

Tuomas Laiho

**TEKOÄLYN JA SENSORIFUUSION KEHITYKSEN
VAIKUTUKSET TÄYSIN AUTOMATISOITUJEN
AJONEUVOJEN TURVALLISUUDEN
PARANTAMISEKSI**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2021

TIIVISTELMÄ

Laiho, Tuomas

Tekoälyn ja sensorifuusion kehityksen vaikutukset täysin automatisoitujen ajoneuvojen turvallisuuden parantamiseksi

Jyväskylä, Jyväskylän yliopisto, 2021, 35 s.

Tietojärjestelmätiede, kandidaatintutkielma

Ohjaaja: Halttunen, Veikko

Nykypäivänä autot ovat älykkäämpiä kuin koskaan ennen sisältäen monenlaisia kuljettajaa avustavia ja jollain tasolla ajoneuvoa itseohjaavia ominaisuuksia. Täysin itsenäiset, automatisoidut ajoneuvot tulevat muuttamaan koko ajamisen merkityksen parantaen merkittävästi liikenneturvallisuutta, tuoden uusia tapoja matkustaa ja mahdollistaen uusia liiketoimintamalleja. Tällä hetkellä täysin automatisoituihin ajoneuvoihin liittyy kuitenkin useita niiden käyttöönottoa rajoittavia tekijöitä, joiden perimmäinen syy on, etteivät automatisoidut ajoneuvot ole vielä tarpeeksi turvallisia, jotta ne voisivat toimia liikenteessä itsenäisesti ilman ihmiskuljettajaa. Tämä tutkielma on kirjallisuuskatsaus, jossa tarkastelen automatisoitujen ajoneuvojen turvallisuutta tekoälyn ja sensorien näkökulmasta. Tutkielman tavoitteena on selvittää, miten sensoreiden ja tekoälyn opetusmenetelmien kehitys auttaa tekemään automatisoiduista ajoneuvoista turvallisempia, jotta ne voitaisiin ottaa liikennekäyttöön. Aihetta tullaan ensin käsittelemään kertomalla yleisesti automatisoitujen ajoneuvojen kehityksen nykytilanteesta, luokittelusta, hyödyistä sekä ongelmista turvallisuuden kannalta, jonka jälkeen käsitellään sensoreiden ja niiltä saatavan datan käsittelymallien vaikutusta ajoneuvon ympäristöstä saatavaan informaatioon. Tämän käsitellään ajoneuvon päätöksistä vastaavaa tekoälyä ja pohditaan opetusmallien vaikutusta tekoälyn kykyyn tehdä tarkempia päätöksiä.

Asiasanat: automatisoidut ajoneuvot, itseohjautuvuus, sensorit, sensorifuusio, tekoäly, syväoppiminen, simulaattorit

ABSTRACT

Laiho, Tuomas

The impact of the development of artificial intelligence and sensor fusion to improve the safety of fully automated vehicles

Jyväskylä, University of Jyväskylä, 2021, 35 p.

Information Systems, Bachelor's Thesis

Supervisor: Halttunen, Veikko

Today, cars are smarter than ever before, incorporating a wide range of driver-assistive and, to some extent, self-steering features. Fully independent, automated vehicles will change the meaning of driving, significantly improving road safety, introducing new ways of traveling and enabling new business models. At present, however, fully automated vehicles are subject to several factors limiting their introduction. The root cause of the limitations is that automated vehicles are not yet safe enough to operate independently in traffic without a human driver. This thesis is a literature review in which I look at the safety of automated vehicles from the perspective of artificial intelligence and sensors. The aim of this thesis is to find out how advances on sensors and artificial intelligence learning methods help making autonomous vehicles safer so that they can be put into service. The subject will first be addressed by giving a general overview of the current state of development of automated vehicles, their classification, benefits, and safety problems. The effect of the sensors and the data processing models obtained from them on the information obtained from the vehicle environment is then discussed. This is followed by a discussion of the artificial intelligence responsible for vehicle decisions and the impact of teaching models on the ability of artificial intelligence to make more accurate decisions.

Keywords: autonomous vehicles, self-driving, sensors, sensor fusion, artificial intelligence, deep learning, simulators

KUVIOT

KUVIO 1 Automatisoidun ajoneuvon järjestelmän rakenne	10
KUVIO 2 Automatisaation tasot.....	12
KUVIO 3 Sensoreiden kokoava vertailu	21

TAULUKOT

TAULUKKO 1 Turvallisuutta parantavat tekijät havainnointikyvyn ja päätöksentekokyvyn näkökulmasta	30
---	----

SISÄLLYS

TIIVISTELMÄ

ABSTRACT

KUVIOT JA TAULUKOT

1	JOHDANTO.....	6
2	AUTOMATISOIDUT AJONEUVOT	9
2.1	Toimintaperiaate	9
2.2	Automatisoitujen ajoneuvojen luokittelu ja kehityksen nykytila	10
2.2.1	Luokittelu SAE Internationalin standardin mukaan	11
2.2.2	Nykytilanne.....	12
2.3	Hyödyt.....	13
2.4	Yleisiä ongelmia turvallisuuden kannalta	14
3	SENSORIT JA DATAN KÄSITTELY AUTOMATISOIDUSSA AJONEUVOSSA	17
3.1	Automatisoidun ajoneuvon sensorit yleisesti	17
3.2	Sensoryypit.....	18
3.2.1	Kamera.....	18
3.2.2	Tutka	19
3.2.3	Lidar	19
3.2.4	Ultraääni	19
3.2.5	GNNS.....	20
3.2.6	Havainnoivien sensoreiden yhteenveto.....	20
3.3	Sensoriratkaisut automatisoiduissa ajoneuvoissa.....	21
3.4	Sensoreiden puutteellisesta havainnoimiskyvystä aiheutuvat ongelmat.....	22
3.5	Sensorifuusio	22
3.5.1	Sensorifuusion luokitseminen	23
3.5.2	Fuusion haasteet automatisoiduissa ajoneuvoissa	24
4	AUTOMATISOITUJEN AJONEUVOJEN TEKOÄLYN OPETTAMINEN.....	25
4.1	Tekoäly yleisesti	25
4.2	Tekoälyn opettaminen simulaattoreita käyttämällä.....	26
4.2.1	Pelimoottoreiden hyödyt simulaattorialustalle	27
4.2.2	Suosittu pelimoottorit ja simulaattorialustat.....	27
4.2.3	Pelimoottoreihin perustuva opettaminen.....	27
5	YHTEENVETO JA POHDINTA	29
	LÄHTEET.....	32

1 JOHDANTO

Itseohjautuvuus ja automatisaatio ovat olleet relevantteja termejä autoteollisuudessa lähivuosina, koska ajoneuvoja itsenäisesti ohjaavalla teknologialla on paljon potentiaalia. Useat yritykset, kuten Google, Apple, Honda, Porsche ja Tesla ovat perustaneet tutkimuslaitoksia kehittämään automatisoituja ajoneuvoja (Sajjad ym. 2021). Varsinaisten ajoneuvoja kehittävien toimijoiden lisäksi ala vaikuttaa myös useisiin muihin teknologiateollisuuden osa-alueisiin. Monet teknologia-alan yritykset ovatkin keskittyneet kehittämään ja parantamaan automatisoituihin ajoneuvoihin liittyvää teknologiaa, kuten sensoreita, viestintää, käyttöjärjestelmiä ja laskentatehoa (Sajjad ym. 2021).

Sajjadin ym. (2021) mukaan Gehrig ja Stein (1999) sekä Thrun (2010) määrittelevät ajoneuvon automatisoiduksi, jos se kykenee havainnoimaan ympäristöään ja ohjaamaan itseään ilman ihmisen vaikutusta. Ajoneuvo pystyy siis ympäristöstä saatavan informaation perusteella ja tekoälyä hyödyntämällä tekemään tietyn tasoisia itsenäisiä päätöksiä ajoneuvon ajamiseen liittyviä tehtäviä koskien. Käyttöönottaessa täysin automatisoidut ajoneuvot tuovat mukanaan useita hyötyjä parantaen liikenneturvallisuutta, säästäten energiaa ja lisäten liikkuvuutta. Liikenteessä ei kuitenkaan vielä ole yhtään täysin automatisoitua ajoneuvoa johtuen siitä, etteivät ajoneuvot ole yksinkertaisesti riittävän turvallisia, jotta ne ratkaisisivat lainsäädännölliset, eettiset ja vastuukysymyksiin liittyvät ongelmat. Täysin automatisoitujen ajoneuvojen turvallisuuden takaaminen vaatii monitieteellistä lähestymistapaa, joka ottaa huomioon järjestelmän vikasietoisuuden ja suunnittelemattomissa ympäristöissä toimimisen, joustavan koneoppimisen, yhteistyön ihmiskuljettajien kanssa sekä säädösten noudattamisen (Koopman, 2017).

Automatisoitu ajoneuvo on yleinen termi, jota voidaan käyttää kuvaamaan niin maalla, meressä tai ilmassa toimivia ajoneuvoja. Ajoneuvon käyttöympäristöstä riippumatta niiden tulee pystyä havainnoimaan ja ymmärtämään ympärillään tapahtuvia asioita ja ohjautua automatisoidusti. Tässä tutkielmassa automatisoidulla ajoneuvolla tarkoitetaan kuitenkin automatisoitua eli itseohjautuvaa autoa. Täysin automatisoituja ajoneuvoja ei vielä ole, joten tutkielman tarkoituksena on selvittää täysin automatisoitujen ajoneuvojen käyttöönottoon

vaikuttavia turvallisuusongelmia ajoneuvon sensorien havainnoimiskyvyn ja tiedonkäsittelyn sekä tekoälyn opettamisen näkökulmasta. Automatisoituun ajamiseen liittyy myös eettisiä ongelmia, joita kuvataan lyhyesti luvussa 2.4. Tutkielma ei kuitenkaan ota kantaa, miten automatisoidun ajoneuvon tulisi toimia eettisestä näkökulmasta, vaan keskittyy selvittämään, miten ajoneuvo havainnoi paremmin ympäristöään ja tekee näiden havaintojen perusteella parempia päätöksiä. Tutkimusongelmana on kartoittaa tekniikoita, joiden avulla itseohjautuva ajoneuvo osaa toimia kaikissa muuttuvissa olosuhteissa mahdollisimman turvallisesti. Tutkimuskysymystä voidaan purkaa esimerkiksi siihen, miten ja kuinka paljon tekoälyä pitää opettaa sekä kuinka ajoneuvo saa parempaa tietoa ympäristöstään. Tutkielmassa tullaan käsittelemään erilaisten opetusmenetelmien merkitystä tekoälyn kouluttamisessa sekä selvittämään sensorifuusion ja sensorivalikoiman merkitystä tekoälyn päätöksenteon tarkkuudelle. Tutkimuskysymykset voidaan siis tiivistää seuraavasti:

- Kuinka tekoäly voi saada paremmin tietoa automatisoidun ajoneuvon ympäristöstä?
- Kuinka tekoäly osaa reagoida paremmin sensoreilta saatuun tietoon?

Tämä kandidaatintutkielma on tyypiltään kirjallisuuskatsaus, jossa tutkimusongelmaa tarkastellaan kerätyn lähdekirjallisuuden pohjalta. Kirjallisuutena on pyritty käyttämään luotettavista julkaisukanavista peräisin olevia vertaisarvioituja lähteitä, joiden hakeminen on toteutettu JYKDOK-kirjaston, Scopusin, Google Scholarin, IEEE Xplore Digital Libraryn ja ACM Digital Libraryn avulla. Hakuosoina käytettiin englanninkielisiä aihepiiriin liittyviä termejä, kuten "autonomous driving", "self-driving cars", "autonomous vehicles", "deep learning" ja "sensor fusion", sekä näiden erilaisia yhdistelmiä. Hakutuloksia arvioitiin niiden relevanttiuden, luotettavuuden ja Julkaisufoorumin julkaisukanavahaun luokituksen avulla, jonka jälkeen soveltuvat lähteet valittiin tarkemmin tutkittaviksi. Julkaisufoorumin julkaisukanavahaulla löytyvät lähteet tarkastettiin ja käytettäväksi valittiin vähintään tasolle 1 kuuluvat lähteet. Lähteitä valittaessa pyrittiin kuitenkin käyttämään mahdollisimman korkeatasoisen luokituksen saaneita lähteitä ja yli puolet käytettävistä lähteistä onkin vähintään tasolla 2. Mikäli lähde ei löytynyt Julkaisufoorumin julkaisukanavahaulla, tarvetta sen käyttämiseen tutkielmassa harkittiin tarkasti. Tutkielmassa käytetyt luokittelemattomat lähteet ovat esimerkiksi valmistajien verkkosivustoja, kansainvälisiä tilastoja tai muita luotettavaksi arvioituja materiaaleja. Tutkielman pohjaa ei ole kuitenkaan rakennettu näille luokittelemattomille lähteille, vaan ne toimivat perusteluina yksittäisille argumenteille ja teknisille tiedoille.

Tutkielma koostuu johdannosta, kolmesta sisältöluvusta sekä yhteenvedosta ja pohdinnasta. Ensimmäinen sisältöluke käsittelee automatisoituja ajoneuvoja yleisellä tasolla kertoen niiden toimintaperiaatteesta, luokittelusta ja nykytilasta sekä hyödyistä ja ongelmista. Toinen sisältöluke käsittelee sensoreita automatisoiduissa ajoneuvoissa esitellen ensin sensorit yleisesti, jonka jälkeen pohditaan sensoridatan käsittelyn merkitystä. Kolmas sisältöluke käsittelee

automatisoiduissa ajoneuvoissa hyödynnettyä tekoälyä ensin yleisellä tasolla, jonka jälkeen pohditaan tekoälyn opetusmenetelmien merkitystä automatisoidun ajoneuvon turvallisuuden kannalta. Lopuksi on vielä yhteenveto, jossa tärkeimmät asiat kootaan yhteen ja pohditaan jatkotutkimusaiheita.

2 AUTOMATISOIDUT AJONEUVOT

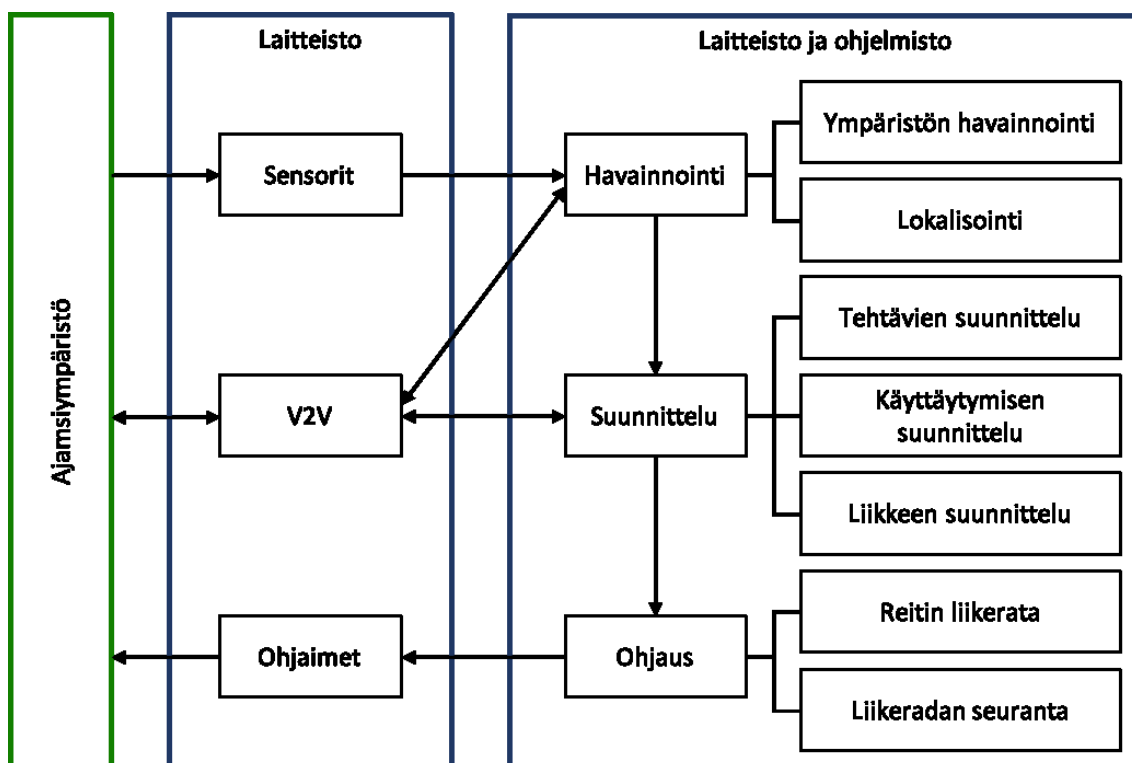
Tämän luvun tarkoitus on käsitellä automatisoituja ajoneuvoja yleisellä tasolla. Ensin käydään läpi automatisoitujen ajoneuvojen toimintaperiaate, jonka jälkeen esitellään menetelmä niiden luokitteluksi ja kerrotaan niiden kehityksen nykytilasta. Tämän jälkeen käsitellään automatisoitujen ajoneuvojen hyötyjä, jonka jälkeen esitellään niiden turvallisuuden vaikuttavia ongelmia.

2.1 Toimintaperiaate

Oikean maailman jatkuvasti muuttuvassa ympäristössä turvallinen ajaminen vaatii kykyä ennustaa eri tapahtumien todennäköisyyksiä ja tehdä oikeita päätöksiä tilanteiden ennaltaehkäisemiseksi. Ihmiset tekevät tätä päivittäin ja kykenemme selviytymään yllättävistäkin tilanteista useimmiten hyvin. Osaamme havaita vaaratilanteita, kuunnella hälytysajoneuvojen ääniä, sekä tunnemme hiljaiset kirjoittamattomat säännöt ja eleet liikenteessä. Voidakseen ymmärtää ympärillä tapahtuvia asioita edes kohtalaisella tasolla, automatisoitu ajoneuvo tarvitsee tarkkaa tietoa ympäristöstään ja omasta sijainnistaan siinä, jonka jälkeen se hyödyntää tekoälyä tekemään päätöksiä liittyen ajoneuvon liikkeisiin reaali-aikaisessa maailmassa. Tekoäly saa tietoa ajoneuvon ympäristöstä sensorien, kuten tutkien, Lidarien ja kameroiden kautta ja tekee tämän datan pohjalta itsenäisiä päätöksiä (Guo, Manglani, Liu & Jia, 2018). Automatisoidut ajoneuvot voivat myös saada tietoa esimerkiksi toisiltaan. Ajoneuvojen välinen V2V (Vehicle to Vehicle) kommunikatio voi vähentää liikenneonnettomuuksia ja liikenneuhkia vaihtamalla paikka- nopeus- ja suuntatietoja toistensa kantamalla olevien ajoneuvojen kesken (Uhlmann, 2015). V2V-kommunikatio antaa automatisoiduille ajoneuvoille käytännössä lisähavaintoja täydentäen ajoneuvon omia sensoreita.

Automatisoidun ajoneuvon järjestelmän rakenne koostuu Rosiquen, Navarron, Fernándezin ja Padillan (2019) mukaan sen laitteistosta ja ohjelmistosta (kuvio 1). Havainnointijärjestelmä havainnoi ympäristöä sensoreilta saadun informaation avulla, jonka jälkeen se pystyy määrittämään oman sijaintinsa siinä,

eli lokalisoimaan itsensä. Havainnointijärjestelmä voi myös saada muilta ajoneuvoilta tietoa ja vastaavasti jakaa tietoa muille ajoneuvoille V2V-kommunikaation kautta. Suunnittelujärjestelmä vastaa ajoneuvon tehtävien, käyttäytymisen ja liikkeen suunnittelemisesta ja se saa tarkat tiedot ympäristöstä havainnointijärjestelmästä, joita voidaan myös täydentää V2V-kommunikaation kautta. Lopuksi ohjausjärjestelmä vastaa liikeradan seurannasta ja hallinnasta ja välittää ajoneuvon ohjaimille komentoja, jotka vaikuttavat ajoneuvon liikkeisiin ympäristöön.



KUVIO 1 Automatisoidun ajoneuvon järjestelmän rakenne (Rosique ym., 2019 mukaan)

2.2 Automatisoitujen ajoneuvojen luokittelu ja kehityksen nykytila

Itseohjautuvan ajoneuvon määrittelyyn on olemassa useita erilaisia standardeja ja näkemyksiä. Useat alan laitokset, kuten German Federal Highway Institute, National Highway Traffic Safety Administration ja Society of Automotive Engineers (SAE) ovat nähneet huomattavasti vaivaa automatisoidun ajamisen luokitteluksi (Inagaki & Sheridan, 2018). Näistä SAE (Society of Automotive Engineers) Internationalin standardi J3016 *levels of driving automation* on kuitenkin kerännyt suosiota ja sen tarjoamat automatisoidun ajamisen tasot tunnetaankin puhekielenä jo maailmanlaajuisesti (Inagaki & Sheridan, 2018). Myös esimerkiksi Yhdysvaltain liikenneministeriö käyttää J3016 -standardia omassa automatisoitujen ajoneuvojen säätelevässä *Federal Automated Vehicles Policy* -ohjeistuksessaan

(US Department of Transportation, 2016). SAE Internationalin J3016 -standardi on julkaistu ensimmäisen kerran vuonna 2014, jonka jälkeen se on tarkastettu uudelleen vuonna 2016, 2018 ja 2021. Tässä tutkielmassa itseohjautuvia ajoneuvoja tarkastellaan SAE Internationalin (2021) standardin mukaan juuri sen yleisen tunnettavuuden, käytettävyyden ja sen tieteellisissä konteksteissa esiintyvyyden takia.

2.2.1 Luokittelu SAE Internationalin standardin mukaan

Itseohjautuvat ajoneuvot voidaan jakaa SAE Internationalin J3016 -standardin (2021) mukaan kuuteen eri luokkaan (0–5) niiden automatisoidun ajamisen ominaisuuksien perusteella. Automatisoitu ajaminen tarkoittaa ajoneuvon järjestelmän ja laitteiston suoriutumista dynaamisista ajotehtävistä osittain tai kokonaan jatkuvasti (SAE International, 2021). Seuraavaksi esittelen standardin määrittelemät tasot tarkemmin, jonka jälkeen ne on koottu yhteen niiden ominaisuuksien vertaamisen helpottamiseksi kuviossa (kuvio 2), joka perustuu SAE (2021) luomaan grafiikkaan.

Tasoilla 0, 1 ja 2 kuljettaja suorittaa itse kaiken tai suurimman osan dynaamisista ajotehtävistä ja automatisoidun ajamisen ominaisuudet ovat vain kuljettajaa avustavia ominaisuuksia. Taso 0 tarkoittaa automatisoitujen ominaisuuksien puuttumista ja ajoneuvo vaatiikin kuljettajan täyttä kontrollia kaikissa tilanteissa. Kuten kuvio 2 havaitaan, tasolla 0 esiintyvät ominaisuudet, kuten automaattinen hätäjarrutus, ajoneuvon kuolleita kulmia tarkkailevat sensorit ja kaistavahti eivät siis vielä tarkoita ajamisen automatisaatiota. Tasoilla 1 ja 2 ajoneuvojen automatisoidun ajamisen ominaisuudet ovat kuljettajaa avustavia ominaisuuksia. Tason 1 ominaisuudet kykenevät suoriutumaan dynaamisen ajamistehtävän pitkittäissuuntaisista tai sivuttaissuuntaisista liikkeen ohjauksista, eli joko kiihdyttämisestä ja jarruttamisesta, tai ratin ohjausliikkeistä. Esimerkkinä pitkittäissuuntaisia ohjausliikkeitä tekevistä ominaisuudesta on adaptiivinen vakionopeudensäädin ja esimerkkinä sivuttaissuuntaisia ohjausliikkeitä tekevistä ominaisuudesta on kaistankeskitin, joka pitää ajoneuvon kaistan keskellä automaattisesti. Taso 2 kuvataan SAE Internationalin (2021) standardissa osittaisen automatisaation tasoksi sen tarjotessa sekä pitkittäissuuntaisia, että sivuttaissuuntaisia ohjausliikkeitä tekeviä ominaisuuksia. Tasosta 1 poiketen taso 2 sisältää siis molemmat tason 1 ominaisuudet, eli adaptiivisen vakionopeudensäätimen ja kaistankeskittimen, eikä vain jompaakumpaa, niin kuin tasolla 1. Tasoilla 1 ja 2 ihmisen rooli on toimia jatkuvasti ajoneuvon kuljettajana ja valvoa järjestelmän toimintaa valmiina ottamaan ajoneuvo hallintaan heti halutessaan, uhkaavan tilanteen havaitessaan tai järjestelmän niin vaatiessa.

Tasoilla 3, 4 ja 5 ajoneuvo pystyy suorittamaan itse kaikki dynaamisen ajotehtävän osa-alueet, kun automatisoidun ajamisen ominaisuudet ovat päälle kytkettynä. Taso 3 tarkoittaa ehdollista ajamisen automatisaatiota, jolloin tämän tason ajoneuvo kykenee suoriutumaan ja olemaan vastuussa dynaamisesta ajamistehtävästä automatisoidun ajamisen ominaisuuksien ollessa päälle kytkettynä. Ajoneuvolla on vastuu ajamisesta niin kauan, kun automatisoidun ajamisen ominaisuudet ovat kytkettynä päällä ja jos ajoneuvon ominaisuudet eivät riitä

dynaamisen ajamistehtävistä suoriutumiseen, ajoneuvo vaatii kuljettajaa ottamaan ajoneuvo hallintaansa. Ihmisen rooli on tällöin olla vastuussa ajamisesta, kun ajoneuvo ei siihen itse kykene, eli toimia varmistuksena järjestelmälle. Taso 4 tarkoittaa korkeaa ajamisen automatisaatiota ja tason 4 itseohjautuva ajoneuvo kykenee toimimaan tason 3 ajoneuvon tapaan vain tietyissä olosuhteissa, mutta se ei enää tarvitse ihmistä ottamaan ajoneuvoa hallintaan. Automatisoidun ajamisen ominaisuuksien ollessa päällä, kyydissä olevan rooli onkin olla pelkästään matkustaja, eikä ajoneuvossa ole välttämättä edes ohjauspyörää tai polkimia. Kaikki vastuu ajamisesta on tällöin automatisoidulla ajoneuvolla, joka toimii myös omana varmistuksenaan pysäyttämällä ajoneuvon hallitusti, jos ajamisen edellytykset eivät toteudu. Taso 5 tarkoittaa täyttä ajamisen automatisaatiota ja tason 5 ajoneuvo eroaa tason 4 ajoneuvosta siten, että se kykenee toimimaan kaikissa ympäristöissä, joissa myös ihmiskuljettaja pystyisi ajamaan perinteisellä ajoneuvolla. (SAE, 2021.)

	Kuljettajaa avustavat tasot			Automatisoidun ajamisen tasot		
	SAE TASO 0	SAE TASO 1	SAE TASO 2	SAE TASO 3	SAE TASO 4	SAE TASO 5
Mitä ihminen täytyy tehdä?	Kuljettajan täytyy jatkuvasti tarkkailla ominaisuuksien toimintaa ja toimia itse varmistaa ajamisen turvallisuus. Kuljettaja jatkuvasti vastuussa ajamisesta			Ihminen ei aja ajoneuvoa, kun automatisoidun ajamisen ominaisuudet ovat kytkettyinä päälle.		
Kuka on vastuussa?	Kuljettaja jatkuvasti vastuussa ajamisesta			Kun ajoneuvo vaatii, ihmisen tulee ottaa vastuu ajamisesta	Ajoneuvo ei vaadi ihmistä ajamaan, ihminen ei myöskään tällöin vastuussa ajamisesta	
	Kuljettajaa avustavat ominaisuudet			Automatisoidun ajamisen ominaisuudet		
Mitä ominaisuudet tekevät?	Ominaisuudet tarjoavat ainoastaan varoituksia ja hetkellistä avustusta	Ominaisuudet tarjoavat tukea ohjaamiseen tai kaasulle ja jarrulle	Ominaisuudet tarjoavat tukea ohjaamiseen ja kaasulle ja jarrulle	Ajoneuvo kykenee ajamaan rajoitetuissa tilanteissa ja olosuhteissa, eikä operoi jos kriteerit eivät täyty		Ajoneuvo kykenee ajamaan kaikissa olosuhteissa ja tilanteissa
Esimerkkejä ominaisuuksista	Automaattinen hätäjarrutus Kuolleen kulman varoitus Kaistavahti	Kaistakeskitin TAI adaptiivinen vakionopeudensäädin	Kaistakeskitin JA adaptiivinen vakionopeudensäädin	Ruuhka-avustin	Paikallisen alueen kuljettajaton taksi Ratin ja poljinten ei täydy olla asennettuna	Samat ominaisuudet kuin tasolla 4, mutta kaikissa olosuhteissa

KUVIO 2 Automatisaation tasot (SAE, 2021, muokattu)

2.2.2 Nykytilanne

Vaikka itseohjautuvat ajoneuvot ovat olleet lähes jatkuvasti uutisotsikoissa, tois-taiseksi yhtäkään täysin automatisoitua tason 5 ajoneuvoa ei vielä ole ja tason 4 ajoneuvojakin on testikäytössä vain muutamia, joista tunnetuimpia ovat Googlen Waymo (Jeyachandran, 2020) ja Kiinalaisen Baidun Apollo-projekti (Apollo, 2020). Tason 3 ajoneuvojakin on vain yksi, Hondan vuonna 2021 julkaistu Sensing Elite (Honda, 2021). Tällä hetkellä liikenteessä olevat ajoneuvot kuuluvat kuitenkin jollekin tasolle automatisoitujen ajoneuvojen luokituksessa. Uudet autot kuuluvat ominaisuuksiltaan useimmiten tasolle 0 niiden ollessa vielä täysin manuaalisesti ohjattavia tai tasolle 1 niiden ollessa paremmin varusteltuja sisältäen esimerkiksi adaptiivisen vakionopeudensäätimen tai kaistavahdin. Tason 2 ajoneuvoista, jotka sisältävät kehittyneitä kuljettajaa tukevia avustusjärjestelmiä,

voidaan käyttää termiä ADAS (Advanced Driver Assistance Systems). ADAS ajoneuvot sisältävät kehittyneitä kuljettajaa tukevia apujärjestelmiä, esimerkiksi hätäjarrutukseen tai kaistalla pysymiseen liittyen. ADAS ajoneuvot tajoavat varoituksia vaarallisista ajotilanteista, turvallisuusominaisuuksia uhkaavien tilanteiden välttämiseksi, automatisoituja ohjausliikkeitä esineiden väistämiseksi ja kuljettajan huomion tarkkailemista (Chavez-Garcia & Aycard, 2016).

Sähköautovalmistaja Tesla on ottanut käyttöönsä ajoneuvoissaan Autopilot-nimisen järjestelmän, joka tukee kuljettajaa ajamisessa. Teslan Autopilot ei kuitenkaan nimestään huolimatta ole täysin automaattinen, vaan se sisältää rajoittuneita ominaisuuksia, jotka pystyvät esimerkiksi pitämään ajoneuvon kaistalla tai tekemään väistöliikkeen. (Tesla, 2021.) Tesla sijoittuukin SAE-luokituksen mukaan tasolle 2, joka kuuluu osittaiseen automatisaatioon. Aiemmin mainittu Googlen vuonna 2009 alkanut Waymo-projekti on tunnetuimpia esimerkkejä tason 4 automatisoidusta ajoneuvosta ja onkin nykyään johtava automatisoitujen autojen kehittäjä, jonka kuljettajaton kokeellinen taksi toimii rajoitetulla kaupunkialueella kyydittäen matkustajia.

Itseohjautuvuus on paljon muuta, kuin ajoneuvon kyky tehdä hätäjarrutus törmäysuhan takia. Osittain itseohjautuvat ADAS-ajoneuvot osaavat pitää ajoneuvon tiellä, mutta vastuu ajamisesta on silti kuljettajalla. Kun tämän tasoiset itseohjautuvat järjestelmät eivät kykene toimimaan tilanteessa, ne vaativat kuljettajalta kontrollia. Kuljettajan täytyy myös jatkuvasti seurata ympäristöään. Kun mennään kohti täyttä itseohjautuvuutta, vastuu ajamisesta siirtyy täysin ajoneuvolle itselleen ja ihminen kyydissä muuttuu kuljettajasta matkustajaksi. Kyydissä oleva ihminen ei istu välttämättä ratin takana tai rattia ei edes ole. Tällöin ajoneuvon turvallinen toiminta vaativassakin tilanteessa tulee pystyä takaamaan, vaikka jokin ajoneuvon järjestelmistä epäonnistuisi.

2.3 Hyödyt

Ihminen on todennäköisin tekijä liikenneonnettomuuden aiheuttajaksi ja jopa 97,5 % kaikista liikenneonnettomuuksista tapahtuu ihmisen tekemän virheen takia (Pakgohar ym., 2011). Maailman terveysjärjestö (WHO, 2020) mukaan noin 1,35 miljoonaa ihmistä kuolee liikenneonnettomuuksissa maailmanlaajuisesti joka vuosi. Onnettomuuksista aiheutuu myös 20–50 miljoonaa loukkaantumista, joista moni johtaa pysyvään vammautumiseen (WHO, 2020). Jokainen menetetty henki tai pysyvä vammautuminen vaikuttaa tietenkin yksilöihin ja heidän lähipiiriinsä henkisellä tasolla voimakkaasti. Liikenneonnettomuudet aiheuttavat myös merkittäviä taloudellisia menetyksiä yksilöille, heidän perheilleen ja valtioille hoitokustannuksien muodossa ja tuottavuuden laskiessa ihmisen kuollessa tai vammautuessa, jolloin myös perheenjäsenet voivat joutua käyttämään aikaa vammautuneesta huolehtimiseen (WHO, 2020). Itseohjautuva ajoneuvo voi vähentää ja poistaa inhimillisen syyn vaikutuksen ajotilanteissa ja näin vähentää onnettomuuksia merkittävästi.

Itseohjautuvat ajoneuvot eivät kuitenkaan vain paranna turvallisuutta ja sujuvoita liikennettä, vaan ne myös mahdollistavat vapaamman liikkuvuuden liikuntarajoitteisille. (Geary & Danks, 2019). Toisiinsa kytketyt itseohjautuvat ajoneuvot voivat kommunikoida keskenään ja näin parantaa liikenteen sujumista ja tätä kautta säästää aikaa ja polttoainetta, sekä lisätä turvallisuutta (Talebpour & Mahmassani, 2016).

2.4 Yleisiä ongelmia turvallisuuden kannalta

Automatisoitujen ajoneuvojen turvallisuuteen liittyy useita ongelmia. Esimerkiksi korkean tason kuljettajaa avustavia järjestelmiä sisältävässä ADAS-ajoneuvoissa automatisoitu ajamisjärjestelmä huolehtii ajamiseen liittyvistä tehtävistä, mutta ihminen kyydissä on kuitenkin velvollinen valvomaan järjestelmän toimintaa ja ottamaan ajoneuvon hallintaan tarvittaessa. Kuljettajan on kuitenkin helppo keskittyä epäoleelliseen, koska ajoneuvo pitää auton esimerkiksi kaistalla ja säätelee nopeutta automaattisesti ajamisen muuttuessa passiiviseksi. Mihnasin, Hernández-Sabatén, Ehsanin ja McDonald-Maierin (2020) tekemän tutkimuksen mukaan mikä tahansa toissijainen tehtävä ajaessa johtaakin ajamisen laadun heikkenemiseen. Osittaisesta automatisaatiosta voi siis olla jopa haittaa turvallisuuden kannalta, koska kuljettajana oleva ihminen voi helposti unohtaa olevansa vastuussa ajoneuvon hallinnasta.

Schoettlen ja Sivakin (2014) tekemässä ja Michiganin yliopiston liikenteen tutkimuslaitoksen rahoittamassa kyselytutkimuksessa selvitettiin julkista mielenpidettä liittyen automatisoituihin ajoneuvoihin Yhdysvalloissa, Yhdistyneessä kuningaskunnassa ja Australiassa. Suurimmalla osalla kyselytutkimukseen osallistuneilla oli positiivinen mielikuva teknologiasta, mutta suurinta osaa kuitenkin huolettivat turvallisuuteen liittyvät ongelmat ja automatisoidun ajoneuvon suoriutumisen huonommin kuin ihminen. SAE-luokituksen mukaan tasoilla 4 ja 5 ajoneuvon kuljettaja muuttuukin matkustajaksi, eikä ole enää vastuussa ajoneuvon hallinnasta. Tällöin vastuu ajamisesta siirtyy automatisoidulle ajoneuvolle, joka tekee itsenäisesti kaikki ajamiseen liittyvät päätökset.

SAE-luokituksen mukaisten, täyden automatisaation itseohjautuvien ajoneuvojen käyttöönotossa julkisilla teillä on lukuisia ongelmia, joista iso osa liittyy itse ajoneuvon turvallisuuteen niin matkustajien, muiden ajoneuvojen ja jalankulkijoiden osalta. Useiden reaaliaikaisesti toimivien järjestelmien, sensorien, ohjelmistojen ja itse ajoneuvoalustan tulee kommunikoida sujuvasti keskenään, jotta voidaan mahdollistaa ajoneuvon täysi autonomisuus ennakoimatonta liikennettä sisältävässä ympäristössä (Levinsol ym., 2011). Tämänhetkiset tason 4 kokeelliset projektit kuten esimerkiksi Waymo, kykenevät toimimaan vain rajoitetulla alueella, joka on kartoitettu huolella korkealaatuisia kolmiulotteisia karttoja hyödyntäen. Isoimpana haasteena voidaankin pitää rajoittamatonta ja kartoittamatonta ympäristöä, kun tasolta 4 siirrytään tasolle 5. Rajoittamattomassa todellisessa ympäristössä virhemarginaali on todella pieni ja läheltä piti tilanteiden määrä puolestaan todella suuri (Fridman ym., 2019). Ihmiset tekevät siis

jatkuvasti pieniä virheitä liikenteessä, jotka johtavat läheltä piti tilanteisiin, joista ei kuitenkaan seuraa mitään. Ihmiskuljettajat myös ajavat maailmanlaajuisesti joka vuosi 10 biljoonaa mailia, joiden aikana aiheutuu miljoonia monimutkaisia ja uusia tilanteita, joista automatisoidut ajoneuvot eivät välttämättä selviäisi (Daily, Medasani, Behringer & Trivedi, 2017).

Automatisoidun ajoneuvon tulee kyetä toiminaan liikenteessä ihmistä jopa huomattavasti paremmin, jotta perusteita automatisoidun ajoneuvon käyttöön-ottoon olisi. Automatisoidun ajoneuvon turvallisuuden määrittäminen on kuitenkin hyvin haastavaa. Vaikka ajoneuvo selviäisikin jostain tehtävästi ihmistä paremmin, se voi epäonnistua toisessa tehtävässä. Vaikeita tilanteita aiheuttavat esimerkiksi sääolosuhteet, kirjoittamattomat säännöt ja monenlaiset eleet ja käsi-merkit liikenteessä. Huonot sääolosuhteet, kuten sade, lumi, sumu ja rakeet ovatkin yksi vaikeimmista automatisoitujen ajoneuvojen suorituskykyyn vaikuttavista ongelmista (Zang, Ding, Tyler, Rakotoarivelo & Kaafar, 2019).

Päätöksenteon oikeellisuuteen liittyvät eettiset ongelmat aiheuttavat myös omat haasteensa automatisoitujen ajoneuvojen turvallisuudelle. Yksi klassinen esimerkki on Philippa Footin vuonna 1967 luoma eettinen dilemma nimeltään ”trolley problem”, jossa jarrurikkoinen juna kulkee kohti viittä raidetyöntekijää, jotka eivät pysty väistämään junaa. Kiskoista haarautuu kuitenkin sivuraide, jolla on vain yksi työntekijä, joka ei myöskään kykene väistämään junaa. Juna ei kykene jarruttamaan, mutta koehenkilöllä on mahdollisuus ohjata juna sivuraiteelle vetämällä vivusta ja näin tappaa vain yksi henkilö. Toinen vaihtoehto on olla osallistumatta tapahtuman kulkuun, jolloin kaikki viisi saavat surmansa. (Foot, 1967.) Automatisoituihin ajoneuvoihin sovellettuna kyseisenlainen eettinen ongelma muodostuisi silloin, kun ajoneuvon tekoälyn tulisi päättää, väistetäänkö edessä olevaa kohdetta tekemällä väistöliike esimerkiksi suoraan betoniestettä päin, jolloin törmäysuhan alla ollut henkilö säilyy vahingoittumattomana, mutta ajoneuvon kuljettaja mahdollisesti menehtyy. Tähän ongelmaan ei ole yhtä selvää vastausta, vaan ratkaisut riippuvat useista tulkintatavoista. Täysin automatisoidun ajoneuvon ei kuitenkaan tulisi ikinä joutua kyseisenlaisiin tilanteisiin, vaan sen pitäisi pystyä ennakoimaan omaa toimintaansa niin, että tällaiset tilanteet voitaisiin välttää ennen niiden syntymistä.

Automatisoidut ajoneuvojen turvallisuuteen liittyvät useita ongelmia, joiden merkitys korostuu, mitä korkeammalle automatisaation tasoilla mennään. Vaikka esimerkiksi tason 2 ajoneuvoja on sallitussa rajoittamattomassa käytössä tieliikenteessä, eivät ajoneuvojen ominaisuudet ole kyenneet aina estämään onnettomuuksia syntymästä. Vuonna 2018 Uberin itseajava auto törmäsi pyöräänsä tien yli taluttaneeseen jalankulkijaan kuolettavasti. Ajoneuvon sensorit havaitsivat jalankulkijan jo 6 sekuntia ennen osumaa, mutta tekoälyjärjestelmä luokitteli tämän aluksi tuntemattomaksi esineeksi ja vasta myöhemmin pyöräilijäksi. Tämä johti tekoälyn tekemään virheellisiä arvioita jalankulkijan liikeradasta ja ajoneuvo arvio hätäjarrutuksen tarpeelliseksi vain 1.3 sekuntia ennen törmäystä, mutta ei jarruttanut automaattisesti ominaisuuden ollessa pois käytöstä. Tekoälyjärjestelmä toimi normaalisti, mutta sitä ei ollut suunniteltu varoittamaan kuljettajaa. (NTSB, 2018.) Tuoreemmassa, vuoden 2021 tapauksessa kaksi henkilöä

kuoli Teslan tason 2 ajoneuvon törmätessä puuhun ja syttyessä palamaan (The New York Times, 2021).

3 SENSORIT JA DATAN KÄSITTELY AUTOMATISOIDUSSA AJONEUVOSSA

Tässä luvussa käsitellään ensin yleisesti automatisoitujen ajoneuvojen sensoreita, jonka jälkeen esitellään tarkemmin niissä käytettävät sensorityypit. Tämän jälkeen esitellään menetelmiä sensoreiden tuottaman datan yhdistämiseksi eli fuusioimiseksi ja pohditaan sen merkitystä tason 5 itseohjautuvuuden saavuttamiseksi.

3.1 Automatisoidun ajoneuvon sensorit yleisesti

Automatisoidun ajoneuvon toiminta rakentuu viiden perustoiminnon ympärille, joita ovat havainnointi, lokalisointi, suunnittelu, ohjaus ja järjestelmän hallinta (Jo, Kim, Jang & Sunwoo, 2014). Tämä tarkoittaa, että ajoneuvo saa kaiken tiedon ympäristöstään havainnoinnin ja lokalisoinnin avulla, jonka pohjalta sen tulee kyetä toimimaan muuttuvissa olosuhteissa ja tilanteissa turvallisesti. Ympäristön havainnointi toteutetaan useiden sensoriteknologioiden, kuten tutkan, valotutkan eli LIDARin ja kamerapohjaisen konenäön avulla, jonka jälkeen ajoneuvo sijoitetaan ympäristöönsä lokalisatiojärjestelmän GPS-sijainnin, merkintälaskun ja karttojen avulla (Jo, ym., 2014). Kartat eivät kuitenkaan ole tavallisia karttoja, vaan HD (High Definition) kartoiksi kutsutut korkealaatuiset kartat sisältävät tarkkaa tietoa ajoympäristön kiinteistä esineistä, kaistoista ja sijainneista jopa 10 cm tarkkuudella (Yoganandhan ym., 2020).

Sensoreiden toisiaan täydentävät modaliteetit ovat tärkeitä, jotta voidaan mahdollistaa nopea ja riittävän tarkka esineen tunnistaminen mahdollistaen ohjausjärjestelmän reagointi tilanteisiin (Kumar ym., 2020). Itseohjautuvat ajoneuvot toimivat useimmiten sähköllä, on myös sensorien ja datankäsittelyyn vaadittavan laskentatehon virrankulutus otettava huomioon sensoreita valittaessa. Sensorien hinnat eivät vaikuta tällä hetkellä itseohjautuvien ajoneuvojen prototyyppinä olevien robotaksien sensorivalikoimaan, mutta hinta vaikuttaa

käytettäviin sensoreihin siinä vaiheessa, kun täysin automatisoituja ajoneuvoja on tarkoitus tuoda kuluttajamarkkinoille.

3.2 Sensorityypit

Tässä luvussa esitellään automatisoiduissa ajoneuvoissa käytettävät sensorit ja kerrotaan tarkemmin niiden ominaisuuksista. Tämän jälkeen havainnointikyvyn kannalta oleellisten sensoreiden ominaisuudet koostetaan ja niitä verrataan keskenään.

3.2.1 Kamera

Kamera on passiivinen sensori, joka muodostaa sensoriin tulleen valon mukaan kuvan ympäristöstä. Kameran tuottamat kuvat muodostuvat kuvamatriisiin pikseleistä, joista jokainen koostuu tietyistä väreistä, jolla on oma numeerinen arvo (Yoganandhan ym., 2020). Ne voivat olla varustettuina erilaisilla linseillä, jotka voivat tarjota laajakuvaa lähiympäristöstä tai zoomata kuvaa kauas satojen metrien päähän. Niitä on mahdollista halvan hintansa takia sijoittaa itseohjautuviin ajoneuvoihin useita. Kameroita varten on kehitetty useita syväoppimista hyödyntäviä algoritmeja, joten niitä voidaan käyttää tunnistamaan esineitä, tieviivoja tai liikennemerkkien tekstejä. Kamerrat ovatkin tarkkoja tunnistamaan esineitä, mutta eivät kykene arvioimaan esineen etäisyyttä luotettavasti. Ne myös tuottavat valtavia määriä dataa, minkä käsittely voi olla todella raskasta (Rosique ym., 2019). Myös fyysiset esteet, kuten roskat, lumi tai sade heikentävät tai jopa estävät kameran toimintaa.

Automatisoiduissa ajoneuvoissa havainnoimiseen käytettävät kamerrat voidaan luokitella näkyvän valon aallonpituuksilla toimiviin RGB-kameroihin, sekä infrapunan (IR) aallonpituuksilla toimiviin kameroihin (Rosique ym., 2019). RGB-kamerrat ovat halpoja, näkevät hyvin värejä ja niillä on korkea resoluutio, mutta ne eivät näkyvän valon aallonpituuksilla toimiessaan näe pimeässä hyvin. Pimeässäkin näkevät IR kamerrat tuovat useita hyötyjä täydentäen tavallisia RGB-kameroita. IR-kamerrat eivät sokaistu tilanteista, kuten suorasta auringonvalosta linssiin tai pimeästä tilasta poistumisesta ja ne voivat havaita ihmisten, eläinten ja muiden ajoneuvojen lähettämää lämpösäteilyä (Rosique ym., 2019). Ne eivät kuitenkaan kykene kokonaan korvaamaan RGB-kameroita, koska Rosique ym. (2019) mukaan IR-kamerrat tuottavat mustavalkoista kuvaa ja niiden resoluutio on merkittävästi huonompi.

Etäisydentunnistamista varten on olemassa menetelmiä, joilla kamerrat voivat tehokkaammin arvioida ympäristön etäisyyksiä ja tuottaa kolmiulotteista dataa. Yksi vaihtoehto on käyttää kahden kameran stereojärjestelmää, joka mahdollistaa ympäristön kolmiulotteisen uudelleenrakentamisen kuva kualta (Derome, 2016).

3.2.2 Tutka

Tutka on radioaaltoihin perustuva sensori, jolla voidaan mitata kohteiden etäisyyksiä tutkasta. Tutka lähettää radiosignaalin, joka osuessaan esineeseen kimpoaa takaisinpäin, jolloin tutka vastaanottaa tämän signaalin ja osaa laskea etäisyyden kohteeseen. Tutka pystyy mittaamaan etäällä olevan kohteen etäisyyden ja nopeuden hyvin tarkasti (Zang ym., 2019). Automatisoidussa ajoneuvossa käytettävät tutkat toimivat taajuuksilla 24/77/79 GHz, joita kutsutaan millimetriaalloiksi (Rosique ym., 2019).

Millimetriaaltojen avulla tutka selviytyy sen pidemmän aallonpituuden ansiosta paremmin sateesta, lumesta ja sumusta (Wang ym., 2020). Kuvion 3 mukaan sen näkökenttä (FOV) on kuitenkin kapea sekä sen resoluutio on huono, vaikeuttaen esineiden erottamista toisistaan. Tutka on myös altis väärin positiivisten signaalien vastaanottamiseen signaalin kimmotessa väärin (Rosique ym., 2019).

3.2.3 Lidar

Lidar (Light Detection and Ranging) eli valotutka on optinen laite, joka kykenee mittaamaan etäisyyksiä ja nopeuksia laser-säteiden avulla. Lidar pystyy tallentamaan samoja tietoja, kuin tutka, mutta on huomattavasti tarkempi ja pystyy erottamaan pienetkin esineet toisistaan. Lidar skannaa ympäristöä ja tallentaa tietoa kolmiulotteisiin pistepilviin, joita voidaan hyödyntää esineiden tunnistamiseen ja seurantaan sekä vapaan tilan hallintaan. Pistepilvien dataa voidaan verrata HD kartastoihin ajoneuvon lokalisoimiseksi ympäristöönsä.

Lidariin perustuva esineiden etäisyyksien tunnistaminen on hyvin luotettava ja tarkka menetelmä, mutta sen kyky tunnistaa esineitä on hyvin rajoituttu (Kumar, 2020). Lidar on huomattavan kallis sen hintojen liikkuesssa useissa tuhansissa ja koska se on optinen sensori, vaikeat sääolosuhteet tuottavat haittaa sen tarkalle toiminnalle.

Lidar-sensorit ovat tyypiltään joko mekaanisia pyöriviä sensoreita tai kiinteitä (Solid State) sensoreita. Uudempaa teknologiaa olevat kiinteät LIDAR-sensorit ovat kestävämpiä, huoltovapaampia ja halvempia kuin mekaaniset sensorit, mutta niiden näkökenttä (FOV eli Field of View) on kapeampi (Rosique ym., 2019).

3.2.4 Ultraääni

Ultraäänisensorit ovat lyhyen kantaman sensoreita, joita käytetään etäisyyden mittaamiseen. Ultraäänisensorin toimintaperiaatteena on mitata etäisyys laskeamalla aika, joka kuluu ultraääniaallon matkaan lähettimeltä vastaanottimelle sen jälkeen, kun ultraääniaalto on heijastunut kohteesta (Marioli ym., 1992). Tekniikkaa hyödynnetään nykyään esimerkiksi henkilöautojen peruutustutkissa, mutta se tarjoaa myös ratkaisuja edistyneempään käyttöön.

Ultraäänisensorit ovat halpoja ja ne mittaavat etäisyyttä tarkasti riippumatta sääolosuhteista tai kohteen materiaalista. Huonoja puolia kuitenkin ovat

niiden taipumus tuottaa vääriä positiivisia signaaleja ääniaallon heijastuessa väärin, kyvyttömyys huomata minimietäisyyttä lähempänä olevia kohteita (Rosique ym., 2019) ja ääniaaltojen suhteellisen lyhyt kantama.

3.2.5 GNNS

Maailmanlaajuinen satelliittipaikannusjärjestelmä GNNS (Global Navigation Satellite System) on eniten käytetty teknologia ajoneuvon paikantamiseen niin maalla, merellä kuin ilmassa. Sen toiminta perustuu aikaan, joka satelliitin lähettämällä signaalilla kestää matkata vastaanottimelle. (Rosique ym., 2019.) Tunnetuimpia GNNS-järjestelmiä ovat esimerkiksi puhekieliseksi yleisilmaisuksi vakiintunut Yhdysvaltalainen GPS, Eurooppalainen GALIELO ja Venäläinen GLONASS. GNNS-järjestelmä vaatii vähintään neljä esteetöntä satelliittia, jotta vastaanottimen sijainti ja aika voidaan määrittellä luotettavasti (Rosique ym., 2019).

GNNS-järjestelmät eivät yksinään ole ratkaisu automatisoitujen ajoneuvojen lokalisatio-ongelmiin, koska ne eivät ole riittävän tarkkoja. Esimerkiksi ilmakehän olosuhteet voivat vaikuttaa mittaustuloksiin tai infrastruktuuri voi estää signaalin vastaanottamisen. (Guillaume ym., 2017.) Tarkkuutta voidaan parantaa käyttämällä maa-asemiin perustuvaa Real Time Kinematic GNSS-teknologiaa, mutta sen saatavuudessa on ongelmia (Guillaume, Alsayed, Yu & Glaser, 2017).


3.2.6 Havainnoivien sensoreiden yhteenveto

Erilaiset sensorit kykenevät havaitsemaan ympäristöään eri tavoin. Etäisyyttä havaitsevat tutkat ja Lidarit kykenevät mittamaan kohteiden etäisyyksiä ja nopeuksia tarkasti jopa pitkänkin matkan päästä. Ultraäänen kantama on näitä kahta sensorityyppiä lyhyempi, mutta sitä voidaan käyttää tarkkaan ajoneuvon lähiympäristön havainnoimiseen ja varmistamiseen sen halvan hinnan takia. Näkevät kamerasensorit eivät puolestaan mittaa etäisyyksiä tarkasti, mutta ne toimivatkin parhaiten kohteiden tunnistamisessa, koska niiden tuottamaan dataan voidaan soveltaa tarkkoja syväoppimisalgoritmeja.

Rosique ym. (2019) havainnollistivat sensoreiden eroja usealla kuviolla, joissa erilaisia sensorityyppejä verrattiin keskenään yhdentoista ominaisuuden perusteella, joita olivat näkökenttä (FOV), etäisyys, tarkkuus, kuvataajuus (FPS eli Frames per Second), resoluutio, värien havaitseminen, koko, alttius säälle, huollon tarve, näkyvyys ja hinta. Tämän tutkielman kannalta oleellista on selkeyttää havainnoivien sensoreiden vertailemista ja tämän takia Rosiquen ym. (2019) mukaisista kuvioista koostettiin seuraavalle sivulle kokoava kuvio (kuvio 3), jolla havainnoivien sensoreiden keskinäisiä eroja voidaan vertailla helposti.

Rosiquen ym. (2019) mukainen kuvitteellinen täydellinen sensori olisi halpa ja fyysisesti pienikokoinen, olisi sijoitettu huomaamattomasti, ei tarvitsisi huoltoa eikä olisi altis säälle, mutta tarjoaisi kuitenkin laajan näkökentän, näkisi pitkän matkan päähän, mittaisi tarkasti, omaisi tiheän kuvataajuuden ja tarkan resoluution sekä havaitsisi värejä. Kuten kuvioista 3 huomataan, yhdelläkään

sensorilla ei yksistään ole täydellisen sensorin ominaisuuksia, mutta oikeilla sensorivalinnoilla toisiaan täydentäen ne voivat päästä lähelle sitä.



KUVIO 3 Sensoreiden kokoava vertailu (Rosique ym., 2019, muokattu)

3.3 Sensoriratkaisut automatisoiduissa ajoneuvoissa

Automatisoituja ajoneuvoja kehittävä tai tutkivat ovat eri mieltä siitä, millaisia sensoreita automatisoiduissa ajoneuvoissa tulisi käyttää. Tavoitteena olisi, että sensorivalikoima tarjoaisi mahdollisimman tarkan ja luotettavan käsityksen ajoneuvon ympäristöstä kaikissa olosuhteissa kuitenkin olematta liian kallis, kookas tai huoltoa vaativa. Esimerkiksi Teslan Autopilot -järjestelmä saa tietoa ajoneuvon ympäristöstä 8 kameran, 12 ultraäänianturin ja tutkan avulla. Kamerat muodostavat 360 asteen kuvan ajoneuvon ympäristöstä ja havainnoivat enimmillään 250 metrin päähän. Ultraäänianturit tarkkailevat ajoneuvon ympäristöä 8 metrin enimmäisetäisyydellä ja tutka havainnoi eteenpäin jopa 160 metrin etäisyydelle. (Tesla, 2021.) Tesla voidaan luokitella tason 2 ajoneuvoksi ja sen Autopilot on erinomainen esimerkki edistyneestä kuljettajaa avustavasta ADAS-järjestelmästä, koska se osaa navigoida vilkkaammassakin liikenteessä ja ohjata itseään myös monimutkaisemmilla teillä (Tesla, 2021). Tasolle 4 luokitettava Waymon kuljettajaton robotaksi puolestaan käyttää ajoneuvoissaan useista LIDAR-sensoreista, tutkista ja kameroista koostuvaa ratkaisua. Ajoneuvon katolle sijoitettu kupu pitää sisällään 360 asteiset kamera- ja Lidar-järjestelmät, pitkän matkan kamerasensorin ja tutkan. Ajoneuvon jokaiselle sivulle on myös sijoitettu lyhyen

kantaman LIDAR-sensorit mittaamaan ajoneuvon lähietäisyyttä tarkasti. (Jeyachandran, 2020.)

Teslaa ja Waymoa vertaamalla huomataan, että mitä korkeammalle automatisaation tasoilla mennään, sen tarkempaa tietoa ajoneuvon tulee saada ympäristöstään. Waymon kattava sensorivalikoima mahdollistaa sen, että sensorit toimivat päällekkäisissä tehtävissä ja kattavat päällekkäisiä alueita ajoneuvon ympäristön tarkkailusta. Koska itseohjautuva ajoneuvo saa kaiken reaaliaikaisen tiedon ympäristöstään sensorien kautta, sensorien tyyppi, laatu, tarkkuus ja luotettavuus vaikuttavat suoraan ajoneuvon tekemiin ajamista koskeviin päätöksiin. Kaikille on kuitenkin vielä avoinna, paljonko sensoreiden suorituskykyä pitäisi parantaa täyden tason 5 itseohjautuvuuden saavuttamiseksi.

3.4 Sensoreiden puutteellisesta havainnoimiskyvystä aiheutuvat ongelmat

Sensoreiden havainnoimiskykyyn vaikuttavat monet tekijät ja ne voivatkin tehdä virheellisiä havaintoja. Sensoreiden tekemät virheet voidaan jakaa virheelliseen positiiviseen ja virheelliseen negatiiviseen arvoon. Virheellinen positiivinen arvo tarkoittaa, että ajoneuvon sensorit havaitsevat ajoneuvon ympäristössä jotain, mitä ei oikeasti ole ympärillä. Virheellinen negatiivinen arvo tarkoittaa, että ajoneuvo luulee, ettei sen ympäristössä ole mitään etsittyä, vaikka sen ympärillä olisi jotain.

Sensorihavaintojen toimiessa ainoana reaaliaikaisena informaationa ympäristön tapahtumista, on äärimmäisen tärkeää, että sensorit tuottavat luotettavaa informaatiota. Virheellinen negatiivinen arvo voi saada ajoneuvon huomaamaan edessä olevan kohteen liian myöhään, jolloin se voi johtaa törmäykseen. Virheellinen positiivinen arvo voi saada ajoneuvon reagoimaan esimerkiksi edessä olevaan uhkaan jarruttamalla, vaikka siihen ei olisi syytä. Näistä kahdesta virheellisestä havaintovirheestä virheellinen negatiivinen on huomattavasti pahempi, koska siinä on kyse turhan reagoinnin sijaan kokonaan reagoimatta jättämisestä. Virheellinen negatiivinen havainto voikin pahimmillaan aiheuttaa vakavan onnettomuuden, esimerkiksi kun ajoneuvon hätäjarrutusominaisuudet eivät toimi, koska ajoneuvo ei koskaan havainnut jalankulkijaa.

3.5 Sensorifuusio

Sensoreilla havaittiin olevan keskenään erilaisia kykyjä havainnoida ympäristöä. Yksi sensoryyppi ei vielä anna riittävää kokonaiskuvaa, vaan siihen vaaditaan useampia, toisiaan täydentäviä sensoreita. Sensorit tuottavat dataa, jota voidaan yhdistää sen käsittelyn tehostamiseksi. Sensorifuusio tarkoittaa itseohjautuvissa ajoneuvoissa sensoreiden tuottaman datan fuusioimista eli yhdistelemistä. Sensorifuusion tarkoituksena on tuottaa tarkempaa dataa, kuin mitä data olisi

yksistään ilman fuusiota (Rosique ym., 2019). Sensorifuusion hyödyntäminen päällekkäiseen dataan vähentää epävarmaa tietoa, lisää tarkkuutta ja parantaa järjestelmän eheyttä vikasietoisuutta lisäämällä (Rosique ym., 2019). Näin esimerkiksi yhdeltä sensorilta tuleva virheellinen signaali ei vielä vaikuta järjestelmän toimintaan.

Datan yhdistämisen lisäksi ajoneuvon laskentakapasiteetin kannalta on oleellista, missä sensoridata käsitellään. Sensoritasolle voidaan lisätä älykkyyttä, joillain sensori pystyy jo itsenäisesti käsittelemään havaitsemaansa asiaa, ennen kuin lähettää siitä dataa eteenpäin. Älykäs sensori ei siis lähetä pelkkää raakadataa eteenpäin, vaan sen lähettämä data voi sisältää jo tarkempaa tietoa kohteesta. Tätä tietoa voi olla esimerkiksi kohteen tyyppi, tai muu seurantaan liittyvää informaatio.

3.5.1 Sensorifuusion luokittelu

Sensorifuusio voidaan luokitella fuusioitavan datan perusteella erilaisiin kategorioihin. Kumar ym. (2020) mukaan sensorifuusio voidaan jakaa kolmeen pääkategoriaan fuusiossa käytetyn datan tason mukaan, alhaisen tason fuusioon, ominaisuustason fuusioon ja korkean tason fuusioon. Alhaisen tason fuusiossa raakamittausdata fuusioidaan sensorin sijainnin perusteella, ominaisuustason fuusiossa tietty ominaisuus erotetaan raakamuotoisesta mittausdatasta ja korkean tason fuusiossa jokainen sensori on itse vastuussa kohteen tunnistamisesta tai seurannasta ennen datan fuusioimista (Kumar ym., 2020).

Sensorifuusion jakamiselle on olemassa myös tarkempia menetelmiä. Wang ym. (2020) jakavatkin sensorifuusion neljään eri tasoon, jotka ovat datatason fuusio, täydentävien ominaisuuksien fuusio, kohteen ominaisuuksiin perustuva fuusio ja usean lähteen päätöksentekoon perustuva fuusio. Datatason fuusio tarkoittaa fuusiota, jossa data erotettavissa olevista eri sensoriyksiköistä fuusioidaan suoraan, jonka jälkeen fuusioitu data prosessoidaan eteenpäin (Wang ym., 2020). Täydentävien ominaisuuksien fuusio yhdistää vastaavasta sensoridatasta erotetut monen kohteen ominaisuudet ja suorittaa luokittelun ja tunnistamisen fuusioitujen useiden sensorien ominaisuuksien perusteella (Wang ym., 2020). Kohteen ominaisuuksiin perustuva fuusio tarkoittaa jaettua datankäsittelyprosessia, jossa jokainen sensori erottaa kohteen parametrit ja tunnistaa erilaiset kohteet muodostaen listan kohteista. Useat kohdelistat fuusioidaan luotettavan ja aidon kohteen tiedon luomiseksi, joka auttaa välttämään vääriä hälytyksiä ja ohimenneitä havaintoja. (Wang ym., 2020.) Usean lähteen päätöksentekoon perustuva fuusio tekee alustavia päätöksiä kohteen sijainnista, ominaisuuksista ja luokittelusta yhdeltä sensorilta saadun datan perusteella. Tämän jälkeen omaksutaan tietty fuusiostrategia useilta sensoreilta kerättyjen päätösten yhdistämiseksi ja sopivien menetelmien kautta fuusiotuloksen saavuttamiseksi. (Wang ym., 2020.)

Jokaisella fuusiomenetelmällä on omat hyödyt ja haitat keskenään verrattuna ja matalan tason fuusio vaikuttaa olevan kaikkein optimaalisin itseohjautuviin ajoneuvoihin sen reaaliaikaisen suorituskyvyn ja tarkemman datafuusion takia (Kumar ym., 2020). Kumarin ym. (2020) esittelemän matalan tason fuusion

raakamuotoisen mittausdatan käsittely ei kuitenkaan ole ratkaisu kaikkiin ongelmiin, koska sen käsittely vaatii enemmän laskentatehoa ja tiedonsiirtokapasiteettia, kuin esimerkiksi jo sensoritasolla esikäsitellyn datan käsittely.

3.5.2 Fuusion haasteet automatisoiduissa ajoneuvoissa

Kumar ym. (2020) mukaan nykytilan kirjallisuus kuvailee erinomaisen tarkan kohteentunnistusjärjestelmän käyttäen näkeviä ja etäisyyttä havaitsevia sensoreita, mutta automatisoitujen ajoneuvojen kohteentunnistamiseen liittyy silti useita ongelmia, kuten esimerkiksi rajoittunut kohteen etäisyyden havaitseminen. Visuaalista kuvaa tuottavat sensorit kykenevät tunnistamaan esineitä luotettavasti ja tarkasti, mutta eivät kykene mittamaan kohteen etäisyyksiä. Etäisyyksiä mittaavat sensorit, kuten Lidar ja tutka puolestaan mittaavat etäisyydet tarkasti, mutta tunnistavat kohteita heikosti.

Edellä mainittu ongelma voidaan ratkaista fuusioimalla reaaliaikaisesti Lidarin ja kameran dataa mahdollistaen tarkan esineiden etäisyyksien mittaamisen yhdistettynä lyhyen ja pitkän matkan esineiden tunnistamiseen (Kumar ym., 2020). Kumar ym. (2020) ehdottamassa fuusiomenetelmässä Lidarin ja kameran avulla havainnoidaan ympäristön tilannetta tallentamalla useita ympäristön fyysisiä ominaisuuksia. Kyseinen fuusiomenetelmä alkaa ensin Lidar-sensorin ja kameran kalibroimisesta, jonka jälkeen Lidarin tuottama kolmiulotteinen pistepilvidata yhdistetään kameran tuottamaan kuvaan. Tällaista fuusiomenetelmää voidaan Gaon ym. (2018) mukaan hyödyntää pitkän matkan päässä olevien kohteiden tunnistamiseksi.

Sensorit tuottavat ajoneuvon ympäristöstä valtavia määriä dataa, joka vaatii paljon laskentatehoa sen käsittelemiseksi. Sensorifuusion ideana on yhdistää sensoreilta saatua dataa ja käsitellä sitä. Mitä lähempänä sensoria sensoridataa esikäsitellään ja yhdistetään, sitä vähemmän se kuormittaa keskussuoritinta, koska suorittimelle lähetettävän datan määrää vähenee.

4 AUTOMATISOITUJEN AJONEUVOJEN TEKOÄLYN OPETTAMINEN

Tässä luvussa käsitellään automatisoitujen ajoneuvojen päätöksenteosta vastaavan tekoälyn opettamista. Aiheen käsitteleminen aloitetaan yleiseltä tasolta esittelemällä ensin tekoäly ja siihen liittyvät opetusmenetelmät kuten kone- ja syväoppiminen. Tämän jälkeen kerrotaan tekoälyn opettamisesta simulaattoreiden avulla, jonka jälkeen käsitellään pelimoottoreiden hyödyntämistä simulaattoreiden toiminnan parantamiseksi.

4.1 Tekoäly yleisesti

Tekoäly on laaja käsite, joka voidaan kuitenkin Kaplanin ja Haenleinin (2019) mukaan määritellä järjestelmän kyvyksi tulkita ulkoisia tietoja oikein, oppia näistä tiedoista ja käyttää opittuja asioita tiettyjen tavoitteiden ja tehtävien saavuttamisessa joustavan sopeutumisen kautta. Tekoäly käyttää tätä ulkoista tietoa syötteenä tunnistamaan piileviä sääntöjä ja kuvioita koneoppimisen avulla (Kaplan & Haenlein, 2019). Ihminen törmää koneoppimiseen lähes jatkuvasti jokapäiväisessä elämässä: Koneoppimista hyödyntäviä järjestelmiä käytetään esimerkiksi asioiden tunnistamiseen valokuvista, muuntamaan puhe tekstiksi, valikoidaan käyttäjälle kiinnostavia uutisia tai postauksia ja valitsemaan relevantteja hakutuloksia (LeCun, Bengio & Hinton, 2015). Tekoälyn tapaan myös koneoppiminen on terminä laaja ja LeCunin, Bengion ja Hintonin (2015) mukaan perinteisiä koneoppimistekniikoita pidetään rajoittuneina prosessoimaan luonnollista raakamuotoista dataa.

Syviä neuroverkkoja hyödyntävä syväoppiminen on osa koneoppimista ja yksi tekoälyn opetusmuodoista. LeCunin, Bengion ja Hintonin (2015) mielestä syväoppiminen tarjoaa useita mahdollisuuksia lähitulevaisuudessa, koska se tarvitsee vain vähän käyttäjän puuttumista ja se osaa hyödyntää kasvavaa laskentakapasiteettia ja saatavilla olevaa datamäärää. Tavallinen neuroverkko koostuu useista yksinkertaisista yhdistetyistä käsittelijöistä eli neuroneista, joista jokainen

tuottaa sarjan reaaliarvoihin perustuvia aktivointeja. Syötöneuronit aktivoituvat esimerkiksi ympäristöä havainnoivien sensorien toimesta ja muut neuronit aktivoituvat edellisiltä neuroneilta painotettujen yhteyksien kautta saaduista syöteistä. (Schmidhuber, 2014.) Syvät neuroverkot (DNN, Deep Neural Network) ovat autonomisten ajamisjärjestelmien ydinkomponentteja koska niiden avulla analysoidaan useilta sensoreilta saatua dataa reaaliaikaisesti ajamista ohjaavien parametrien määrittämiseksi (Stocco, Weiss, Calzana & Tonella, 2020).

4.2 Tekoälyn opettaminen simulaattoreita käyttämällä

Liikenteessä tapahtuu päivittäin lukuisia ennustamattomia tilanteita, eikä yksikään matka ole täysin identtinen. Tällä hetkellä onkin epätodennäköistä, että syviä neuroverkkoja (DNN) hyödyntämällä ajoneuvo voisi tehdä oikeanlaisia yleistyksiä koskemaan lukemattomia ajamistilanteita, joita ihmiskuljettajat kohtaavat päivittäin (Stocco ym., 2020). Tekoälyn päätöksenteko vaatii kykyä arvioida ja ennustaa tulevia tilanteita ja erilaiset opetusmenetelmät vaikuttavat ennustamisen tarkkuuteen, mikä puolestaan vaikuttaa tekoälyn tekemien päätösten tarkkuuteen. Syväoppiminen vaatii paljon opetusdataa ajotilanteista neuroverkon opettamiseksi, jotta se voi kehittää itseään tekemään tarkempia päätöksiä. Dataa saadaan kerättyä normaaleista ajotilanteista isoja määriä, esimerkiksi sähköautovalmistaja Tesla on ilmoittanut asiakkaidensa ajaneen Autopilot -järjestelmän avulla yhteensä jo yli miljardin mailin matkan. Harvinaisemmat tilanteet, kuten onnettomuudet ovat kuitenkin vaikeammin opetettavissa, koska onnettomuuksia tapahtuu huomattavasti vähemmän suhteessa muuhun ajoon. Tesla ilmoittaakin verkkosivullaan yhden onnettomuuden tapahtuvan jokaista 3.45 miljoonaa ajomailia kohden, kun kuljettaja ajaa Autopilot -järjestelmä päällä (Tesla, 2020).

Automatisoitujen ajoneuvojen algoritmien käyttöönotto ja testaaminen oikeassa ympäristössä on kallis ja aikaa vievä prosessi (Shah, Dey, Lovett & Kapoor, 2017). Syvien neuroverkkojen testaamiseksi yritykset suorittavatkin vain rajatun määrän oikeassa ympäristössä toteutettavia kalliita kenttätestejä, joissa ajoneuvoa ajetaan oikeilla teillä tai suljetun alueen testilaitoksissa (Stocco, 2020., Cerf, 2018 mukaan). Opetusdataa onkin paljon saatavilla normaaleista arkipäiväisistä tilanteista, mutta mitä erikoisimmista tilanteista on kyse, sitä vaikeampaa niitä on opettaa johtuen opetusdatan vähyydestä. Oikeassa ympäristössä suoritettut testit tuottavat sensoridataa, joka voidaan tallentaa simulaatiossa uudelleentoistettavaksi ja keinotekoisesti muokattavavaksi, jolloin voidaan luoda tilanteiden kokonaisvaltaista testaamista (Cerf, 2018) ilman suuria kustannuksia (Stocco, 2020).

Synteettisellä, simulaattorin avulla kerätyllä datalla on useita hyötyjä verrattuna testiajoneuvojen keräämään oikeaan dataan. Synteettinen datan käyttäminen on kustannustehokkaampaa, kuin datan kerääminen oikeasta ympäristöstä (Osinski ym., 2020). Simulaattoreilla voidaan myös luoda tilanteita, jotka ovat harvinaisia ja vaarallisia oikeassa elämässä, esimerkiksi onnettomuuksia.

4.2.1 Pelimoottoreiden hyödyt simulaattorialustalle

Avoimeen lähdekoodiin perustuva simulaattorialusta Gazebo on ollut yksi suosituimmista simulaatioalustoista sen modulaarisen rakenteen mahdollistaessa useiden fysiikkamoottoreiden ja sensorimallien käyttämisen ja kolmiulotteisten maailmojen luomisen (Shah ym., 2017). Shah ym. (2017) kuitenkin toteavat, että vaikka Gazebo on ominaisuuksiltaan runsas, sitä käyttämällä on ollut vaikeaa luoda isoja monimutkaisia visuaalisesti runsaita ja realistisia ympäristöjä.

Pelimoottorit kuten Unreal Engine 4 ja Unity sekä niihin perustuvat simulaattorit, kuten Carla ja AirSim, ovat mahdollistaneet monimutkaisten visuaalisesti realististen ympäristöjen luomisen, joita voidaan käyttää automatisoitujen ajoneuvojen opettamiseen ja testaamiseen (Osinski ym., 2020). Pelimoottoreihin pohjautuvien simulaattorien hyödyntämisessä automatisoitujen ajoneuvojen opettamisessa ja testaamisessa on korkealaatuisten grafiikkojen lisäksi Rosique ym. (2019) mukaan myös lukuisia muita hyötyjä, kuten tarkat ja täsmälliset fysiikkaaliset ominaisuudet, laskentatehoa lisäävä hajautettu arkkitehtuuri ja helposti ohjelmoitavissa oleva kehitysympäristö. Pelimoottoreilla saadaan siis lisättyä simulaattoreille lisää todentuntuisuutta, jolloin simulaattorilla kerätty data olisi mahdollisimman lähellä vastaavaa todellisesta ympäristöstä kerättävää dataa.

4.2.2 Suositut pelimoottorit ja simulaattorialustat

Unity 3D on avoimeen lähdekoodiin perustuva pelimoottori, jota käytetään pääsääntöisesti kehittämään videopelejä ja simulaatioita tietokoneille, konsoleille ja älypuhelimille. Unreal Engine on suosittu yleiskäyttöinen pelinkehitysmoottori, joka tarjoaa ohjelmointi- ja fysiikkamoottorit sekä korkealaatuiset realistiset grafiikkaominaisuudet. (Rosique ym., 2019.) Seuraavaksi otetaan tarkempaan tarkasteluun näistä kahdesta suositumpaan Unreal Engineen pohjautuvat Carla ja AirSim -simulaattorit. AirSim on avoimeen lähdekoodiin perustuva simulaattorialusta, jonka tavoitteena on kaventaa simulaation ja todellisuuden välistä rakoja auttaakseen automatisoitujen ajoneuvojen kehittämistä (Shah ym., 2017). AirSim tukee tällä hetkellä kameroita, IMU (Inertial Measurement Units), GPS ja Lidar-sensoreita (AirSim). IMU-sensoreilla tarkoitetaan useita ajoneuvoon kohdistuvia voimia mittaavia sensoreita, joita ovat ajoneuvon kiihtyvyyssanturit, gyroskoopit ja magnetometrit.

Carla on myös avoimeen lähdekoodiin perustuva simulaattori, joka tarjoaa vapaasti käytettäviä resursseja, kuten useita sisäänrakennettuja karttoja, säätiloja sekä useita ajoneuvoja erilaisilla fyysisillä ominaisuuksilla (Osinski ym., 2020). Carlan tukemia sensoreita ovat AirSimin tapaan kamerat, IMU, GPS ja Lidar-sensorit (Carla).

4.2.3 Pelimoottoreihin perustuva opettaminen

Osinski ym., (2020) tutkivat simulaatioon pohjautuvaa tekoälyn vahvistusoppimista kehittääkseen ajamisjärjestelmän, joka voisi ohjata automatisoitua ajoneuvoa todellisessa maailmassa. Tutkimuksen simulaattoriksi valikoitui Carla,

koska se tarjosi riittävän tarkat fyysiset ja visuaaliset ominaisuudet. Osinski ym. (2020) saivat kerättyä simuloitua ajamiskokemusta sadan vuoden ajalta, jonka jälkeen tällä datamäärällä opetettua tekoälyä testattiin useissa oikeissa ajamistilanteissa erilaisten mallien avulla. Ajamismalleista saatujen tuloksien avulla vahvistui, että toimintatavat siirtyivät simulaattoriympäristöstä oikeaan ympäristöön onnistuneesti (Osinski ym., 2020).

Osinskin ym. (2020) tutkimuksessa kuitenkin huomattiin, että simuloitun ympäristön ja oikean ympäristön välillä on eroavaisuuksia, jotka johtuvat todellisen ympäristön havaitsemiseen vaikuttavasta ympäristön kohinasta eli datasignaaliin kuulumattomasta satunnaissignaalista. Vaikka automatisoitu ajoneuvo suoriutuikin oikeassa ympäristössä lupaavasti esimerkiksi, kun opetusta oli säädelty enemmän ja ajoneuvolle oli annettu selkeät reittipisteet, simulaattoriympäristön ja todellisen ympäristön eroavaisuudet vaikeuttivat hyvän simulaattorissa saavutetun suorituskyvyn siirtämistä oikeaan ajoympäristöön (Osinski ym., 2020). Simulaattoriympäristöön tulisikin kyetä lisäämään kohinaa, jotta tekoälyn opetusmallien siirtäminen simuloitusta ympäristöstä oikeaan ympäristöön tehostuisi.

5 YHTEENVETO JA POHDINTA

Tutkimusongelmana oli, kuinka automatisoitu ajoneuvo pystyy toimimaan kaikissa muuttuvissa tilanteissa mahdollisimman turvallisesti. Tutkielma käsitteli automatisoitujen ajoneuvojen turvallisuuden parantamista oikeilla sensorivalinnoilla, sensorien tuottaman datan käsittelemisellä ja tehokkaammilla opetusmenetelmillä. Näistä tekijöistä muodostettiin tutkimuskysymykset, jotka olivat ”Kuinka tekoäly voi saada paremmin tietoa automatisoidun ajoneuvon ympäristöstä?” ja ”Kuinka tekoäly osaa reagoida paremmin sensoreilta saatuun tietoon?”.

Aihetta lähdettiin käsittelemään ensin yleisellä tasolla toisessa luvussa, jossa kerrottiin yleisesti automatisoiduista ajoneuvoista ja niiden luokittelemisestä. Luokittelamisen jälkeen kerrottiin automatisoitujen ajoneuvojen tuomista hyödyistä, jonka jälkeen keskityin kertomaan mahdollisista ongelmista turvallisuuteen liittyen. Turvallisuuden kannalta automatisoiduilla ajoneuvoilla on yksi kriittinen ongelma, nykyiset automatisoidut ajoneuvot eivät vain kykene toimimaan vielä riittävän turvallisesti, jotta ne voisivat liikkua rajoittamattomassa ja muuttuvassa ympäristössä täysin itsenäisesti ja näin ollen luokitua tasolle 5. Automatisoidut ajoneuvot eivät osaa vielä saada tarpeeksi tarkkaa ja laajaa kokonaiskuvausta ympäristöstä kaikissa olosuhteissa, eivätkä ne myöskään osaa tehdä riittävän tarkkoja päätöksiä muuttuvissa tilanteissa. Nykyiset automatisoidut ajoneuvot ratkaisevat ongelman antamalla tarvittaessa ihmiskuljettajalle vastuun ajamisesta tai rajoittamalla ajoneuvon toiminta-aluetta ja huippunopeutta.

Tutkimusongelman sensoreihin ja datankäsittelyyn liittyviä ongelmia käsiteltiin luvussa kolme. Kirjallisuuslähteitä tutkimalla voitiin huomata, että tiedonkäsittelystä osa voidaan suorittaa jo sensoritasolla, jolloin ajoneuvon keskusyksikölle lähetettävän datamäärä aiheuttama kuormitus pienenee. Myös sensorifuusion, eli sensoreiden tuottaman datan yhdistäminen jollain datafuusion tasolla mahdollisti hyötyjä havainnoinnin kannalta. Raakaa dataa sisältävä fuusio vaatii huomattavan paljon laskentatehoa ja sillä opettaminen on vaikeaa, mutta samalla se tarjoaa parhaan mahdollisen suorituskyvyn datan osalta. Enemmän modulaarisuutta sisältävissä menetelmissä sensoreiden esikäsittelemää dataa on

helpompi fuusioida ja opettaa, mutta samalla menetelmien suorituskyky laskee. Sensorifuusiossa kysymyksenä onkin tasapainottelu suorituskyvyn ja modulaa-risuuden välillä. Sensorit myös paranevat jatkuvasti tuottaen yhä enemmän tar-kempaa dataa, jolloin sensorifuusion merkitys tulevaisuudessa korostuu.

Tutkimusongelman tekoälyn opettamista ja siihen liittyviä ongelmia käsi-teltiin luvussa neljä. Huomattiin, että opetusmenetelmissä korostui laadukkaam-man ja kattavamman opetusdatan keräys, sekä ajoneuvon kyky oppia asioita myös ilman massadatalla opettamista. Opetusdataa voidaan esimerkiksi kerätä ensin suljetuilta testiradoilta ja lokaaleilta testiajoilta yleisillä teillä, jonka jälkeen kerättyä dataa voidaan toistaa ja muokata simulaatioissa kattavamman opetta-misen mahdollistamiseksi. Toinen merkittävä opetusmenetelmä on käyttää si-mulaattorihjelmia, joissa harvinaisiakin tilanteita voidaan virtuaalisesti luoda. Ajoneuvo saadaan virtualisoitua kokonaan laitteistoa ja järjestelmiä myöten ope-tusympäristöön, jolloin sen toimintaa on helppo testata ja uusia tilanteita tehokas opettaa.

Automatisoitujen ajoneuvojen turvallisuudessa on vielä usealla osa-alu-eella parannettavaa, jotta täysin automatisoidut ajoneuvot olisivat mahdollisia. Keskeisiä turvallisuuteen vaikuttavia osa-alueita ovat tutkielmassa käsitelty ha-vainnointikyky ja päätöksentekokyky. Kattava ja toisiaan täydentävä sensoriva-likoima ja sensoridatan fuusioiminen yhdessä V2V-kommunikaation kautta saa-dun datan kanssa varmistavat nopean ja tarkan ympäristön havainnoinnin. Pää-töksenteosta saadaan nopeampaa, kun sensoridataa esikäsitellään ja fuusioidaan korkean tason sensorifuusiolla, jolloin keskusyksikölle siirrettävä datamäärä vä-henee. Päätöksenteon tarkkuutta puolestaan voidaan lisätä matalan tason senso-rifuusiolla, käyttämällä kattavampaa simulaattoreilla kerättyä opetusdataa ja te-hokkaampia simulaattoripohjaisia opetusmenetelmiä. Seuraava taulukko (tau-lukko 1) koostaa vielä nämä tutkielmassa esiintyneet automatisoidun ajoneuvon turvallisuutta parantavat havainnointi- ja päätöksentekokyvyn kehityskohteet ja toimenpiteet, joita ne vaativat.

TAULUKKO 1 Turvallisuutta parantavat tekijät havainnointikyvyn ja päätöksentekokyvyn näkökulmasta

Kehityskohde	Toimenpiteet	Lähteet
Havainnoinnin nopeus	Toisiaan täydentävät sensorityypit ja sensorien tekninen kehitys, ennakoivat havainnot V2V-kommunikaation kautta	(Kumar ym., 2020), (Uhlemann, 2015)
Havainnoinnin tarkkuus	Sensorien määrän lisääminen ja toisiaan täydentävät sensorityypit, sensorifuusio, lisähavainnot V2V-kommunikaation kautta	(Rosique ym., 2019), (Kumar ym., 2020), (Wang ym., 2020), (Uhlemann, 2015)
Päätöksenteon nopeus	Keskusyksikköön siirrettävän datan vähentäminen korkean tason sensorifuusiolla: osa laskennasta suoritetaan sensoritasolla, jolloin keskusyksikön laskentatehon tarve vähenee.	(Kumar ym., 2020), (Wang ym., 2020)

Päätöksenteon tarkkuus	Kattavampi opetusdata, tehokkaammat tekoälyn opetusmenetelmät, matalan tason fuusio	(Rosique ym., 2019), (Shah ym., 2017), (Osinski ym., 2020), (Kumar ym., 2020)
------------------------	---	--

On kuitenkin huomattava, että taulukossa esitetyt havainnointikykyä ja päätöksentekokykyä parantavat toimenpiteet eivät yksinomaan riitä, vaan täysin automatisoitu ajoneuvo vaatii parhaan mahdollisen suorituskyvyn kaikilta ajamiseen liittyviltä osa-alueilta. Tarkastelemani menetelmät kuvaavat, kuinka havainnointikykyä ja päätöksentekokykyä kehittämällä turvallisuutta voidaan parantaa, mutta tarkoituksenani ei ollut ottaa kantaa, kuinka paljon turvallisuutta pitäisi lisätä, jotta ajoneuvoa pidettäisiin riittävän turvallisena.

On mahdollista, että ennen tason 5 täyden automatisaation ajoneuvojen liikennekäyttöönottoa, markkinoilla tullaan näkemään useita niin sanottuja väli-vaiheen ratkaisuja, kunhan tällaiseen automatisaatioon vaadittavien sensoreiden hinnat laskevat mahdollistaen esimerkiksi ratkaisuja yksityisten ja yhteisöjen tarpeeseen. Kyseisten ajoneuvojen massaa ja nopeutta ja ajoympäristöä voidaan rajoittaa, jolloin tilanteet muuttuvat helpommin hallittaviksi ja ympäristö tunnetaan jo entuudestaan. Käyttökohteena ei välttämättä tarvitse olla edes ihmisten kuljettaminen, esimerkiksi pienet, jalankulkijoiden seassa liikkuvat automatisoidut ruokalähetit liikkuvat hitaasti eivätkä aiheuta vaaraa liikenteessä.

Tutkielma onnistui vastaamaan yleisellä tasolla asetettuihin tutkimuskysymyksiin käsitellen sensoriratkaisuja, sensoridatan fuusioimista ja tekoälyn opettamisen tehostamista. Kandidaatintutkielmaan käytettävät resurssit ovat kuitenkin rajalliset ja rajoittavat tutkielman laajuutta. Täysin automatisoitujen ajoneuvojen mahdollistamiseksi usean eri osa-alueen tuleekin toimia keskenään saumattomasti ja tämä tutkimus onkin siinä mielessä rajoittunut, koska se tarkastelee vain kahta ajoneuvon turvallisuuteen vaikuttavaa tekijää, havainnointikykyä ja päätöksentekokykyä. Näihin molempiin vaikuttaa kuitenkin paljon yksityiskohtaisempia tekijöitä, joita ei tässä tutkielmassa ollut mahdollista käsitellä.

Tutkielman perusteella aihepiiristä löytyy monia mahdollisia jatkotutkimusaiheita. Mielenkiintoista olisi tutkia tarkemmin, mikä olisi optimaalinen ja konkreettinen sensoriratkaisu tason 5 ajoneuvoissa, jolla saataisiin paras mahdollinen havainnointikyky kaikissa ajoympäristöissä ja olosuhteissa. Eettiset ongelmat nostettiin esille turvallisuuteen vaikuttavien ongelmien käsittelevässä luvussa, mutta niitä ei kuitenkaan tässä tutkielmassa käsitelty sen tarkemmin. Koska eettisiin ongelmiin ei ole aina oikeita ratkaisuja, olisikin hyvä tutkia, miten niiden syntymiseltä välttyttäisiin kokonaan, jotta automatisoitu ajoneuvo ei ikinä joutuisi tällaisen ongelman eteen. Tähän liittyy oleellisesti myös täysin automatisoidun ajoneuvon riittävän turvallisuustason määrittämisen, koska niiden turvallisuuteen liittyvä sääntely on vielä varhaisessa vaiheessa. Tekoälyn simulaattoriopettamisessa huomattiin, että todellisen ja simuloitun ympäristön välillä on eroavaisuuksia, koska todellinen ympäristö on ennalta-arvaamaton. Olisikin myös mielenkiintoista tutkia, miten tätä väliä todellisen ja simuloitun ympäristön välillä voitaisiin pienentää.

LÄHTEET

- AirSim. Sensors in Air Sim. Haettu 25.5.2021 osoitteesta <https://microsoft.github.io/AirSim/sensors/>
- Apollo. (2020). Robotaxi. Haettu 14.5.2021 osoitteesta <https://apollo.auto/robotaxi/index.html>
- Bresson, G., Alsayed, Z., Yu, L. & Glaser, S. (2017). Simultaneous Localization and Mapping: A Survey of Current Trends in Autonomous Driving. *IEEE Transactions on Intelligent Vehicles*, 2(3), 194-220. <https://doi.org/10.1109/TIV.2017.2749181>
- Carla. Sensors reference. Haettu 25.5.2021 osoitteesta https://carla.readthedocs.io/en/latest/ref_sensors/
- Cerf, V. (2018). A comprehensive self-driving car test. *Communications of the ACM*, 61(2), 7. <https://doi.org/10.1145/3177753>
- Chavez-Garcia, R. O. & Aycard, O. (2016). Multiple Sensor Fusion and Classification for Moving Object Detection and Tracking. *IEEE Transactions on Intelligent Transportation Systems*, 17(2), 525-534. <https://doi.org/10.1109/TITS.2015.2479925>
- Daily, M., Medasani, S., Behringer, R., & Trivedi, M. (2017). "Self-Driving Cars. *Computer*, 50(12), 18-23. <https://doi.org/10.1109/MC.2017.4451204>
- Derome, M., Plyer, A., Sanfourche, M. & Besnerais, G. L. (2015). Moving Object Detection in Real-Time Using Stereo from a Mobile Platform. *Unmanned Systems*, 3(4), 253-266. <https://doi.org/10.1142/S2301385015400026>
- Foot, P. (1967). The problem of abortion and the doctrine of the double effect. *Oxford Review*, 5, 5-15.
- Fridman, L., Brown, D. E., Glazer, M., Angell, W., Dodd, S., Jenik, B., ... & Reimer, B. (2019). MIT advanced vehicle technology study: Large-scale naturalistic driving study of driver behavior and interaction with automation. *IEEE Access*, 7, 102021-102038. <https://doi.org/10.1109/ACCESS.2019.2926040>
- Gao, H., Cheng, B., Wang, J., Li, K., Zhao, J. & Li, D. (2018). Object Classification Using CNN-Based Fusion of Vision and LIDAR in Autonomous Vehicle Environment. *IEEE Transactions on Industrial Informatics*, 14(9), 4224-4231. <https://doi.org/10.1109/TII.2018.2822828>
- Geary, T. & Danks, D. (2019). Balancing the Benefits of Autonomous Vehicles. *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society (AIES '19)*. Association for Computing Machinery, New York, NY, USA, 181-186. <https://doi.org/10.1145/3306618.3314237>
- Gehrig, S., K. & Stein, F., J. (1999). Dead reckoning and cartography using stereo vision for an autonomous car. *Proceedings 1999 IEEE/RSJ International Conference on Intelligent Robots and Systems. Human and Environment Friendly*

- Robots with High Intelligence and Emotional Quotients (Cat. No.99CH36289)*, 3, 1507-1512. <https://doi.org/10.1109/IROS.1999.811692>
- Guo, L., Manglani, S., Liu, Y. & Jia, Y. (2018). Automatic Sensor Correction of Autonomous Vehicles by Human-Vehicle Teaching-and-Learning. *IEEE transactions on vehicular technology*, 67(9), 8085-8099. Haettu osoitteesta <https://doi.org/10.1109/TVT.2018.2846593>
- Honda. (2021. 4. Maaliskuuta). Honda launches next generation Honda SENSING Elite safety system with Level 3 automated driving features in Japan. Haettu 5.5.2021 osoitteesta <https://hondanews.com/en-US/honda-corporate/releases/release-e86048ba0d6e80b260e72d443f0e4d47-honda-launches-next-generation-honda-sensing-elite-safety-system-with-level-3-automated-driving-features-in-japan>
- Inagaki, T., Sheridan, T., B. (2019). A critique of the SAE conditional driving automation definition, and analyses of options for improvement. *Cogn Tech Work*, 21, 569–578. <https://doi.org/10.1007/s10111-018-0471-5>
- Jeyachandran, S. (2020. 4. maaliskuuta). Introducing the 5th-generation Waymo Driver: Informed by experience, designed for scale, engineered to tackle more environments. Haettu 14.4.2021 osoitteesta <https://blog.waymo.com/2020/03/introducing-5th-generation-waymo-driver.html>
- Jo, K., Kim, J., Kim, D., Jang, C. & Sunwoo, M. (2014). Development of Autonomous Car-Part I: Distributed System Architecture and Development Process. *IEEE transactions on industrial electronics*, 61(12), 7131-7140. <https://doi.org/10.1109/TIE.2014.2321342>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15-25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Koopman, P. & Wagner, M. (2017). Autonomous Vehicle Safety: An Interdisciplinary Challenge. *IEEE Intelligent Transportation Systems Magazine*, 9(1), 90-96. <https://doi.org/10.1109/MITS.2016.2583491>
- Kumar, G. A., Lee, J. H., Hwang, J., Park, J., Youn, S. H. & Kwon, S. (2020). LiDAR and Camera Fusion Approach for Object Distance Estimation in Self-Driving Vehicles. *Symmetry (Basel)*, 12(2), 324. <https://doi.org/10.3390/sym12020324>
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>
- Levinson, J., Askeland, J., Becker, J., Dolson, J., Held, D., Kammel, S., ... & Thrun, S. (2011, June). Towards fully autonomous driving: Systems and algorithms. *2011 IEEE Intelligent Vehicles Symposium (IV)* 163-168. <https://doi.org/10.1109/IVS.2011.5940562>

- Marioli, D., Narduzzi, C., Offelli, C., Petri, D., Sardini E. & Taroni, A. (1992). Digital time-of-flight measurement for ultrasonic sensors. *IEEE Transactions on Instrumentation and Measurement*, 41(1), 93-97. <https://doi.org/10.1109/19.126639>
- Minhas, S., Hernandez-Sabate, A., Ehsan, S. & McDonald-Maier, K. D. (2020). Effects of Non-Driving Related Tasks During Self-Driving Mode. *IEEE transactions on intelligent transportation systems*, 1-9. <https://doi.org/10.1109/TITS.2020.3025542>
- NTSB. (2018). PRELIMINARY REPORT HIGHWAY HWY18MH010. Haettu 10.4.2021 osoitteesta <https://www.nts.gov/investigations/AccidentReports/Reports/HWY18MH010-prelim.pdf>
- Osiński, B., Jakubowski, A., Miłoś, P., Zięcina, P., Galias, C., Homoceanu, S. & Michalewski, H. (2020). Simulation-Based Reinforcement Learning for Real-World Autonomous Driving. *IEEE International Conference on Robotics and Automation (ICRA)*, 6411-6418. <https://doi.org/10.1109/ICRA40945.2020.9196730>
- Pakgozar, A., Tabrizi, R. S., Khalili, M. & Esmaeili, A. (2011). The role of human factor in incidence and severity of road crashes based on the CART and LR regression: A data mining approach. *Procedia computer science*, 3(C), pp. 764-769. <https://doi.org/10.1016/j.procs.2010.12.126>
- Rosique F, Navarro PJ, Fernández C & Padilla A. (2019). A Systematic Review of Perception System and Simulators for Autonomous Vehicles Research. *Sensors*, 19(3). <https://doi.org/10.3390/s19030648>
- SAE International. (2021). *Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles* (SAE Standard J3016). Haettu osoitteesta https://doi.org/10.4271/J3016_202104
- Sajjad, M., Irfan, M., Muhammad, K., Ser, J. D., Sanchez-Medina, J., Andreev, S., . . . Lee, J. W. (2021). An Efficient and Scalable Simulation Model for Autonomous Vehicles With Economical Hardware. *IEEE transactions on intelligent transportation systems*, 22(3), 1718-1732. <https://doi.org/10.1109/TITS.2020.2980855>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Schoettle, B., & Sivak, M. (2014). A survey of public opinion about autonomous and self-driving vehicles in the US, the UK, and Australia. *University of Michigan, Ann Arbor, Transportation Research Institute*. Haettu osoitteesta <http://hdl.handle.net/2027.42/108384>
- Shah, S., Dey, D., Lovett, C. & Kapoor, A. (2018). Airsim: High-fidelity visual and physical simulation for autonomous vehicles. *Field and service robotics*, 5, 621-635. https://doi.org/10.1007/978-3-319-67361-5_40

- Stocco, A., Weiss, M., Calzana, M. & Tonella, P. (2020). Misbehaviour prediction for autonomous driving systems. *Proceedings of the ACM/IEEE 42nd International Conference on Software Engineering (ICSE '20)*. Association for Computing Machinery, New York, NY, USA, 359–371.
<https://doi.org/10.1145/3377811.3380353>
- Talebpour, A. & Mahmassani, H. S. (2016). Influence of connected and autonomous vehicles on traffic flow stability and throughput. *Transportation research. Part C, Emerging technologies*, 71, 143-163.
<https://doi.org/10.1016/j.trc.2016.07.007>
- Tesla. (2021). Tesla autopilot Haettu 20.5.2021 osoitteesta https://www.tesla.com/fi_FI/autopilot?redirect=no
- Tesla. (2020). Tesla Vehicle Safety Report. Haettu 14.2.2021 osoitteesta https://www.tesla.com/fi_FI/VehicleSafetyReport?redirect=no
- The New York Times. (2021, 18. toukokuuta). 2 Killed in Driverless Tesla Car Crash, Officials Say. Haettu 27.5.2021 osoitteesta <https://www.nytimes.com/2021/04/18/business/tesla-fatal-crash-texas.html>
- Thrun, S. (2010). Toward robotic cars. *Communications of the ACM*, 53(4), 99-106.
<https://doi.org/10.1145/1721654.1721679>
- US Department of Transportation. (2016). Federal Automated Vehicles Policy. Haettu 10.4.2021 osoitteesta <https://www.transportation.gov/sites/dot.gov/files/docs/AV%20policy%20guidance%20PDF.pdf>
- Wang, Z., Wu, Y. & Niu, Q. (2020). Multi-Sensor Fusion in Automated Driving: A Survey. *IEEE Access*, 8, 2847-2868.
<https://doi.org/10.1109/ACCESS.2019.2962554>
- WHO, World Health Organisation. (2020, 7. Tammikuuta). Road traffic injuries. Haettu 22.5.2021 osoitteesta <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- Yoganandhan, A., Subhash, S., Hebison Jothi, J. & Mohanavel, V. (2020). Fundamentals and development of self-driving cars. *Materials today: proceedings*, 33, 3303-3310. Haettu osoitteesta <https://doi.org/10.1016/j.matpr.2020.04.736>
- Zang, S., Ding, M., Smith, D., Tyler, P., Rakotoarivelo, T., Kaafar, M., A. (2019). The Impact of Adverse Weather Conditions on Autonomous Vehicles: How Rain, Snow, Fog, and Hail Affect the Performance of a Self-Driving Car. *IEEE Vehicular Technology Magazine*, 14(2), 103-111.
<https://doi.org/10.1109/MVT.2019.2892497>