

Primjena umjetne inteligencije kod autonomnih automobila

Kekić, Kristijan

Undergraduate thesis / Završni rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:137:944817>

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

Download date / Datum preuzimanja: **2025-04-01**



Repository / Repozitorij:

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

Kristijan Kekić

Primjena umjetne inteligencije kod autonomnih automobila

Završni rad

Pula, rujan, 2021.

Sveučilište Jurja Dobrile u Puli
Fakultet informatike u Puli

Kristijan Kekić

Primjena umjetne inteligencije kod autonomnih automobila

Završni rad

JMBAG: 0303082334, redoviti student

Studijski smjer: Informatika

Kolegij: Informatička tehnologija i društvo

Znanstveno područje: Društvene znanosti

Znanstveno polje: Informatičke i komunikacijske znanosti

Znanstvena grana: Informatički sustavi i informatologija

Mentor: doc. dr. sc. Snježana Babić

Pula, rujan, 2021.



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Kristijan Uehić, kandidat za prvostupnika informatike ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljeni način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

Kristijan Uehić

U Puli, 15. rujna 2021.



IZJAVA O KORIŠTENJU AUTORSKOG DJELA

Ja, Kristijan Uekić dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj Završni rad pod nazivom

Primjena umjetne inteligencije kod autonomnih automobila

koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, 15. rujna 2021.

Potpis

Kristijan Uekić

SADRŽAJ

1. UVOD	6
2. UMJETNA INTELIGENCIJA	8
2.1. Opći pojam umjetne inteligencije	8
2.2. Povijest i razvoj	9
2.3. Vrste učenja moderne umjetne inteligencije	12
2.3.1. Nenadgledano učenje	13
2.3.2. Nadgledano učenje	14
2.3.3. Pojačano učenje	14
3. AUTONOMNI AUTOMOBILI	16
3.1. Opći pojam autonomnog automobila	16
3.1.1. Razine autonomije	16
3.2. Primjeri proizvođača autonomnih automobila	18
3.2.1. Tesla	18
3.2.2. Waymo	18
3.2.3. Baidu	19
3.2.4. Primjer autonomnog kamiona i dostavljača pizze	19
3.3. Utjecaj autonomnih automobila na društvo	19
4. PRIMJENA UMJETNE INTELIGENCIJE U AUTONOMNIM AUTOMOBILIMA	23
4.1. Primjeri lateralne kontrole	24
4.2. Primjeri longitudinalne kontrole	26
4.3. Primjeri cijelokupne kontrole	28
4.4. Problem percepcije	32
5. TREND RAZVOJA UMJETNE INTELIGENCIJE KOD AUTONOMNIH AUTOMOBILA	36
Zaključak	37
Literatura	38
Popis slika	41
Sažetak	42
Summary	43

1. UVOD

Sam pojam umjetne inteligencije je i dan danas novo, veoma široko područje koje se nastavlja razvijati i otkrivati. Ovo ne bi bilo moguće da nije bilo eksponencijalnog napretka tehnologije u zadnjih 100 godina. Taj napredak je omogućio razvoj sve jačih, bržih računala, omogućio je razvoj interneta kakvog danas poznajemo, upravo to je pomoglo da se otkrije i razvije novo područje: umjetna inteligencija.

Danas se umjetna inteligencija primjenjuje u različitim područjima, od logistike, trgovine, video nadzora, zdravstva, menadžmenta, agrikulture. Pojam automobila je na drugu stranu poznat već preko 130 godina. Međutim, nakon više od 130 godina postojanja automobila, današnji proizvođači su krenuli u novom pravcu: autonomni automobil.

Kad čujemo pojam autonomni automobil, većinu ljudi će to najvjerojatnije asociirati na Teslu, najpoznatiji autonomni automobil današnjice. Međutim, Tesla nije jedina koja razvija autonomni automobil.

„Važni proizvođači automobila poput Mercedes, General Motors, Ford, Daimler, Audi, BMW i Nissan, planiraju izbaciti na tržište autonomni automobil u sljedećih 10 godina.“ (Adouane, 2016)

Svakako, pojava autonomnih automobila stvara određena društvena i etička pitanja. Međutim, uklanja jedan veoma ključni aspekt zbog kojeg se autonomni automobili razvijaju: ljudska pogreška, koja uzrokuje 90% prometnih nesreća. (Kuutii, 2019.) te prema Stavensu (2011:4) svake godine oko 1,2 milijuna osoba pogine u automobilskim nesrećama te ih oko 50 milijuna ostane ozlijeđeno, što je prema Dhawanu (2018:13) „više nego što ih pogine u ratovima“.

Cilj ovog završnog rada je objasniti pojmove umjetne inteligencije, autonomnog automobila i strojnog učenja, prikazati njihov razvoj, objasniti koje se metode strojnog učenja koriste u autonomnim automobilima, te objasniti njihov mogući utjecaj na društvo. Ovaj rad sadrži 4 poglavlja. U prvom poglavlju, umjetna inteligencija, objasnit će se pojam umjetne inteligencije, njezina povijest i metode strojnog učenja. U drugom poglavlju će se objasniti pojam autonomnog automobila te povijest autonomnih automobila, navesti će se neki najpoznatiji modeli autonomnih automobila, te će se na kraju objasniti njihov

moćući utjecaj na društvo. U trećem poglavlju će se nabrojati metode longitudinalne, lateralne i potpune kontrole te će se objasniti različita rješenja za svaki tip kontrole. Nakon toga još će se prikazati rješenje problema percepcije. U zadnjem poglavlju, nabrojati će se metode i načini razvoja primjene umjetne inteligencije u budućnosti autonomnih automobila.

2. UMJETNA INTELIGENCIJA

U ovom poglavlju, objasniti će se pojam umjetne inteligencije, njegovu definiciju te povijest od nastanka pojma umjetne inteligencije do danas. Nakon toga, objasniti će se metode strojnog učenja, jednog od subpodručja umjetne inteligencije.

2.1. Opći pojam umjetne inteligencije

Prije objašnjenja samog pojma umjetne inteligencije, treba postaviti pitanje: što je to inteligencija? Što predstavlja značenje da je netko inteligentan?

Postoji nekoliko definicija pojma inteligencije. Prvi primjer, iz Novog engleskog rječnika (New English Dictionary) nastao 1932. godine, objašnjava inteligenciju kao „vježba razumijevanja, intelektualna snaga, skupljeno znanje, brzina intelekta“. Bliže našem vremenu, Macmillanova enciklopedija tumači inteligenciju kao „mogućnost promišljanja i profitiranja iz iskustva. Razina inteligencije individualca je određena složenim međudjelovanjem njihovog nasljedstva i okoline.“ (Warwick, 2012)

Prema Kaplanu (2016:1), pitanje umjetne inteligencije nije jednostavno za odgovoriti. Razlog tome su dva razloga: prvi, iako je prije rečeno da postoji nekoliko definicija pojma inteligencija, ne postoji mnogo slaganja u vezi pitanja što je točno inteligencija. Drugi razlog je slabo uvjerenje da uređaji mogu imati inteligenciju sličnu čovjeku.

Usprkos postojanju mnogih definicija umjetne inteligencije, sve one se slažu u vezi ideje pravljenja kompjuterskih programa ili uređaja koji bi čovjeku bili na izgled inteligentni. John McCarthy, čovjek koji je osnivač same discipline umjetne inteligencije, je 1955. predstavio umjetnu inteligenciju kao „proces učenja uređaja da se ponaša inteligentno kao čovjek“. (Kaplan, 2016)

Nadalje, što se tiče umjetne inteligencije, postoje 4 vrste umjetne inteligencije (Government technology, 2021):

- 1. Reaktivni strojevi
- 2. Ograničena memorija

- 3. Teorija uma
- 4. Samosvijest

Reaktivni strojevi predstavljaju najjednostavniju vrstu umjetne inteligencije, koji kako im ime kaže, se ponašaju reaktivno, bez mogućnosti da koriste ranija iskustva. Primjer ovakvog uređaja je Deep Blue, IBM-ovo superračunalo namijenjeno igranju šaha. Strojevi koji imaju ograničenu memoriju mogu koristiti prošla iskustva. Primjer uređaja koji koristi ovakav način umjetne inteligencije je autonomni automobil. On promatra stanje na cesti, te koristi prikupljene podatke u daljnjem odlučivanju. Strojevi u teoriji uma ne stvaraju samo predodžbu svijeta, nego i ostalih sudionika. Ti uređaji razumiju da osjećaji i misli mogu utjecati na ponašanje ljudi. Do ove razine današnja umjetna inteligencija nije stigla. Samosvijest je zadnji korak umjetne inteligencije. Predstavlja nastavak na teoriju uma, gdje strojevi imaju svoju svijest, i mogu razumijeti druge. (Government technology, 2021)

Osim toga, umjetna inteligencija ima 3 kognitivne vještine (SearchEnterpriseAI, 2021):

- Učenje
- Odlučivanje
- Ispravljanje

Kod učenja, cilj je prikupljanjem podataka i stvaranjem pravila (algoritama) stvoriti korisne informacije. Kod odlučivanja, cilj je odabrati pravi algoritam da se dođe do određenog cilja, dok god ispravljanja umjetna inteligencija popravljaju algoritme da bi donijeli bolje rezultate u sljedećim odlukama. (Government technology, 2021)

2.2. Povijest i razvoj


Iako je pojam umjetne inteligencije tek u ovom stoljeću dobio na popularnosti, njegov koncept je nastao još 50-tih godina prošlog stoljeća.

Riječ „umjetna inteligencija“ je svoju premijeru našla 1956. godine na konferenciji vezanoj uz inteligenciju uređaja. Na konferenciji su bili pristuni tadašnji veliki znanstvenici poput John McCarthy, Marvin Minsky, Claude Shannona, Allen Newella i Herbert Simona. (Bramer, 2009)

Kasnije, Newell, Cliff Shaw i Simon su kasnije izmislili jezik za umjetnu inteligenciju, nazvan IPL (Information Processing Language), koji je korišten za kompjuterski program zvan teoritičar logike (Logic Theorist), koji se smatra prvi program umjetne inteligencije ikada napravljen. (Taulli, 2019)

Važno je spomenuti i Alana Turinga, kojeg nazivaju ocem umjetne inteligencije. On je izmislio poznati „Turingov test“. Turingov test je igra koju igraju tri igrača, od njih su dva čovjek, a jedan računalo. Na slici 1 (vizualizacija Turingovog testa) se može vidjeti kako Turingov test funkcionira. Igra funkcionira na taj način da se za ocjenjivača (evaluator) postavi jedan od dva čovjeka, nakon čega on postavlja pitanja drugom čovjeku i računalu, s ciljem da ocjenjivač nakon dobivenih odgovora prepozna tko je čovjek. U slučaju da je ocjenjivač u nemogućnosti odrediti tko je čovjek a tko je računalo, smatralo bi se da je računalo inteligentno. Međutim, u to doba takav test nije bilo moguće izvršiti, zbog hardverskih ograničenja. (Taulli, 2019)

Turingov test je u međuvremenu napretkom tehnologije i interneta bilo moguće ostvariti, pa su napravljeni pokušaji Turingovog testa 2014. i 2018. godine. 2014. godine, računalo je glumilo da ima 13 godina. Zbog grešaka u odgovorima, suci su bili zavarani da je računalo čovjek. 2018. godine na Googleovoj konferenciji je napravljen prikaz ranog Google Pomoćnika (Google Assistant). Direktor tvrtke Sundar Pichai je pred publikom iskoristio priliku da pokaže što Google Assistant može. Preko Google Assistana je nazvao lokalnog frizera da dogovori termin, dok se frizer ponašao kao da razgovara sa čovjekom. Osim Turingovog testa, nastale su alternative na Turingov test poput Kurzweil-Kaporovog testa (računalo razgovara sa 2 ili 3 suca 2 sata) i test kave (Coffe test, robot mora ući u nasumičnu kuću, pronaći kuhinju i skuhati kavu). (Taulli, 2019)



Slika 1. Vizualizacija Turingovog testa (izvor: autor izradio na osnovu rada: *Artificial intelligence Basics. A Non-Technical Introduction*, Taulli T., 2019)

Newall i Simon su nastavili svoj rad sa tvorbom novog programa, rješavača generalnih problema (GPS). Za GPS se može reći da je uspjeh, jer je za razliku od teoretičara logike imao pristup bliži ljudskom razmišljanju. Iako je postojao ograničen broj puzzle koje je mogao riješiti, način uzimanja podriješenja i obavljanja radnji je bio sličan čovjekovom pristupu. (Russell, 2016)

Od 1956. do 70-tih godina 20. stoljeća, predstavlja se zlatno doba umjetne inteligencije. Zahvaljujući otkriću integriranih krugova, računala su uvelike smanjila veličinu sistema a i ubrzala svoj rad. Osim toga, hladni rat i utrka na mjesec su dodatno ubrzali razvoj umjetne inteligencije. U tom razdoblju je nastalo nekoliko programa umjetne inteligencije, poput SAINT-a, STUDENT-a, koji su rješavali matematičke probleme, ELIZA, koji je služio kao psihoanalitičar, ili Mac Hack, program koji je igrao šah. (Taulli, 2019)

Sljedeći bitni sustavi u razvoju umjetne inteligencije su sustavi bazirani na znanju i ekspertni sustavi. Kod takvih sustava je naglašena važnost IF (uvjet) THEN (uvjet) izraza. MYCIN, jedan od prvih uspješnih ekspertnih sustava, je imao namjenu u dijagnostici krvnih infekcija. Sustav je sadržavao oko 450 pravila pomoću kojih je donosio odluke. To je pozicioniralo sustav na višoj razini od mladog liječnika pa čak i oko razine iskusnih liječnika. Ovakav sustav je imao svoje prednosti poput jednostavnog programiranja, dobrog dizajna za rješavanje stvarnih problema te brzina odgovora. No,

postojali su i nedostaci, poput „kombinatoričke eksplozije“, koja dolazi kad sustav ima previše pravila, jer je sustav dizajniran da sva pravila uključi u donošenje odluke, i kod donošenja npr. neke jednostavne odluke te ako je sustav prevelik, donošenje odluke može biti sporije od čovjeka. Osim toga, takvi sustavi mogu biti veoma skupi, pogotovo ako je potrebno više sustava. (Warwick, 2012)

Nakon vremena ekspertnih i sustava baziranim na znanju, došlo je do pojave neuralnih mreža i strojnog učenja.

Važno je istaknuti da je sama struktura neuralnih mreža inspirirana strukturom ljudskog mozga, sa slojevima međusobno povezanih neurona koji prenose informacije. (Kuutii, 2019.)


Bitno sposobnost umjetne inteligencije je sposobnost učenja. To im omogućava da se prilagode svoj način rada i promjene svoje ponašanje u srži. (Warwick, 2012)

Svakako, postoje i neke bitne činjenice koje su utjecale da je moderna umjetna inteligencija takva kakvu poznajemo. U činjenice ubrajamo eksplozivan rast skupa podataka zahvaljujući pojavi Interneta, koja je omogućila nastanak ogromnih skupa podataka. Imamo i infrastrukturu, gdje je glavni akter Google. Google je omogućio indeksiranje interneta te je stvorio izdržljive i robusne sisteme koji su mogli izdržati ogroman rast Interneta. Na kraju, jedinica za obradu grafike (GPU), koja je svojim ogromnim napretkom zadnjih godina te mogućnošću paralelnog procesiranja omogućila izračunavanje modela brže od uobičajenih centralnih jedinica za obradu (CPU). (Taulli, 2019)

2.3. Vrste učenja moderne umjetne inteligencije

Prije objašnjenja današnjih metoda učenja umjetne inteligencije, treba predstaviti modernu vizualizaciju umjetne inteligencije. Na slici 2, može se vidjeti da umjetna inteligencija sadrži podskup strojnog učenja, koji još u sebi sadrži podskup dubokog učenja. Postoji razlika između strojnog i dubokog učenja, u tome da duboko učenje osim

tehnika učenja (nadgledano, nenadgledano, pojačano) koristi i koncept neuronskih mreža.



Slika 2. Vizualizacija modernog modela umjetne inteligencije (izvor: autor izradio na osnovu rada: Deep Learning for Autonomous Vehicle Control: Algorithms, State-of-the-Art, and Future Prospects, Kuutii, 2019)

2.3.1. Nenadgledano učenje

Nenadgledano učenje se koristi u slučaju podataka koji nisu klasificirani i označeni. Klasteriranje (clustering) je najkorišteniji način učenja koji se koristi kod nenadgledanog učenja, ono promatra i otkriva korisne skupine uzoraka koji se kasnije mogu koristiti kod sljedećih podataka koje će učenje primiti. (Russell, 2016)

Nenadgledano učenje također koristi otkrivanje podataka i zapisivanje zapažanja koje može kasnije pomoći kod traženja uzoraka iz neoznačenih podataka. (Saravanan, 2018)

2.3.2. Nadgledano učenje

Kod nadgledanog učenja se za razliku od nenadgledanog učenja koriste podatci koji su prema Kuutiju (2016) „označeni“ tj. ulaz i izlaz (točno rješenje) otprije poznati.

Uz pomoć označenih podataka, nadgledano učenje postaju bolji u predviđanju događaja koji nisu označeni. Algoritam uspoređuje svoja predviđanja te ih uspoređuje sa točnim odgovorom te na temelju toga ispravlja greške i poboljšava svoj model. (Saravanan, 2018)

Nadgledano učenje koristi dvije vrste algoritma:

- Klasifikacija
- Regresija


Klasifikacija i regresija imaju različite principe, dok se kod klasifikacije koriste algoritmi poput Naive Bayesa i k-najbližeg susjeda za podjelu skupa podataka u česte oznake, regresija koristi algoritam linearne regresije i stabala odluke da pronalazi slične uzorke u podacima. (Taulli, 2019)

Prednost ovakvog učenja je relativno brz proces učenja, koji skraćuje vrijeme koje je algoritmu potrebno da nauči i da se prilagodi situacijama. Sa druge strane, nadgledano učenje ima i mane: nadgledano učenje treba ogromnu količinu podataka da bi se zadovoljila adekvantna performansa i kapacitet uopćavanja. Osim toga, „označeni“ podatci možda nisu dostupni nakon početka učenja, što limitira primjenu na neka područja. (Kuutii, 2019)

2.3.3. Pojačano učenje

Pojačano učenje na drugu stranu funkcionira na taj način da se nauči napraviti red odluka. Na slici 3 imamo vizualizaciju pojačanog učenja. U pojačanom učenju postoji agent koji uči kako postići određeni cilj u nepoznatom okruženju (environment). Umjetna inteligencija se suočava u situaciji poput igre. Ona pokušava riješiti problem metodom pokušaja i pogrešaka (action), te da bi se motivirala, umjetna inteligencija može dobiti nagradu (reward) ili kaznu ovisno kako odradi zadatak. Cilj je maksimizirati nagradu.

Umjetna inteligencija ne dobiva nikakvu pomoć ili savjet kako „riješiti igru“. Na umjetnoj inteligenciji je da otkrije kako riješiti problem, te počinje od nasumičnih pokušaja pa sve do sofisticiranih taktika i superljudskih vještina. Pojačano učenje je jedan od najefektivnijih načina kako potaknuti kreativnost. (Deepsense.ai, 2021)



Slika 3. Vizualizacija pojačanog učenja (izvor: <https://towardsdatascience.com/deep-q-network-combining-deep-reinforcement-learning-a5616bcfc207>)

3. AUTONOMNI AUTOMOBILI

Nakon objašnjenja pojma umjetne inteligencije, sljedeći pojam koji će biti objašnjen je pojam autonomnog automobila. U ovom poglavlju će se osim objašnjenja pojma autonomnog automobila proći i kroz njihovu povijest, navesti će se nekoliko modela autonomnih automobila, objasniti će se razine autonomije u autonomnih automobila i njihov mogući utjecaj na društvo u budućnosti.

3.1. Opći pojam autonomnog automobila

Prije pitanja što predstavlja pojam autonomnog automobila, treba odgovoriti na pitanje što točno znači autonomija? Autonomija predstavlja mogućnost ili sposobnost samouprave. Imati autonomiju u automobilu znači imati sustav koji može kontrolirati upravljanje volana, ubrzavanje i kočenje bez potrebe da čovjek obraća pažnju na cestu. (Zanchin, 2017)

Što točno znači pojam autonomni automobil? Prema Sjafrieu (2019), autonomni automobil može imati više opisa, ovisno kako ga ljudi vide. Ljudi mogu definirati autonomni automobil kao vozilo koje putuje neovisno o čovjeku ili kao vozilo koje putuje sa svojim odlukama, ali treba čovjeka iza volana u slučaju nezgode.

Zanchin (2017) predstavlja autonomni automobil kao vozilo koje ima mogućnost prepoznavanja okoline i sposobnost navigacije kroz tu okolinu bez čovjekove pomoći. Razlika između običnog i autonomnog automobila je u tome što autonomni automobil može donositi odluke, te što autonomni automobil sadrži mnoštvo senzora koji služe za sakupljanje podataka (kasnije pomažu u percepciji, lokalizaciji, donošenju odluka).

3.1.1. Razine autonomije

SAE (kratica od Society of Automotive Engineering) je postavila šest razina autonomije u automobilima. Tih 6 razina su nadalje podijeljene u subkategorije, jedna gdje čovjek prati i upravlja vožnjom i druga gdje ADAS (Automated Driving Assistance System, ukratko „system“) ili na hrvatskom automatizirani sustav za asistiranje u vožnji, upravlja vožnjom.

- Razina 0

- Razina 1
- Razina 2
- Razina 3
- Razina 4
- Razina 5
- Razina 6

Prema Adouaneu (2016:7), tih 6 razina imaju sljedeća objašnjenja.

Razina 0 predstavlja nedostatak autonomije, cjelokupna odgovornost je na čovjeku što se tiče vožnje.

U razini 1 (podrška u vožnji) vozač cijelo vrijeme obraća pažnju nad longitudinalnim (ubrzanje, usporavanje) i lateralnim kontrolama (upravljanje volanom). Sistem pomaže sa ostalim zadacima vezanim uz vožnju.

Razina 2 ili djelomična automatizacija obavezuje vozača da i dalje obraća pažnju na sve sisteme cijelo vrijeme, međutim sistem može imati longitudinalnu i lateralnu kontrolu u specifičnim slučajevima.

Unutar razine 3 (uvjetne automatizacije) vozač ne mora pratiti sistem cijelo vrijeme ali treba biti spreman preuzeti kontrolu, sistem ima longitudinalnu i lateralnu kontrolu u specifičnim slučajevima i dalje. Sistem uz to prepoznaje svoje limite i zahtijeva od vozača da preuzme kontrolu u pravovremenom vremenskom periodu.

Razina 4 (visoka automatizacija) predstavlja razinu gdje vozač nije uopće potreban u definiranim slučajevima, dok za ostale nedefinirane je. Sistem se može snalaziti u situacijama automatski unutar definiranog slučaja.

Razina 5 (potpuna automatizacija) predstavlja razinu automatizacije gdje se sistem može snalaziti sa svim situacijama automatski bez potrebe vozača.

3.2. Primjeri proizvođača autonomnih automobila

Nakon što je pojam autonomnih automobila objašnjen, bilo bi važno navesti i nekoliko primjera autonomnih automobila. Osim najpoznatije Tesle, drugi poznatiji autonomni automobili poput Googlovog Waymoa i kineskog Baidua će biti uključeni.

3.2.1. Tesla

Tesla je danas jedan od najpoznatijih proizvođača automobila koji nude mogućnost određene razine autonomije. Neki od njihovih najpoznatijih modela uključuju Tesla Model 3, Model S. Prema Herrmannu (2018) Tesla je glavni vođa što se tiče tehnologije autonomnih automobila. Zanimljivo je navesti činjenicu da su Teslini automobili, specifičnije Model S, dobili mogućnost određenog stupnja autonomne vožnje još sredinom 2015. godine, što prema Simonsu (2020) predstavlja brojku od 200 tisuća automobila u Sjedinjenim Američkim Državama, do 2018. godine. Teslin sustav autonomne vožnje trenutno pruža 1. i 2. razinu autonomije.

3.2.2. Waymo

Waymo, Googlov autonomni automobil, je svoj razvoj započeo krajem listopada 2016. godine, u suradnji sa grupom Alphabet. Zanimljivo, Google je krenuo sa razvojem autonomnih automobila još 2005. godine. Google za razliku od ostalih proizvođača, koristi 64-zračni laserski skener, koji stvara 3D sliku okruženja. (Herrmann, 2018)

Waymo je do travnja 2019. prošao oko 16 milijuna kilometara na pravim cestama, te oko 11.2 milijuna u simulaciji. U Phoenixu, Waymo je od kolovoza 2018. godine korišten na ulicama bez čovjeka za volanom, što ga čini prvim od svojih konkurenata koji je učinio to. Nadalje, Waymo za razliku od Tesle dosad nije imao nijedan incident sa smrtnim slučajem. (Simons, 2020)

3.2.3. Baidu

Baidu, poznati kineski pretraživački div je također krenuo sa razvojem svog autonomnog automobila. Baidu za razvoj autonomne vožnje koristi BMW 3. serije na prometnicama u Pekingu i Wuhuu. Osim BMW-ova, Baidu je planirao napraviti i autonomni autobus, zvan CityMobile2, 2018. godine. Primjeri poput Baidua i Googleovog automobila Waymo pokazuju da će divovi internetske industrije također imati veliki utjecaj u automobilskoj industriji. (Herrmann, 2018)

3.2.4. Primjer autonomnog kamiona i dostavljača pizze

Postoje još 2 zanimljiva primjera vozila na kojima je isprobana umjetna inteligencija, kamion i dostavljač pizze. Što se tiče kamiona, Uber je 2016. godine nabavio autonomni kamion zvan Otto. Kamion je isproban u nekoliko prijevoza u Arizoni, većinom na autocestama. Od 2016. do 2018., kamion je napravio tisuće vožnji. (Simons, 2020)

Proizvođači pizze poput Dominosa sa Fordom testiraju autonomne automobile u nekoliko američkih gradova poput Michigana i Ann Arboru. Osim Dominosa sa Fordom, Pizza Hut ima plan testirati autonomni automobil sa Toyotom. (Simons, 2020)

3.3. Utjecaj autonomnih automobila na društvo

Bez obzira misle li ljudi da će autonomni automobili biti dobra stvar za društvo ili loša stvar za društvo, njihov razvoj i primjena će bez sumnje ostaviti posljedice.

Zanchin (2017) navodi da postoje određena polja gdje bi uvođenje autonomnog automobila pomoglo ljudima, poput:

- Sigurnosti (manji broj prometnih nesreća)
- Manjih troškova (smanjenje potrošnje i rjeđe servisiranje)
- Produktivnosti (obavljanje drugih radnji tokom vožnje)
- Udobnosti (unutrašnjost auta bi bila veća i udobnija)

Ali također postoje određene zapreke u njihovoj primjeni, koje se mogu vidjeti u:

- Zakonu (etička pitanja, npr. tko bi bio odgovoran za nesreću)

- Strukturi (slabo označavanje cesta)
- Prijetnjama sustavu (veća opasnost od prijetnja poput hakerskih napada s obzirom na visoku razinu kompjuterske kontrole)
- Zaposlenosti (neki ljudi u određenim područjima bi mogli izgubiti posao)
- Cijeni (autonomni automobili bi bili skuplji od običnih)

Nadalje, ići ćemo u dublju analizu prethodno objašnjenih prednosti i nedostataka. U današnjem svakodnevnom prometu, „čepovi“ na cestama nisu neuobičajena pojava. Herrmann (2018) objašnjava da je uzrok tim čepovima pretjerano kočenje i ubrzavanje, čime se ujedno i smanjuje propusnost vozila. Autonomni automobili bi zahvaljujući V-to-V (vozila s vozilom) komunikaciji mogli izračunati kad treba kočiti a kad treba ubrzati, čime bi se povećala propusnost vozila na cesti.

Osim pretjeranog kočenja i ubrzavanja, autonomni automobili bi mogli riješiti još jedan problem koji također utječe na gužve, kontrolu putanje. Riješavanjem tog pitanja propusnost prometa bi se mogla poboljšati do čak 30%. Autonomni automobili bi se mogli uskladiti sa semaforima, tako da bi uvijek dolazili na zeleno, čime bi također smanjili potrošnju i zagađenje, a i nervozno ponašanje ljudi dok čekaju na zeleno svijetlo. (Herrmann, 2018)

Nadovezujući se na prošlu prednost, autonomni automobili bi ljudima olakšali život tim što bi osim manje potrošnje goriva i zagađenja, također trebali smanjiti troškove osiguranja, parkiranja i održavanja. Cijene osiguranja bi zasigurno pale, budući da bi uvođenjem autonomnih automobila broj nesreća na cesti smanjio, te bi ljudi mogli zatražiti autonomni taksi ili bus, koji bi bio jeftiniji od taksija kojim upravlja vozač. Osim toga, ljudi koji su prije i vozili bi imali više vremena za sebe tokom vožnje, kao što se može vidjeti na slici 4, tako što bi mogli odrađivati aktivnosti koje prije nisu mogli tokom vožnje, poput surfanja internetom, ili čitanja knjiga/časopisa. (Herrmann, 2018)



Slika 4. Vizualizacija provođenja vremena u autonomnom automobilu (izvor: <https://www.autovision-news.com/data/ai/ai-in-automotive-vsi/>)

Sigurnost ljudi bi osim prethodno navedenog smanjenja broja prometnih nesreća bila povećana korištenjem autonomnih automobila na taj način da bi oni mogli pratiti komponente unutar automobila poput ulja, stanja guma, stanje baterija, remenja. Osim toga bili bi u mogućnosti predvidjeti i zakazati servis. Osim toga, autonomni automobil bi mogli koristiti i osobe koje nemaju položen vozački ispit, poput starijih osoba ili djece koja idu u školu. (Herrmann, 2018)

Jedan od negativnijih utjecaja autonomnih automobila na društvo bi mogao biti njihov utjecaj na određena ljudska zanimanja. Prema izvoru, u Americi oko 2.9% ljudi je zaposleno u zanimanjima povezanim s vožnjom, što predstavlja oko 4 milijuna ljudi. Sa prosječnom plaćom od 45 tisuća dolara godišnje, korištenje autonomnih automobila bi uzrokovalo gubitak od 180 milijardi dolara godišnje, i to samo u Americi. No, ljudi u zanimanjima povezanim s vožnjom nisu jedini koji bi osjetili štetu. Tesla je krenula nuditi vlastito osiguranje, što bi moglo prouzrokovati štetu današnjim osiguravačkim kućama

zbog manjka automobila za osiguranje, ako bi autonomni automobili postali uobičajena stvar. (Greener ideal, 2021)

Postoji jedna vrsta pitanja koja se nameće autonomnim automobilima, koja su više etičkog i moralnog karaktera. Kako napraviti algoritam koji će odlučivati čiji je život vrijedniji?

U situaciji gdje je neizbježna nesreća, a u automobilu se nalazi 5 osoba i postoji način da se izbjegne nesreća, a to je da se automobil udari pješaka sa strane ceste čime bi ga mogao potencijalno ubiti. Ili obrat situacije, gdje postoji jedna osoba u autu dok je njih 5 sa strane ceste i automobil se nalazi u istoj situaciji kao ranije spomenutoj. Tu se postavlja pitanje, što napraviti? Čiji je život vrijedniji? Ovakav problem predstavlja veliki etički i moralni izazov programerima koji rade na algoritmima autonomnih automobila. (Titu, 2020)

Nyholm (2018) objašnjava da postoje zamisli što se tiče tog pitanja, poput ideje Gurneya da autonomni automobil sadrži u sebi snažno računalo, koje bi moglo donijeti odluku brže od čovjeka. Osim toga navodi da bi utilitarističari prema Gurneyu ovakav pristup bio preporučen, te bi bio fokusiran na to da se smanji broj gubitka ljudskih života, što znači da ako se u automobilu nalaze 2 osobe a sa strane ceste 3, i automobil nema drugu opciju da izbjegne nesreću nego da udari 3 osobe sa strane, automobil će radije biti spreman žrtvovati 2 osobe koje se nalaze unutar automobila, jer su prema algoritmu svi „jednake vrijednosti“.

U svakom slučaju, može se zaključiti da će prema pretpostavkama autonomni automobili donijeti ljudima te time samom društvu više prednosti nego nedostataka. Iako bi mogli imati veću cijenu nego obični automobili, mogu dovesti do smanjenja gubitaka ljudskih života, koji su ipak nasuprot njima, neprocjenjivi.

4. PRIMJENA UMJETNE INTELIGENCIJE U AUTONOMNIM AUTOMOBILIMA

U prošlim poglavljim je bila prikazana umjetna inteligencija te neke od njezinih metoda i subpodručja, kao i pojam autonomnih automobila te njihov mogući utjecaj na društvo. Kad govorimo o njezinoj primjeni u autonomnim automobilima, postoji par ključnih područja kod kojih u normalnim automobilima, čovjek ima potpunu kontrolu:

- Odlučivanja
- Percepcije

Kod problema odlučivanja, koji bi predstavljao longitudinalnu i lateralnu kontrolu, imamo rješenje u obliku nadgledanog i pojačanog učenja, dok se kod problema percepcije koristi konvolucijska neuronska mreža (CNN).

Longitudinalna kontrola predstavlja kontrolu upravljanja volanom, dok lateralna kontrola predstavlja kontrolu brzine (ubrzavanje, usporavanje, održavanje brzine).

CNN ili konvolucijska neuronska mreža pripada jednoj od dubokih neuronskih mreža koje koriste konvoluciju, tj funkciju koja je nastala integriranjem umnoška dvaju funkcija po intervalu njihove definicije gdje su te funkcije ravnopravne tako da svaka svaka infinitezimalna promjena jedne funkcije utječe na drugu funkciju u cijelome intervalu definicije. (Struna, 2021)

CNN pripada jednoj od dubokih neuralnih mreža, te je inspirirana pronalaskom modela neurona u dijelu kore mozga zaslužan za vid. Kod nje između dva sloja sakrivenih neurona, veze ne postoje između bilo koja dva neurona u istom sloju, nego su samo lokalni, što znači da neuroni u „višem“ sloju primaju podatke samo od neurona s „nižeg“ sloja. Uvjet je i da neuroni moraju biti blizu, u kvadratnom području. Lokalne težine veza su prostorno podijeljene sa svim neuronima u istom sloju. Ovo postiže nepromijenjivost u vizualnim podacima i time se postiže olakšanje za CNN model time što mu u tom slučaju treba manje parametara. (Liu, 2020)

CNN se prema istraživanju Thammachantueka (2018) pokazao kao najbolji algoritam za odlučivanje. Pokazao se efikasnijim od ostalih algoritama korištenim u

strojnom učenju, poput SVM-a(Support Vector Machine), MLP-a(Multilayer perceptron), DT-a(Decision Tree) i RF-a(Random Forest).

4.1. Primjeri lateralne kontrole

Što se tiče primjene, najraniji pokušaj primjene neuronske mreže datira još iz 1989. Autonomno kopneno vozilo u neuralnoj mreži (ALVINN) od Pomerleaua. ALVINN je koristio jedan sloj neuronske mreže da predvidi kut upravljanja ovisno o primljenoj slici. Izlaz mreže je obuhvaćao 30 mogućih kutova upravljanja. Učenje koje se koristilo je bilo nadgledano učenje gdje su podaci za učenje bile slike sa prednje kamere „označena“ sa upravljačkim naredbama čovjeka. Za poboljšanje sistema i za dopuštenje mreži da popravi greške koje nisu bile u primjerima za učenje, izumitelj je povećao skup podataka sa dodatnim sintetiziranim podacima. Slike u skupu za učenje su bile izokrenute da se dobije simulacija u kojem se vozilo nalazi u drugim pozicijama na cesti (bočno). Osim toga, da se izbjegne pristranost prema nedavnim unosima u mrežu riješenje u obliku međupohrane je bilo implementirano. U međupohrani su mogla biti pohranjena 4 uzorka u bilo kojem vremenu. (Kuutii, 2019)

Povećanjem skupa podataka i korištenjem međuspremnika u učenju su značajno uspjeli poboljšati performanse sustava. Brzina u kojoj se automobil testirao su bile u rasponu od 8 do 88km/h. Vozilo je uspjelo održati upravljanje volanom bez intervencije čak 35km! Zanimljiva činjenica je i da je vozilo uspjelo održati prosječnu udaljenost od sredine linije od 1.6cm, u usporedbi sa čovjekom kod kojeg je prosjek 4cm. Ovo je dobar primjer da mreže mogu naučiti upravljati vozilom koristeći nadgledano učenje. (Kuutii, 2019)

Korištenjem pojačanog učenja kao nastavak na nadgledano učenje, nastao je prošireni pristup ALVINNu. Prošireni pristup je učio mrežu da upravlja volanom vozila koristeći slike uz pojačano učenje, tako da je mreža mogla učiti iz iskustava i nakon razvoja. (Kuutii, 2019)

Nakon ALVINNa, trebalo bi spomenuti još dva primjera primjene umjetne inteligencije kod longitudinalne kontrole: Darpa i Rausch. Nakon poboljšanja procesorske

moći jedinica grafičke obrade, mogućnost korištenja dubljih modela sa značajno većom količinom podataka je bila postignuta. Koristeći konvolucijsku neuronsku mrežu da upravlja vozilom, Muller je demonstrirao mogućnosti dubljih modela za autonomno upravljanje vozilima. To vozilo, Darpa Autonomous Vehicle (DAVE) je naučilo voziti van ceste brzinama 7km/h i uz to izbjegavati prepreke na putu. NVIDIA se tu također uključila sa svojim sistemom, PilotNet. PilotNet je učio uz pomoć slika prednje kamere koja je snimala dok je čovjek upravljao vozilom. Skupljeni skup za treniranje se koristio da se nauči CNN da predvidi kutove upravljanja ovisno o primljenoj slici. Da se učini sigurnim da se mreža može prilagoditi nakon grešaka, skup podataka je proširen sa ostale 3 kamere (lijeva, desna i u sredini) tako da mreža dobije simulaciju kao da je vozilo izašlo sa ceste. Taj skup podataka je skupljen u periodu od 72h i skupljan je u različitim vremenskim uvjetima. Rezultati su bili odlični: početni testovi su pokazali da mreža može održavati vozilo u istoj prometnoj traci, sa velikim postotkom od čak 98% autonomije, te su testiranja na autocesti pokazala da vozilo može voziti 16 kilometara bez ljudske intervencije. (Kuutii, 2019)

Još jedan pristup je korišten od Rauscha za treniranje CNNa za kontrolu upravljanja volanom u simulaciji. Mreža je učila od 15 minuta skupljenih podataka vožnje, dok je čovjek upravljao vozilom. Naučena mreža je pokazala da je naučila dobar dio vozačevog načina vožnje čak i sa malom količinom podataka. Međutim postojao je jedan problem, upravljački signal je pokazivao oscilacije u ponašanju, što je bilo uzrokovano time što je sistem procjenjivao upravljački kut za svaki vremenski okvir, a nije uzimao prijašnje stanje u obzir. (Kuutii, 2019)

Moguće rješenje za ovaj problem bi bilo korištenje ponavljajućih neuronskih mreža, RNN-a da pruži kontekst vremena za mrežu. Model na koji se taj CNN-RNN primjenio, Eraqi, je učio da pretpostavi upravljačke kutove iz slika. Model je koristio slike iz javnog skupa podataka. Iako nije postojalo testiranje na cesti, naučena mreža je pokazala da je učenje upravljanja volana kod CNN-RNN modela bilo u prednosti nasuprot CNN modelu. Iz tog je zaključeno da ponavljajuća arhitektura može pomoći vozilu u glatkom i konzistentnom načinu vožnje (Kuutii, 2019)

Većina modela je odlučila koristiti način nadgledanog učenja. Iako je većina ovih modela koristila učenje za jednostavne zadatke (održavanja vozila u jednoj liniji) ili u

jednostavnim uvjetima (simulacija, bez prometa) rezultat je pokazao da se duboko učenje može koristiti da se sistemi percepcije (kamere) koriste za određivanje kuta upravljača. (Kuutii, 2019)

4.2. Primjeri longitudinalne kontrole

Osim kod lateralne kontrole, duboko učenje može pomoći i u longitudinalnoj kontroli. Longitudinalnu kontrolu se može opisati kao problem zadovoljavajućeg praćenja za složeni nelinearni sustav. Iako postoje sistemi kontrole u longitudinalnim složenim sustavima za asistiranje vozaču (ADAS) poput prilagođene kontrole putovanja (ACC), takav sistem nema dobru prilagodbu na različite situacije. Metode dubokog učenja zato mogu pomoći u nelinearnim problemima kontrole. (Kuuti, 2019)

U ranoj fazi razvijanja mreže za longitudinalnu kontrolu, nastao je neizrazit algoritam, koji je uključivao pojačano učenje. Takav algoritam je kombinirao pojačano učenje i neizrazitu logiku. Pojačano učenje je bilo osnovano na Q-učenju, unutar kojeg prema objašnjenju Chisthia (2018) postoje parametri s i a , koji predstavljaju stanje i radnju te se kasnije koriste da se izračuna Q , gdje Q predstavlja funkciju koja računa buduću vrijednost. Logika tog algoritma je koristila Takagi-Sugeno tip zaključivanja. Poanta Q-učenja je bila da modul pretpostavi radnju za optimalnu kontrolu, dok bi sustav zaključivanja proizveo radnju ovisno o izračunatoj vrijednosti. Unutar tog Q-učenja je postojao sustav nagrade koji bi nagradio sustav kad bi pratio vozilo ispred na određenoj distanci, iz razloga da potakne sustav da vozi na sigurnoj distanci od drugog vozila. Rezultat ovakvog načina učenja je bio odličan: u simulacijskim uvjetima, vozilo je uspješno pratilo vozilo ispred 68 puta bez greške. Iako je ovakav način pojačanog učenja može biti korišten uspješno kod praćenja vozila ispred, takav sustav nagrade gdje postoji samo jedan cilj može dovesti do neočekivanih ponašanja. Ali u svakom slučaju, sustav nagrađivanja je mogao potaknuti autonomna vozila na sigurnu i udobnu vožnju. (Kuutii, 2019)

Primjer funkcije koja je koristila nagrade sa više ciljeva bi bila funkcija Desjardinsova i Chaib-Draaova. Ona je koristila sustav nagrade koji je ovisio o

vremenskom razmaku i izvodu vremenskog razmaka. Cilj ovoga je bio da se agenta potakne da održava vremenski razmak od drugog vozila ali ga se također i nagrađivalo kada bi se agent približavao idealnom vremenskom razmaku te kažnjavalo kad se odmicao od tog vremenskog razmaka. Ovaj pristup je također bio implementiran i u pridruženi sustav ACC. Mreža koja je bila odabrana je bila arhitekture jednog smjera, sakriveni sloj je sadržavao 20 neurona dok je izlazni sloj mogao izvršiti 3 funkcije: ubrzavanje, kočenje ili ne napraviti ništa. Nakon obavljanja 10 probnih testova gdje je sustav iskoristio primjer praćenja vozila koji mu je bio prije pokazan, sustav je pokazivao grešku od 0.039 sekundi u testovima hitnim kočenjima. Iako sjajan rezultat, problemi su se pojavili kod sigurnosti i udobnosti putnika, zbog oscilacija u brzini. Postoji nekoliko rješenja za ovaj problem, korištenjem RNNa ili dodavanjem uvjeta za glatku vožnju u funkciju. Korištenjem ovoga vožnja je mogla biti udobnija, bez nepotrebnih naglih ubrzavanja ili usporavanja. Međutim, sigurnost i dalje nije bila uključivana u uvjet. (Kuutii, 2019)

Postojao je još jedan algoritam koji je koristio ACC sustav (prilagodljivi tempomat), te je koristio Q-učenje iz razloga da procjeni udaljenost od vozila nakon određenog vremenskog perioda. Q-učenje je bilo određivano jednoslojnom jednosmjernom mrežom. Udaljenost nakon procjene je bila održavana od strane kontrolera proporcionalnog integralnog izvoda (PID). Sličan pristup ovome je koristio Zhao, koji je koristio algoritam kritike glumcu da bi ACC sistem naučio personalizirane načine vožnje. Sustav nagrade je uključivao 3 parametra, navike vozača, udobnost putnika i sigurnost vozila. Rezultat testiranja je pokazao da je pojačano učenje moćan alat za primjenu kod longitudinalne kontrole vozila, nakon što je algoritam pokazao superiornost nasuprot klasičnim PID kontrolerima i linearno kvadratnim regulatorskim kontrolerima (LQR). (Kuutii, 2019)

Chae je razvijao sustav na temelju metode pojačanog učenja kojemu je bio cilj izbjegavanje sudara. Sustav je koristio algoritam duboke Q-mreže koji je mogao birati između 4 vrijednosti usporavanja, koristeći funkciju sa 2 parametra vrijednosti (izbjegavanje sudara, izbjegavanje visokorizičnih situacija). Sustav bi bio nagrađivan koristeći pravilno kočenje, te bi koristio 2 memorije: ponavljanja i traume. Memorija ponavljanja je pomagala kod usklađivanja učenja dok bi memorija traume pomogla kod

stabilnosti učenja. Sistem se učio izbjegavati pješake, te je imao popriličan uspjeh u tome. Vrijeme do sudara (TTC) je bio kriterij kojim se mjerila uspješnost testova, od kojih je svaki bio ponavljan 10000 puta. Najbolji rezultat je bio onaj od 100% za vrijeme do sudara od 1.5 sekundi, dok bi za vrijeme od 0.9 sekundi do sudara rezultat uspješnosti bio 61.29%. Ovo je svakako dokazalo da autonomni automobili mogu pružiti dovoljnu visoku razinu izbjegavanja sudara u prometu. (Kuutii, 2019)

Kod longitudinalne kontrole, metoda pojačanog učenja se pokazala poželjnom pokazujući izvrsne rezultate kod longitudinalne kontrole automobila. Koristeći jednodimenzionalne mjere, poput udaljenosti od vozila, smanjuje kompliciranost mreže. To je također utjecalo na to da se umjesto senzora za vid poput kamera, koriste senzori za mjerenje udaljenosti. (Kuutii, 2019)

No postoje i nedostaci metoda učenja: u longitudinalnom učenju kod pojačanog učenja, nedostaci bi bili težina i trošak sakupljanja podataka za učenje dok bi kod nadgledanog učenja nedostatak bio niža razina uopćavanja za razliku od pojačanog učenja. No, kombiniranjem ovih dviju metoda koje mogu nadopuniti jednu drugu je nastao novi algoritam, nadgledana kritika glumca (SAC). Algoritam je koristio metodu nadgledanog učenja kao početno učenje, da bi se nakon početnog učenja nadovezalo pojačano učenje. Sustav je trenirao u različitim uvjetima, po mokroj i suhoj cesti. Sustav je bio uspoređen sa PID-om koji je koristio nadgledano učenje te se pokazalo da je ovaj kombinirani sustav pokazao najbolje performanse te je pokazalo da je kombiniranje nadgledanog i pojačanog učenja bila efikasna kombinacija. (Kuutii, 2019)

Kod longitudinalne kontrole, pretežito dominira metoda pojačanog učenja, iz ranije spomenutih razloga poput sustava nagrađivanja, te mogućnosti sustava da se nastavlja razvijati nakon početnog razvoja. (Kuutii, 2019)

4.3. Primjeri cijelokupne kontrole

Osim pojedinačne lateralne i longitudinalne kontrole, cjelokupna kontrola vozila od strane neuralne mreže je također uhvatila pažnju. Kuuti (2019) objašnjava da je jedna od predloženih ideja bila ideja Zhenga, da se napravi sistem odlučivanja baziran na metodi

pojačanog učenja. Sistem bi se našao u okruženju autoceste, te su tri parametra bila uključena u funkciju nagrade:

- Sigurnost (udaljenost od drugih automobila)
- Glatkoća vožnje (intezitet promjena brzine)
- Praćenje brzine (usporedba željene i trenutne)

Sama simulacija je bila poprilično jednostavna, koristilo se jednostavno okruženje gdje je vozilo trebalo proći kroz više manevara prestizanja drugih automobila. Sustav je to odradio s uspjehom. (Kuutii, 2019)

Na drugu stranu, Shalev-Shwartz je pokušao drugačiji scenarij: vozilo je moralo operirati u složenijem okruženju, okruženo automobilima koji su se kretali nepredvidivo.

Cilj je bio dizajnirati sustav koji je mogao sigurno i efikasno zaobilaziti. Kao i prošli sustav, tri parametra su bila uključena u funkciju nagrade:

- Držanje distance od drugih vozila
- Vrijeme potrebno da se dođe do cilja
- Glatkoća ubrzavanja

Za razliku od prošlog sustava, ovaj sustav je koristio RNN, zbog svojih mogućnosti da bez pretpostavke nauči funkciju između odabrane radnje, trenutnog stanja i stanja u sljedećem vremenskom intervalu. Metoda je na početku testiranja koristila predvidivi i nepredvidivi dio: vozilu je bila poznata lokacija i brzina automobila pokraj, ali mu nisu bila poznata njihova ubrzanja. U nastavku učenja vozilu više nisu bili dani poznati parametri, nego je vozilo moralo samo učiti tokom testiranja. Usprkos otežavanju učenja, vozilo je i dalje bilo uspješno. Ova metoda je pokazala da automobil može naučiti da treba usporiti prije zaobilaženja, da propusti agresivnije vozače te da se vozilo zna uključiti u promet sa manje agresivnijim vozačima, ali da se ovo učenje može primjeniti i na ostale elemente vožnje poput mijenjanja prometne trake, izlaska s autoceste i ulazak na nju, propuštanje pješaka te poštivanje pravila desnog. (Kuutii, 2019).

Korištenjem nadgledanog učenja se može znatno skratiti vrijeme potrebno za učenje sistema. To je iskoristio Xia, napravivši algoritam na temelju Q-učenja za kontrolu

vožnje. U algoritam je i ubacio učenje na osnovi prijašnje demonstracije. Također je koristio filtriranje testova, gdje je loše rezultate uklonio, dok su dobri rezultati korišteni za učenje. Koristeći ove tehnike, ne samo da je poboljšana kontrola nego je i poboljšano usklađivanje brzina za 71%. Sallab je nastavio istraživanje kompletne kontrole tako što je koristio 2 algoritma za kontrolu vozila. Prvi, algoritam dubokog Q-učenja je korišten za trenutačne radnje, dok je algoritam kritike glumca korišten za kontinuirane radnje. Simulacija na kojoj je ova kombinacija algoritma testirana je bila održavanje vozila na sredini trake. Simulacija je pokazala da su algoritmi koji koriste vrijednosti kontinuirane radnje efektivniji u kontroli automobila, dok se algoritam koji je bio korišten kod trenutačnih radnji imao problema održavati vozilo na sredini trake, pogotovo na zavojitim cestama. (Kuutii, 2019)

Zhang je problem kontrole vozila pokušao riješiti algoritmom koji je koristio nadgledano učenje i vizualizaciju za kontrolu automobila. Algoritam se bazirao na tehnici učenja zvanom agregacija skupa podataka (DAGger), te je nazvan SafeDAGger. Nakon što bi u prvoj fazi DAGgera algoritam trenirao metodom klasičnog nadgledanog učenja iz seta u kojem je ekspert isti zadatak riješio prije, sljedeći korak bi bio riješiti zadatak u novom skupu podataka koristeći načine učenja iz prošlog skupa. Ekspert bi nakon učenja riješio novi skup podataka na točan način, te bi se prošli i novi skup podataka skupio u novi skup, koji bi se koristio za daljnje treniranje sustava. Taj proces se ponavlja unutar DAGgerovog radnog okvira. Takav pristup rješava problem kod nadgledanog učenja, koje pati od činjenice da se greške koje nastaju tokom učenja mogu spojiti. Dobra stvar DAGgerovog radnog okvira je da sustav može napraviti grešku, ali su primjeri također sadržavaju ekspertovo rješenje problema, i u sljedećoj fazi sustav zna sam popraviti grešku. Nadgledano učenje tu ima problem jer sustav u slučaju da npr. kreće skretati izvan centra prometne trake, sustav neće znati kako se ispraviti u toj situaciji. Ovo je ojačalo sustav prema manjim greškama, ali su se kompliciranost i trošak povećali. SafeDAGger je nastavak ovog radnog okvira, koji se razlikovao tako što je imao mogućnost pretpostavke dali se način obavljanja zadatka sustava razlikuje od načina obavljanja zadatka eksperta. Kasnije, tradicionalno nadgledano učenje, DAGger i

SafeDagger su bili uspoređivani, i pokazalo se da je SafeDagger najbolji što se tiče kontrole vozila. (Kuutii, 2019)

Pan je također probao koristiti sustav baziran na DAggerovom random okviru. Sustav je koristio algoritam za predviđanje kontrole sa skupim sensorima dok je način učenja bio modeliran CNNom koji je koristio jeftine senzore. Testiranje je pokazalo da je način učenja omogućio sustavu da upravlja vozilom visokim brzinama na zemljanoj stazi, čak i sa jeftinim sensorima (Kuutii, 2019)

Wang, Porav i Newman su također prezentirale svoja rješenja problema autonomnih automobila. Wang je koristio način kontrole dubokog učenja gdje je fokus bio na objekt. Koristio je CNN koji je imao fokus na istaknute dijelove slike, te su kasnije korišteni da se na osnovu njih odradi neka radnja, kasnije izvršena od strane PID kontrolera. Wangov pristup je nadmašio načine upravljanja koji nisu imali pažnje ili one koji su bili samo istraživačko obilježeni. Porav i Newman su zato prikazali sustav izbjegavanja sudara koristeći varijacijski autokoder i RNN uz pomoć semantičkih slika. Cilj je bio pretpostaviti kontinuirane radnje upravljanja i kočenja, te je njihov sustav ispio veoma uspješan. U usporedbi sa Chaeovim sustavom, smanjen je broj sudara gdje je vrijeme do sudara ispod 1.5 sekundi. (Kuutii, 2019)

Hecker je išao korak naprijed te je dodao plan puta u CNN. Mreža je bila učena od strane nadgledanog učenja, gdje je čovjek isto pratio plan puta koji je kasnije dodan u skup podataka za učenje. Iako je Hecker imao nedostatak testiranja na pravoj cesti, testiranja su pokazala da je vozilo učilo pratiti određenu rutu. Codevilla je sa sličnim pristupom uz dodatak navigacijskih zapovijedi probao napraviti isto. Ovaj dodatak je omogućio čovjeku da kaže vozilu kamo treba ići dok bi vozilo pratilo tu rutu. Sama arhitektura mreže za ovaj zadatak se sastojala od mreže jednog smjera, gdje je početni sloj bio zajednički, ali su podmoduli bili podijeljeni za svaku određenu radnju. Uz ovakvu arhitekturu i način učenja, vozilo je uspjelo naučiti pratiti navigacijske zapovijedi. (Kuutii, 2019)

Waymo je imao različiti pristup od ostalih, sa svojim ChauffeurNet sustavom. Sustav je koristio „mid-to-mid“ učenje, koje je koristilo prethodno obrađenu sliku sa istaknutim

objektima kao ulaz dok bi izlaz bio određena zapovijed koja bi sadržavala putanju i brzinu kretanja. Kontroler niže razine bi zatim izvršio zadatak. Koristeći zastupljenost na srednjoj razini, model je imao lakši prijelaz sa simulacije na pravu cestu zbog jednostavnog mješanja simulacijskih i podataka iz svakidašnjeg života. Osim tog učenja, model je koristio i sintetizirane skupove podataka (npr. vozilo se nalazi u krivoj traci) da se izbjegne opasna vožnja. Vozilo nije imalo razlike u prikazu svojih mogućnosti u simulaciji i na pravoj cesti. Autori naglašavaju tri ključna pojma koji su omogućili vozilu da autonomno vozi bez nepoželjnih ponašanja: „mid-to-mid“ način učenja, korištenje sintetiziranih skupova podataka i povećani gubitci. (Kuutii, 2019)

Iako se vide neki uspjesi u autonomiji (u lateranoj i longitudinalnoj kontroli), automobil sa potpunom najvišom razinom autonomne kontrole je i dalje još daleko od izlaska na cestu.

4.4. Problem percepcije

Jedan od većih problema za autonomne automobile je kako vidjeti i na osnovu viđenog donijeti odluku? Bitan aspekt tog pitanja bi bio „kako vidjeti“, tj. što koristiti kako bi sustav prepoznao objekte i scene na slici kao što ih ljudsko oko može prepoznati. Postoji par područja u kojima su prema Liu (2020) donesena rješenja za to:

- Prepoznavanje objekata
- Semantička segmentacija
- Stereo i optički tok

Kod detekcije, postoji problem kod uobičajenih algoritama za otkrivanje objekata jer oni samo prikupljaju samo najvažnije informacije sa slika te koriste strukturirani klasifikator za prostorne strukture. Ovakav algoritam ne može iskoristiti ogromne količine podataka niti prepoznavati velik broj kombinacija izgleda i oblika objekta. Tu se korištenjem CNNa poboljšavaju performanse kod prepoznavanja objekata. Postoje još brži CNNovi za prepoznavanje objekata, dvije ponavljajuće konvolucijske neuronske mreže (C-RNN), brzi R-CNN i brži R-CNN. (Liu, 2020)

Brži R-CNN funkcionira tako da prepoznavanje objekta prolazi kroz 2 faze:


1. Nakon što je dobio sliku, prvo smanjuje broj kandidata iz razloga jer objekt može biti na različitim mjestima u slici, ili može imati različite proporcije unutar slike, koristeći mrežu prijedloga regije (RPN). RPN uzima zadnju mapu svojstva CNNa kao ulazni podatak, spaja to sa sakrivenim slojem koristeći klizni prozor veličine 3x3 te na kraju spaja CNN sa preostalim slojevima, jedan za klasu objekta a drugi za poziciju objekta. 3x3 se koristi iz razloga da se različiti omjeri slika mogu efikasno provjeriti. Na kraju prvog koraka koristi se suzbijanje da se makne redundantnost i da se ostavi oko 2000 prijedloga objekta. (Liu, 2020)
2. U drugoj fazi nakon dobivanja prijedloga područja, precizira se klasa, omjer i lokacija objekta kroz sloj za raspodjelu ovisno o svojstvenoj mapi. Na kraju klasa objekta, njegova veličina i pozicija su pretpostavljene od 2 različite grane. (Liu, 2020)

Semantička segmentacija je imala veliki benefit razvojem umjetne inteligencije. Kod semantičke segmentacije ili jednostavnije rečeno procjenjivanje scene, koristi se potpuno konvolucijska mreža (FCN). FCN ovisi o velikom receptornom polju značajkama više razine (objekti, događaji) da pretpostavi oznake na razini piksela. Ovo može otežati procjenjivanje manjih objekata jer se informacija malog objekta miješa sa ostalim pikselima u istom polju. Taj problem nejasnoća se može riješiti tako da se u obzir uzmu zajednički prisutni vizualni obrasci kao strategiju da se kombinira cjelokupna slika sa lokalno izvučenim značajkama. (Liu, 2020)

Jedan primjer mreže koja funkcionira na ovakav način je mreža prepoznavanja scene piramide (PSPNet). Glavna značajka ove mreže je modul udruživanja u obliku piramide. Na slici 5 se može vidjeti vizualizacija sljedećih 4 faza kroz koje prolazi (Liu, 2020):

1. Slika prolazi kroz CNN da bi ona uspjela izvući sve moguće mape sa svojstvima (Input Image).
2. Mape prolaze kroz različite slojeve udruživanja iz razloga da se smanji prostorna rezolucija i spoje dodatne informacije (Feature Map).

3. Mape koje nastanu iz prošlog koraka se kasnije koriste da se prikaže kontekst. Mape još moraju proći kroz konvolucijski sloj veličine 1x1 iz razloga jer vektorska veličina svojstva i veličina svojstva unutar receptivnog polja nisu jednake, te se vektorska veličina smanjuje da budu proporcionalne jedna drugoj (Pyramid Pooling Module).
4. Na kraju, mreža uzima sve obrađene mape sa svojstvima za prikaz konteksta te ih udružuje u početnu sliku sa mapama koje je na početku izvukao CNN. Zadnji sloj konvolucije iskorištava te mape te ih koristi da bi označio sve piksele. (Final Prediction)



Slika 5. Vizualizacija prepoznavanja scene piramide (autor izradio na osnovu rada: *Creating Autonomous Vehicle Systems*, Liu S., 2020)

Kod preostalog područja, sterea i optičkog toka, njihova uloga u percepciji slike je da rješavaju problem sličnosti kod slika. Tu im pomaže nenadgledano učenje kod problema uskih sličnosti. Nastali su novi algoritmi poput monoDeptha i njegovog nasljednika, monoDepth2. Njihov cilj je da iz dvije slike (lijevi i desni pogled) opiše funkciju gubitka u 3 dijela (Liu, 2020):

1. Gubitak kod podudaranja izgleda: tu algoritam pretpostavi da su pikseli koji su slični u obje slike također slični i u izgledu.
2. Gubitak kod glatkosti nepodudaranja: ovdje algoritam pretpostavlja da su kriteriji za nepodudaranje lokalno uglađeni sa povremenim prekidima.

3. Gubitak konzistentosti nepodudarnja lijevo i desno: pretpostavka da su nepodudaranje lijeve slike i desne slike povezani međusobno.

Prednost ovakvog pristupa je što je ovo moguće izračunati iz slika, te time nema potreba za podacima nepodudaranja prije računanja. (Liu, 2020)

5. TREND RAZVOJA UMJETNE INTELIGENCIJE KOD AUTONOMNIH AUTOMOBILA

Trenutno većina automobila posjeduju 1. ili 2. razinu autonomije prema SAE ljestvici. Postoje planovi da se krene sa proizvodnjom i isporukom automobila 3. razine autonomije, među kojima je prvima Honda, koja je već to napravila 2020. godine. Očekuje se da bi proizvođači poput Hyundai, Kia, BMW-a i Mercedes mogli pustiti automobile 3. razine autonomije u prodaju 2021. godine. (IEEE Innovation at work, 2020)

Što se tiče razvoja umjetne inteligencije, specifično neuronskih mreža, tu će svakako pomoći korištenje hardverskih neuronskih mreža. Uz pomoć svojstava neuronske mreže koje su naknadno iskorištene sa multi-čipom (više povezanih primjera ubrzavača) se može dobiti poboljšano učenje zahvaljujući rješavanju problema ograničenja kapaciteta memorije na jedinici za obradu podataka. (Temam, 2016)

5G mreža bi također imala svoju svrhu unutar umjetne inteligencije. Omogućit će bolju povezanost između vozila i ostalih sudionika (vozila sa vozilom, vozila sa infrastrukturom koju trenutno nudi 4G) tako što će omogućiti povezanosti poput vozila sa pješacima (V2P) i vozila sa mrežom (V2N). Vozila bi bila u mogućnosti javiti pješacima gdje će ići čime bi se smanjio broj nesreća, ili bi bila u mogućnosti bolje isplanirati rutu do odredišta. Osim toga, unutar 5G okruženja će nastati digitalna realnost gdje postoji mogućnost spajanja sa svime (C-2VX). Time bi vozila dobili mogućnost navigacije kroz virtualnu realnost sa potpunim razumijevanjem okoline oko sebe. (Martínez, 2021)

Zaključak

Usred tehnološkog napretka u zadnjih 50-tak godina, automobili i tehnologija su postali neizbježni dio naše svakodnevnice. Umjetna inteligencija također može zahvaliti svoj razvoj tehnologiji. Ključan element osim toga je bilo razumijevanje ljudskog mozga te stvaranje arhitektura neuronske mreže po modelu ljudskog mozga.

Razvoj strojnog učenja i otkriće neuronskih mreža je pomoglo u otkrivanju nove vrste učenja: duboko učenje, a samim time i različitih metoda dubokog učenja (nadgledano, pojačano, nenadgledano) koje je proširilo načine implementacije različitih postojećih algoritama unutar neuronskih mreža a i razvijanje novih. Raznovrsnost primjena tih metoda u problemima primjene umjetne inteligencije kod autonomnih automobila je uvelike pomogla čovjeku da otkrije prednosti i nedostatke tih metoda, te mu je osim metoda omogućila razvoj novih, efikasnijih algoritama i kombiniranih metoda kod kontrola upravljanja i brzine, ali je i otvorila nove načine obrade slike u obliku algoritama prepoznavanja koji su približili percepciju automobila ljudskoj.

Autonomni automobili će zasigurno ostaviti neizbježan trag na društvo u budućnosti, u nadi da će život ljudi učiniti boljim sa svojim prednostima koje imaju potencijala negirati sve negativne posljedice koje bi autonomni automobili ostavili na društvo, ali trenutno, važno je razumjeti da je umjetna inteligencija i dalje na nedovoljno razvijenoj razini u pogledu odlučivanja i percepcije i da današnji autonomni automobili trebaju biti shvaćeni ozbiljno u tom smislu da je autonomija samo djelomična, te da je čovjek i dalje bitan akter u vožnji automobila.

Literatura

1. Kuutii, S. i sur. (2019), Deep Learning For Autonomous Vehicle Control: Algorithms, State-Of-The-Art, And Future Prospects [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/16801117/Ac5d27> [Pristupljeno: 13.08.2021.]
2. Dhawan, C. (2018), Autonomous Vehicles Plus: A Critical Analysis Of Challenges Delaying Av Nirvana [online] Dostupno Na: <https://Books.Google.Hr/Books?Id=Cr2idwaaqbaj> [Pristupljeno: 18.08.2021.]
3. Adouane, L. (2016), Autonomous Vehicle Navigation: From Behavioral To Hybrid Multi-Controller [online] Dostupno Na: <https://Books.Google.Hr/Books?Id=Egzycwaaqbaj> [Pristupljeno: 16.08.2021.]
4. Stavens, D. (2011), Learning To Drive: Perception For Autonomous Cars [online] Dostupno Na: <https://Books.Google.Hr/Books?Id=Uu9lgaquf14c> [Pristupljeno: 19.08.2021.]
5. Deepsense.Ai, [online], Dostupno Na: <https://Deepsense.Ai/What-Is-Reinforcement-Learning-The-Complete-Guide/> [Pristupljeno: 29.08.2021.]
6. Greener Ideal, [online], Dostupno Na: <https://Greenerideal.Com/News/Vehicles/Driverless-Cars-Environmental-Benefits/> [Pristupljeno: 30.08.2021.]
7. Warwick, K. (2012), Artificial Intelligence: The Basics [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/2324675/0169b4> [Pristupljeno: 02.09.2021.]
8. Kaplan J. (2016), Artificial Intelligence: What Everyone Needs To Know [online] Dostupno Na: https://Books.Google.Hr/Books?Id=7y_Kdaaaqbaj [Pristupljeno: 03.09.2021.]
9. Bramer M., Solar M., Atkinson J. (2009), Artificial Intelligence: An International Perspective [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/703660/1fae33> [Pristupljeno: 03.09.2021.]
10. Taulli T. (2019), Artificial Intelligence Basics. A Non-Technical Introduction [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/5224431/6c983f> [Pristupljeno: 04.09.2021.]

11. Russell S., Norvig P. (2016), Artificial Intelligence: A Modern Approach [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/3704484/55dad1> Pristupljeno: [06.09.2021.]
12. Government Technology, [online], Dostupno Na: <https://Www.Govtech.Com/Computing/Understanding-The-Four-Types-Of-Artificial-Intelligence.Html> [Pristupljeno: 06.09.2021.]
13. SearchenterpriseAI, [online], Dostupno Na: <https://Searchenterpriseai.Techtarget.Com/Definition/Ai-Artificial-Intelligence> Pristupljeno: [07.09.2021.]
14. Saravanan R., Sujatha P. (2018), A State Of Art Techniques On Machine Learning Algorithms: A Perspective Of Supervised Learning Approaches In Data Classification [online] Dostupno Na: <https://leeexplore-lee-org.Ezproxy.Nsk.Hr/Document/8663155> Pristupljeno: [07.09.2021.]
15. Zanchin B., i sur. (2017), On The Instrumentation And Classification Of Autonomous Cars [online] Dostupno Na: <https://leeexplore-lee-org.Ezproxy.Nsk.Hr/Document/8123022> [Pristupljeno 07.09.2021.]
16. Sjafrie H. (2019), Introduction To Self-Driving Vehicle Technology [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/5954618/B640a8> [Pristupljeno: 08.09.2021.]
17. Herrmann, A., Brenner W., Stadler R. (2018), Autonomous Driving: How The Driverless Revolution Will Change The World [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/5314380/3ff40d> [Pristupljeno: 09.09.2021.]
18. Struna, [online], Dostupno Na: <http://Struna.Ihjj.Hr/Naziv/Konvolucija/19228/> [Pristupljeno: 09.09.2021.]
19. Simons R. (2020), Driverless Cars, Urban Parking And Land Use [online] Dostupno Na: <https://Books.Google.Hr/Books?Id=Y6rodwaaqbaj> [Pristupljeno: 09.09.2021.]
20. Titu, A., Stanciu A., Mihaescu L. (2020), Technological And Ethical Aspects Of Autonomous Driving In A Multicultural Society [online] Dostupno Na: <https://leeexplore-lee-org.Ezproxy.Nsk.Hr/Document/9223225> [Pristupljeno: 10.09.2021.]
21. Nyholm S. R. (2018), The Ethics Of Crashes With Self-Driving Cars: A Roadmap I [online] Dostupno Na:

- https://Pure.Tue.Nl/Ws/Portalfiles/Portal/101570905/Nyholm_2018_Phi [Pristupljeno: 10.09.2021.]
22. Liu S., i sur. (2020), Creating Autonomous Vehicle Systems [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/13953252/992318> [Pristupljeno: 10.09.2021.]
23. Thammachantuek I., Kosolsomnbat S., Ketchman M. (2018), Comparison Of Machine Learning Algorithm's Performance Based On Decision Making In Autonomous Car [online] Dostupno Na: <https://leeeexplore-ieee-Org.Ezproxy.Nsk.Hr/Document/8693002> [Pristupljeno: 11.09.2021.]
24. Chishti S., i sur. (2018), Self-Driving Cars Using Cnn And Q-Learning [online] Dostupno Na: <https://leeeexplore-ieee-Org.Ezproxy.Nsk.Hr/Document/8595684> [Pristupljeno: 12.09.2021.]
25. Temam O. (2016), Enabling Future Progress In Machine-Learning [online] Dostupno Na: <https://leeeexplore-ieee-Org.Ezproxy.Nsk.Hr/Document/7573457> [Pristupljeno: 14.09.2021.]
26. Ieee Innovation At Work, [online], Dostupno Na: <https://Innovationatwork.Ieee.Org/New-Level-3-Autonomous-Vehicles-Hitting-The-Road-In-2020/> [Pristupljeno: 15.09.2021.]
27. Martínez I. (2021), The Future Of The Automotive Industry: The Disruptive Forces Of Ai, Data Analytics, And Digitization [online] Dostupno Na: <https://Rs.Zlibcdn2.Com/Book/16450917/Fcffe> [Pristupljeno 15.09.2021.]

Popis slika

Slika 1. Vizualizacija Turingovog testa (izvor: autor izradio na osnovu rada: Artificial intelligence Basics. A Non-Technical Introduction, Taulli T., 2019).....	11
<i>Slika 2. Vizualizacija modernog modela umjetne inteligencije (izvor: autor izradio na osnovu rada: Deep Learning for Autonomous Vehicle Control: Algorithms, State-of-the-Art, and Future Prospects, Kuutii, 2019)</i>	<i>13</i>
Slika 3. Vizualizacija pojačanog učenja (izvor: https://towardsdatascience.com/deep-q-network-combining-deep-reinforcement-learning-a5616bcfc207)	15
Slika 4. Vizualizacija provođenja vremena u autonomnom automobilu (izvor: https://www.autovision-news.com/data/ai/ai-in-automotive-vsi/).....	21
Slika 5. Vizualizacija prepoznavanja scene piramide (autor izradio na osnovu rada: Creating Autonomous Vehicle Systems, Liu S., 2020).....	34

Sažetak

Jedan od ključnih elemenata u razvoju autonomnih automobila predstavlja umjetna inteligencija. Razvoj umjetne inteligencije je bio drastično ubrzan otkrićem tehnologije poput tranzistora, mikroprocesora te razvoju Interneta. Autonomni automobil je vozilo koje uz pomoć umjetne inteligencije može donositi odluke u vožnji koje inače čovjek donosi. Zahvaljujući razvoju metoda strojnog učenja i neuralnih mreža, autonomni automobil je u stanju razmišljati i donositi odluke tokom vožnje. Glavni cilj ovog rada je bio prikazati razvoj autonomnih automobila, objasniti metode strojnog učenja koje se koriste u razvoju istih te objasniti moguće utjecaje autonomnih automobila na društvo. Rezultati ovog rada omogućuju bolje razumijevanje i svrhu metoda koje se koriste kod strojnog učenja u autonomnim automobilima.

Ključne riječi: autonomija, umjetna inteligencija, strojno učenje

Summary

One of the key elements in the development of autonomous cars is represented as artificial intelligence. Development of artificial intelligence was drastically accelerated with the discovery of technology such as transistor, microprocessor and the development of Internet. Autonomous car is a vehicle that is able to make decisions while driving in the place of human with the assistance of artificial intelligence. With the development of machine learning methods and neural networks, autonomous car is able to think and make decisions while driving. Main goal of this work is to present the development of autonomous cars, explain methods of machine learning which are used and explain the possible influence of autonomous cars on society. Results of this work help with understanding and purpose of methods used in machine learning inside autonomous cars.

Key words: autonomy, artificial intelligence, machine learning