putnika uvijek kao vozača mogao bi biti taj što inače, kad se prometna nesreća dogodi kao posljedica vozila autonomnog sustava vožnje, nadzirani policijski službenik nema načina znati koga bi trebao ispitati ili uhititi kao odgovornog vozača, što bi moglo otežati brzo donošenje odluka na licu mjesta. Vezano uz ovu točku, revidirani Zakon o prometu trajat će sve dok tehnologija razine 4 ne postigne praktičnu primjenu koja će dalje ovisiti o konceptu ODD-a. Stoga se revizija može smatrati privremenom mjerom za nužno brzo rješavanje primjenjivih pitanja [19].

Primjerice, autonomno vozilo razine 4 približava se pješačkom prijelazu, dok pet osoba ignorira crveno svjetlo na semaforiziranom raskrižju i planira svejedno prijeći preko kolnika. Vozilo može predvidjeti da će udariti pješake ako se nastavi kretati naprijed, što će rezultirati njihovom smrću ili nesrećom. Dakle, sustav razine 4 promijenio bi smjer, skrečući ulijevo (prema pločniku). Slijedom toga, sustav izbjegava udaranje 5 pješaka koji prelaze crvenom bojom, udarajući umjesto toga jednog pješaka koji je hodao kolnikom. Primjera radi, desi se da taj pješak nastrada i umre pri naletu i udaru autonomnog vozila. U ovom primjeru život jednog pješaka žrtvovan je kako bi se spasili životi pet drugih. Ako gledamo sa zakonske strane, došlo je do nezakonite radnje odnosno do ubojstva. To bi bilo jednako ubojstvu da je rezultat odnosno ishod donio vozač. Međutim, za društvo u cjelini spašena su 4 života. Stoga se, iz perspektive aktualnog utilitarizma, ponašanje autonomnog sustava vožnje 4. stupnja ne može smatrati kazneno nezakonitim [19]. To se također temelji na pretpostavci da se umjetna inteligencija (AI) koja kontrolira autonomno vozilo razine 4 smatra kriminalno odgovornom osobom, te da se obrana iz nužde može primijeniti na radnje AI. Međutim, moguća primjena kaznenog zakona na AI pitanje je koje zahtijeva daljnju raspravu. Čak i ako se odbije primjena kaznenog zakona na AI, njegova primjena na stranku (operatori ili korporacije) koji su stvorili AI (ili njezin algoritam) i dalje bi omogućili primjenu obrane nužnosti, donoseći isti zaključak [19].

Ako sustavi umjetne inteligencije ili stranke uključene u njihovo stvaranje (ljudski operateri ili tvrtke) ne podliježu kaznenom zakonu, zabrinutost zbog uporabe sustava autonomne vožnje na umjetnoj inteligenciji na prometnicama (zabrinutost zbog moguće pravne odgovornosti) mogla bi se znatno smanjiti, osobito na strani dobavljača. No, vjerojatno je da žrtve i njihove obitelji ne bi prihvatile ovaj zaključak da nitko nije kriv. Stoga moramo pažljivo tražiti logiku po kojoj obje strane ne bi bile potpuno protiv uporabe autonomnog vozila. Drugim riječima, veliko je pitanje kako se može postići društveno prihvaćanje vozila s autonomnom vožnjom.

Kako bi se olakšalo to pitanje i ta velika moralna dilema, moraju se jasno definirati zakonske regulative i zakoni u slučaju kao što je naveden. Mogle bi postojati dvije mogućnosti koje bi takav AI algoritam odabrao. Prvo je to da se usredotoči na očuvanje života putnika kao preduvjeta za radnje (samoodrživi ili egoistični algoritam), a drugo je odabir opcije s najmanjim učinkom na ljude ili vozila kada je sudar neizbježan (algoritam za smanjenje nesreće ili optimalni algoritam sudara) . U gore spomenutom primjeru, drugi bi se algoritam odlučio sudariti s jednim pješakom. Ako se smatra da je ovaj rezultat intuitivno nepravedan i etički nedopušten većini u društvu, treba razmotriti izmjene. Za provedbu ovih izmjena bilo bi potrebno javno etičko povjerenstvo i demokracija odnosno glas i mišljenje većine.

6.3. Zahtjevi potpuno autonomne vožnje

Sektor autonomne vožnje se oblikuje. Teslina sve naprednija tehnologija u vožnji, za koju je Elon Musk tvrdio da će mu uskoro omogućiti upravljanje flotom robotaxija i opravdati procjenu njegove tvrtke, te s druge strane, tvrtke poput Wayma, Didi ili AutoX koja već upravlja flotama visoke razine autonomnih vozila koje su dio krajolika nekoliko gradova u SAD-u, Kini i Rusiji. Neke tradicionalne tvrtke poput Volva također imaju namjeru upravljati voznim parkom ove vrste ili isporučiti autonomna vozila za ostale konkurente.

Suprotno tome, tvrtke poput GM-a nastoje prodati autonomna vozila izravno javnosti do oko 2030. To zanemaruje stvarnost da neiskorišteni automobili koji većinom koriste njihovi vlasnici oko 3% vremena, dok preostali dio oko 97% , su parkirani u garaži ili na ulici. Ako će ljudi kupovati vozila s tehnologijom autonomne vožnje, tada će troškovi senzora i tehnologije koju koriste morati i dalje padati. LIDAR senzori su doživjeli vrlo strmo

smanjenje cijena i veličine u odnosu na 2015. godinu koja su koštala oko 75.000 američkih dolara na današnjih 100 američkih dolara

Volkswagen vidi budućnost u kojoj su ljudi i dalje u vlasništvu vozila. Međutim, problem s tim scenarijem nije toliko u dostupnosti tehnologije, troškova ili poslovnog modela, koliko u urbanom dizajnu. Recimo u Republici Hrvatskoj jednostavna zamjena klasičnih automobila s autonomnim vozilima ne bi riješila problem gužvi u prometu već bi vjerojatno i donijela dosta nedostataka i izazova.

Tabela 6. prikazuje razna pitanja s kojima se autonomna vozila i infrastruktura autonomnih vozila susreću i s kojima bi se mogla susretati u budućnosti kako bi se postizali ciljevi autonomnog planiranja vozila. Tiču se pouzdanosti i sigurnosti, utjecaja na putovanja i dijeljenje vozila, utjecaj na energiju i emisiju štetnih plinova, regulatornih pitanja i zakonske legislative, utjecaj i sukob mješovitog prometa (autonomnog i neautonomnog) itd.

Tabela 6. Pitanja i problemi autonomnog planiranja vozila

Problem	Potrebna analiza	Potrebna pravila	Vrijeme
Pouzdanost i sigurnost	Procjenjivanje pouzdanosti i sigurnosti. Uspostavljanje regulatornog okvira	Određivanje zahtjeva performansi, ispitivanja i podataka za rad autonomnih vozila na javnim cestama	2020. - 2030.
Sveukupni utjecaji putovanja	Istraživanje promjene putovanja, vjerojatne koristi i troškova	Upravljanje transportom radi smanjenja zagušenja, nesreća i emisija	2020. - 2040.
Utjecaji lokalnih prometnih vozila	Istraživanje promjene u prometu motornih vozila i njihovih utjecaja	Cijene za zakrčenje, ograničenja vozila, prioritet HOV-a i pravila koja favoriziraju zajedničke vožnje	2020. - 2040.
Sigurnost	Istraživanje novih rizika, utjecaj sudara, osobito na druge sudionike u prometu	Reguliranje autonomnih vozila kako bi se osigurala sigurnost za sve sudionike u prometu, održavanje i upravljanje cestama radi sigurnosti	2020. - 2060.
Mobilnost za nevozače	Dostupnost autonomnih vozila za nevozače	Politike koje osiguravaju da autonomna vozila služe osobama s invaliditetom i niskim primanjima	2020. - 2030.
Utjecaji na dijeljenje vozila	Kvaliteta zajedničkih autonomnih vozila i vožnji	Reguliranje i poticanje zajedničkog autonomnog vozila i vožnje	2030. - 2040.
Utjecaji energije i emisije	Vrsta goriva i potrošnja autonomnih vozila, utjecaji na ukupno putovanje vozilom	Poticanje učinkovitih i električnih autonomnih vozila, Smanjivanje ukupnog putovanja vozila	2030. - 2060.

Parkiranje i utovar putnika	Utjecaji na vlasništvo i korištenje vozila, potrebe parkiranja i utovara	Smanjivanje zahtjeva za parkiranje i učinkovito upravljanje parkirališnim i rubnim prostorom	2040. - 2050.
Projektiranje kolnika	Utjecaji na prometnicu i potrebe projektiranja	Mijenjanje dizajna kolnika i stvaranje traka za autonomna vozila, Te određivanje njihove cijene	2050. - 2070.
Plan mješovitog prometa	Stupanj sukoba između autonomnih vozila i drugih sudionika u prometu	Razviti politike i projekte objekata kako bi se sukobi i rizici sveli na minimum	2040. - 2060.
Mandati autonomnih vozila	Potencijalne prednosti ovlaštenja autonomnih vozila	Ako su koristi vrlo velike, zahtijeva se da sva vozila budu autonomna i da se ograničava vožnja ljudi	2060. - 2080.

Do 2050. godine predviđa se da će autonomna vozila:

- smanjiti gužvu u prometu (30% manje vozila na cesti),
- smanjiti troškove prijevoza za 40% (u smislu vozila, goriva i infrastrukture),
- poboljšati prohodnost i sposobnost življenja,
- osloboditi parkirališta za druge namjene (škole, parkovi, društveni centri),
- smanjiti gradske emisije CO2 za 80% širom svijeta.
-

Najveći izazov će biti masovna primjena autonomnih vozila odnosno migracija ljudi s klasičnih vozila na autonomna te izgradnja infrastrukture koja pogoduje autonomnim vozilima. Veliko pitanje o evoluciji prijevoza automobila je hoće li se u budućnosti i dalje kupovati i posjedovati vozilo ili će se jednostavno unajmiti kada to bude bilo potrebno.

7. Zaključak

Čovjekove pogreške su neizbježne, a ljudski faktor je primaran razlog za više od 90% nesreća koje se dogode u prometnom sustavu i to se mora prihvatiti kao trenutna činjenica. Čovjek teži idealu odnosno perfekciji, ali nikada neće biti u mogućnosti doći do te razine. Sporija reakcija, oslabljen vid, slabljenje kognitivnih sposobnosti s godinama, utjecaj vožnje pod alkoholom i opijatima, ubrzana vožnja.To su samo neki od brojnih razloga koji utječu na sveukupnu brojku i na poražavajući postotak nesreća za koje je čovjek odgovoran.

Unazad 100 godina, počele su rane ideje i koncepti tada čineći se futurističkih vozila. Primjenom u to doba dostupnih tehnologija stvarala se vizija o samovozećem automobilu i već tada se govorilo o izbacivanju čovjeka kao vozača iz vozila. Danas, na nekoliko koraka od potpune autonomije, te vizije i ideje postaju stvarnost. Sve spomena vrijedne tvrtke svijeta autoindustrije koje se relevantne imaju svoj centar za razvoj autonomije i automatiziranih vozila. Ulažu se brojna i mukotrpna sredstva, te nebrojeni sati simuliranja i testiranja autonomnih vozila, sve to s jednim ciljem, kako bi se došlo do potpuno funkcionalnog i samostalnog autonomnog vozila koje može u bilo koje doba dana, nezavisno o vremenskim uvjetima, okolini i nenadanim situacijama stići od polazišta do zadanog odredišta. Iako su zadnjih 5 godina predviđanja bila optimistična po pitanju potpune autonomije, taj cilj nažalost, još uvijek nije postignut. Međutim, s trenutno funkcionalnom četvrtom razinom autonomnosti vozila koje su razvile pojedine tvrtke poput Wayma, Argo AI i Motionala, korak nas dijeli od potpune autonomije i do migracije na petu razinu autonomije. Taj korak je zadnji i najteži korak, te iziskuje dosad neviđeni broj uvjeta i propisa koji moraju biti zadovoljeni. Bit će potrebno mijenjanje prometne infrastrukture sukladno promjeni zahtjeva autonomnih vozila. Taj proces podrazumijeva velika novčana ulaganja, konstantno investiranje i održavanje prometne infrastrukture.

Razne su prednosti autonomnih vozila. Smanjenje emisije štetnih plinova, smanjenje broja prometnih nesreća i povećana mobilnost su samo neke od brojnih. Druga i treća razina autonomije su u ovom trenutku u komercijalnoj uporabi, što znači da je djelomična autonomija vožnje već na snazi. Potrebni su brojni senzori, kamere, međusobna povezanost (V2I, V2V,V2X) i algoritmi upravljanja kako bi vozilo ispravno primalo i slalo pouzdane informacije, te obavljalo svoju zadaću bez pogreške. Dolazak i primjena 5G mreže će imati značajnu ulogu u autonomnim vozilima.

Dolaskom sve veće razine autonomije dolaze i sigurnosni problemi poput kibernetičke sigurnosti i hakerskih napada na vozilo. Potrebna je promjena po tom pitanju s obzirom na to da se ne ulažu dovoljna sredstva, a zaštita sustava autonomnih vozila nije u toku sa stupnjem i rapidnim razvojem autonomnih vozila. Kriptografijom i kodiranjem mogu se zaštiti putnici autonomnih vozila, a njihov identitet je potpuno sakriven i zaštićen od krađe podataka i kriminalnih radnji.

Optimistično gledano, potpuno autonomna vozila bit će sigurna i pouzdana do 2025. godine, a do 2030. godine autonomna vozila mogla bi biti komercijalno dostupna i dopuštena za rad u mnogim područjima i gradovima. Realna slika je nešto drugačija gledajući brojne prepreke i izazove s kojima se autonomna vozila susreću. Veliki izazov predstavljaju zakonske regulative i moralne dileme poput pitanja tko snosi odgovornost prilikom nesreće. Analiza u ovom diplomskom radu sugerira da će prije nego što većina vozila postanu autonomna, barem prije nego li budu pristupačna široj javnosti, proći najmanje još 20-ak godina, s obzirom na još i dalje velik broj prepreka i izazova koji nisu razriješeni.. No jedno je sigurno, a to je da svake godine potpuna autonomija u vozilima je sve bliža, te autonomna vozila, prometne infrastrukture i gradovi kreirani prema tim zahtjevima su neizbježni.

Literatura

[1] Herman, A. , Brenner, W. , Stadler, R. : Autonomous Driving: How the Driverless Revolution will Change the World, University of St. Gallen, Switzerland, 2018.

[2] Lawrence D. Burns: Autonomy: The Quest to Build the Driverless Car-And How It Will Reshape Our World, New York, 2018.

[3] Mandžuka, S. : Inteligentni transportni sustavi II - autorizirana predavanja, (Merlin 2020. /2021.)

[4] Vujić, M. : Telematika u prijevoznim sredstvima - autorizirana predavanja, (Merlin 2020. /2021.)

[5] M. Bosch, P. , Becker, F , Becker, H. : Cost-based analysis of autonomous mobility services, IVT, Zurich, 2018.

[6] Edouard, I. : Umjetna inteligencija - autorizirana predavanja, (Merlin 2020. /2021.)

[7] https://asia.nikkei.com/Business/Automobiles/Cheaper-lidar-sensors-brighten-the-future-of-autonomous-cars , pristupljeno u svibnju 2021.

[8] https://www.nvidia.com/en-us/self-driving-cars/drive-videos/, pristupljeno u kolovozu 2021.

[9]https://www.wabco-auto.com/emea/News-Events/News/2020/Addressing-the-Cybersecurity-Risks, pristupljeno u srpnju 2021.

[10] https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775, pristupljeno u svibnju 2021.

[11]https://www.zf.com/mobile/en/technologies/domains/autonomous_driving/autonomous_driving.html, pristupljeno u kolovozu 2021.

[12] https://www.tandfonline.com/doi/full/10.1080/01441647.2018.1494640, pristupljeno u kolovozu 2021.

[13] https://www.h2020caramel.eu/, pristupljeno u travnju 2021.

[14] https://www.frontiersin.org/articles/10.3389/fpsyg.2019.00995/full, pristupljeno u srpnju 2021.

[15]https://edutorij.e-skole.hr/share/proxy/alfresco-noauth/edutorij/api/proxy-guest/4f77c550-2b26-4717-b65e-82b845685f3f/biologija-8/m03/j05/index.html, pristupljeno u lipnju 2021.

[16] https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries , pristupljeno u kolovozu 2021.

[17] Ministarstvo unutarnjih poslova: Bilten o Sigurnost Cestovnog Prometa, Zagreb, 2020.

[18] https://www.enciklopedija.hr/natuknica.aspx?id=42173 pristupljeno u kolovozu 2021.

[19] Imai, T. : Legal regulation of autonomous driving technology: Current conditions and issues in Japan, Hasei University, Tokyo, Japan, 2019.

[20] https://en.wikipedia.org/wiki/History_of_self-driving_cars,pristupljeno u ožujku 2021.

[21] https://www.robsonforensic.com/articles/autonomous-vehicles-sensors-expert/, pristupljeno u svibnju 2021.

[22] https://www.bbc.com/news/technology-54175359, pristupljeno u svibnju 2021.

[23] https://www.iflscience.com/technology/will-self-driving-cars-reduce-energy-use-and-make-travel-better-environment/, pristupljeno u travnju 2021.

[24] Litman, T. : Autonomous Vehicle Implementation Predictions, Victoria Transport Policy Institute, 2021.

[25] Karnouskos, S. , Kerschbaum, F. : Privacy and Integrity Considerations in Hyperconnected Autonomous Vehicles, SAP, 2018.

Popis slika

Slika 1. Širenje i skupljanje zjenica pri izlaganju različitoj razini svjetlosti [15].....5
Slika 2. Modificirani Citroen DS19 iz 1960. godine [20] 16
Slika 3. ParkShuttle u Nizozemskoj [20].....18
Slika 4. Teslin Model [3] 19
Slika 5. Waymo autonomno vozilo [24].....21
Slika 6. Razine autonomije vozila [10] 24
Slika 7. Senzorski sustav autonomnog vozila 28
Slika 8. Prikaz LIDAR-ove detekcije okoline putem laserskih impulsa [8].....29
Slika 9. Širenje naljepnica graničnih okvira za automobile iz domene podataka LIDAR u domenu podataka RADAR [8].....31
Slika 10. Opažanje pješaka putem kamere na pješačkom prijelazu [8].....32
Slika 11. Prikaz percepcije okoline Teslinog autonomnog vozila [8].....33
Slika 12. Prepoznavanje znakova ograničenja brzine [8] 36
Slika 13. Vizualizacija Velodyne LIDAR senzora [8] 36
Slika 14. Lokalizacija autonomnog vozila [8] 37
Slika 15. Detekcija i komunikacija između vozila [8] 39
Slika 16. Prikaz smjera kretanja na kolniku i detekcija vozila i infrastrukture [8].....40
Slika 17. Proširenji oblik AKO-ONDA zaključivanja 42
Slika 18. Arhitektura neuronske mreže [6].....43
Slika 19. Slijed koraka u detekciji objekta neuronske mreže i genetskog algoritama [6].....44
Slika 20. Prikaz trenutne i predviđanje buduće pozicije vozila/objekta [8] 44
Slika 21. Autonomno Uber vozilo marke Volvo [22] 46
Slika 22. Arhitektura CARAMEL projekta cyber sigurnosti [13] 51
Slika 23. Detekcija lica i gestura vozača [8].....55
Slika 24. Cijene po putničkom kilometru u odnosu na broj putnika [5] 60

Popis tablica

Tabela 1. Poredak 10 glavnih uzroka izgubljenih zdravih godina zbog invaliditeta [3].....7
Tabela 2. Prometne nesreće i posljedice kroz godine u RH od 1970. do 2019. godine [17].....9
Tabela 3. Poginule osobe u prometu u RH od 1970. do 2019. godine [17].....10
Tabela 4. Prometne nesreće nastale zbog pogreške vozača, pješaka i ostalih uzroka u 2019. godini [17].....12
Tabela 5. Ljudski faktor u kibernetičkoj sigurnosti po razinama automatizacije [14].....53
Tabela 6. Pitanja i problemi autonomnog planiranja vozila 64

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj Diplomski 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 Diplomskog rada pod naslovom **Sigurnost i pouzdanost autonomnih vozila**

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 10.9.2021

(potpis)