Utjecaj autonomnih vozila na sigurnost cestovnog prometa

Gamilec, Tomislav

Undergraduate thesis / Završni rad

2022

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:119:633304

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

ZAVRŠNI RAD

UTJECAJ AUTONOMNIH VOZILA NA SIGURNOST CESTOVNOG PROMETA

THE IMPACT OF AUTONOMOUS VEHICLES ON ROAD TRAFFIC SAFETY

Mentor: Doc. dr. sc. Željko Šarić

Student: Tomislav Gamilec

JMBAG:0135250498

Zagreb, rujan 2022.

Sveučilište u Zagrebu
FAKULTET PROMETNIH ZNANOSTI
Vukelićeva 4, 10000 Zagreb
PREDDIPLOMSKI STUDIJ

Preddiplomski studij: Cestovni
Katedra: Zavod za prometno tehnička vještačenja
Predmet: Cestovna prijevozna sredstva

ZADATAK ZAVRŠNOG RADA
br. 6720.

Pristupnik: Tomislav Gamilec
Matični broj: 0135250498
Smjer: Cestovni promet

Zadatak: Utjecaj autonomnih vozila na sigurnost cestovnog prometa

Engleski naziv zadatka: The impact of autonomous vehicles on road traffic safety

Opis zadatka:

U radu je potrebno navesti kako su se autonomna vozila razvijala kroz povijest te navesti komponente koje su nužne za njihovo samostalno funkcioniranje. Navesti razine autonomnosti, prednosti i nedostatke autonomnih vozila. Analizirati utjecaj korištenja te tendenciju razvoja.

Nadzorni nastavnik: Predsjednik povjerenstva za završni ispit

Doc. dr. sc. Željko Šarić

Sadržaj

1. UVOD 3
2. POVIJEST AUTONOMNIH VOZILA 5
   2.1. Općenito o pojmu autonomnih vozila 5
   2.2. Povijesni razvoj 6
   2.3. Pregled povijesnih činjenica koje su vodile do razvoja autonomnih prijevoznih sredstava 8
3. PRINCIP RADA AUTONOMNIH VOZILA 9
   3.1. Osnovne značajke autonomnih vozila 9
   3.2. Razina automatizacije inteligentnih vozila 9
   3.3. Upravljački sustavi autonomnih vozila 12
   3.4. Komunikacija autonomnih prijevoznih sredstava 15
4. PREDNOSTI I NEDOSTACI UPORABE AUTONOMNIH VOZILA 16
   4.1. Prednosti autonomnih vozila 16
   4.2. Nedostaci autonomnih vozila 19
5. UTJECAJ KORIŠTENJA AUTONOMNIH VOZILA NA SIGURNOST CESTOVNOG PROMETA 23
   5.1. Pojam sigurnosti cestovnog prometa 23
   5.2. Osnovni čimbenici sigurnosti cestovnog prometa 23
      5.2.1. Čovjek kao čimbenik sigurnosti cestovnog prometa 24
      5.2.2. Vozilo kao čimbenik sigurnosti cestovnog prometa 27
      5.2.3. Cesta kao čimbenik sigurnosti prometa 29
      5.2.4. Čimbenik „promet na cesti“ 31
   5.3. Proporcionalnost sigurnosti i autonomije vožnje 32
6. TENDENCIJA RAZVOJA AUTONOMNIH VOZILA U BUDUĆNOSTI 37
   6.1 Konkurentske prednosti različitih senzora 37
   6.2 Društvene navike 38
   6.3 Ljudska psihologija 39
   6.4 Pravni problem 39
7. ZAKLJUČAK 42

LITERATURA 44

POPIS SLIKA 47

POPIS TABLICA 47

POPIS KRATICA 47

Sažetak:

Autoindustrije sve više teže prema elektrificiranim te automatiziranim prijevoznim sredstvima radi očuvanja prirode, poboljšanja klimatskih uvjeta i komfora vožnje. Uz očuvanje prirode i klimatskih uvjeta, potrebno je voditi računa i o sigurnosti cestovnog prometa kada su u pitanju autonomna vozila. Sve je više pokušaja izrade što većeg stupnja automatizacije vozila (teži se petom stupnju, tj. potpunoj autonomnosti), ali je u ovom trenutku radi postojeće cestovne infrastrukture, cijene potrebnih senzora i ostalih komponenata nužnih za funkcioniranje autonomnog vozila nije pristupačno običnom čovjeku. Veći problem će biti sa dobivanjem povjerenja u autonomna vozila iz razloga što ljudi više vjeruju vlastitim sposobnostima vožnje.

Ključne riječi: autonomna prijevozna sredstva, cestovni promet, senzori, razina automatizacije vozila

Summary:

The car industry is increasingly moving towards electrified and automated vehicles in order to preserve nature, improve climate conditions and driving comfort. In addition to preserving nature and climatic conditions, it is also necessary to take into account the road traffic safety when it comes to autonomous vehicles. There are more and more attempts to create the highest possible level of vehicle automation (the fifth level or full autonomy), but at the moment, due to the existing road infrastructure, the price of the necessary sensors and other components necessary for the functioning of an autonomous vehicle is not affordable for an ordinary person. A bigger problem will be gaining trust in autonomous vehicles because people have more confidence in their own driving abilities.

Key words: autonomous vehicles, road traffic, sensors, level of automation

1. UVOD

Suvremeno društvo karakterizira ubrzani tehnološki razvoj, digitalizacija i globalizacija. Tendencije u daljnjem tehnološkom razvoju u svakoj grani industrije tiču se daljnjeg razvitka robotike i umjetne inteligencije. Kako se u razvoju robotike i njene percepcije kod ljudi već nekoliko godina vidi napredak, na današnji dan već se uzima u obzir i komercijalizacija, kao i korištenje pojedinih strojeva koji se služe umjetnom inteligencijom u okruženju ljudi.

Jedno od ključnih područja za primjenu automatizacije i robotizacije je i područje prometa, odnosno upotreba autonomnih vozila u prometu.

Autonomna prijevozna sredstva jesu motorna vozila koja imaju mogućnost da se samostalno kreću te im vozač nije neophodan. Takvim prijevoznim sredstvima ne nedostaje sposobnost da obavljaju sve funkcije vezane za upravljanje i kretanje koje se inače obavljaju i u komercijalnim vozilima kojima upravlja čovjek. Autonomna vozila imaju i sposobnost da detektiraju odnosno vide okolinu u kojoj se kreću, a „vozač“ je neophodan isključivo za izbor destinacije i nema potrebe da obavlja ikakvu funkciju tijekom vožnje.

Sustav kao cjelina autonomnog vozila obrađuje i interpretira informacije pomoću kojih vrši izbor dopuštene brzine, potencijalnih prepreka na putu, kao i same ceste. Autonomno vozilo može samostalno upravljati pomoću video kamere, radarskih senzora i laserskih daljinomjera na osnovu kojih može i "vidjeti" druge sudionike u prometu. Obradom slike sa video kamera upravljački sustav autonomnog vozila detektira položaj vozila i u suradnji sa drugim senzorskim sustavima spomenuti sustav utvrdi razmak koji postoji između prijevoznih sredstava koje je detektirao, a i relativne brzine među njima.

Uz pomoć tehnologija poput LIDAR, GPS, RADAR i sl. autonomna prijevozna sredstva mogu detektirati ono što se nalazi u njihovoj okolini. Sakupljene senzorne podatke suvremeni upravljački sustavi analiziraju sa ciljem da se ustanovi odgovarajući navigacijski put, uključujući i prepreke i odgovarajuće signalizacije.

Autonomna vozila predstavljaju budućnost prometa. Neke od naprednih tehnologija za pomoć u vožnji već su usvojene. Tu se ubrajaju npr., pomoć pri održavanju trake i prilagodljivi tempomat koji su već potpuno komercijalizirani. Također već je sada u upotrebi automatska vožnja na autocesti, što predstavlja značajan korak prema autonomnoj vožnji. Pretpostavka je

da će se u budućnosti, potpuno autonomno vozilo prihvatiti kao uobičajeni način vožnje i prijevoza.

Naslov završnog rada je: Utjecaj autonomnih vozila na sigurnost autonomnih vozila. Rad se dijeli na sedam cjelina:

1. Uvod
2. Povijest autonomnih vozila
3. Princip rada autonomnih vozila
4. Prednosti i nedostaci uporabe autonomnih vozila
5. Utjecaj korištenja autonomnih vozila na sigurnost cestovnog vozila
6. Tendencije razvoja autonomnih vozila u budućnosti
7. Zaključak

U drugoj cjelini je opisan razvitak autonomnih prijevoznih sredstava. Navedene su tri faze razvitka te povijesni prikaz razvitka autonomnih prijevoznih sredstava.

Treća cjelina opisuje kako autonomno prijevozno sredstvo funkcionira te koje su komponente uopće nužne za samostalno kretanje u prostoru. Nabrojane su i opisane razine automatizacije i arhitektura upravljačkog sustava autonomnih vozila.

Četvrta cjelina obuhvaća prednosti i nedostatke autonomnih vozila.

U petom poglavlju su spomenuti ključni faktori sigurnosti cestovnog prometa, a to su cesta, čovjek i vozilo. Za čovjeka kao sudionika opisano je što utječe na njegovo ponašanje u prometu. Za vozilo su navedeni aktivni i pasivni elementi sigurnosti, te su također za cestu navedeni čimbenici sigurnosti prometa.

Šesta cjelina govori o budućem razvitku autonomnih vozila te se spominju određene prepreke za komercijalizaciju autonomnih vozila.

2. POVIJEST AUTONOMNIH VOZILA

2.1. Općenito o pojmu autonomnih vozila

Sam pojam autonomnih vozila podrazumijeva autonomno kretanje vozila odnosno samostalno kretanje vozila bez vozača. Autonomno vozilo predstavlja krajnji stupanj razvoja inteligentnih vozila koja „podrazumijevaju primjenu informacijskih, komunikacijskih i upravljačkih tehnologija kako bi se povećala učinkovitost vozača“[1] odnosno u krajnjem slučaju, kao kod autonomnih vozila, omogućilo potpuno autonomno kretanje vozila bez vozača. Da bi se vozilo moglo kretati autonomno, nužna je opremljenost vozila različitom senzorskom tehnologijom potrebnom za prepoznavanje okoline u kojoj se vozilo nalazi, kao i sustavom za navigaciju.

Sama tehnologija autonomnih prijevoznih sredstava daje mogućnost za temeljnu i potpunu promjenu prometnog sustava. Autonomna vozila predstavljaju sasvim novi oblik pokretljivosti, ali kao i pri implementaciji raznih suvremenih tehnologija, postoje prednosti i nedostaci njihove upotrebe. „Prikladne strategije i zakoni mogu povećati potencijalne koristi povezane s brzim razvojem autonomnih vozila i minimizirati rizike povezane s tehnološkim smetnjama kao i negativne i nenamjerne posljedice.”[2]

[1] Ezgeta,D.: Inteligentni transportni sustavi, Univerzitet u Sarajevu, Fakultet za saobraćaj i komunikacije, Sarajevo 2018, str.103

[2] Taeihagh, Araz; Lim, Hazel Si Min: Governing Autonomous Vehicles: Emerging Responses for Safety, Liability, Privacy, Cybersecurity, and Industry risks. Transport Reviews

2.2. Povijesni razvoj

Razvitak autonomnih prijevoznih sredstava povezan je sa suvremenim društvom, to jest sa modernim vremenom, ali prvi oblici razvoja automatiziranih vozila javljaju se već u 20. st. Može se reći da je povijesno gledano, razvitak autonomnih prijevoznih sredstava izvršavao se u tri faze:

1. **faza temeljnog istraživanja**
   - uz surađivanje sa transportnim agencijama, centri za istraživanja rade na jednostavnijim studijama autonomnog transporta.
   - od 1980. do 2003. godine
   - „izdvajaju se dva ključna tehnološka koncepta“[3]:
     - razvoj autonomnih sustava prilagođenih uvjetima na cesti, pri čemu vozila najviše ovise o infrastrukturi ceste koja im služi za usmjeravanje.
     - razvoj autonomnih vozila koja bi funkcionirala u djelomičnoj ovisnosti o infrastrukturi ceste ili u potpunosti bez njene pomoći

2. **faza velikih izazova**
   - od 2003. do 2007. godine
   - Agencija za obrambene napredne istraživačke projekte američkog Ministarstva obrane (eng. Defense Advanced Research Projects Agency - DARPA) temeljni je pokretač unaprjeđenja tehnologije autonomnih vozila[4] istražujući potencijal da se autonomna prijevozna sredstva upotrebe u vojne svrhe.

3. **faza komercijalnog razvitka**
   - „pokrenuti su brojni programi s ciljem unaprjeđenja tehnologije autonomnih vozila među kojima su najvažniji Kolaborativni istraživački laboratorij za autonomnu vožnju (eng. Autonomous Driving Collaborative Research Lab), partnerstvo između General

[3] Maurer M., Gerdes C., Lenz B., Winner H.: Autonomous Driving: Technical, Legal and Social Aspects, 2016.
[4] Buehler M., Iagnemma K., Singh S.: The DARPA Urban Challenge: Autonomous Vehicles in City Traffic, Springer Tracts in Advanced Robotics series, 2010.

Motorsa i Sveučilišta Carnegie Mellon te partnerstvo između Volkswagena i Sveučilišta Stanford.“[5]

[5] Carnegie Mellon University, General Motors–Carnegie Mellon Collaborative Research Labs; http://www.cmu.edu/corporate/partnerships/gm-lab.shtml

2.3. Pregled povijesnih činjenica koje su vodile do razvoja autonomnih prijevoznih sredstava

„Povijesni prikaz razvitka autonomnih prijevoznih sredstava“[6]:

- 1925. godine Francis P. Houdina razvio je vozilo upravljano radio kontrolom
- 1939. godine General Motors je predstavio ideju električnih automobila upravljanih uz pomoć elektromagnetskog polja
- 1953. godine Radio Corporation of America proizveo je automobil kojim se upravljalo žicama položenim na laboratorijskom podu
- 1960-ih godina razvijena su eksperimentalna vozila koja su vozila bez vozača, a njima se upravljalo pomoću električnih uređaja
- 1970-ih godina Bendix Corporation razvio je i testirao automobil kojim se upravljalo zakopanim kablovima i komunikatorima bez prisustva vozača
- 1980-ih Mercedes Benz je razvio robotski kombi i testirao ga na cesti bez prometa
- 1994. godine dva robotska vozila testirana su na više od 1000 km autoceste s gustim prometom
- 2000. godine američka vlada financirala je autonomna vozila za vojne svrhe
- 2009. godine Google je započeo privatno istraživanje o autonomnim vozilima
- 2010. godine ista istraživanja započele su i veće automobilske kompanije (Ford, Mercedes Benz, BMW , Audi, Toyota, Nissan i Volvo)
- 2012. godine Volkswagen je razvio privremeni autopilot
- 2013. godine Toyota je razvila autonomno vozilo sa senzorima i sustavom za komuniciranje
- 2014. godine Tesla je razvila prvu verziju autopilota
- 2015. godine Volvo je razvio autonomno vozilo razine 3
- 2017. godine Audi je započeo razvoj modela A8 sa svim autonomnim opcijama
- 2020. godine sve automobilske kompanije pokušavaju razviti autonomno vozilo razine 5

Tesla je najpoznatije autonomno vozilo, a još nisu kreirali prijevozno sredstvo 5 stupnja autonomnosti.

[6] Raviteja,T., Vederaj, R.: An Introduction of Autonomus Vehicle and A Brief Survey, Journal of Critical Reviews, 7.13, 2020

3. PRINCIP RADA AUTONOMNIH VOZILA

3.1. Osnovne značajke autonomnih vozila

Prvi korak ka autonomnim prijevoznim sredstvima sastoji se u tome da njima bude poznato njihovo okruženje. U tu svrhu, takva prijevozna sredstva se mogu služiti brojnim komponentama i senzorima te pomoću informacija prikupljenih uz pomoć senzora i ostalih tehnoloških komponenti, uspješno manevrirati cestama. „Komponente autonomnih vozila uključuju razne senzore poput radara, lidara, sonara, GPS-a, odometrije i inercijalnih mjernih jedinica.“[7] Osim toga, kako bi se kreiralo što uspješnije i sigurnije prijevozno sredstvo, kao i promet, u upotrebi su složeni algoritmi, sustavi strojnog učenja i snažni procesori.

Osnovno načelo funkcioniranja autonomnih vozila je „osjeti-planiraj-djeluj“ koje je ujedno i ključni element mnogih robotskih sustava. „Autonomno vozilo najprije sa skupom senzorskih sustava koje posjeduje prikuplja podatke o vanjskom svijetu i vlastitoj okolini. Zatim, naprednim algoritmima obrađuje prikupljene podatke i prema tome izrađuje planove o odlukama koje treba donijeti. Ti se planovi mijenjaju u djelotvorne naredbe za upravljački sustav vozila. Navedene naredbe mogu biti vezane za upravljač, kočnice, tempomat ili sličan sustav.”[8]

3.2. Razina automatizacije inteligentnih vozila

Prema taksonomiji i definiciji pojmova koji se odnose na sustave automatskog upravljanja cestovnih vozila, međunarodno udruženje automobilskih inženjera *Society of Automotive Engineers* - SAE[9] je izvršilo podjelu automatizacije upravljanja vozilom na šest razina:

- **razina 0** – **neautomatizirana vožnja** – Vozilo koje nema nikakvu automatiziranost. Vozač upravlja sa svim komandama potrebnim za ubrzavanje kočenje i upravljanje vozilom.

[7] Bosnjak, I.; Inteligentni transportni sustavi 1. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.
[8] Maurer M., Gerdes C., Lenz B., Winner H.: Autonomous Driving: Technical, Legal and Social Aspects, 2016.
[9] Society of Automotive Engineers:Taxonomy and Definitions for Terms Related to On-Road Automated Vehicles, SAE document J3016, 2014, str.16

- **razina 1** – **pomoć vozaču** - kroz tzv. „hands on“ sustav podrške koji prijevoznom sredstvu pruža mogućnost upravljanja ili kočenja i ubrzavanja, međutim, uz kontrolu vozača (npr. tempomat i sustav za održavanje u traci).

- **razina 2** – **djelomična automatizacija** - tzv. “ hands off “ sustav pomoći gdje oba zadatka vožnje iz prethodne razine obavlja vozilo dok je vozač i dalje odgovoran za nadgledanje vožnje i mora biti pripravan intervenirati u bilo kojem trenutku ukoliko automatizirani sustav ne reagira pravilno.

- **razina 3** – **uvjetna automatizacija** - tzv. „eyes off“ – vozaču se pruža mogućnost da ne obraća pažnju na zadaću vožnje jer prijevozno sredstvo samo upravlja svojom putanjom.
- funkcionira samo u slučaju manje kompliciranih i odlično referenciranih ruta, zbog čega vozač još uvijek mora biti spreman za djelovanje u određenoj situaciji.

- **razina 4 – visoka automatizacija –** tzv. „mind off“ - za sigurnost se nikada ne zahtijeva pozornost vozača. Samovožnja je podržana samo u ograničenim prostornim područjima ili u posebnim okolnostima, a izvan ovih područja vozilo mora biti u mogućnosti samo prekinuti putovanje.

- **razina 5 – potpuna automatizacija – tzv.** „steering wheel optional“, gdje se ne zahtjeva da vozač bude prisutan za komandama vozila. Jedina radnja koju vozač-putnik mora napraviti je zadati vozilu odredište putovanja.

Razine automatizacije prikazane su u tablici 1. u nastavku.

Table 1. Razina automatizacije inteligentnih vozila

Razine	Tip automatizacije	Primjer	Mjesto korištenja	Prestanak rada sustava AV
	Vozač upravlja svim ili dijelom zadataka vožnje			
0	Bez automatizacije	Automatizacija nije prisutna nigdje	Nije primjenjivo	Nije primjenjivo
1	Vozačevo sudjelovanje	Prilagodljivi tempomat ili sustav održavanja u traci	Određene ceste	Vozač i dalje upravlja svim bitnim zadatcima vožnje
2	Djelomična autonomnost	Prilagodljivi tempomat i sustav održavanja u traci	Određene ceste	Vozač i dalje upravlja svim bitnim zadatcima vožnje
	Sustavi autonomne vožnje upravljaju svim zadatcima vožnje			
3	Uvjetna autonomnost	Automatizirana vožnja na autocestama	Određena područja i ceste	Vozač preuzima kontrolu nakon upozorenja
4	Visoka autonomnost	Automatizirana vožnja u centru grada	Određena područja i ceste	Sustavi autonomne vožnje sigurno zaustavljaju vozilo
5	Potpuna autonomnost	Automatizirana vožnja svugdje	Svugdje na cesti	Sustavi autonomne vožnje sigurno zaustavljaju vozilo

Izvor: Rajasekhar MV, Kumar Jaswal A: Autonomous Vehicles: The Future Of Automobiles

3.3. Upravljački sustavi autonomnih vozila

Arhitektura upravljačkog sustava autonomnog vozila petog stupnja autonomnosti prema SAE klasifikaciji već je definirana te je podijeljena u četiri dijela koja se sastoji od[10]:

- senzorskih sustava,
- klijentskih sustava,
- akcijskih sustava,
- korisničkih sustava

Senzorski sustavi se sastoje od različitih senzora čija je zadaća prikupljanje podataka iz okruženja prijevoznog sredstva u realnom vremenu. „Podaci koje senzori prikupe koriste se za percepciju, planiranje rute, izračunavanje udaljenosti od prepreka ili za navigaciju."[11] Postoji i podjela senzora upravljačkih sustava autonomnih prijevoznih sredstava na senzore kratkog dometa i senzore srednjeg ili dugog dometa. "Senzori kratkog dometa su ultrazvučni senzori, kapacitivni senzori ili infracrveni senzori dok su senzori dugog dometa RADAR, LIDAR, računalni vid i GPS."[12]

LIDAR (eng. Light Detection and Ranging) sustavi služe kako bi se odredila distanca do prepreka laserima koji su kreirani tako da emitiraju zrake svjetlosti i procjenjuje vrijeme koje je potrebno da se refleksija od objekata u okruženju vrati. "Prilikom prepoznavanja objekta LIDAR stvara detaljnu trodimenzionalnu mapu terena pomoću koje vozilo može razlikovati različite objekte (automobile, kamione, bicikle, itd.) i ovisno o tome reagirati na odgovarajući način. Nedostatak im je što su manje korisni na velikim dometima i loša refleksija na određenim materijalima."[13]

RADAR (eng. Radio Detecting and Ranging) upotrebljava radio valove. Oni odlično uočavaju metalne konstrukcije; međutim, ne vide objekte koji nisu metalni. "Nakon što radar zaprimi reflektirani signal on dobije informaciju koliko je zapravo objekt ili prepreka udaljena od radara i koliko se brzo kreće te time prati brzine drugih vozila koja ga okružuju u stvarnom vremenu."[14]

[10] Liu, S., Tang, J., Zhang, Z.: Computer architectures for autonomous driving, IEEE Comput. Archit. Lett., 2017
[11] Anderson J., Kalra N., Stanley K., Sorensen P., Samaras C., Oluwatola O.: Autonomous Vehicle Technology; A Guide for Policymakers
[12] Maurer M., Gerdes C., Lenz B., Winner H.: Autonomous Driving: Technical, Legal and Social Aspects, 2016
[13] Kočić J., Jovičić N., Drndarević V.: Sensors and Sensor Fusion in Autonomous Vehicles, 2018.
[14] Ibid.

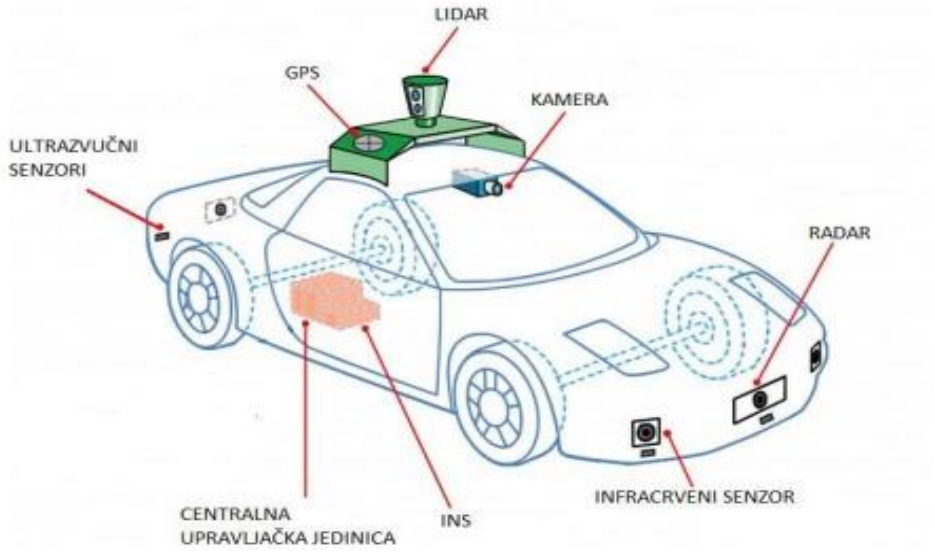
Računalni vid predstavlja znanstvenu i tehnološku disciplinu koja služi izvlačenju informacija iz fotografija (iz jedne ili nekoliko slika ili video uradaka). Zadatak računalnog vida je identificiranje objekata, njihovo nadziranje, detektiranje već određenih situacija, rekonstrukcija fotografija, itd.[15] U autonomnim vozilima koristi se osam ili više kamera koje služe za prepoznavanje objekata, praćenje putanje u voznoj traci, svjetlosnih signala i sličnih ulaznih podataka.[16]

U upotrebi su, između ostalog, i sustavi senzora za lokalizaciju, ili, jednostavnije rečeno, definiranje vlastitog položaja na planeti. Za to je najbitnija upotreba Globalnog sustava pozicioniranja (eng. Global Positioning System - GPS). **GPS sustavi vozila** "primaju signale sa orbite satelita koji orbitiraju oko triangulacije njihovih globalnih koordinata. Te su koordinate umrežene s mapama cestovne mreže kako bi se vozilima omogućilo prepoznavanje njihovog položaja na cestama."[17]

Uz GPS se obično koristi i inercijalni navigacijski sustav (eng. Inertional Navigation System - INS) kako bi se umanjila greška pri lokalizaciji. INS "se sastoji od žiroskopa i akcelerometara, radi kontinuiranog izračuna položaja, orijentacije i brzine vozila."[18]

Iako prethodno spomenuti senzori daju uvid u razne vrste informacija, oni imaju ograničenja koja imaju veze sa vidnim poljem, radnim uvjetima okruženja i okolnim elementima koje može detektirati. Na slici 1. vidi se shema senzora koje posjeduje autonomno vozilo koji su potrebni da bi vozilo moglo samostalno upravljati.

[15] Kočić J., Jovičić N., Drndarević V.: Sensors and Sensor Fusion in Autonomous Vehicles, 2018.
[16] Autonomous Vehicles_CSS16-18_e2021.pdf
[17] Varghese J., Boone R.: Overview of Autonomous Vehicle Sensors and Systems, 2015.
[18] Anderson J., Kalra N., Stanley K., Sorensen P., Samaras C., Oluwatola O.: Autonomous Vehicle Technology; A Guide for Policymakers



Slika 1. Prikaz senzora na autonomnom vozilu

Izvor: PRIMJENA AUTONOMNIH VOZILA U KRIZNIM SITUACIJAMA Mandžuka, S., Vučina, A., Škorput, P.

Klijentski sustav predstavlja mozak autonomnog prijevoznog sredstva. Njegova zadaća je da obradi sve prikupljene podatka te izdvoji najvažnije informacije da se može interpretirati okruženje, identificira položaj prijevoznog sredstva, ali da se, također, donese odluka o narednim potezima tokom vožnje.[19]

Akcijski sustav je mehanički dio autonomnog prijevoznog sredstva (primjeri takve vrste sustava mogu biti upravljač, pogonski i kočioni sustavi) koji u stvari i izvršava naredbe koje je poslao klijentski sustav, te stoga služi za usmjeravanje autonomnog prijevoznog sredstva.[20]

Korisnički sustavi predstavljaju kombinaciju hardvera i softvera koja vozaču pruža mogućnost razmjene informacija sa autonomnim prijevoznim sredstvom u realnom vremenu. Interakcijom s korisničkim sustavom putnik može dobivati informacije o kvaliteti, performansama vožnje te također može zatražiti od autonomnog vozila da obavlja određene zadatke unoseći zahtjeve.[21]

[19] https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775, pristupljeno: 1.8.2022.
[20] Ibid.
[21] Ibid.

3.4. Komunikacija autonomnih prijevoznih sredstava

Kooperativnost autonomnih prijevoznih sredstava je od ogromne važnosti da bi se ostvario njihov cjelokupan potencijal. Pri tom komunikacija između vozila i infrastrukture (eng. Vehicle to Infrastructure - V2I) i vozila među sobom (eng. Vehicle to Vehicle - V2V) je vrlo bitno za kooperativnost autonomnih prijevoznih sredstava. Osim toga, V2X (eng. Vehicle to Everything) ili komunikacija između vozila i cjelokupne njegove okoline koja mu može biti izvor podataka postaje od velike važnosti u posljednje vrijeme.[22]

Komunikacija između vozila i infrastrukture (V2I) neophodna je kako bi se upravljalo prometom i koordinirala autonomna prijevozna sredstva. "Nadzorni sustavi instalirani na infrastrukturi moraju prikupljati globalne i lokalne podatke o stanju u prometu, uvjetima kolnika i slično. Nakon što se ti podaci analiziraju u stvarnom vremenu (u centru za upravljanje prometom ili u oblaku), koriste se u osnovnim modelima protoka prometa te se specifične radnje primjenjuju na određenoj grupi vozila. Prethodno spomenuto međudjelovanje infrastrukture i prijevoznog sredstva ima potencijal da unese velike promjene u buduće okruženje. Podaci sakupljeni uz pomoć infrastrukture bit će direktno preneseni kontroli prijevoznog sredstva uz podršku bežičnih komunikacijskih sustava kratkog dometa da bi se postigla optimizacija brzine, optimalan razmak između vozila, itd."[23]

Komunikacija između vozila (V2V) omogućuje obližnjim vozilima međusobno povezivanje te razmjenu informacija. "Autonomna vozila razmjenjuju informacije lokalno omogućujući koordinaciju njihovih procesa odlučivanja s ciljem 'glatkoga prometa'. U ovom su slučaju autonomna vozila ujedno i nadzorni elementi, a struktura upravljanja prometom je potpuno decentralizirana"[24]

Razvitak autonomnih prijevoznih sredstava i njihova primjena bitno će utjecati i na upravljanje prometom koje će se u budućnosti oslanjati na kombinaciju informacija iz interakcije prijevoznog sredstva i infrastrukture i prijevoznih sredstava jednih sa drugima. Neophodno je i da postoji zajednički model za komunikaciju između uprava, tehnoloških tvrtki i kompanija koje proizvode vozila da bi se stvorila mogućnost za sve vrste potencijalnih interakcija.

[22] https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775, pristupljeno: 1.8.2022.
[23] Ibid.
[24] Ibid.

4. PREDNOSTI I NEDOSTACI UPORABE AUTONOMNIH VOZILA

Mišljenje većine analitičara je kako će veliki dio prijevoznih sredstava do 2030. godine preći na autonomni režim rada. Takvim inovativnim rješenjima najčešće su neophodna desetljeća za apsolutni uspon na komercijalnom tržištu prijevoznih sredstava iz razloga što su motorna vozila dugotrajna i skupa, zbog čega vozači izbjegavaju nabavljati nova samo kako bi iskusili najnovije tehnologije. No još uvijek nije poznato rješenje odnosno model autonomnog vozila koji je dovoljno pouzdan i siguran da je zadovoljio uvjete za komercijalnu proizvodnju i potpunu autonomiju.[25]

4.1. Prednosti autonomnih vozila

Prednosti autonomnih prijevoznih sredstava naspram klasičnih vrsta vozila su mnogobrojni. Anksioznost korisnika takvih vozila se reducira, dok se produktivnost povećava. Vozačima je omogućeno da se opuštaju, igraju i rade dok putuju. Uvećana je mobilnost za vozače, a poznato je da samostalnija pokretljivost vozača ima tendenciju da umanji njihova opterećenja i potrebe za subvencijama za tranzit. Dolazi i do umanjenja troškova usluga kao što je taksi, kao i vozača komercijalnog transporta. Znatno se poboljšava sigurnost zato što kompletno ispravno i funkcionalno autonomno prijevozno sredstvo reducira vjerojatnost nepravilnosti skoro na nulu. Naknade za osiguranje se mogu umanjiti iz razloga što se umanjuje rizik od sudara. Smanjuje se i visokorizična vožnja poput vožnje velikom brzinom. Još jedan od prednosti autonomnih prijevoznih sredstava je uvećan obujam prometa, smanjenje zagušenja i smanjenje potrošnje. Potrošnja energije i zagađenje se također dosta smanjuju, iz razloga što se paralelno uvećava učinkovitost goriva (energije), što dovodi do jasnog smanjenja emisije. Kada bi autonomna prijevozna sredstva stupila u upotrebu osjetno bi se uvećala i učestalost dijeljenja vozila, i ta vrsta dijeljenja (automobila i vožnje) ne samo što bi olakšala, već bi i umanjila kompletno vlasništvo nad prijevoznim sredstvom, a također i putovanja. Starijim osobama i tjelesnim invalidima pružila bi se mogućnost da imaju samostalnost u pokretljivosti.

[25] Litman, T. (2021) Autonomous Vehicle Implementation Prediction, Victoria Transport Policy Institute

Istraživanje instituta prometnih studija iz Kalifornije je pokazalo da, u slučaju da se automatizirana prijevozna sredstva masovno koriste i da su elektrificirana, do 2050. bi emisija stakleničkih plinova mogla biti reducirana do 50% i više.[26] Između ostalog, moguće je korisno upotrijebiti vrijeme tijekom putovanja kada se vozači pretvore u putnike. Nije lako pružiti argumentirano objašnjenje ove potencijalne prednosti autonomnog prijevoznog sredstva, ali je potencijalni rezultat lakše podnijeti dugu vožnju, kao i vožnje tijekom dana.

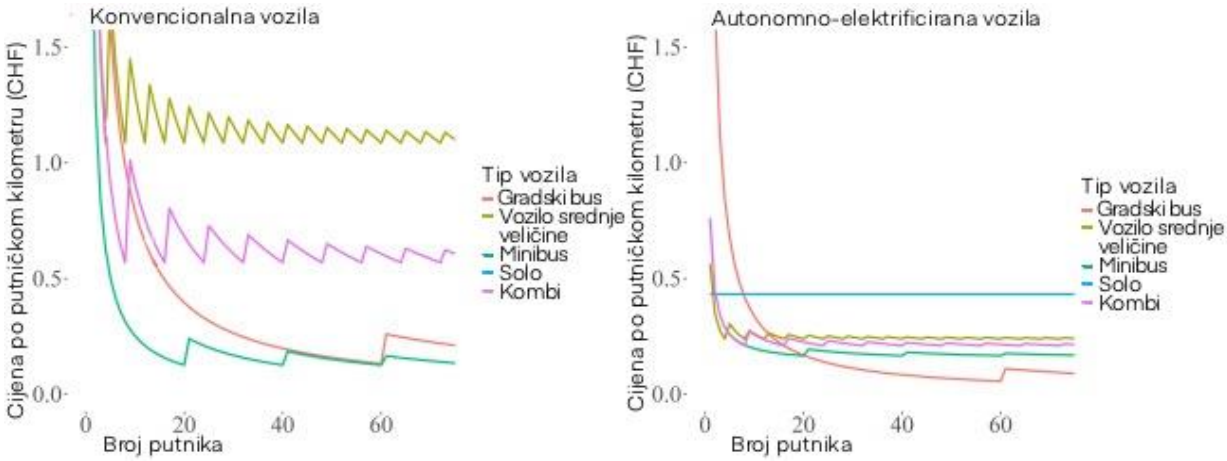
Što se tiče stabilnih i dinamičnih troškova javnih željezničkih i autobusnih usluga, ne predviđa se da će automatizacija i električni pogon imati drastični utjecaj na njih, iz razloga što je tehnologija vezana za automatizaciju unaprijed ugrađena (u vlakovima) ili ne bi mogla bitno utjecati na povećanje cijene za nabavku prijevoznih sredstava (za autobuse). Čak se i predviđa da će sustavi nastaviti funkcionirati na identičan način kao i sada, stoga će na administrativne troškove utjecati neznatno. Kako bi se saznala prosječna potrošnja po klijentu treba uzeti u obzir značajke prijevoznog sredstva, ali i efikasnost usluge, to jest upotrebu prijevoznog sredstva, prazna putovanja i troškove. Na osnovu istraživanja u Švicarskoj iz 2020. godine otkriveno je da je u Švicarskoj srednja cijena privatnog automobila 0,71 CHF, ili 5 KN po kilometru.[27]

Kako se prijevozna sredstva automatiziraju, značajno se smanjuje koncepcija troškova različitih usluga. Sve u svemu, jasni su sljedeći učinci: neovisne tehnologije prijevoznih sredstava čine da se vrijednost vozila pri kupnji povećava, dok također reduciraju operativne troškove tako što imaju manje troškove za osiguranje, održavanje i gorivo. Osim toga, taksi flote u tom slučaju imaju mogućnost da funkcioniraju bez vozača, što smanjuje ključni faktor troškova.

Prikupljene informacije ukazuju na to da su autonomna prijevozna sredstva najpovoljnija sredstva samo za relaciju izvor-početak. Sve u svemu, nabavka autonomnog prijevoznog sredstva može se interpretirati kao investiranje u privatnog robota za pokretljivost, čija bi namjena mogla biti kako u ulozi vozača, tako i za izvršavanje zadataka; upravo zato taj pothvat ima mogućnost biti još primamljiviji od klasičnog prijevoznog sredstva. Shodno tome, predviđa se da će mnogi prepoznati upotrebnu vrijednost robota za pokretljivost i neće im biti problem platiti odgovarajuću cijenu.[28]

[26] https://www.washingtonpost.com/sf/brand-connect/ucdavis/driverless-cars-could-be-a-solution-to-climate-change/, pristupljeno: 15.8.2022.
[27] M. Bosch, P. , Becker, F , Becker, H. : Cost-based analysis of autonomous mobility services, IVT, Zurich, 2018.
[28] Ibid.

Na slici 2. mogu se vidjeti sličnosti i razlike među klasičnim (ili konvencionalnim) modelom transporta prema broju ljudi koji putuju i autonomnim-električnim modelom transporta prema broju ljudi koji putuju. Istog trena se kreira slika o tome da se za svaki oblik funkcioniranja bitno reducira cijena zahvaljujući tehnologijama električnog pogona i autonomnog upravljanja. Kod dijeljenih prijevoznih sredstava prosječne veličine primjetni su najuočljiviji uspjesi – njihova cijena gledana po putničkom kilometru osjetno se spušta za 78%. Međutim, interesantno je da, kada su ovakva prijevozna sredstva maksimalno opterećena, ona nisu značajno skuplja od autonomnih električnih kombija (1,47 KN/km) i minibuseva (1,19 KN/km). Primjera radi, prikupljene informacije ukazuju na to da su autonomna prijevozna sredstva najpovoljnija prijevozna sredstva samo za relaciju izvor-odredište sa malom potražnjom. Uzimajući u obzir srednju opterećenost dvije osobe u okviru ovakve udaljenosti, prosječan automobil mogao bi biti efikasniji.[29]



Slika 2. Cijene po putničkom kilometru u odnosu na broj putnika

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

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

4.2. Nedostaci autonomnih vozila

Do danas je širom svijeta obavljen značajan broj studija koje se bave temom autonomnih prijevoznih sredstava. Međutim, pojedinci i zajednica za sada nisu dovoljno informirani o autonomnoj tehnologiji i o značenju autonomnosti. Tijekom provođenja studija i anketiranja ispitanika, može se uočiti da pojedinci većinom razmišljaju o posljedicama neispravnosti na sustavu i pratećim sadržajima, kao i konkretne vožnje u apsolutno autonomnom prijevoznom sredstvu, ali i za svaki oblik automatizirane vožnje (javni prijevoz, prijevoz tereta, taksi, itd.) Rezultati istraživanja pokazuju kako se veliki broj pojedinaca izjasnio da nema želju biti vlasnik apsolutno autonomnog prijevoznog sredstva zato što se brinu i strahuju od hakerskih udara, zakonskih obaveza, moralnih dilema, privatnosti i sigurnosti.[30]

Izdvajaju se mane autonomnih u usporedbi sa tradicionalnim vozilima[31]:

- uvećani troškovi za prijevozno sredstvo,
- potreba za dopunskom opremom prijevoznog sredstva, uslugama i troškovima,
- dopunski rizici za vlasnike (neočekivani pad sustava),
- osjetljivost na zlouporabu informacija (hakiranje),
- reducirana sigurnosti i privatnost (korištenje informacija i lociranje),
- uvećanje uporabe prijevoznog sredstva (više prijevoznih sredstava na cestama),
- uvećanje troškova za infrastrukturu i zahtijevanje kvalitetnijih prometnica,
- umanjenje radnih mjesta i kolektivni otkazi (vozači buseva, kamiona, taksisti itd.)

Osim toga, promjene vremena značajno otežava funkcioniranje autonomnog prijevoznog sredstva, primjera radi, ukoliko autocestu pokriva snijeg, gubi se vidljivost traka. Bitno je umanjena sposobnost prijevoznog sredstva da funkcionira u sličnim okolnostima.

Od velike je važnosti da se definira i odrede zakonske obaveze ukoliko se desi incident pri uporabi autonomne vožnje da bi se unaprijedilo razumijevanje kako tehnološkog aspekta autonomne vožnje, tako i njezina primjena na prometnicama. Iz ove perspektive, dilema je vezana za to da li je prijevozno sredstvo funkcioniralo u okviru svog ODD-a (u režimu

[30] https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775, pristupljeno: 29.7.2022.
[31] Ibid

autonomne vožnje) ili nije. Prijevozno sredstvo koje funkcionira u okviru svog ODD-a promatra se kao autonomno prijevozno sredstvo stupnja 4 ili dalje. Vozač takvog prijevoznog sredstva ili njegov sustav odgovoran je za konkretne zadaće u procesu vožnje ili ima ulogu operatera nad ovakvim sustavom. Ukoliko se desi da autonomno prijevozno sredstvo izađe iz režima ODD-a, osoba/vozač ponovo preuzima odgovornost za upravljanje vozilom. Poslije preuzimanja, model upravljanja vozilom je na stupnju 2 ili niže, i zato ako se desi incident poslije toga, operater snosi odgovornost zato što se kategorizira kao vozač u tradicionalnom smislu[32].

Pojedinca koji upravlja autonomnim prijevoznim sredstvom stupnja 3 stvarno nema potrebe promatrati kao vozača, već on prelazi u ulogu putnika još i prije samog procesa preuzimanja. Do promjene statusa putnika bi trebalo doći u trenutku kada se zahtjeva preuzimanje upravljanja nad prijevoznim sredstvom. Bez obzira na to što putnik konstantno nadzire rad sustava za autonomnu vožnju i to pojednostavljuje potvrdu zahtjeva za preuzimanjem, ovo ne slijedi iz modela putnika na stupnju 3. Potencijalni motiv korigiranog prava za tretiranje putnika nužno kao vozača je taj što najčešće kad se nezgoda na cesti desi kao rezultat prijevoznog sredstva autonomnog sustava vožnje, odgovorni policijski službenik ne zna koga je potrebno ispitati ili uhititi kao upravitelja vozilom, a to bi moglo biti otežavajući čimbenik za odlučivanje na mjestu događaja. Samim time, korigirani Zakon o prometu bit će na snazi sve dok se tehnologija stupnja 4 ne primjeni u praksi koja će se nadalje oslanjati na model ODD-a. Iz tog razloga je ovo korigiranje trenutačna mjera kako bi se brzo razriješile primjenjive dileme[33].

Primjer sljedeće situacije: pješačkom prijelazu prilazi autonomno prijevozno sredstvo stupnja 4, a u isto vrijeme petero ljudi želi prijeći cestu ne obazirući se na semafor koji pokazuje crveno svjetlo. Prijevozno sredstvo ima sposobnost detektirati mogućnost udaranja pješaka ukoliko nastavi pratiti svoju putanju bez promjena, što će dovesti do njihove smrti. Stoga, sustav stupnja 4 izabrao bi skretanje ulijevo (u smjeru kolnika) kako bi promijenio putanju. Tako sustav stupnja 4 bira da ne udari pet osoba koje se ne obaziru na crveno svjetlo na semaforu, ali bi umjesto njih udario jednog pješaka koji je normalno hodao pločnikom. U ovakvom primjeru je došlo do pogibije tog jednog pješaka pri udaru autonomnog prijevoznog sredstva. Dakle, da bi se sačuvali životi pet pješaka, žrtvovan je jedan. Iz pravne perspektive, desilo se ubojstvo, što

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

je, naravno, nezakonita radnja. Ukoliko bi to bilo rješenje vozača, takva radnja bi se smatrala ubojstvom. Ali, uzima se u obzir da su 4 života ostala netaknuta. Iz tog razloga, takav postupak autonomnog sustava stupnja 4 se, iz gledišta aktualnog utilitarizma, ne može vidjeti kao kaznenim djelom. Osnova toga je između ostalog i konstatacija da se umjetna inteligencija (AI) čiji je zadatak upravljanje prijevoznim sredstvom stupnja 4 promatra kao neko tko snosi kriminalnu odgovornost, i zato je na djelovanje AI moguće primijeniti obranu iz nužde. Bez obzira na sve ovo, o potencijalnom primjenjivanju kaznenog prava na AI je neophodno još uvijek diskutirati. I u slučaju da se kazneno pravo ne primjeni na AI, primjenjivanje njega na stranke (kao što su kompanije ili operatori) koje su odgovorne za proizvodnju AI (također njezinog algoritma) pružilo bi mogućnost da se uspostavi obrana iz nužnosti, što bi slijedom donijelo identični rezultat[34].

Ukoliko se kaznenim pravom ne tretiraju sustavi umjetne inteligencije, kao i stranke koje su odgovorne za njihovu proizvodnju (kao što su kompanije ili operateri), značajno bi se reducirala briga vezana za primjenu na autocestama autonomnog prijevoznog sredstva sa umjetnom inteligencijom (briga se zasniva na potencijalnoj zakonskoj odgovornosti), najviše iz perspektive nabavljača. Međutim, velika je vjerojatnost da zaključak o izuzimanju krivice ne bi odgovarao žrtvama i obiteljima žrtvi. Iz tog razloga bitno je oprezno se okrenuti potrazi rješenja koje bi dozvolilo da i jedni i drugi ne budu apsolutno oponirani primjeni autonomnog prijevoznog sredstva. Jednostavnije rečeno, značajna je dilema na koji način se može doprinijeti tome da društvo prihvati autonomna prijevozna sredstva.[35]

Bitno je konkretno utvrditi pravni aspekt i zakone koji bi se primijenili u prethodno definiranom primjeru da bi došlo do pojednostavljivanja takvih pitanja i moralnih dilema. Mogla bi biti mogućnost da se definiraju dva izbora u okviru kojih bi umjetna inteligencija funkcionirala. Prva opcija je davanje prednosti očuvanju života ljudi u vozilu kao preduvjet za djelovanje (egoistični ili samodrživi algoritam), a druga opcija je biranje varijante koja bi rezultirala najmanjim problemom za osobe i prijevozna sredstva u slučaju da nije moguće izbjeći nezgodu (optimalni algoritam sudaranja i algoritam koji umanjuje nezgodu). U prethodno navedenom primjeru, odluka drugog algoritma bi pala na sudar sa jednim pješakom. Takvo nešto bi trebalo potencijalno promijeniti ukoliko postoji viđenje da je to rješenje nepravedno i etički

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

[35] Ibid

nedozvoljeno velikom djelu društva. Kako bi se ove promjene implementirale, neophodno je javno etičko povjerenstvo, kao i demokracija koja se ogleda u analiziranju odluka većine.

Prognoze su da će do 2050. autonomna prijevozna sredstva:[36]

- reducirati prometne gužve (umanjenje broja prijevoznih sredstava na cesti za 30%)
- reducirati putne troškove za 40% (u ovo spadaju gorivo, prijevozna sredstva, infrastruktura),
- unaprijediti uvjete života,
- ostaviti parkirališta kako bi se koristila u druge svrhe (parkovi, obrazovne ustanove, društveni centri),
- reducirati emisije CO2 u gradovima za 80% po čitavoj planeti.
- Smanjiti broj nesreća za 90%

Najteži poduhvat bit će učestalo korištenje autonomnih prijevoznih sredstava, to jest tranzicija osoba sa tradicionalnih prijevoznih sredstava na automatizirana, ali i gradnja infrastrukture koja bi odgovarala potrebama autonomnih prijevoznih sredstava. Ključna dilema vezana za evoluciju prijevoznih sredstava sastoji se u tome da li će kupnja automobila i vlasništvo nad njim biti još uvijek zastupljeni u budućnosti ili će se vozila iznajmljivati kada je to neophodno.

[36] https://www.telegram.hr/partneri/evolucija-automobila-povezanih-uz-5g-brze-putovanje-uz-manju-potrosnju-manje-sudara-i-ozlijedenih/

5. UTJECAJ KORIŠTENJA AUTONOMNIH VOZILA NA SIGURNOST CESTOVNOG PROMETA

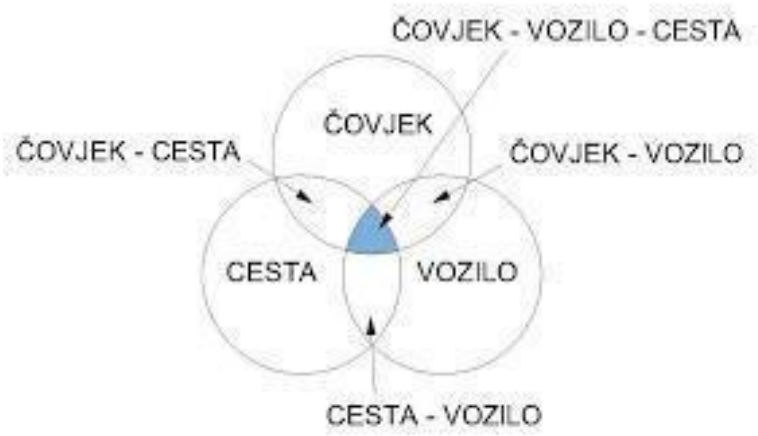
5.1. Pojam sigurnosti cestovnog prometa

Kao rezultat brzog unapređenja prometnog sustava, kao i uvećane gustoće prometa, javljaju se problemi nalik reduciranju sigurnosti prometa. Sigurnost prometa na cestama ogleda se u statističkim podacima koji pokazuju kakvo je stanje na prometnicama, ukazuje na pogreške koje se događaju te se prema tim podacima izvlače korisne informacije koje pomažu inženjerima da procjene stanje dijela cestovne prometnice na kojoj se često događaju nesreće te kako te dijelove poboljšati.

Cesta, prijevozno sredstvo i čovjek su tri ključna faktora sigurnosti prometa na cestama koja se gledaju u slučaju evaluacije nezgoda u prometu. Evaluacija sigurnosti prometa na cestama u konkretnom području obavezno treba imati strateški pristup u okviru kojeg se procjenjuje svaki potencijalni čimbenik čije su osnove prometna dokumentacija, izlazak na lice mjesta i predlaganje najnovijih rješenja kako bi se reducirao broj nezgoda na rizičnim lokacijama.

5.2. Osnovni čimbenici sigurnosti cestovnog prometa

Brzina i učestalost kretanja u okviru složenog sustava prometa je razlog što se svaki dan dešavaju problematična djelovanja i stanja koja narušavaju sigurnost sudionika u prometu na cestama. Kako bi se informirali o osnovnim zakonitostima prometa, neophodno je istražiti sigurnost prometa na cestama prema ključnim faktorima. Tri ključna faktora sigurnosti jesu: čovjek, vozilo i cesta. Međudjelovanje prethodno spomenuta tri faktora je vidljivo na slici 2. u formi Venovog dijagrama.



Slika 3. Venov dijagram

Izvor: Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001.

Na slici 2. prikazano je međudjelovanje sustava čovjek – vozilo – cesta u formi Venovog dijagrama. U sredini je plavom bojom označeno područje preplitanja navedenih podsustava.

5.2.1. Čovjek kao čimbenik sigurnosti cestovnog prometa

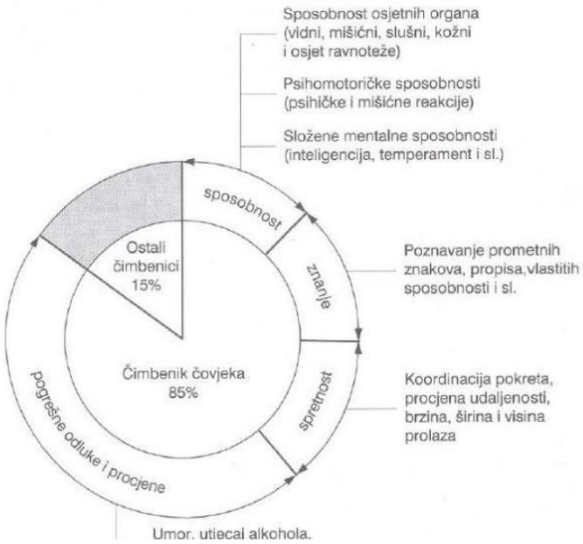
Čovjek se smatra najvažnijim čimbenikom sigurnosti prometa na autocesti. Uloga čovjeka u prometu može se promatrati sa više aspekata: kao vozač, suvozač, putnik i pješak. Utjecaj na ponašanje u prometu imaju:[37]

- osobne značajke vozača,
- psihofizička svojstva,
- kultura i obrazovanost.

Osobne značajke vozača dio su sveukupne osobnosti pojedinca koja predstavlja organiziranu cjelinu svih osobina, svojstava i ponašanja kojima se svaka ljudska individualnost izdvaja od svih drugih pojedinaca društvene zajednice.[38]

[37] Cerovac, V.: Tehnika i sigurnost prometa. Zagreb: Fakultet prometnih znanosti, 2001.
[38] Luburić, G.: Sigurnost cestovnog i gradskog prometa 1- radni materijal za predavanja, Fakultet prometnih znanosti, 2010.

Slika 3. u nastavku prikazuje ulogu osobe kao vozača gdje se kombiniraju karakteristike bitne za funkcioniranje u okviru sustava prometa.



Izvor: Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001.

Slika 4. Uloga čovjeka kao vozača

Vozača kao glavnog čimbenike sigurnosti prometnog sustava uvelike određuju psihofizička svojstva, psihomotoričke sposobnosti i kultura i obrazovanje.

Psihofizička svojstva koja su od najvećeg značaja za vozačke sposobnosti i kompetencije vezana su uz funkcioniranje organa osjeta vida. Prilikom informiranja vozača prijevoznog sredstva osjet vida ima najveći značaj, zato što je on osnovan osjet za više od 95% vozačevih odluka. Ključne karakteristike kod osjeta vida jesu: [39]

- prilagodljivost oka na tamu i svijetlost,
- vidno polje,
- razlikovanje boja,
- oštrina vida,
- sposobnost stereoskopskog zamjećivanja.

Sluh ima značajno manji utjecaj na sigurnosti u prometu. Njegova svrha je provjera funkcioniranja motora, opredjeljivanje smjera i razdaljine prijevoznog sredstva u slučaju

[39] Cerovac, V.: Tehnika i sigurnost prometa. Zagreb: Fakultet prometnih znanosti, 2001.

kočenja, itd. Kako bi nadomjestili tu manjkavost, osobe koje imaju problema sa sluhom više naprežu vid.[40]

Psihomotoričke sposobnosti su sposobnosti koje „omogućuju uspješno izvođenje pokreta koji zahtijevaju brzinu, preciznost i usklađen rad raznih mišića."[41]

Kao ključne psihomotoričke sposobnosti pri rukovođenju prijevoznim sredstvom, Cerovac navodi:

- brzina reagiranja,
- brzina izvođenja pokreta,
- sklad pokreta i opažanja.

„Vrijeme reagiranja predstavlja protok vremena od trenutka kada dođe do konkretnog događanja do momenta reagiranja bilo kojom komandom u prijevoznom sredstvu. Brzina reagiranja se razlikuje ovisno o osobnim karakteristikama vozača, ili o njegovim psihofizičkim svojstvima (mentalna stabilnost, zamor, godine starosti, snaga podražaja, i sl.). Sastav vremena reagiranja su vrijeme zapažanja, vrijeme analiziranja i vrijeme djelovanja. Mentalne mogućnosti vozača uključuju pamćenje, učenje, razmišljanje, inteligencija, itd. Ukoliko vozač posjeduje odlične mentalne mogućnosti, mnogo će se kvalitetnije orijentirati u novostvorenim okolnostima, i zato će se i sa manje muke uklopiti u novostvorene okolnosti."[42]

Kultura i obrazovanje jesu bitni faktori za prihvatljivo djelovanje sustava prometa. Ukoliko vozač posjeduje konkretno obrazovanje i kulturu u vezi vožnje, uvažavati će propise i izbjegavati će da izloži u opasnost sebe ili ostale ljude koji sudjeluju u prometu, što će svakako utjecati na poboljšanje djelovanja sustava prometa. To uključuje:[43]

- znanje o zakonima i propisima o regulaciji prometa,
- znanje o kretanju prijevoznog sredstva,
- znanje o svojim mogućnostima.

[40] Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001.
[41] Ibid.
[42] Ibid.
[43] Ibid.

5.2.2. Vozilo kao čimbenik sigurnosti cestovnog prometa

Vjeruje se da je tehnička neispravnost prijevoznih sredstava uzrok za 3-5% prometnih nesreća.[44]

Da bi se smanjio postotak nesreća nužno je redovno kontrolirati stanje vozila tj. nužan je odlazak na redovni godišnji servis.

Komponente prijevoznih sredstava koje imaju utjecaja na sigurnost na cesti mogu biti aktivne i pasivne.

Aktivne komponente sigurnosti prijevoznih sredstava mogu bit:[45]

- kočnice
- upravljački mehanizam
- gume
- svjetlosni i signalni uređaji
- uređaji koji služe za uvećavanje vidnog polja vozača
- konstrukcija sjedala
- spojleri
- uređaji koji služe za provjetravanje, hlađenje i grijanje
- vibracija vozila
- buka

Kočnice – uređaji koji služe za usporavanje ili apsolutno zaustavljanje prijevoznog sredstva. Ručna i nožna kočnica jesu dvije neovisne kočnice koje svako prijevozno sredstvo mora posjedovati.

Upravljački mehanizam – moguće je da problem sa upravljačkim sustavom rezultira nesrećom u prometu. U slučaju čelnog sudara, najozbiljnije povrede kod vozača dešavaju se iz razloga što se prsni koš sudari sa kolom upravljača, kao i glava osobe sa vjetrobranskim staklom.

Gume – glavni zadatak guma je da uspiju postići što efikasnije prianjanje između podloge i kotača. Za teretna prijevozna sredstva i buseve dubina nareza obavezno treba biti veća od dva milimetra.

[44] Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001.
[45] Ibid.

Svjetlosni i signalni uređaji – uz pomoć svjetlosnih i signalnih uređaja prijevozno sredstvo osvjetljava cestu. Služi i za bilježenje toga gdje se prijevozno sredstvo nalazi na cesti i za slanje relevantnih signala.

Uređaji koji služe za uvećavanje vidnog polja vozača – stakla na prozorima prijevoznog sredstva, perači i brisači vjetrobranskog stakla, vozačka zrcala.

Konstrukcija sjedala – bitno je da se sjedalo u prijevoznom sredstvu napravi na način koji bi osigurao udobnost sjedenje, koji bi bio dobra potpora vozaču kada u zavoju djeluje centrifugalna sila, koji bi osigurao odličnu vidljivost, ali i adekvatnu udaljenost od uređaja za upravljanje prijevoznim sredstvom.

Usmjerivači zraka – dijelovi školjke prijevoznog sredstva koji imaju cilj reducirati otpor zraka i poboljšati stabilnost prijevoznog sredstva u slučaju da ono ide većom brzinom.

Uređaji koji služe za provjetravanje, hlađenje i grijanje unutrašnjosti vozila – provjetravanje, grijanje i hlađenje veoma su bitni za funkcioniranje vozača, a stoga i za prometnu sigurnost. Radna sposobnost vozača se smanjuje već ukoliko se temperatura spusti ispod 13°C ili se povisi iznad 30°C.

Buka – Buka iznad 80 dB je štetna za organe sluha te štetno djeluje na živčani sustav. U djelu za putnike frekvencija ne bi trebala biti veća od 70 dB. Postoji mogućnost da se već strukturom prijevoznog sredstva reducira jačina zvuka tako što će se ugraditi akustična izolacija između prostora za smještanje motora i prostora za putnike.

U pasivne komponente sigurnosti vozila spadaju:[46]

- karoserija
- vrata
- sigurnosni pojasevi
- nasloni za glavu
- vjetrobranska stakla i zrcala
- položaj motora, spremnika, rezervnoga kotača i akumulatora
- odbojnik
- sigurnosni zračni jastuk

[46] Doc. Dr. sc. Grgo Luburić, Sigurnost cestovnog I gradskog prometa I, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2017.

Vrata – Funkcija im je spriječiti savijanje karoserije te imati otpornost na svaki oblik udarnog opterećenja.

Sigurnosni pojasevi – time što se instaliraju i koriste sigurnosni pojasevi smanjuje se mogućnost udarca glavom o vjetrobransko staklo u slučaju sudara, kao i prsnim košem o upravljačko kolo ili instrumentalnu ploču. Prednost korištenja sigurnosnih pojaseva je taj da se tri puta reducira broj ljudi koji su teško ozlijeđeni, dok se mortalitet smanjuje 60%. Osim „Y“ pojasa koji je u najvećoj upotrebi, postoji „H“ pojas koji pruža maksimalnu sigurnost, a koristi se u zrakoplovstvu.

Vjetrobranska stakla i zrcala – ukoliko dođe do lomljenja, stakla koja su višeslojna i kaljena su pokazala bolje rezultate. Kaljeno staklo se razbije u male krhotine sa brojnim tupim rubovima.

Položaj motora, spremnika, rezervnog kotača i akumulatora – Za upijanje većeg dijela kinetičke energije kod sudara najbolji položaj motora je sa prednje strane vozila. Prednja pozicija je najkorisnije mjesto za rezervni kotač zato što reducira štetu na motoru i služi kao zaštita za središnji dio vozila. Spremnik za gorivo ne bi trebao biti blizu akumulatora iz razloga što može doći do samozapaljenja.

Odbojnik – osnovni cilj odbojnika je da u slučaju sudara upije dio kinetičke energije. Ugrađuju se na prednju i stražnju stranu prijevoznog sredstva te bi trebali u sebi sadržavati gumene elemente.

Sigurnosni zračni jastuci – automatski se aktiviraju kada dođe do sudara. Veoma brzo, tijekom 26 tisućinka sekunde iz upravljačkog kola ili prednjeg dijela prijevoznog sredstva se izbacuje zračni jastuk, a zatim odmah dolazi do punjenja plinom dušikom kako bi postojala mogućnost da se smanji udar čovjeka o tvrdu površinu. Trajanje tog procesa je pola sekunde.

5.2.3. Cesta kao čimbenik sigurnosti prometa

Prevladavajući razlog dešavanja nesreća u prometu su manjkavosti ceste u tehničkom smislu, dok se one javljaju uslijed lošeg projektiranja cesta i loše gradnje istih.

Osnovna obilježja ceste kao faktora za sigurnost prometa su: [47]

- Trasa ceste
- Tehnički elementi ceste
- Stanje kolnika
- Oprema ceste
- Rasvjeta ceste
- Križanja
- Utjecaj bočne zapreke
- Održavanje ceste

Trasa ceste – uz pomoć trase ceste definira se pravac i visina ceste. Dijelovi trase ceste su: pravac, zavoj i prijelazna krivina; te komponente moraju se birati na način da osiguraju siguran promet prijevoznih sredstava pri unaprijed proračunatoj brzini. Bitna je homogenost trase ceste, što znači da ona treba ostvariti konstantnu brzinu samog prijevoznog sredstva. Neophodno je uzajamno usklađivanje duljine zavoja i pravaca.

Površina kolnika može se kvalitetnije iskoristiti uz pomoć rubnih trakova. Postoji mogućnost da njihovo korištenje bude efikasno za zaustavljanje prijevoznih sredstava uslijed kvara na vozilu. U slučaju da nije izvodljiva izrada rubnih trakova, potrebno je obilježiti rubne crte. Uz njihovu pomoć vozaču se nudi dodatno optičko sredstvo vođenja.

Tehnički elementi ceste – bitni su faktori za sigurnost prometa. Naše ceste izrađene su sa kolnikom koji ima dva prometna traka. Rezultati studija ukazuju na to da postoji trend reduciranja broja nesreća ukoliko se proširuju prometni trakovi. Ukoliko je u pitanju mješoviti promet gdje ima velik broj biciklista, moraju se izraditi biciklističke staze. Iz razloga psihološke sigurnosti vozača, trebalo bi izvesti rubne trakove.

Stanje kolnika – umanjivanje koeficijenta trenja među kotačima i kolnikom je uzrok nastanka mnogih nesreća u prometu, kao i oštećenja gornjeg površinskog sloja kolnika, to jest nastanak udarnih rupa. Adekvatno prianjanje sprječava proklizavanje prijevoznog sredstva, bilo u pravcu kretanja vozila ili u poprečnom smjeru. Veliki utjecaj na umanjivanje prianjanja imaju: mokar zastor, zaprljan i blatan zastor, vodeni klin, izbočine i neravnina na zastoru, itd. Rezultati

[47] Doc. Dr. sc. Grgo Luburić, Sigurnost cestovnog I gradskog prometa I, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2017.

belgijskih studija ukazuju na to da pad koeficijenta na cestama ispod 0,40 dovodi do 20 puta većeg broja nesreća nego na autocestama sa hrapavim i suhim zastorom.[48]

Oprema ceste – opremu ceste čine: znakovi, kolobrani, ograde, živice, smjerokazi, snjegobrani i vjetrobrani.

Križanja – udio prometnih nesreća na gradskim križanjima broji 40-50% od kompletnog broja nesreća. Rezultati prethodnih studija ukazuju na to da umanjenjem preglednosti na križanju 3 puta, sigurnost opada čak 10 puta. Iz tog razloga neophodno je da se križanja projektiraju u dva ili više nivoa. Ukoliko takvo rješenje nije ostvarivo, potrebno je osigurati odličnu preglednost i posvetiti osobitu pažnju upravljanju prometom.[49]

Utjecaj bočne zapreke – ukoliko su u okolini ruba kolnika trajne ili privremene zapreke, to ima za posljedicu smanjenje sigurnosti prometa. Postojeća regulativa propisuje da, ukoliko postoji zaustavni trak u slučaju nužde, razmak do unutarnjeg ruba zaštitne konstrukcije jest 0,70m, dok ukoliko takav trak ne postoji, njen razmak ovisi o širini prometnog traka.

Održavanje ceste –Obavljaju se svi neophodni popravci zastora, čišćenja drenažnih kanala, mijenjanje stare signalizacije, a također se održavaju nagibi nasipa same ceste. Investicijskim ulaganjima se reguliraju rizične točke, obnavlja se zastor, nanovo izrađuju tehničke komponente ceste itd.

5.2.4. Čimbenik „promet na cesti“

Čimbenik „promet na cesti“ uključuje podčimbenike: organizacija, upravljanje i kontrola prometa.

Organizacija prometa – uključuje regulative vezane za promet i tehnička sredstva za održavanje prometa organiziranim.

Upravljanje prometom – obuhvaća način i tehniku upravljanja cestovnim prometom.

Kontrola prometa – obuhvaća način kontrole prometa, kao i istraživanje i statističke podatke o prometnim nesrećama.[50]

[48] Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001.
[49] Ibid.
[50] Ibid.

5.3. Proporcionalnost sigurnosti i autonomije vožnje

Kako bi se postiglo da se sustav vožnje u autonomnom režimu poboljšava izvan okvira automatizirane pomoćne vožnje, on bi trebao posjedovati kvalitetnu percepciju okolnih smetnji od 360 stupnjeva. Dostići komfornu i sigurnu vožnju moguće je u slučaju poboljšanja mogućnosti detektiranja i reakcije na objekte i stvari unutar prijevoznog sredstva i van njega.

Kao rezultat opreznije automatizirane vožnje, predviđa se da će autonomna prijevozna sredstva biti lakša za servisiranje od klasičnih vozila. Ipak, troškovi servisiranja će vjerojatno ostati isti, iz razloga što je i novim senzorima potrebno redovito održavanje. Prethodno provedene studije su pokazale da će sigurnija vožnja reducirati stopu osiguranja vozila za 50%. Međutim, spomenuta računica se sada već promatra kao konzervativna, budući da postoje izvještaji kako je suvremeni Tesla Autopilot već uspio reducirati stope nezgoda za 40%.[51]

Hakerima se otvara više mogućnosti zbog povećane povezanosti prijevoznih sredstava sa svojom okolinom. Prijevozna sredstva su sve konkretnije vezana za druga prijevozna sredstva, za infrastrukturu prometa, kao i za oblak. Komunikacija V2X bit će u značajnom porastu kako se automatizacija uvećava. Prijevozna sredstva će biti u sve frekventnijoj interakciji sa prometnim znakovima, semaforima, mobitelima, kao i lokacijama za punjenje. Ti dijelovi infrastrukture za sada nisu dovoljno osigurani. Iz tog razloga je veoma bitno sačuvati prijevozno sredstvo od vanjskog cyber napada, primjerice, uz pomoć vatrozida.

Tabela 2. ilustrira prednost raznih dilema vezanih za proučavanje ljudskog faktora u kibernetičkoj sigurnosti autonomnih prijevoznih sredstava na različitim stupnjevima automatiziranosti.

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

Table 2. Ljudski faktor u kibernetičkoj sigurnosti po razinama automatizacije

SEA level automatizacije	(0) Bez automatizacije	(1) Vozačko sudjelovanje	(2) Djelomična autonomnost	(3) Uvjetna autonomnost	(4) Visoka autonomnost	(5) Potpuna autonomnost
Istraživačka pitanja:						
Sklonost kvaru hibernetičke sigurnosti radi ljudskih osobina	Mala	Mala	Srednja	Visoka	Visoka	Srednja
Način povećanja karakteristika kibernetičke sigurnosti	Mala	Mala	Mala	Visoka	Visoka	Visoka
Oslanjanje na mogućnosti AV	Mala	Srednja	Srednja	Visoka	Visoka	Visoka
Edukacija neupućenih osoba	Srednja	Srednja	Srednja	Srednja	Srednja	Srednja
Prihvatljivost istovremenih radnji	Mala	Srednja	Srednja	Visoka	Visoka	Mala
Smanjenje obrambenih mogućnosti kibernetičke sigurnosti	Mala	Mala	Srednja	Visoka	Visoka	Visoka
Postupanje tijekom kibernetičkih napada	Mala	Mala	Visoka	Visoka	Visoka	Visoka
Zahtjevi u proizvodnji AV	Mala	Mala	Mala	Visoka	Visoka	Visoka
Mogućnost kibernetičkih napada na AV	Mala	Mala	Srednja	Visoka	Visoka	Visoka

U radu je već ukazano na to da se može izdvojiti 6 stupnjeva automatizacije prijevoznih sredstava, od najmanjeg (0) do najvećeg (5), ili od prijevoznog sredstva koje vozi osoba do apsolutno automatiziranog prijevoznog sredstva. Razne dileme za proučavanje bit će bitne pri raznim koracima do automatizacije autonomnih prijevoznih sredstava. Proučavanje ponašanja ljudi koje se odnosi na autonomna prijevozna sredstva mora se baviti i iskustvom vožnje takvog vozila na prosječnim osobama. Međutim, nije lako naći ljude koji bi sudjelovali u proučavanju zbog nepotpune rasprostranjenosti autonomnih prijevoznih sredstava. Proučavanja kibernetičke sigurnosti autonomnih prijevoznih sredstava bit će primjenljivija kasnije, kada čovjek bude više upotrebljavao takva prijevozna sredstva.[52]

Nulti stupanj automatizacije je onaj pri kojem je osoba jedini upravljač prijevoznim sredstvom, i automatizirana vožnja nije prisutna ni na koji način (to je još uvijek većina prijevoznih sredstava danas), ključna je sigurnost (valjanost) prijevoznog sredstva i komfornost (ugođaj) tijekom vožnje. U primjeni su sustavi kao što su ECS, ABS, kočenje u slučaju nužde i sl., a cilj je da prijevozno sredstvo stalno bude što ispravnije. Kako o svemu odlučuje vozač, on je u obavezi da odgovara za kompletnu vožnju, a stoga i za nesreće, bez obzira na to što prethodno spomenute tehnologije uvećavaju sigurnost i ugođaj tijekom vožnje. U okviru ovog stupnja čovjek mora obavezno učiti o prometnoj infrastrukturi, kao i znakovima i kompletnoj vožnji i ponašanju (kulturi) u prometu, čime se osigurava sigurnija vožnja.

U okviru prvog stupnja automatizacije prijevoznog sredstva ono samo podržava vozača tijekom vožnje, a sadrži pojedine tehnologije kao što je adaptivna kontrola brzine (ACC) uz čiju pomoć

[52] https://www.frontiersin.org/articles/10.3389/fpsyg.2019.00995/full, pristupljeno 7.7.2022.

prijevozno sredstvo ostaje adekvatno odmaknuto od prijevoznog sredstva ispred, iako je vozač i dalje u obavezi da upravlja procesom i promatra okruženje. Stoga, prvi stupanj je sigurniji i pouzdaniji od nultog stupnja iz razloga što posjeduje svaku tehnologiju nultog stupnja uz dodatna unapređenja koje služe za poboljšanje i komfornosti vožnje, bez reduciranja istih.

U okviru drugog stupnja se parcijalno automatizira vožnja, a to znači da do 25 osobnih tehnologija unapređuje sigurnost, komfornost i funkcionalnost vožnje, kao što su, na primjer, podrška pri upravljanju i zadržavanju traka, smanjivanju i povećavanju brzine, omogućavanju stvaranja sigurne distance između vozila, kao i podrška pri gužvi na cesti i prepoznavanje semafora. Vozač ima mogućnost da bilo kada odluči da sam upravlja prijevoznim sredstvom. Primjer ovakvog stupnja automatizacije je Teslin autopilot, u kojem vozač još uvijek najčešće upravlja prijevoznim sredstvom. Međutim, pošto na ovom stupnju prijevozno sredstvo ima konekciju sa internetom i oblakom, postoji pitanje kibernetičke sigurnosti i sredstava protiv hakiranja prijevoznog sredstva, ili preuzimanja upravljanja.

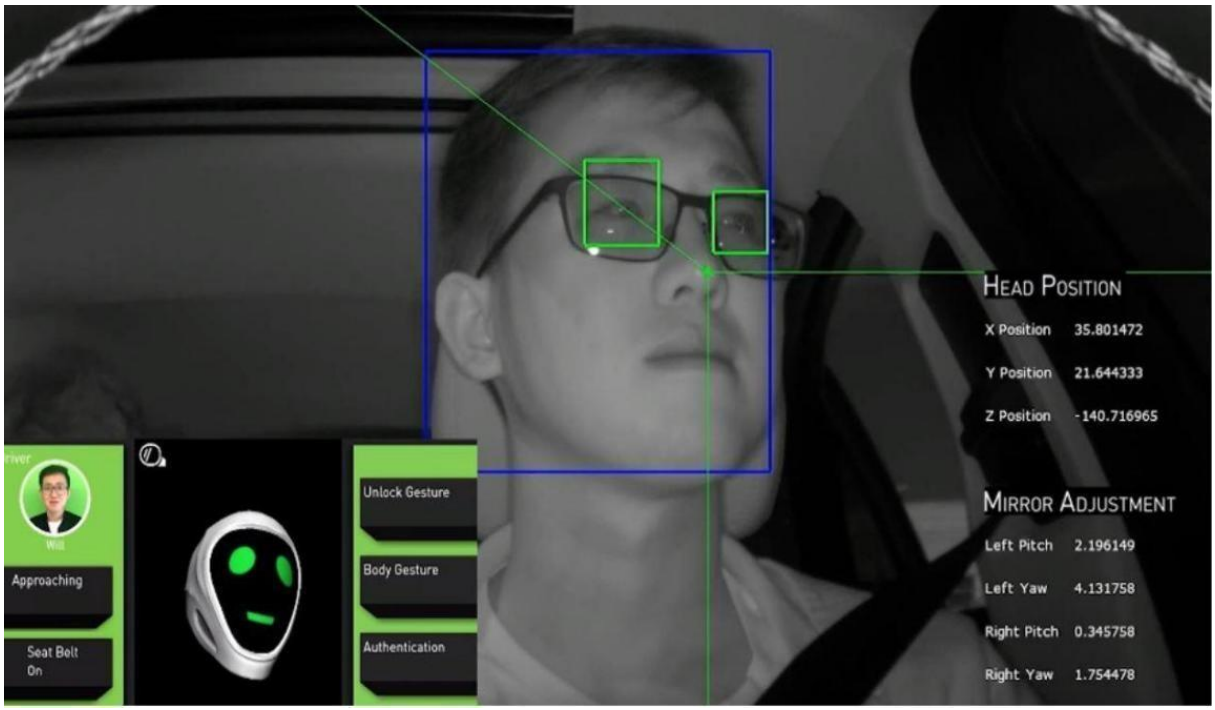
Treći stupanj podrazumijeva da automatski sustav percipira okruženje prijevoznog sredstva, kao što su ceste, ostala prijevozna sredstva i objekti. Prijevozno sredstvo ima mogućnost da preuzme upravljanje i da zaobiđe prijevozno sredstvo koje je previše sporo. Takvo prijevozno sredstvo većinom upravlja tijekom vožnje, iako je korisnik u stanju da bilo kada odluči da sam rukovodi. Na ovom stupnju prijevozno sredstvo se može podvrgnuti cyber napadu, i stoga je neophodno provesti i ugraditi prethodno spomenute sustave protiv hakiranja i napada. Što se tiče ugođaja tijekom vožnje, on je uvećan jer se vozač ne mora uključivati u vožnju, pa je i ona sama komfornija.

U okviru četvrtog stupnja, prijevozna sredstva posjeduju visok stupanj autonomnosti. Pošto prijevozno sredstvo samo upravlja tijekom vožnje, komfornost je višestruko poboljšana, i korisnik ima mogućnost da tijekom vožnje ima druge zanimacije, kao što je čitanje knjige, korištenje mobitela, pričanje preko istog, sudjelovanje u video pozivu i sl. Prijevozna sredstva četvrtog stupnja stavljaju u upotrebu aplikacije koje pomažu prijevoznom sredstvu (i korisniku) da stvara, skladišti, ekstrahira i konzumira sadržaj, zato što se skladišti povijest o vožnji prijevoznog sredstva, o gužvama na cestama, o biranju putanje ili metodi za parkiranje. Osim nebrojenih prednosti ovakvih sposobnosti i tehnologija, stvaraju se i moguće opasnosti kao što je cyber napad. Prijevozno sredstvo još uvijek posjeduje upravljač i pričuvne kontrole koje služe u slučaju neočekivanog problema sa sustavom ili obične odluke korisnika. Sigurnost je

višestruko poboljšana zato što prijevozno sredstvo određuje brzinu prema svojoj okolini i ima prognoze za potencijalna događanja.

Bez obzira na to koliko je sustav za olakšanje upravljanja vozila suvremen i automatiziran, neophodno je da osoba-vozač bude na oprezu za upravljačem i da vjeruje AI sustavu. Klasični sustavi za kontrolu vozača često ne percipiraju diskretne signale kao što je kognitivno stanje, ponašanje i ostale karakteristike vozača koje mogu pokazati da li je u stanju upravljati vožnjom.

Najbitniji čimbenik sustava koji autonomnom prijevoznom sredstvu daje mogućnost da vozač bude na oprezu i da bude svjestan prometa je percepcija vozača. To također daje mogućnost sustavu umjetne inteligencije da sprovodi operacije kokpita koje bi se mogle smatrati instinktivnijim i inteligentnijim. Sustav percipira koncentraciju, aktivnost, emocije, stav, ponašanje, razgovor, gestikuliranje i položaj vozača sa raznim varijacijama otkrivanja. Signali poput onih na licu nisu laki za analiziranje. Čak i obična bora na čelu ili skretanje pogleda mogu se protumačiti na razne načine.



Slika 5. Detekcija lica vozača

Izvor: https://www.nvidia.com/en-us/self-driving-cars/drive-videos/

Na Slici 3. vidi se sustav DNN-a (Duboka neuronska mreža) čiji je zadatak da slijedi pogled i uočava vektor očiju korisnika, ujedno ga prenoseći na cestu sa ciljem da otkrije da li mogu

identificirati smetnje koje nailaze. Osim toga, prati želju čovjeka da spava, određujući jesu li oči zatvorene ili otvorene ne bi li procijenio stupanj pospanosti. Sustav također analizira i djelovanje vozača, na primjer, da li koristi mobitel, da li su mu ruke uključene ili isključene s upravljačkog kola, da li sa oprezom promatra cestu. Još jedna od funkcija je analiziranje položaja vozača, to jest da li je on dobro smješten da bi se skoncentrirao na događanja na cesti. Takav sustav je izvanredan za korištenje u okviru trećeg i četvrtog stupnja autonomnosti jer poboljšava sigurnost tijekom vožnje.

Peti stupanj podrazumijeva apsolutno autonomna prijevozna sredstva, gdje je prijevozno sredstvo napravljeno tako da može samostalno odrađivati sve zadatke tijekom vožnje bez vozača. U ovom stupnju autonomnosti prijevoznom sredstvu nije neophodan vozač jer ne posjeduje pričuvne ručne kontrole, i stoga je vozač zapravo putnik, a ne onaj koji upravlja vozilom.

Provođenje finalne varijante apsolutno automatiziranog prijevoznog sredstva rezultirati će brojnim koristima što se tiče sigurnosti i pouzdanosti. Ljudska pogreška će bit reducirana na nulu; međutim, ključno će biti da se prijevozno sredstvo sačuva od cyber napada (pošto vozač nikako ne može preuzeti upravljanje), kao i da se poboljša povjerenje korisnika u svoje prijevozno sredstvo.

6. TENDENCIJA RAZVOJA AUTONOMNIH VOZILA U BUDUĆNOSTI

Kao što je ranije navedeno, eksperimentalni prototipovi autonomnih vozila već su testirani na više od milijun kilometara, no praktična upotreba autonomnih vozila osim tehničkog i tehnološkog testiranja na cesti, odnosno primjene odgovarajuće tehnologije, uvelike je određena i njegovom cijenom, društvenim navikama ljudi, psihologijom, pravnim okvirom i drugim čimbenicima. Stoga Jianfeng, Bodong i Quixia navode kako je "još uvijek dalek put do komercijalizacije autonomnih vozila."[53]

Trenutačno autonomni automobili konfiguriraju mnoge senzore koji ne postoje u tradicionalnim automobilima. Pri tome su najznačajniji laser i senzori za percepciju okoline koji su dosta skupi i zahtjevni za upotrebu. Štoviše, ugrađivanjem u vozilo, životni vijek ovih senzora znatno će se smanjiti.[54] Još uvijek je zabrinjavajuća i sama pouzdanost autonomnih vozila, te je svakako potrebno još neko vrijeme da društvena navika ljudi prihvati autonomne automobile. Stoga se može reći da postoje određene prepreke za komercijalizaciju autonomnih vozila. naročito u domeni razlika između kamera i senzora, društvenih navika, ljudske psihologije i pravne problematike.

6.1 Konkurentske prednosti različitih senzora

Dva su ključna senzora za opažanje okoline autonomnog automobila: LIDAR i VISION, od kojih svaki ima svoje prednosti i nedostatke. LIDAR-a je u stanju jasnije uočiti okolinu oko vozila, na njega manje utječu vanjski čimbenici, posebno svjetlost. Ovaj laserski radar za trodimenzionalne slike je trenutno najučinkovitiji senzor, ali i najprecizniji senzor za dobivanje širokog raspona trodimenzionalne slike scene. Nedostatak je što je trenutni proizvodni proces za LIDAR vrlo složen i skup (trenutna cijena je između 1000 - 80 000 USD).[55]

Nasuprot LiDAR-u, VISION ima nisku cijenu, ali je njegova sposobnost opažanja okoline manja i na nju utječe kvaliteta algoritma i okoline, posebno svjetla. Za tehnologiju opažanja

[53] Jianfeng, Z, Bodong,L.,Qiuxia,Ch.: The key technology toward the self-driving car, IJIUS,6,1, School of Automotive and Transportation Engineering, Shenzhen Polytechnic, Shenzhen, China
[54] Ibid
[55] https://www.neuvition.com/media/blog/lidar-price.html, pristupljeno: 19.8.2022.

okoline kod autonomnih vozila, Google kao predstavnik uglavnom koristi LiDAR, a Tesla Vision.[56]

Harris,[57] tvrdi da će kamere zamijeniti LiDAR u budućnosti, a Shchetko[58] vjeruje da će tehnologija proizvodnje LiDAR-a doživjeti novi iskorak zajedno s velikom potražnjom koja će rezultirati značajnim smanjenjem cijena LiDAR-a. Navedeni autori se slažu da će LIDAR biti glavni senzor percepcije okoliša pod režimom potpune automatizacije; međutim, smatraju i da će se VISION također koristiti za pomoć za opažanje okoline pri autonomnoj vožnji. Smatraju da će u budućnosti, mješovito okruženje temeljeno na LIDAR-u, a potpomognuta VISION-om biti standardni model.[59]

6.2 Društvene navike

Društvene navike su vrlo važno pitanje u sociološkim istraživanjima i vrlo značajne pri implementaciji novih tehnologija u društvo. Daljnji razvoj autonomnih vozila imati će veliki utjecaj na prijevoz ljudi. Prije svega, taksi i kamion će biti zamijenjeni, a značajan će biti i utjecaj na javni prijevoz.

S druge strane, autonomno vozilo može biti prikladnije i za putovanje ljudi, što može imati dugoročne posljedice i urušiti postojeći model društvenog prijevoza. Posljedica veće primjene autonomnih vozila u javnom prijevozu može dovesti do smanjenja autobusnih usluga i zagušenijeg gradskog prometa. Tendencija razvoja autonomnih vozila promovira i ekonomiju dijeljenja, odnosno dijeljenje autonomnih vozila pri gradskom prijevozu.[60]

[56] Jianfeng, Z, Bodong,L.,Qiuxia,Ch.: The key technology toward the self-driving car, IJIUS,6,1, School of Automotive and Transportation Engineering, Shenzhen Polytechnic, Shenzhen, China
[57] Harris, M. (2015), "A cheaper way for robocars to avoid pedestrians", IEEE Spectrum, Vol. 52 No. 7, p. 16.
[58] Shchetko, N. (2014), "Laser eyes pose price hurdle for driverless cars", available at: www.lux researchinc.com/sites/default/files/WSJ_7-21-14.pdf
[59] Jianfeng, Z, Bodong,L.,Qiuxia,Ch.: The key technology toward the self-driving car, IJIUS,6,1, School of Automotive and Transportation Engineering, Shenzhen Polytechnic, Shenzhen, China
[60] Banks, V.A. and Stanton, N.A. (2016), "Keep the driver in control: automating automobiles of the future", Applied Ergonomics, Vol. 53, pp. 389-395.

6.3 Ljudska psihologija

Potencijalni problem praktičnog prihvaćanja autonomne vožnje proizlazi iz dva aspekta – iz ljudske potrebe za sigurnošću, te domene društvenih i etičkih pitanja upotrebe ovakvog vozila. Već više od jednog stoljeća ljudi su navikli na samostalno kontroliranje upravljanja vozilom. Činjenica da autonomno vozilo može izazvati ozljede ili čak smrt putnika, ima veliki utjecaj na ljudsku psihologiju. Mnogi ljudi nisu voljni koristiti autonomna vozila što bitno utječe na njihovu budućnost i komercijalizaciju.

6.4 Pravni problem

Sadašnji pravni sustav odnosno pravni okviri većine države, ne zadovoljavaju potrebe za praktičnom primjenom autonomnih vozila.

Nekoliko je temeljnih problema vezano za ovo područje:[61]

1. problem s licencom
    - trenutačno mnoge zemlje ne donose pravila za autonomna vozila
2. propisi vožnje
   – propisi za vožnju autonomnih vozila svoj temelj imaju u propisima za ljudsku vožnju
3. definicija odgovornosti
    - kako definirati odgovornost ukoliko nema vozača?
4. informacijska sigurnost
    - ima li autonomno vozilo pravo na bilježenje put prolaza?
    - Je li mapiranje autonomnog vozila povezano sa sigurnošću informacija

u zemlji ili regiji?

[61] Greenblatt, N.A. (2016), "Self-driving cars and the law", IEEE Spectrum, Vol. 53, pp. 46-51.

Ujedinjeni narodi su 23. ožujka 2016. uveli izmjene u Konvenciju o cestovnom prometu koja se bavi upravljanjem cestovnim prometom.[62] Ovim izmjenama uklanjaju se prepreke za primjenu autonomnih vozila u prijevozu.

SAD daje sve od sebe u reguliranju pravnog okvira za autonomna vozila pa su neke države donijele relevantne zakone o ispitivanju autonomnih vozila, Najvažniji među njima su:

- Savezna politika o automatiziranim vozilima (USDO Transportation, 2016.),[63]
- Zakon o sigurnom osiguranju života o budućoj implementaciji i istraživanju razvoja vozila (SAD Kongres, 2017).

Ostale zemlje donose samo neke dopuštene uvjete testiranja i razmatraju relevantno zakonodavstvo.

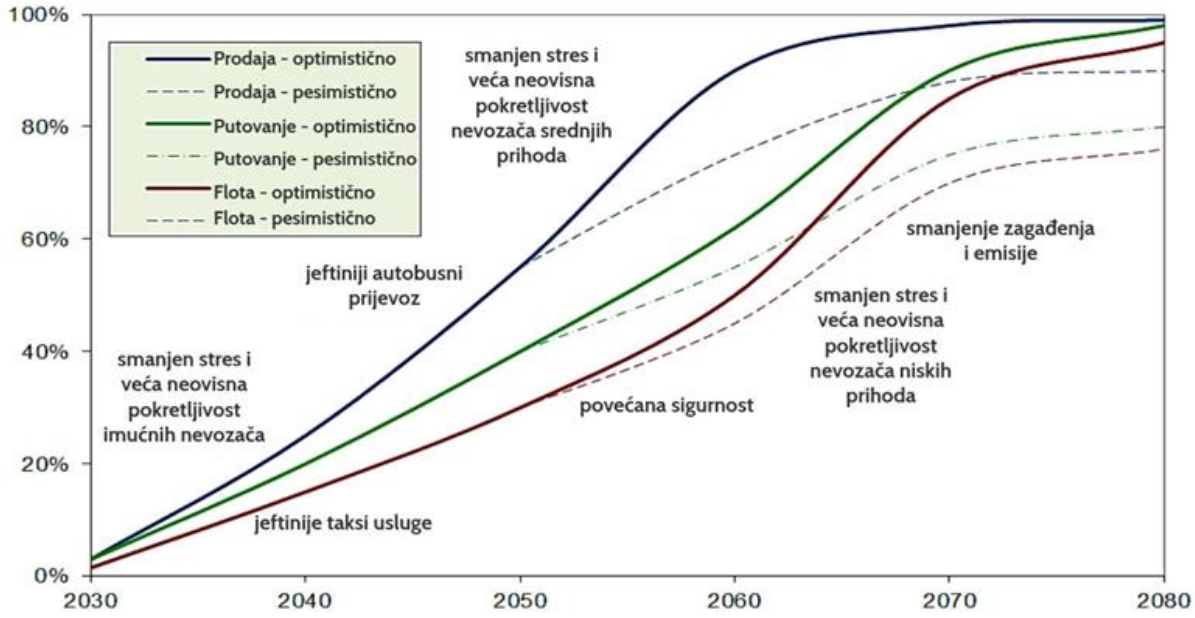
Danas se sve više tehnologija za pomoć u vožnji koje potječu iz autonomnih vozila koristi u tradicionalnim automobilima. Može se predvidjeti da će razvoj autonomnih vozila ići postepeno - od pomoćne vožnje do autonomnog vozila u posebnom okruženju (kao što je autocesta), i konačno do potpune autonomne vožnje.

Predviđa se da će do 2025. godine autonomna vozila biti prilično pouzdana i sigurna. Budući da je za komercijalnu upotrebu potreban niz testiranja, pretpostavka je da će autonomna vozila za komercijalne svrhe biti dostupna do 2030. godine.[64] Glavna pretpostavka je da će prva komercijalna upotreba autonomnih vozila biti zamjena za taksije, a kasnije i javni prijevoz.

Očekuje se da će u početku komercijalne primjene autonomna vozila biti jako skupa. Predviđa se da će većina i dalje koristiti vlastita vozila kojima sami upravljaju, te da će tek iza 2060. godine 50% vozila biti autonomno, odnosno dostupno većini.[65]

Grafikon u nastavku prikazuje očekivani razvoj komercijalizacije autonomnih vozila kroz predikciju prodaje, voznog parka, putovanja i korisnosti autonomnih vozila.

[62] https://unece.org/press/unece-paves-way-automated-driving-updating-un-international-convention, pristupljeno: 1.9.2022.
[63] https://www.ncsl.org/research/transportation/regulating-autonomous-vehicles.aspx
[64] Litman, T. (2021) Autonomous Vehicle Implementation Prediction, Victoria Transport Policy Institute
[65] Ibid



Slika 6. Grafikon. Predikcija prodaje, voznog parka, putovanja i korisnosti autonomnih vozila

Izvor: Litman, T. (2021) Autonomous Vehicle Implementation Prediction, Victoria Transport Policy Institute

Mnoge tehnologije za pomoć u vožnji već su usvojene. Tu se ubrajaju npr., pomoć pri održavanju trake i prilagodljivi tempomat koji su već potpuno komercijalizirani. Također već je sada u upotrebi automatska vožnja na autocesti, što je već korak prema autonomnoj vožnji. Pretpostavka je da će se u budućnosti, potpuno autonomno vozilo prihvatiti kao uobičajeni način vožnje i prijevoza.

7. ZAKLJUČAK

Razvitak autonomnih prijevoznih sredstava povezan je sa suvremenim društvom, to jest sa modernim vremenom, no prvi oblici razvoja automatiziranih vozila javljaju se već u 20. stoljeću. Povijesno gledano, razvitak autonomnih prijevoznih sredstava vršio se u tri faze. Prva faza, koja je trajala od 1980. do 2003. godine, je obuhvaćala temeljno istraživanje gdje su, uz surađivanje sa transportnim agencijama i organizacijama koje se bave automobilima, centri za istraživanja formirali manje zahtjevna istraživanja o autonomnom transportu. Druga faza definira se kao „faza velikih izazova“. Njeno trajanje je bilo od 2003. do 2007. godine, i u njoj ključnu poziciju ima Agencija za obrambene napredne istraživačke projekte američkog Ministarstva obrane (DARPA), koja je glavna za pokretanje ovih triju „velikih pothvata“ koja služe za poboljšavanje funkcionalnosti autonomnih prijevoznih sredstava. Najbitnija namjena ovih izazova predstavljalo je izučavanje potencijalnog korištenja autonomnih prijevoznih sredstava u vojne svrhe. Treća i posljednja faza bazira se na komercijalnom razvitku, pa je stoga i njen naziv „faza komercijalnog razvitka“. Godine 2014. udruga inženjera za prijevozna sredstva SAE (Society of Automotive Engineers) proizvela je podjelu autonomnih prijevoznih sredstava na šest stupnjeva, a ona je obnovljena 2016. godine. Temelj ove podjele je koliko je neophodno da vozač posveti pažnje kod vožnje prijevoznim sredstvom.

Osnovno načelo funkcioniranja autonomnih vozila je „osjeti-planiraj-djeluj“ koje je ujedno i ključni element mnogih robotskih sustava. Prijevozno sredstvo prvo, uz pomoć sustava senzora, preuzima informacije o okolini i o stanju samog vozila. Nakon toga, uz pomoć suvremenih algoritama, ono analizira preuzete informacije i shodno tome definira planove o tome koje će odluke donijeti. Slijedom za analiziranjem informacija i definiranjem planova dolazi na red implementiranje rješenja vezanih za upravljački mehanizam prijevoznog sredstva, što je ujedno i kraj načela „osjeti-planiraj-djeluj“.

Senzorski sustavi se sastoje od brojnih raznolikih senzora čiji je cilj preuzimanje informacija iz okruženja prijevoznog sredstva u realnom vremenu. Informacije koje senzor preuzima služe za percepciju, planiranje putanje, računanje distance do smetnji, navigiranje, itd. Percepcija je mogućnost prijevoznog sredstva da vidi svoje okruženje, i u tu svrhu su najviše u upotrebi LIDAR, RADAR i GPS. LIDAR sustavi (Light Detection and Ranging) određuju distancu do prepreke laserima koji emitiraju zrake svjetlosti i računaju vrijeme koje je potrebno za refleksiju da se vrati od stvari u okruženju. Njihova mana se sastoji u tome da imaju manju mogućnost

da se koriste na visokim dometima i nije im dobra refleksija na pojedinim materijalima. Nasuprot LIDAR sustavu, RADAR (Radio Detecting and Ranging) upotrebljava radio valove. Oni odlično uočavaju metalne konstrukcije; međutim, ne vide objekte koji nisu metalni. Za percipiranje upotrebljavaju i kamere koje služe za poimanje bazičnih faktora u okruženju kao što su oznake traka, semafori, prometni znakovi. Kamere nisu skupe, međutim, algoritmi koji se bave analiziranjem dobivenih informacija nisu za sada dovoljno napredni kao čovjek pri prepoznavanju vizualnih informacija.

Promatrajući sprovedene studije, za sada se ne zna na koji će način implementiranje autonomnih prijevoznih sredstava imati utjecaja na sadašnju infrastrukturu ceste. Postoje dva modela, i svaki od njih pruža prostor za razne izmjene u tome kako će se sve dešavati. Oni koji podržavaju prvi model zalažu se za apsolutno autonomna prijevozna sredstva koja su samostalna u odnosu na druga vozila i koja djeluju u skladu sa komponentama sadašnje infrastrukture. Međutim, drugi potenciraju da je neophodno da se autonomna prijevozna sredstva mogu podijeliti za različite stupnjeve autonomnosti uzimajući u obzir to koji stupanj je preporučen za konkretnu infrastrukturu. Kako postoje brojne dileme oko implementiranja takvih prijevoznih sredstava, ključno će u tome biti zakonodavno tijelo jer će njegov zadatak biti da odredi tko će snositi odgovornost: vozač ili prijevozno sredstvo. Osim toga, računa se i na pravne propise koji se tiču autonomnih sustava, licenciranja vozača i određivanja adekvatne infrastrukture. Njihov rezultat bit će rješenje mnogih dilema, i bit će početak realizacije uvođenja autonomnih prijevoznih sredstava u promet.

LITERATURA

1. Ezgeta,D.: Inteligentni transportni sustavi, Univerzitet u Sarajevu, Fakultet za saobraćaj i komunikacije, Sarajevo 2018, str.103

2. Taeihagh, Araz; Lim, Hazel Si Min: Governing Autonomous Vehicles: Emerging Responses for Safety, Liability, Privacy, Cybersecurity, and Industry risks. Transport Reviews

3. Maurer M., Gerdes C., Lenz B., Winner H.: Autonomous Driving: Technical, Legal and Social Aspects, 2016.

4. Buehler M., Iagnemma K., Singh S.: The DARPA Urban Challenge: Autonomous Vehicles in City Traffic, Springer Tracts in Advanced Robotics series, 2010.

5. Carnegie Mellon University, General Motors–Carnegie Mellon Collaborative Research Labs; http://www.cmu.edu/corporate/partnerships/gm-lab.shtml

6. Raviteja,T., Vederaj, R.: An Introduction of Autonomus Vehicle and A Brief Survey, Journal of Critical Reviews, 7.13, 2020

7. Bosnjak, I.; Inteligentni transportni sustavi 1. Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.

8. Society of Automotive Engineers:Taxonomy and Definitions for Terms Related to On-Road Automated Vehicles, SAE document J3016, 2014, str.16

9. Liu, S., Tang, J., Zhang, Z.: Computer architectures for autonomous driving, IEEE Comput. Archit. Lett., 2017

10. Anderson J., Kalra N., Stanley K., Sorensen P., Samaras C., Oluwatola O.: Autonomous Vehicle Technology; A Guide for Policymakers

11. Kočić J., Jovičić N., Drndarević V.: Sensors and Sensor Fusion in Autonomous Vehicles, 2018.

12. Autonomous Vehicles_CSS16-18_e2021.pdf

13. Varghese J., Boone R.: Overview of Autonomous Vehicle Sensors and Systems, 2015.

14. Anderson J., Kalra N., Stanley K., Sorensen P., Samaras C., Oluwatola O.: Autonomous Vehicle Technology; A Guide for Policymaker

15. Rajasekhar MV, Kumar Jaswal A: Autonomous Vehicles: The Future Of Automobiles

16. J. Wang, J. Liu and N. Kato, Networking and Communications in Autonomous Driving

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

18. https://www.bug.hr/transport/autonomna-cestovna-vozila-robote-vozi-polako-20775, pristupljeno: 29.7.2022.

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

20. https://www.telegram.hr/partneri/evolucija-automobila-povezanih-uz-5g-brze-putovanje-uz-manju-potrosnju-manje-sudara-i-ozlijedenih/ pristupljeno: 5.7.2022.

21. Cerovac, V.: Tehnika i sigurnost prometa, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2001

22. Doc. Dr. sc. Grgo Luburić, Sigurnost cestovnog I gradskog prometa I, Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2017.

23. https://www.frontiersin.org/articles/10.3389/fpsyg.2019.00995/full, pristupljeno: 7.7.2022.

24. https://www.washingtonpost.com/sf/brand-connect/ucdavis/driverless-cars-could-be-a-solution-to-climate-change/, pristupljeno: 15.8.2022.

25. Jianfeng, Z, Bodong,L.,Qiuxia,Ch.: The key technology toward the self-driving car, IJIUS,6,1, School of Automotive and Transportation Engineering, Shenzhen Polytechnic, Shenzhen, China

26. Harris, M. (2015), "A cheaper way for robocars to avoid pedestrians", IEEE Spectrum, Vol. 52 No. 7, p. 16.

27. Shchetko, N. (2014), "Laser eyes pose price hurdle for driverless cars", available at: www.lux researchinc.com/sites/default/files/WSJ_7-21-14.pdf

28. Banks, V.A. and Stanton, N.A. (2016), "Keep the driver in control: automating automobiles of the future", Applied Ergonomics, Vol. 53, pp. 389-395.

29. Greenblatt, N.A. (2016), "Self-driving cars and the law", IEEE Spectrum, Vol. 53, pp. 46-51.

30. https://unece.org/press/unece-paves-way-automated-driving-updating-un-international-convention, pristupljeno: 1.9.2022.

31. Litman, T. (2021) Autonomous Vehicle Implementation Prediction, Victoria Transport Policy Institute

32. https://www.ncsl.org/research/transportation/regulating-autonomous-vehicles.aspx, pristupljeno:1.9.2022.

POPIS SLIKA

Slika 1. Prikaz senzora na autonomnom vozilu 14
Slika 2. Cijene po putničkom kilometru u odnosu na broj putnika 18
Slika 3. Venov dijagram 24
Slika 4. Uloga čovjeka kao vozača 25
Slika 5. Detekcija lica vozača 35
Slika 6. Grafikon. Predikcija prodaje, voznog parka, putovanja i korisnosti autonomnih vozila 41

POPIS TABLICA

Table 1. Razina automatizacije inteligentnih vozila 11
Table 2. Ljudski faktor u kibernetičkoj sigurnosti po razinama automatizacije 33

POPIS KRATICA

LiDAR – Light Detection and Ranging

RADAR – Radio Detection and Ranging

GPS – Global Positioning System

ODD - Operationak Design Domain

INS – Inertial Navigation System

DNN – Deep Neural Network

DARPA – Defense Advanced Research Projects Agency

Sveučilište u Zagrebu
Fakultet prometnih znanosti
Vukelićeva 4, 10000 Zagreb

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOSTI

Izjavljujem i svojim potpisom potvrđujem da je završni rad
(*vrsta rada*)
isključivo rezultat mojega vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju upotrijebljene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedopušten način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu završnog/diplomskog rada pod naslovom „utjecaj autonomnih vozila na sigurnost cestovnog prometa“, u Nacionalni repozitorij završnih i diplomskih radova ZIR.

Student/ica:

U Zagrebu, 6.9.2022.

Tomislav Gamilec T. Gamilec
(ime i prezime, *potpis*)