

Autonomisten ajoneuvojen käyttöönotto Suomessa

Reija Pekkinen



Tekijä(t) Reija Pekkinen	
Koulutusohjelma Tietojenkäsittely	
Raportin/Opinnäytetyön nimi Autonomisten ajoneuvojen käyttöönotto Suomessa	Sivu- ja liitesivumäärä 27
<p>Tutkimus käy läpi itseajavien autojen kehitystyötä ja käyttöönoton haasteita Suomessa. Teoriaosuudessa keskitytään autonomisen ajoneuvon termistön määrittelyyn ja kehityshistoriaan ja pohditaan sitä kuinka itseajavat autot voivat muuttaa suomalaista liikennekulttuuria.</p> <p>Teknisessä osuudessa demonstroidaan datasetin keräämistä ja neuroverkon kouluttamista tietokonenäköä silmällä pitäen.</p>	
Asiasanat Tekoäly, autonomia, ajoneuvot, itseajavat autot	

Sisällys

1	Johdanto	1
2	Autonomisten ajoneuvojen kehityshistoria.....	3
2.1	Mikä on autonominen ajoneuvo?	3
2.2	Autonomian eri tasot	7
2.3	Autonomisten ajoneuvojen suunnittelu ja kehittäminen	8
2.4	DARPA -haaste.....	10
2.5	Kehitystyö Suomessa.....	11
3	Käyttöönottoon liittyvät haasteet.....	15
3.1	Sääolosuhteet ja liikenneinfrastruktuuri.....	15
3.2	Lakitekniset ja eettiset haasteet	16
3.3	Yleinen mielipide ja työllisyys	18
4	Tekninen demo	20
4.1	Demon kuvaus	20
4.1.1	Käytetyt teknologiat.....	21
4.2	Jetson Nanon käyttöönotto.....	22
4.2.1	Datasetin luominen ja kouluttaminen.....	23
4.2.2	Koodi.....	24
4.3	Demon tulokset ja kehittämiskohteet.....	25
5	Yhteenveto.....	26
	Lähteet	28

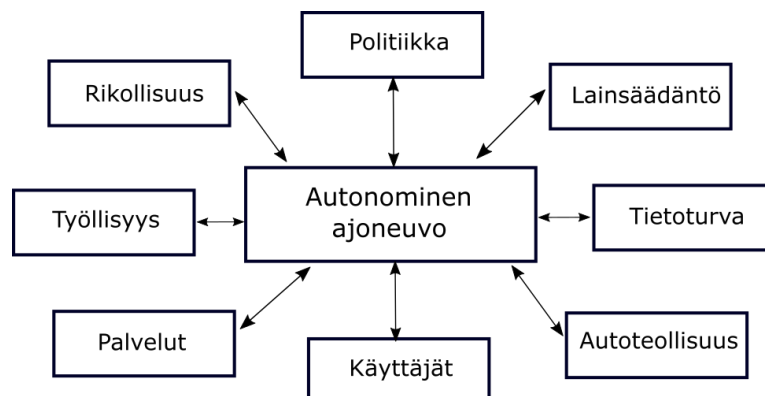
1 Johdanto

Kun ensimmäiset autot saapuivat Suomeen 1900-luvun alussa, kukaan tuskin osasi ennustaa että sadan vuoden kuluttua maahan olisi kehittynyt paitsi elinvoimainen autokulttuuri, tai että autoilu konseptina muistuttaisi jotain tieteiskirjallisuudesta. Tätä nykyä autoteollisuus kulkee käsi kädessä ICT-alan kanssa eikä ajatus autonomisten ajoneuvojen käyttöönotosta ole enää kaukainen haave.

Moderneissa autoissa on ominaisuuksia kuten vakionopeuden säädin, peruutuskamera joka varoittaa esteistä ja törmäysvaarasta ja lisäksi nykyään on saatavilla yhä enemmän automalleja, jotka kulkevat sähköllä. Nykyautot ovat kuin pyörillä kulkevia tietokoneita (Mikrobitti, 2019) ja autoteollisuuden kehittämien teknologioiden yhdistäminen on mahdollistanut ensimmäisten itseajavien autojen kehittämisen ja testaamisen.

Nyt kun autonomiset ajoneuvot eivät ole vain teoreettinen mahdollisuus, vaan osa nykyistä todellisuutta, on hyvä miettiä mitä tämä tarkoittaa Suomen näkökulmasta. Miten autonomiset ajoneuvot tullaan ottamaan käyttöön Suomessa ja mihin lainsäädännöllisiin, eettisiin ja logistisiin haasteisiin pitää löytää vastaukset ennen kuin näin voidaan tehdä?

Tässä tutkimuksessa pyrin vastaamaan näihin kysymyksiin ja antamaan lukijalle kontekstia siitä miten olemme saapuneet tähän pisteeseen. Olen jakanut työn kahteen osioon, teoriaan ja tekniseen demonstraatioon. Ensimmäisen osion tarkoituksena on antaa lukijalle lähtökohdat ymmärtää toisen osion teknisiä elementtejä. Lähden siitä oletuksesta, että tätä tekstiä tulevat lukemaan pääosin sellaiset henkilöt, joilla ei ole aikaisempaa tietoa tai kokemusta autonomisista ajoneuvoista, ja jotka eivät ole perehtyneet Suomessa tapahtuneeseen kehitystyöhön.



Kuva 1 – Sidosryhmämalli (Rouse, M. 2017)

Yllä olevan sidosryhmämallin pohjalta tulen tarkastelemaan teoriaosiossa autonomisten ajoneuvojen potentiaalisia vaikutuksia yhteiskunnassa. Tarkastelen miten tämän teknologian käyttöönotto tulee vaikuttamaan työllisyyteen, palveluihin ja liikennekulttuuriin. Pohdin myös mitä poliitikkojen tulee ottaa huomioon lainsäädännössä, jotta autonomiset ajoneuvot voidaan ottaa käyttöön turvallisesti ja kustannustehokkaasti.

Tulen käymään läpi autojen kehityshistoriaa, keskittyen teknologisiin innovaatioihin, jotka ovat mahdollistaneet autonomisten ajoneuvojen siirtymisen konseptitasolta oikeaksi tuotteeksi ja käyn läpi mahdollisia palvelumalleja, joita autoteollisuus voisi ottaa käyttöön siinä tilanteessa jossa autokulttuuri muuttuu omistajapohjaisesta kulttuurista palvelumallikulttuuriksi.


Teknisessä osiossa käyn läpi omaa prosessiani koneoppimisen ja tietokonenäön peruskonseptien opettelemisesta. Teknisen demonstraation ei ole tarkoitus olla ohjeistus tai opas vastaavan projektin toteuttamiseen, vaan auttaa lukijaa saamaan selkoa siitä mitä figuratiivisen konepellin alla tapahtuu kun neuroverkkoja koulutetaan.

2 Autonomisten ajoneuvojen kehityshistoria

Ennen kuin voimme aloittaa, on hyvä käydä läpi termit ja käsitteet. Tässä luvussa käyn läpi mitä tarkoitan autonomisilla ajoneuvoilla ja itseajavilla autoilla ja pyrin antamaan käytännön esimerkkejä näistä käsitteistä. Tulen käymään läpi teknologiat, joita autonomiset ajoneuvot hyödyntävät toimiakseen, sekä niiden kehityshistoriaa. Osa luvusta tulee keskittymään nimenomaisesti Suomessa tehtyyn tutkimustyöhön.

2.1 Mikä on autonominen ajoneuvo?

Tulen tässä tutkimuksessa käyttämään termejä autonominen kulkuneuvo, autonominen ajoneuvo ja itseajava auto. Termit autonominen ja itseajava voivat kontekstista riippuen olla keskenään vaihtokelpoiset.



Kuva 2: Termihierarkia (Terminologian sanasto, 2006)

Kuvassa 2 esitetty termihierarkia viittaa käsitteiden hierarkkiseen suhteeseen. Tässä kontekstissa kulkuneuvo on yläkäsite ja sen alakäsitteet ajoneuvo ja auto sisältävät kaikki kulkuneuvo-käsitteen piirteet, sekä vähintään yhden lisäpiirteen. Alakäsitteen voidaan siis ajatella olevan yläkäsitteen erikoistapaus. (Terminologian sanasto, 2006, 16)

Autonominen (tai itseajava) kulkuneuvo voi olla mikä tahansa kulkuneuvo joka kuljettaa matkustajia tai tavaroita paikasta toiseen. Autonominen kulkuneuvo voi siis olla juna, metro, droni tai trukki, tai mikä tahansa kulkuneuvo joka kykenee ohjautumaan itsenäisesti, mukautumaan ympäristössä tapahtuviin muutoksiin ja muuttamaan toimintatapaansa tilanteen vaatiessa.

Tällä hetkellä maailman laajuisesti autonomisia kulkuneuvoja esiintyy eniten junaliikenteessä. Junaliikenteen autonomian tasoja on neljä erilaista, joista Grade of

Automation 4 (GoA4) viittaa täysin itsenäisiin järjestelmiin, jotka eivät vaadi ihmiskuskia. GoA4 -järjestelmiä on käytössä muun muassa Kööpenhaminassa ja Sydneyssä, joissa osa tai Sydneyn tapauksessa koko metrojärjestelmä on automatisoitu.

Toisena mielenkiintoisena esimerkkinä, Japanissa toimii maailman ensimmäinen täysin autonominen yleisökäytössä oleva maglev-juna Linimo. Linimon teknologia perustuu magneettiseen levitaatioon ja se kulkee 8.9 kilometrin reittiä Japanin Nagoyassa. Se otettiin käyttöön vuonna maaliskuussa 2005 ja saman vuoden heinäkuussa jo 10 miljoonaa matkustajaa oli käyttänyt junaa. (Aichi Rapid Transit Co., 2016)



Kuva 3: Maglev-juna Linimo, Japani (Aichi Rapid Transit Co., 2016)

Kulkuneuvo toimii kaiken kattavana sateenvarjoterminä, jonka alle autonomiset ajoneuvot ja itseajavat autot kuuluvat. Ajoneuvo on terminä erikoistuneempi, ja sillä viitataan tiellä käytettäväksi tarkoitettua, pyörillä kulkevaa laitetta. (Tilastokeskus, 2020)

Tämä määritelmä tietenkin sisältää auton, mutta myös traktorit, moottoripyörät ja erilaiset moottorityökoneet, kuten kauhakuormaimet ja puominosturit. Myös joidenkin trukkien voisi argumentoida kuuluvan ajoneuvoihin, sillä ne ovat pyörillä kulkevia laitteita ja osassa trukeista on auton kaltaiset hallintalaitteet.

Toyota esitteli vuonna 2018 ensimmäisen itseajavan trukkinsa, joka pystyy itsenäisesti kuljettamaan ja lastaamaan paketteja. Kuvassa 4 näkyvän Trukin teknologia perustuu laser navigaatio-järjestelmään, eli se hyödyntää varastoon asennettuja lasereita

määrittääkseen sijaintinsa. Lisäksi trukissa on sensoreita, joiden avulla se varoo törmäämästä ohikulkijoihin. (Toyota Material Handling Australia, 2018)



Kuva 4: Toyotan itseajava trukki (Toyota Material Handling Australia, 2018)

Itseajavat autot kuuluvat autonomisiin ajoneuvoihin, mutta kaikki autonomiset ajoneuvot eivät ole autoja. Jotta kulkuneuvo, ajoneuvo tai auto voidaan todella määritellä autonomiseksi, sen tulee pystyä toimimaan ilman kuljettajan toimenpiteitä, tekemään itsenäisiä päätöksiä esimerkiksi reitin optimoimiseksi tai onnettomuuksien välttämiseksi, sekä määrittelemään oman tilansa, kullakin hetkellä.

Autonomisten ajoneuvojen kehityksessä on kokeiltu useita erilaisia teknologioita, mutta kaksi merkittävintä koulukuntaa, jotka todennäköisimmin johtavat kaupalliseen tuotteeseen ovat LiDAR (Light Detection and Ranging) ja tietokonenäkö. (Thakur 2016, 48-54)

LiDAR on valotutka, jonka toiminta perustuu kohteiden valaisemiseen ja skannaamiseen laservalolla ja tästä aiheutuvan heijastuksen mittaamiseen sensorilla. Sen perusteella kuinka nopeasti laservalo palautuu sensoriin, voidaan sitten luoda digitaalinen 3D-malli skannatuista kohteista. LiDARilla on monia käyttötarkoituksia myös autonomisen ajoneuvokehityksen ulkopuolelle, muun muassa arkeologisilla kaivauksilla ja maan mittauksessa. Sen avulla pystytään rakentamaan esimerkiksi topografisia karttoja ympäristöstä. (Thakur 2016, 48-54)

Autonomisten ajoneuvojen kehitystyössä LiDARia ovat käyttäneet esimerkiksi Google, sekä suomalainen VTT, joka on kehittänyt robottiauto Marttia. Valotutka-teknologia on kuitenkin saanut myös kritiikkiä osakseen. Teslan perustaja Elon Musk kommentoi LiDARIin keskittyvän kehitystyön olevan ”hölmöjen hommaa,” sillä lasersensorit ovat

kalliita ja näin ollen hankaloittavat kaupallisen tuotteen saattamista markkinoille. (Tesla, 2019)

Lisäksi lasersensorien toiminta perustuu valon etäisyyden mittaamiseen kohteen ja sensorin välillä, jonka vuoksi heijastavat pinnat kuten metalli ja lasi tai sateen kastelema asfaltti voivat aiheuttaa epätarkkoja mittaustuloksia.

Tesla on oman Tesla Autopilot -projektinsa kehityksessä keskittynyt tietokonenäköön, sillä perusteella että tällä teknologialla voidaan parhaiten simuloida ihmiskuljettajaa. Yhtiön tekoälyn ja Autopilot Visionin johtava kehittäjä Andrej Karpathy on sanonut, jotta todelliseen autonomiaan voidaan päästä, tulisi ajoneuvon pystyä näkemään ympäristönsä ja tulkitsemaan ympäristössä olevia esteitä ihmisen tavoin. (Tesla, 2019)

Kuvassa 5 on esimerkki Teslan kehittämästä Tesla Visionista, joka hyödyntää autoon asennettuja kameroita nähdäkseen ympäristönsä ja kerätäkseen dataa jota hyödynnetään neuroverkon kouluttamisessa. (Tesla, 2019)



Kuva 4: Tesla Vision (Tesla, 2019)

Ihmisenäköä voidaan simuloida opettamalla tietokone tunnistamaan esineitä kuvista ja videosta. Näyttämällä tietokoneella useita satoja ja tuhansia kuvia halutusta objektista eri kuvakulmissa, valaistuksissa ja eri taustoilla ja ohjaamalla tuloksia haluttuun suuntaan, voidaan rakentaa kattava neuroverkko, jota tietokone sitten hyödyntää kuvan tunnistuksessa. (Larochelle, Bengio, Louradour & Lamblin 2009, 15-21)

Neuroverkon kouluttamisen huono puoli on, että se vaatii todella suuren määrän dataa heti aloitusvaiheessa ja kouluttaminen on iteratiivista. Tämä tarkoittaa sitä että jokaisen koulutusvaiheen jälkeen neuroverkon oikeellisuutta testataan ja ohjataan kehittäjän haluamaan suuntaan sen perusteella millaisia tuloksia saadaan. Tämä tarkoittaa luonnollisesti sitä, että prosessi on hidas ja kaupalliseen versioon pääseminen vaatii paljon resursseja ja työtunteja. (Larochelle ym. 2009, 15-21)

Hollantilainen start up yritys Comma veisi Teslan neuroverkkoiden vielä askelen pidemmälle. Sen sijaan, että autossa olisi useita kameroita eri puolilla runkoa, jotka toimisivat auton silminä, Comma.ai tiivistäisi neuroverkkoteknologian älypuhelimeen. Yrityksen openpilot-ohjelma asennettaisiin puhelimeen, puhelin sijoitettaisiin auton tuulilasiin ja tällä tavoin käytännössä mistä tahansa modernista autosta voitaisiin tehdä autonominen ajoneuvo. (Hotz 2020)

Lisäksi yrityksen openpilot-projekti perustuu avoimeen lähdekoodiin, joten kuka tahansa innokas käyttäjä voi halutessaan muokata siitä itselleen parhaiten toimivan version. Tämä herättää kysymyksen autonomisten ajoneuvojen kehitystyön tulevaisuudesta. Sillä aikaa kun Googlen ja Teslan kaltaiset suuryritykset sijoittavat miljoonia itseajavien autojen kehitykseen, onko mahdollista että avoimeen lähdekoodiin perustuvat projektit yleistyvät ja antavat kuluttajille mahdollisuuden olla mukana kehitystyössä? (Hotz 2020)

2.2 Autonomian eri tasot

Tässä tutkimuksessa olen viitannut eri autonomian tasoihin, jotka käyn tässä vaiheessa läpi. Autonomian tasot on määritelty käyttäen Society of Automotive Engineers Internationalin kuusiportaista luokittelua. Tasot on jaettu numeraalisiin luokkiin nolasta viiteen. (Arola & Antikainen 2017, 3-10)

Taso 0 tarkoittaa, että ajoneuvossa ei ole automaatiota ja kuljettaja on vastuussa ja kontrollissa kaikista ajoneuvon toiminnoista. Tasot 1 ja 2 lisäävät automaatiota ja avustavia toimintoja ajoneuvoon, kuten vakionopeuden säätimen, mutta kuljettaja on kuitenkin vastuussa suurimmasta osasta ajotehtäviä. (Arola & Antikainen 2017, 3-10)

Tasolla 3 ajoneuvo kykenee monitoroimaan ajoympäristöä ja suoriutumaan joistakin tehtävistä itsenäisesti, mutta kuljettajalla on edelleen merkittävä rooli ajoneuvon ohjaamisessa.

Tason 4 automaatioissa, automaatiijärjestelmä kattaa kaikki ajotehtävien osa-alueet ja ajoneuvo kykenee toimimaan suurimmaksi osaksi täysin itsenäisesti. Ihmiskuljettaja voi kuitenkin halutessaan ottaa ajoneuvosta kontrollin, tilanteen sitä vaatiessa ja ajoneuvoa voi myös ohjata etänä. (Arola & Antikainen 2017, 3-10)

Taso 5 on täyden automaation taso, joka kattaa kaikki dynaamisen ajotehtävän osa-alueet tie -ja ympäristöolosuhteista piittaamatta ja mahdollistaa ajoneuvon täydellisen autonomian ja itsenäisen toimintakyvyn. (Arola & Antikainen 2017, 3-10)

2.3 Autonomisten ajoneuvojen suunnittelu ja kehittäminen

Kun Carl Benz keksi auton vuonna 1885, hän tuli tehneeksi historiaa toisellakin tavalla ajaessaan ensimmäisen kolarin päin seinää testiajon yhteydessä. Autojen kehitystyö on sadan vuoden aikana pyörinyt autoilun epäluotettavimman osan, kuljettajan ympärillä. Autoista on tehty kestävämpiä, niihin on lisätty turvavyöt ja viimeisen parin vuosikymmenen aikana autosta itsestään on yritetty kehittää älykkäämpi tuote. (Urmson, 2015)

Autoteollisuudessa on keskitytty pitkään turvallisuuteen, ilmatyynyistä vakionopeuden säätimiin. Tarkoituksena on ollut minimoida ihmiskuljettajan luomaa epävarmuutta ja luoda turvallinen tuote, siitä huolimatta että ihmiskuljettaja itsessään on riski. Esimerkiksi mukautuva keskinopeuden säädin on älykäs versio manuaalisesta keskinopeuden säätimestä. Sen ideana on, että kuljettaja voi säätää nopeuden jota ohjelma ei ylitä, paitsi tilanteissa jotka se havaitsee epäturvallisiksi jatkaa säädetyllä nopeudella, esimerkiksi ruuhkatilanteissa. (Hearst Autos Research, 2020)

Autojen kehittäminen älykkäämmiksi ei kuitenkaan poistaa kuljettajaa ja siksi autonomisten ajoneuvojen kehitystyössä tulisi keskittyä autonomian kehittämiseen projektin alusta lähtien, sen sijaan että odotetaan autojen jossain vaiheessa saavuttavan täysi autonomia, kunhan niistä kehitetään iteratiivisesti älykkäämpiä. Autonomian saavuttamisen tulee olla projektin keskiössä heti kättelyssä. (Urmson, 2015)

Tällä hetkellä 20-50 miljoonaa ihmistä loukkaantuu vuosittain auto-onnettomuuksissa ja 2.2% kaikista kuolemista aiheutuu liikenneonnettomuuksista. Nämä onnettomuudet johtuvat ihmisten, auton kuljettajien ja jalankulkijoiden tekemistä virheistä, jotka johtavat onnettomuustilanteisiin. Tietokonenäön ja neuroverkkojen avulla onnettomuuksia voitaisiin

vähentää. Tietokonenäkö voi havaita paitsi auton ulkopuolella tapahtuvia asioita, myös esimerkiksi kuljettajan väsymyksen ja huomiokyvyn tilaa. (Neuromation, 2018)

Edistykset tietokonenäössä ja neuroverkkoteknologiassa mahdollistavat sellaisten ajoneuvojen kehittämisen, jotka voivat koordinoitua toistensa kanssa, välttää törmäyksiä ja vähentää liikenneonnettomuuksia hyödyntämällä 'swarm intelligence' -teknologiaa. (The Innovation Enterprise, 2019)


Koska kuskittomien autojen täytyy kyetä välttämään törmäyksiä ja liikenteen ruuhkauttamista, niiden täytyy pystyä toimimaan, kommunikoidaan ja oppimaan kollektiivisesti, yksilöiden sijaan. Tutkijat ympäri maailmaa pitävät ruuhkien ehkäisemistä lupaavana, mikäli järjestelmiin otetaan mallia sosiaalisilta hyönteisiltä kuten muurahaisilta. Tätä kutsutaan kollektiiviseksi älykkyydeksi (swarm intelligence). (Interesting Engineering, 2017)

Jokaisen kollektiiviin kuuluvan jäsenen tulee olla perillä ympäristöstään ja omista toiminnoistaan. Pystyäkseen toimimaan itsenäisesti, on jokaisen jäsenen oltava autonominen ja vastuussa itsestään. Yhden tehtävän päättyessä onnistuneesti, jokaisen jäsenen tulee itsenäisesti etsiä uusi tehtävä. Kollektiivin täytyy pystyä saumattomasti integroimaan lisää jäseniä järjestelmään ja jäsenien poistuessa, järjestelmään tulee pystyä palautumaan ja mukautumaan tapahtuneisiin muutoksiin. (Interesting Engineering, 2017)

Kollektiivista älykkyyttä hyödyntäviä sovelluksia autonomisiin ajoneuvoihin voisivat olla esimerkiksi liikennevalojen vaihtumisesta ilmoittaminen takana tuleville autoille, jolloin nämä autot tietävät alkaa hidastamaan tai olla hidastamatta tilanteesta riippuen. (Interesting Engineering, 2017)

Tietokonenäön tavoitteena on tunnistaa objekteja ja luokitella niitä sekunnin murto-osaa pienemmässä ajassa. Sensori kaappaa kuvan, jonka jälkeen prosessori analysoi sen, vertaamalla kuvaa tietokannasta löytyviin esimerkkeihin. Kun järjestelmä löytää tarpeeksi hyvän yhteensopivuuden tietokannasta, se tekee päätöksen. Verrattuna ihmisaivoihin, tietokonenäköä hankaloittaa, ettei kone voi tunnistaa objekteja samalla tavalla kuin ihminen, sillä se saa datan numeraalisina arvoina, jotka edustavat kirkkautta, etäisyyttä jne. Koneen täytyy arvata mitä kuva edustaa ja tämän arvauksen oikeellisuus perustuu siihen kuinka hyvin neuroverkko on koulutettu. (Innovation Enterprise, 2019)

Kuvassa 5 on esitetty miltä tietokonenäkö konkreettisesti näyttää ajoneuvossa, joka hyödyntää LiDAR-sensoreita nähdäkseen oman ympäristönsä. (Urmson, 2015)



Kuva 5: Googlen itseajavan auton näkökenttä (Urmson, 2015)

On monia osa-alueita, joissa tietokonenäköä voidaan hyödyntää nykyautoissa, oli tavoitteena ajoneuvon täysi autonomia tai ei. Esimerkiksi peruutuskamerat, jotka hyödyntävät tietokonenäköä voivat varoittaa kuljettajaa mikäli auto on liian lähellä toista ajoneuvoa ja on muodostunut törmäysvaara.

Yksi autonomisten ajoneuvojen kehitystyön suurimmista haasteista on kehittää järjestelmiä ja neuroverkkoja, jotka ovat tietoturvallisia. (Forrest & Konca, 2007)

Euroopan alueella ajoneuvojen tulee noudattaa GDPR-lainsäädäntöä. Teoriassa tämä voi tarkoittaa sitä, että dataseteistä pitäisi poistaa tiettyjen henkilöiden kuvia ja tietoja, mikäli nämä eivät haluaisi tietojaan käytettävän itseajavien autojen kehitystyössä. Tämä on LiDARin vahvuus tietokonenäköön verrattuna, sillä valosensorien keräämä data ei ole yhtä tietorikasta kuin valokuvat tai video, jonka vuoksi yksittäisten henkilöiden tunnistaminen LiDAR-datasta ei ole niin yksioikoista.

2.4 DARPA -haaste

DARPA Grand Challenge on DARPA:n (Defence Advanced Research Projects Agency) järjestämä kilpailu amerikkalaisille autonomisille ajoneuvoille, jota rahoittaa Yhdysvaltain puolustusministeriö. Sen pitkäaikaistavoitteisiin kuuluu nopeuttaa itsenäisten ajoneuvojen kehitystyötä, jotta sovellusvalmiit autonomiset ajoneuvot voisivat ennen pitkää korvata ihmiskuljettajat vaarallisissa sotilasoperaatioissa, kuten kuljetussaattueissa. (DARPA, 2014)

Ensimmäinen DARPA-haaste järjestettiin vuonna 2004. Tuolloin haasteeseen osallistujien tavoitteena oli kehittää ajoneuvo, joka pystyi navigoimaan ja ajamaan 228 kilometrin matkan 10 tunnissa täysin itsenäisesti. Yksikään tiimi ei onnistuneesti suorittanut haastetta ja pisimmän matkan suorittanut ajoneuvo ajoi 12 kilometriä. (DARPA, 2014)

Vuonna 2005 järjestetty haaste Nevadassa oli parannus edelliseen. Haasteeseen osallistui 195 ajoneuvoa, joista viisi suoritti 212 kilometrin reitin onnistuneesti. Näistä viidestä nopein oli Stanfordin yliopiston ajoneuvo, Stanley. (DARPA, 2014)

Vuonna 2007 DARPA järjesti kaupunkihaasteen, jossa ajoneuvojen oli navigoitava itsenäisesti kaupunkisimulaatiossa. Haasteeseen kuului Kalifornian osavaltion liikennesääntöjen noudattaminen, esteiden ja kolarien välttäminen, sekä äkillisiin liikennemuutoksiin reagoiminen. Kuusi ryhmää yhdestätoista suoritti tämän simulaation onnistuneesti. (DARPA, 2014)

On vaikea sanoa kuinka paljon DARPA:n järjestämät haasteet edesauttoivat itsenäisten ajoneuvojärjestelmien kehitystyössä, mutta useat tiimit jotka kehittivät ajoneuvoja ja järjestelmiä näitä haasteita varten, kehittävät edelleen järjestelmiä Yhdysvaltain armeijalle, jonka tarpeet ovat ajaneet teknologista kehitystä eteenpäin. (DARPA, 2014)

Lisäksi nämä haasteet saivat paljon julkisuutta ja tämä mahdollisti erityisesti suuryritysten ja yliopistojen välistä yhteistyötä.

2.5 Kehitystyö Suomessa

Suomessa muuttuvat vuodenajat ja erityisesti talviset sääolosuhteet ovat mahdollistaneet ainutlaatuisia tilaisuuksia itseajavien ajoneuvojen kehitystyössä.

Suomen liikenne- ja viestintävirasto Traficom tukee tutkimustyötä muun muassa rahoituksen ja tieinfrastruktuurin hyödyntämisen kautta. Traficom antaa lupia ajoneuvotestaukseen lähes kaikille, jotka osoittavat kiinnostusta autonomisten ajoneuvojen kehittämiseen ja testaamiseen. Maanlaajuinen tieverkosto on vapaasti käytettävissä testaamiseen. (KPMG, 2019)

Traficomien tutkimus- ja kehittämistoiminnan pyrkimyksenä on liikennejärjestelmän turvallisuuden parantaminen, liikenteestä johtuvien ympäristöhaittojen vähentäminen ja viestinnän palvelujen sekä teknologioiden kehittäminen. Liikenneviraston

tutkimustoimintaan kuuluu myös erilaisten liikennelainsäädännön linjauksia tukevien selvitysten, kehittämishankkeiden ja lainsäädännön muutosten vaikutusarvioiden toteuttaminen. (Traficom, 2020)

Liikenneviraston käynnissä oleviin tutkimuksiin kuuluu esimerkiksi ITEM (IoT Traffic Environment Management), jonka tarkoituksena on selvittää älykkään liikenteen hallinnan datatarpeita, tietoturvaa sekä rajapintoja. Tätä tutkimusta toteutetaan yhteistyössä VTT:n kanssa, joka on toteuttanut robottiautot Martti ja Marilynin. (Traficom, 2020)

Martti on tutkimusajoneuvo, joka on kehitetty testaamaan autonomisen järjestelmän kykyä selviytyä hankalista sääolosuhteista, erityisesti lumesta ja jäästä. Se on kehitetty Volkswagen Touaregin alustalle ja varustettu lukuisilla kameroilla, sensoreilla ja laserskannereilla. Vuonna 2017 Martti onnistui ensimmäisenä automaattisena auton ajamaan täysin autonomisesti oikealla tiellä lumisissa keliolosuhteissa Muonion Aurora E8 -älytiellä. (Tekniikan Maailma, 2017)

VTT tutkii myös kuinka 5G-teknoologiaan perustuvilla ratkaisuilla ja palveluilla voitaisiin lisätä tielläliikkujiin turvallisuutta. 5G-verkon siirtonopeus mahdollistaa suurten 3D-näkymien välittämisen ajoneuvojen välillä, jonka ansiosta dataa saadaan alueilta joihin yksittäisen auton anturointi ei kanna. 5G-Safe-nimisen hankkeen ensimmäinen pilotointikohde oli juurikin robottiauto Martti, joka yhdistettiin 5G-verkkoon jotta se pystyi lähettämään keräämäänsä dataa muille verkossa oleville laitteille esimerkiksi tiellä olevista esteistä. (Ojanperä, 2018)

Siinä missä Martti on kehitetty erityisesti lumisia ja hankalia sääolosuhteita silmällä pitäen, sen puoliso Marilyn on kehitetty kaupunkiajo-skenaarioiden testaamiseen. Marilyn on osa Euroopan Komission tilaamaa Autopilot-projektia, jonka tarkoituksena on tutkia IoT:n (Internet of Things) potentiaalisia hyötyjä ajoneuvojen automaatioissa. Automaattisessa parkkeerausdemonstraatiossa Marilyn hyödyntää Ultra Wideband -paikannusteknoologiaa, jonka avulla se pystyy määrittelemään oman sijaintinsa, vapaan parkkipaikan sekä mahdolliset esteet. (Laitinen, 2018)



Kuva 6: Robottiautot Martti ja Marilyn (NDC Networks)

Kuvassa 6 näkyvät VTT:n robottiautot Martti ja Marilyn hyödyntävät muun muassa LiDAR-sensoreita, jotka ovat nähtävissä autojen katoilla. LiDAR-tekniikkaa hyödyntävät myös toisen suomalaisen kehittäjän Sensible 4:n projektit.

Sensible 4 on Helsingissä toimiva yritys, joka kehittää ohjelmistoja joka säässä toimiville autonomisille ajoneuvoille. Yritys perustettiin vuonna 2017 ja se on sen jälkeen tehnyt yhteistyötä muun muassa Mujin kanssa, kehittäessään itseajavan, jokaisessa sääolosuhteessa toimivan Gacha-bussin. (Sensible 4, 2019)

Autonomisten ajoneuvojen tulee pystyä määrittelemään oma sijaintinsa, sekä havaitsemaan esteitä, kuten jalankulkijoita. Sensible 4:n käyttämä paikannustekniikka hyödyntää laserskannereita, eli LiDARia. Laserien tekemän skannauksen perusteella saadaan 3D-malli ajoneuvon ympäristöstä. Katolle sijoitettujen laserskannerien avulla ajoneuvo voi nähdä ympärilleen niin pimeässä kuin päivänvalossa, mutta huono sää vaikuttaa tuloksiin. (Sauliala T, 17.6.2020)

Skannerin lähettämä säde ei kulje pitkälle sateessa tai sumussa. Sensible 4:n paikannustekniikka pyrkii korjaamaan laserskannerien heikkouksia, erilaisella lähestymistavalla. Sen sijaan että ympäristöä koko ajan mallinnettisiin uudelleen, tämä tekniikka luo siitä ennusteen, joka suoraviivaistaa prosessia merkittävästi. (Sauliala T, 17.6.2020)

Sensible 4:n ajoneuvojen itsenäinen ajaminen perustuu täsmälliseen kartoitukseen ja ennalta määritettyyn ajoreittiin. Ensin ihmiskuljettaja ajaa halutun reitin ja tämä reitti

tallennetaan 3D-malliksi sensorien avulla. Koska reitin ensikartoitukseen käytetään ihmiskuljettajaa, virheitä ja poikkeamia ei voida välttää. Kartoitettu reitti ei siis aluksi ole ihanteellinen, vaan tietokoneen täytyy korjata se. Tätä korjaavaa työtä kutsutaan korkean tason liikeran suunnitteluksi. Tietokoneelle annetaan kartoitettu reitti ja se laskee sille parannusehdotuksia. Tämä prosessi johtaa optimaaliseen liikerataan, jota autonominen ajoneuvo käyttää referenssinä ollessaan liikenteessä. (Sauliala T, 15.7.2020)



Kuva 7: Ajoneuvon kohteen tunnistus (Object Detection)
(Sensible 4, 2020)

Ajoneuvon ympäristön skannaamiseen käytetään pääasiallisesti kolmea sensorityyppiä, joista kohteen tunnistuksen kannalta tärkein on kamera. Kameroilla voidaan huomioda ja tunnistaa muita tien käyttäjiä käyttäen tietokonenäön neuroverkkoa, kuten kuvassa 7 on esitetty. Näihin kameroihin kuuluu sekä normaaleja näkyvää valoa hyödyntäviä kameroita, sekä lämpökameroita. Kamerat ovat nykyään todella halpoja ja kykenevät tarkkailemaan maastoa erittäin yksityiskohtaisesti. Niillä on kuitenkin ongelmia haastavissa valaistusolosuhteissa, kuten pimeydessä ja huonolla säällä. Kameran ja laserskannerin välinen yhteistyö mahdollistaa sen, että ne kompensoivat toistensa heikkouksia. (Sauliala T, 15.7.2020)

Kameran ja laserskannerin lisäksi Sensible 4 käyttää ajoneuvoissaan radiotaajuudella toimivia tutkia, jotka ovat ihanteellisia havaitsemaan kulkuneuvoja ja jalankulkijoita, sääolosuhteista huolimatta. Tutkan resoluutio ja kyky tunnistaa objekteja eivät kuitenkaan yllä kameroiden ja laserskannereiden tasolle. Yksikään sensori ei yksinään kykene tunnistamaan objekteja luotettavasti kaikissa olosuhteissa. Näinollen erilaisten sensorien täytyy työskennellä yhdessä parhaiden tulosten saavuttamiseksi. (Sauliala T, 15.7.2020)

Sensible 4 kehittää ajoneuvoautonomiaa Tason 4 automaatiolle. Tällä tasolla ajoneuvo kykenee suoriutumaan itsenäisesti liikenteessä ilman ihmiskuljettajan jatkuvaa valvontaa. Tason 4 automaatio ei kykene suoriutumaan kaikista erikoistilanteista, mutta se pystyy aina pysäyttämään ajoneuvon turvallisesti. Kuljettaja tai käyttäjä on toisessa sijainnissa ja voi tarvittaessa ottaa kontrollin ajoneuvosta. Esimerkiksi robottibussi voi toimia itsenäisesti, mutta etäkäyttäjä voi valvoa sen toimintaa ja tehdä päätöksen ottaa kontrollin ajoneuvosta tilanteen mukaan. (Sauliala T, 14.5.2020)

Traficom, VTT:n ja Sensible 4:n tekemä kehitystyö on vienyt Suomea merkittävästi eteenpäin ajoneuvojen ja liikenteen automaatiossa. Vuonna 2019 Autonomous Readiness Index sijoitti Suomen kuudennelle sijalle autonomisten ajoneuvojen käyttöönottovalmiudessa ja vuoden 2020 tilastossa Suomi oli nostanut sijoitustaan viidennelle sijalle. (KPMG, 2020)

3 Käyttöönottoon liittyvät haasteet

Tässä luvussa käyn läpi ainutlaatuisia haasteita, jotka liittyvät autonomisten ajoneuvojen käyttöönottoon Suomessa. Näihin kuuluvat sääolosuhteet, sekä liikenneinfrastruktuuri, byrokratia ja kuluttajien valmiudet hyväksyä itseajavat ajoneuvot osaksi olemassa olevaa autokulttuuria ja jopa nykyisten ajoneuvojen korvaajiksi.

3.1 Sääolosuhteet ja liikenneinfrastruktuuri

Suomen neljä vuodenaikaa, yksilöllisine sääolosuhteineen, tuovat luonnollisesti erityisiä haasteita autonomisten ajoneuvojen ja älykkään liikenneinfrastruktuurin kehitystyöhön ja käyttöönottoon. Aiemmin tässä tutkimuksessa mainitut VTT Research ja Sensible 4 ovat nimenomaan erikoistuneet tutkimaan ja kehittämään autonomisia liikenneratkaisuja, jotka toimivat säästä huolimatta.

Suomessa on laaja liikenneverkko ja merkittävin liikennekuormitus on raskaan liikenteen aiheuttamaa. Henkilöautojen aiheuttamat rasitukset teillä aiheutuvat lähinnä talvikäytössä olevista nastarenkaista. Kuljetuksissa on siirrytty käyttämään raskaampaa kalustoa ja ajoneuvojen keskimääräiset massat ovat kasvaneet. Raskaan liikenteen lisäksi ilmastokuormitus vaikuttaa tierverkon kuntoon. Lämpötilan muutokset, vesi ja routa vaikuttavat eri tavoin teiden rakennekerroksiin, heikentäen ennen pitkään niiden kuormituskestävyyttä. (Belt, Lämsä, Savolainen & Ehrola, 2002, 16-20)

Liikenneverkon ylläpitoon ja kehitystyöhön määrätty julkinen rahoitus on ollut riittämätöntä ja se on johtanut kasvavaan korjausvelkaan ja tieverkon laadun heikkenemiseen. Korjausvelka tarkoittaa sitä rahamäärää, jolla väylät saataisiin nykytarpeita vastaavaan kuntoon. (Liikenne- ja viestintäministeriö, 2017)

Kansainvälisessä vertailussa Suomen viestintäverkot sen sijaan ovat korkealaatuisia ja maantieteellisesti kattavia. Langattomat 4G-verkot ovat jo lähes koko väestön käytössä ja suurella osalla suomalaisista kotitalouksista on kiinteä laajakaista. Julkinen rahoitus on osittain mahdollistanut laajakaistaverkon rakentamisen myös haja-asutusalueilla, joihin yritykset eivät kannattavuussyistä ole rakentaneet verkkoa. (Aho, Lyly & Mero 2017, 11-17)

Autonomisten ajoneuvojen käyttöönotolla on suuria vaatimuksia liikenneinfrastruktuurille. Esimerkiksi tiemerkinntöjen, jotka osoittavat ajoradat, -kaistat ja suojatiet, täytyy olla oikeanlaiset, jotta itseajava ajoneuvo kykenee havaitsemaan ja tulkitsemaan niitä oikein. Suomi on sitoutunut maalaamaan kaikki keltaiset tiemerkinntät valkoisiksi, koska valkoinen väri on ihanteellisin itseajaville ajoneuvoille ja niiden kyvyille nähdä tiemerkinntät oikein. (KPMG, 2019)

Digitalisoituvan liikenteen vahvuuksiin kuuluvat muun muassa kuljetusten ja matkojen tehostuminen, liikenneturvallisuuden parantuminen, päästövähennykset ja liikkumisen tasa-arvoistumisen parempi toteutuminen. Lisäksi julkisen liikenteen reittejä on helpompi testata ja muokata reaaliaikaisen ja todennetun liikennedatan perusteella. (Aho, Lyly & Mero 2017, 11-17)

Ilmastonmuutos ja muut ympäristöön liittyvät haasteet, pakottavat löytämään uusia ratkaisuja ja muuttamaan vanhoja toimintatapoja. Liikenteen tuottamat kasvihuonepäästöt Suomessa olivat vuonna 2015 noin 11 miljoonaa tonnia. Yli 90% Suomen liikenteen päästöistä syntyy tieliikenteessä. Tämän vuoksi liikennejärjestelmien ja ajoneuvojen energiatehokkuutta on parannettava, esimerkiksi joukkoliikenteen rahoituksella ja korvaamalla fossiilisia polttoaineita uusiutuvilla ja vähäpäästöisillä polttoaineilla ja käyttövoimilla, kuten sähköllä. (Aho, Lyly & Mero 2017, 11-17)

3.2 Lakitekniset ja eettiset haasteet

Tieliikenteen sääntely perustuu kansainvälisesti Geneven 1949 ja Wienin 1968 tieliikennesopimuksiin, joissa Suomi on yhtenä osapuolena. Kansallinen sääntely perustuu

pääasiallisesti Wienin sopimukseen ja sitä täydentävään Euroopan sopimukseen, koska ne ovat yhdessä kattavampia kuin Geneven sopimus. (Arola & Antikainen, 2017, 3-10)

Suomen tieliikennelaki ja sen sääntely mahdollistavat autonomisen ajamisen, sillä laki ei erikseen määrittele, että kuljettajan täytyisi olla ajoneuvon sisällä. Tästä syystä Suomen laki mahdollistaa jo autonomisten ajoneuvojen testaamisen julkisilla teillä. Kuljettajan tulee kuitenkin kyetä puuttumaan ajoneuvon toimintaan ja tarvittaessa pysäyttämään se. (Arola & Antikainen, 2017, 3-10)

Suomen hallitus on saanut joustavan ja tehokkaan maineen päättäessään uudesta tieliikennelainsäädännöstä ja julkisen tieverkon avaamisesta tutkimus- ja testauskäyttöön. Suomi ajaa tällä hetkellä muutoksia Euroopan Unionin lainsäädäntöön, jossa maininnat 'kuljettajista' voisivat potentiaalisesti estää itseajavien ajoneuvojen käytön. (KPMG, 2020)

Suomen liikenne- ja viestintäministeriön toiminta keskittyy erityisesti kansainväliseen vaikuttamiseen, lainsäädännön sallivuuden varmistamiseen, sekä tukipalvelujen ja kokeilujen mahdollistamiseen. Ministeriön ja sen sidosryhmien tavoitteena on edistää robotiikkaa ja automaatiota ripeästi, jotta mahdollisiin säädösongelmiin löydetään nopeasti ratkaisuja. (Arola & Antikainen, 2017, 3-10)

Lakitekniisten haasteiden lisäksi Suomen hallituksella, ja monella muullakin hallituksella on edessään paljon eettisiä kysymyksiä, joihin täytyy löytää ratkaisut ennen autonomisten ajoneuvojen laajamittaista käyttöönottoa. Tietoturvaan liittyvä lainsäädäntö tulee saada ajantasaiseksi, jotta se ottaa huomioon autojen tulevaisuudessa keskenään jakaman datan liikkumisen ja mahdolliset väärin käytökset. (Forrest & Konca, 2007)

Tulevaisuuden liikennearkkitehtuurin toimintaympäristö tulee olemaan enenevässä määrin digitaalinen ja automatisoitu. Sen tulee myös vastata kriittisiin ympäristökysymyksiin ja olla lisäämättä ekologista kuormitusta. Tämän toimintaympäristön kehittäminen ja ylläpito vaativat erikoisosaamista, jota Suomen valtio voi tukea lisäämällä koulutuksen ja tutkimustyön rahoitusta. (Aho, Lyly & Mero 2017, 31-34)

Liikenteen infrastruktuurin kehittämiseen täytyy luoda uusia toimintatapoja, jotta perusinfrastruktuurin kehitys ja ylläpito pysyvät muuttuvan ja uudistuvan teknologian tahdissa. Esimerkiksi uudet rahoitusmallit, jotka hyödyntävät sekä julkista että yksityistä rahoitusta liikenneverkon uudistusten toteuttamiseen ovat varteenotettavia kohteita valtiolliselle sääntelylle. (Aho, Lyly & Mero 2017, 31-34)

Nykyinen liikenteen hinnoittelu ja verotus, esimerkiksi autoveron ja polttoaineveron muodossa perustuvat hiilidioksidipäästöihin. Verotuksen uudistuksia pohtiessa tulisi ottaa huomioon ympäristövaatimukset, liikennemuotojen yhteistyön kannustaminen sekä mukautuvuus palvelujen kysynnän muutoksiin. (Aho, Lyly & Mero 2017, 31-34)

3.3 Yleinen mielipide ja työllisyys

Autonomous Vehicle Readiness Index, joka mittaa eri valtioiden valmiuksia autonomisten ajoneuvojen käyttöönotolle antoi Suomelle hyvät pisteet sekä lainsäädäntöön, että kuluttajien mielipidettä mittaavissa kategorioissa. Vertailussa Suomi ylsi viidennelle sijalle maavertailussa kun arvioitiin kuluttajien asenteita autonomisia ajoneuvoja kohtaan. Suomalaiset ovat nopeita omaksumaan viimeisimpiä markkinoilla saatavilla olevia teknologioita, joka voi mahdollistaa myös avoimen asenteen itseajavien ajoneuvojen käyttöön tulevaisuudessa. (KPMG, 2019)

Luottamus autonomisten ajoneuvojen toimintaan yleisessä liikenteessä ei kuitenkaan ole aivan niin yksioikoista. Tuisku-Tuuli Salosen tekemässä pro gradu-tutkielmassa käydään läpi ammattikuljettajien, kuten taksin kuljettajien, mielipiteitä robottiautoista sana-assosiaatioiden avulla. Muun muassa tekniikan toimivuus, uhka turvallisuudelle sekä moraal- ja vastuukysymykset olivat tutkimuksessa pohdittuja kategorioita. Esimerkiksi tekniikan toimivuuteen liittyi skeptisyyttä ja useat ammattikuljettajat vertasivat omia kokemuksiaan hankalissa keliolosuhteissa, itseajavien ajoneuvojen mahdollisiin vaikeuksiin selviytyä vastaavissa tilanteissa. (Salonen 2019, 40-51)

Autonomiset ajoneuvot assosioitiin tietokoneiden kanssa, sillä toimimattomuutta luonnehdittiin esimerkiksi termein ”kaatuminen” ja ”bugi”. Tutkimukseen vastanneet heijastivat itseajavat autot raideliikenteeseen, jota ei ole vielä saatu Suomessa automatisoitua. Kuitenkin itseajavat ajoneuvot herättivät myös assosiaatioita turvallisuudesta ja liikenneturvallisuuden paranemisesta, sekä onnettomuuksien vähentymisestä. Ennakkoluulot tuntuvat näin ollen liittyvän enemmän ajoneuvojen yleiseen toimivuuteen ja käyttöönoton haasteisiin, kuin siihen kuinka turvallisia ne olisivat liikenteessä. (Salonen 2019, 40-51)

Osa ammattikuljettajien skeptisyydestä autonomisiin ajoneuvoihin liittyen, voi johtua potentiaalisesta vaarasta heidän ammattikunnalleen. Koska ajoneuvojen autonomia ja automaatio käytännössä poistaisivat ihmiskuljettajan tarpeen, voi niiden käyttöönotto aiheuttaa merkittäviä irtisanomisia. (Forrest & Konca, 2007)

Kaupunkien ja valtioiden tekemät säästöt olisivat mittavat kun, mutta työntekijöiden näkökulmasta tämä olisi suuri menetys, erityisesti jos he eivät kykenisi heti työllistymään uudelle alalle. Siksi itseajavien ajoneuvojen käyttöönotosta aiheutuvasta ihmishinnasta täytyy käydä keskustelua ja miettiä mitä automaation takia hyödyttömiksi käyneille työntekijöille tapahtuu. (Forrest & Konca, 2007)

Suomen ikääntyvä väestö aiheuttaa myös haasteita autonomisten ajoneuvojen ja uusien liikennejärjestelmien käyttöönotossa. Väestöennusteen mukaan 65-vuotiaiden suomalaisten osuus väestöstä tulee olemaan 2030-luvulla 26%. Terveys- ja sosiaalipalvelujen tarjonnan kysyntä tulee kasvamaan ja huoltosuhte heikkenemään. Ikääntyvä väestö tulee ottaa huomioon suunniteltaessa esimerkiksi ovelta ovelle liikkumispalveluita. (Arola & Antikainen, 2017, 3-10)

Itseajavat ajoneuvot voivat tuoda mukanaan uusia palvelumalleja, joiden myötä ajoneuvojen omistaminen vähenee. Ilmastonmuutoksen ja muiden eettisten kysymysten vuoksi kuluttajien arvomaailmassa ja asenteissa tapahtuu muutoksia, jotka heijastuvat myös liikenteeseen ja logistiikkaan. Tulevaisuuden liikenteen käyttäjille ajoneuvon omistaminen tai ajokortin hankkiminen ei välttämättä tule olemaan samanlainen virstanpylväs, jona sitä pidetään tällä hetkellä. (Aho, Lyly & Mero 2017, 31-34)

Esimerkiksi itseajavien autojen leasing-palvelut ja automaattitaksipalvelut poistaisivat tai ainakin vähentäisivät auton omistamisen tarvetta, mahdollistaen kuitenkin kuluttajille halutessaan auton käytön. Lisäksi julkiseen liikenteeseen investoiminen ja autonomisten bussien käyttöönotto mahdollistaisi vuorovälien pienentämisen ja lisäisi julkisen liikenteen käyttökapasiteettia. (Forrest & Konca, 2007)

4 Tekninen demo

Tässä luvussa käsittelen teknistä demonstraatiota, jonka avulla pyrin paremmin ymmärtämään autonomisten ajoneuvojen kehitystyössä käytettäviä teknologioita, sekä tutkimaan avoimeen lähdekoodiin ja yhteisölliseen toimintaan perustuvia tapoja tehdä kehitystyötä. Tarkoitukseni oli luoda yksinkertainen tekninen demo, maksimissaan 100€ budjetilla ja hyödyntäen mahdollisimman paljon omasta takaa löytyviä resursseja.

4.1 Demon kuvaus

Jotta autonominen ajoneuvo kykenee toimimaan itsenäisesti liikenteen seassa, sen tulee kyetä tunnistamaan ja erottamaan liikkuvat objektit liikkumattomista, jalankulkijat autoista, sekä tunnistaa ja erottaa erilaiset liikennemerkit toisistaan. Sen tulee olla pystyä tekemään liikennelainsäädännön mukaisia päätöksiä, sekä reagoida oikein yllättävissä tilanteissa, kuten jalankulkijan syöksyessä tielle paikassa, jossa ei ole liikennevaloja tai suojatietä. Ja tämä on vain jäävuoren huippu kaikista niistä ominaisuuksista joita autonomisen ajoneuvon koodin tulee sisältää.

Yksittäisten tutkimusajoneuvojen, kuten VTT Researchin Martin ja DARPA Grand Challenge osallistujien, kehittämiseen vaadittiin kokonainen tiimi. Näin ollen tiesin, että pystyväkseni luomaan tämän tutkimuksen rajoihin soveltuvan demonstraation, minun tuli tehdä radikaaleja rajoituksia sen sisällön suhteen. Liikenteen käyttäjät, jalankulkijoista auton kuljettajiin, ovat tietoisia liikennemerkeistä ja niiden tulkinnasta, joten päätin rajata demoni liikennemerkkien tunnistamiseen. Liikennemerkeissä on kuitenkin suuria eroja, nopeusrajoituksista erilaisiin varoituksiin, sekä etuajo-oikeus ja väistämismerkkeihin.




Kuva 8: Liikennemerkkien eroavaisuuksia (Väylävirasto, 2020)

Kuvassa 8 on esitetty erilaisia liikennemerkkejä, jotka ovat tällä hetkellä käytössä Suomen maanteilla, ja joista jokainen merkitsee eri asiaa. Jotta tietokone voi tunnistaa erilaiset liikennemerkit toisistaan, jokainen merkki tarvitsee luokituksen, tai nimikkeen. Jokaisella nimikkeellä on oma kokoelma kuvamateriaalia, jonka pohjalta neuroverkkoa koulutetaan tunnistamaan liikennemerkkejä toisistaan. Koulutusmateriaalin tulee sisältää kuvia eri

valaistus- ja sääolosuhteista, eri kuvakulmista, sekä eri kuntoisista liikennemerkkeistä. Autonomisen ajoneuvon tulee kyetä tunnistamaan kuluneempi liikennemerkki uudesta ja mahdollisesti lähettää oikeellista tietoa liikennemerkkien sen hetkisestä kunnosta. (Hienonen 2014, 15)

Päätin rajata teknisen demonstraationi nimenomaan nopeusrajoituksia esittäviin liikennemerkkeihin. Tämä tarkoitti käytännössä sitä, että minulla oli vain pieni määrä liikennemerkkejä, joista kerätä koulutusmateriaalia ja joiden pohjalta kouluttaa neuroverkko. Tämä suoraviivaisti ja yksinkertaisti prosessia ja pystyin keskittymään kuvan- ja objektin tunnistukseen liittyviin teknologioihin tutustumiseen.

Kun olin päättänyt demon rajauksesta, oli aika päättää mitä ja miten se tulisi demonstroimaan. Halusin kokeilla pystyisinkö kouluttamaan neuroverkon, joka tunnistaisi sille esitetyt nopeusrajoitukset toisistaan. Halusin että se pystyisi tunnistamaan sille esitetyt nopeusrajoitukset sekä valokuvista, että reaaliaikaisesta videokuvasta ja ilmoittamaan minkä rajoituksen se kulloinkin näkee ruudulla.



Kuva 9: Kuvattuna teknisen demon toimintaperiaate

Kuvassa 9 on esitetty graafisesti miten demon on tarkoitus toimia. Kamera näkee liikennemerkkin ja lähettää neuroverkolle signaalin havainnosta. Neuroverkko tekee vertailua siitä sopiiko tämä havainto yhteen minkään sen sisältämän luokituksen kanssa. Mikäli se löytää yhteensopivuuden, neuroverkko lähettää viestin tekemästään tulkinnasta. Mikäli yhteensopivuutta ei löydy, se tekee virheilmoituksen.

4.1.1 Käytetyt teknologiat

Demon toteuttamiseen halusin käyttää laitteistoa, joka olisi paitsi edullinen ja helposti saatavilla, myös kattavasti dokumentoitu. Tulin valinneeksi Nvidian Jetson Nanon, sillä se on suunniteltu tekoälyn kehittämiseen ja koulutukseen. Se pystyy suorittamaan useita neuroverkkoja rinnakkain esimerkiksi kuvien luokittelu-, kohteen tunnistus -, ja

puheen käsittelyyn tarkoitettuja sovelluksia varten. Lisäksi se on pienikokoinen ja pystyy ottamaan virtaa varavirtalähteestä, mikä mahdollistaa liikkuvan testausalustan luomisen. (Nvidia, 2020)

Käyttöjärjestelmänään Jetson Nano hyödyntää Ubuntuä, joka asennetaan imagena microSD-kortille. Samaa laitetta voi siis hyödyntää useamman eri projektin laitteistona samanaikaisesti, sillä käyttöjärjestelmä ja muut tiedostot asennetaan ulkoiseen muistiin.

Nvidia on henkilökohtaisesti tarjonnut Jetson Nanon käyttäjille paljon ilmaisia resursseja, dokumentaatiota ja esimerkkiprojekteja, joista hakea tietoa ja inspiaraatiota henkilökohtaisiin projekteihin. Dokumentaation ja tutoriaalien määrä oli myös yksi merkittävimmistä syistä, miksi päädyin valitsemaan Jetson Nanon testialustakseni.

Ennen kuin aloin toteuttamaan demoani, tutustuin muun muassa projektiin jonka tarkoituksena oli tunnistaa auton kuljettajan emotionaalista- ja väsymyksen tilaa, hyödyntäen kasvojen tunnistusta. Tämä antoi realistisen kuvan siitä mitä kaikkea tällä laitteistolla voi ylipäänsä tehdä. (Nvidia, 2020)

4.2 Jetson Nanon käyttöönotto

Jetson Nanon käyttöönotto oli todella helppoa. Ensin loin muistikortille imagen käyttöjärjestelmästä käyttäen Etcher-ohjelmaa. Tämän jälkeen muistikortti oli valmis ja minun tarvitsi vain luoda käyttäjä.

Koska Jetson Nano voi ottaa virtaa 5 voltin Micro-USB-portista tai vaihtoehtoisesti suoravirtalähteestä, on se varustettu kahdella virtaprofiililla, Mode 0 (10 wattia) ja Mode 1 (5 wattia). Mode 0 on käytössä automaattisesti, kun käynnistät koneen ensi kertaa. (JetsonHacks, 2019)

Koska käytin micro-USB-porttia, huomasin nopeasti ettei se pystynyt ottamaan sisään niin paljon virtaa kuin Mode 0 vaati. Tästä syystä Nanosta katkesi usein virta kesken datasetin koulutuksen, ennen kuin keksin mistä ongelma johtui.

Virtaprofiilin vaihtaminen onnistui komennolla: `$ sudo nvpmode1 -m 1` .

4.2.1 Datasetin luominen ja kouluttaminen

Datasetin kouluttamiseen hyödynsin transfer learning -tekniikkaa, joka on koneoppimisessa keskeinen tutkimuskysymys. Sen tarkoituksena on soveltaa ongelman ratkaisemiseen tuloksia, jotka ovat syntyneet jonkin toisen, vastaavan ongelman ratkaisemisesta.

Tämä tarkoittaa sitä, että koulutuksen aikana tietokone hyödyntää jo olemassaolevaa neuroverkkoa ja sen sisältämää dataa luodakseen uuden neuroverkon nopeammin ja tehokkaammin. Koska halusin tietokoneen pystyvän tunnistamaan liikennemerkkejä, datasettini sisälsi lukuisia kuvia liikennemerkeistä. Koulutuksen aikana tietokone etsi samankaltaisuuksia pohjana käytettävän datasetin ja verrokkina olleen neuroverkon väliltä. (Lu, Behbood, Hao, Zuo, Xue & Zhang 2015)

Ohjelmistokehys jota hyödynsin demon toteuttamisessa oli PyTorch. Lisäksi sovelsin Dustin Franklinin luomia esimerkkejä neuroverkon kouluttamisessa.



Kuva 10: Datasetin luomiseen käytettyä materiaalia

Luodessani datasettiä, hyödynsin luonnossa ottamiani valokuvia liikennemerkeistä, valokuvia kuvapankeista, sekä kuvia tekemistäni liikennemerkkipienoismalleista saadakseni mahdollisimman suuren määrän kuvia eri taustoilla ja valaistusolosuhteilla, joista esimerkki näkyy kuvassa 10.

LABEL	TRAIN	VAL	TEST
SPEED LIMIT 40	100	30	35
SPEED LIMIT 50	110	30	20
SPEED LIMIT 60	100	30	35
SPEED LIMIT 80	100	30	35
SPEED LIMIT 100	100	30	35

Taulukko 1: Kuvien luokitukset ja määrät

Taulukossa 1 näkyy miten luokittelin kuvat viiden nimikkeen alle ja kuinka monta kuvaa kukin koulutuslaskentakategoria sisältää. Suositeltavaa on, että koulutukseen käytettäviä kuvia on vähintään 100 kappaletta, per nimike ja validaatioon käytettäviä kuvia noin 10-20% koulutuslaskentakategorioista. Testisetin määrä perustuu siihen kuinka montaa staattista kuvaa vastaan neuroverkkoa halutaan testata. (Franklin 2020)

4.2.2 Koodi

Kuvassa 11 näkyvä koodi on python-ohjelma, joka on mukailtu Dustin Franklinin alkuperäisestä esimerkkikoodista, jonka hän kirjoitti osana Jetson Nano -tutoriaalisarjaa. Ohjelma käynnistää imageNetin ja hakee halutun neuroverkon ja nimiketiedoston niille osoitetuista kansioista. ImageNetin ollessa käynnissä, määritelty webkamera menee

```
import jetson.inference
import jetson.utils
import cv2
import numpy as np
import time
width=1280
height=720
dispW=width
dispH=height
flip=0
#camDev='nvguacamerasz0 ! video/x-raw(memory:NVMM), width=3264, height=2464, format=NV12, framerate=21/1 ! nvvidconv flip-method='+str(flip)+' ! video/x-raw, width='+str(dispW)+' , height='+str(dispH)+' ! v4l2sink device=/dev/video0'
#caml=cv2.VideoCapture(camDev)
caml=cv2.VideoCapture('/dev/video0')
#caml.set(cv2.CAP_PROP_FRAME_WIDTH,dispW)
#caml.set(cv2.CAP_PROP_FRAME_HEIGHT,dispH)
net=jetson.inference.ImageNet('alexnet', ['--model=/jetson-inference/python/training/classification/models/speed_Limit/resnet18.onnx', '--input_blob=input_0', '--output_blob=output_0', '--font=cv2.FONT_HERSHEY_SIMPLEX
timeMark=time.time()
fpsFilter=0
while True:
    _, frame=caml.read()
    img=cv2.cvtColor(frame, cv2.COLOR_BGR2RGB).astype(np.float32)
    img=jetson.utils.cudaFromNumpy(img)
    classID, confidence =net.Classify(img, width, height)
    item=' '
    item =net.GetClassDesc(classID)
    dt=time.time()-timeMark
    fps=1/dt
    fpsFilter=.95*fpsFilter +.05*fps
    timeMark=time.time()
    cv2.putText(frame, str(round(fpsFilter,1))+ ' fps '+item, (0,30), font, 1, (0,0,255), 2)
    cv2.imshow('seeCam', frame)
    cv2.moveWindow('seeCam', 0, 0)
    if cv2.waitKey(1) &ord('q'):
        break
cam.release()
cv2.destroyAllWindows()
```

Kuva 11: Mukailtu Dustin Franklinin esimerkkikoodista

päälle ja avaa ikkunan näkemästään ympäristöstä. Webkameralle voi näyttää objekteja, tässä tapauksessa liikennemerkkejä ja neuroverkko tulkitsee imageNetin kautta mikä nimike näkymässä on ja näyttää näkymässä nimiketekstin ja kuvataajuuden. (Franklin 2020)

```
WARNING: ONNX model has a newer ir_version (0.0.4) than this parser was built against (0.0.3).
While parsing node number 0 [Conv -> "l23"]:
```

```
ERROR: ModelImporter.cpp:296 In function importModel:
[5] Assertion failed: tensors.count(input_name)
[ERR] failed to parse ONNX model '/home/peippo/jetson-inference/python/training/classification/models/speed_Limit/resnet18.onnx'
[ERR] device GPU, failed to load /home/peippo/jetson-inference/python/training/classification/models/speed_Limit/resnet18.onnx
[ERR] failed to load /home/peippo/jetson-inference/python/training/classification/models/speed_Limit/resnet18.onnx
[ERR] imageNet -- failed to initialize.
jetson.inference -- imageNet failed to load built-in network 'alexnet'
Traceback (most recent call last):
```

Kuva 12: Onnx virheilmoitukset

Ajaessani ohjelman ensimmäistä kertaa, törmäsin kuvassa 12 näkyviin virheilmoituksiin. ONNX (Open Neural Network Exchange) on avoimeen lähdekoodiin perustuva

tiedostoformaatti, jonka tarkoituksena on mahdollistaa yhteensopivuus useiden eri työkalujen välillä. PyTorchin avulla luotu neuroverkko täytyi muuttaa onnx-formaattiin, jotta python-ohjelmani kykeni ymmärtämään sitä. Ohjelmaa ajettaessa tietokone antoi virheilmoituksen eikä ajanut ohjelmaa loppuun.

Lähdin hakemaan tietoa siitä mistä tämä yhteensopivuusongelma johtuu ja havaitsin ettei versioni käyttöjärjestelmästä tue onnx-versiota, joka minulla oli käytössä. Lisäksi käytössä oleva erillinen TensorRT -plugin aiheutti ongelmia, sillä sen hetkisessä asennuksessa ollut versio oli poistettu käytöstä. Asensin uuden version ONNX ja TensorRT:stä ja exporttasin uuden onnx-mallin, jonka jälkeen ongelma poistui ja pystyin ajamaan koodin. (Nvidia Developer Forums, 2020)

Kun ohjelma oli ajettu onnistuneesti, pystyin näyttämään kameralle vuorotellen tekemiäni liikennemerkkimalleja ja katsomaan kuinka nimiketeksti muuttui sen mukaan mikä liikennemerkki oli kameralle näkyvissä.

4.3 Demon tulokset ja kehittämiskohteet

Vaikka lopulta sain demon toteutettua, se oli odotettua hankalampaa. Alunperin olisin halunnut että kun tietokone tulkitsee kuvaa ja tunnistaa sen, olisi nimikkeen vieressä näkynyt prosenttiluku, joka osoittaisi kuinka suurella varmuudella neuroverkko ajattelee kuvan olevan esimerkiksi "Speed Limit 100."

Lisäksi halusin kirjoittaa ohjelman, joka asettaisi numeraaliset arvot jokaiselle datasetin nimikkeelle ja tallentaisi tietokoneen tunnistamaa kuvaa vastaavan arvon arrayhin. Aina kun tietokoneelle esittäisi uutta kuvaa, se vertaisi nimikkeen numeraalista arvoa siihen numeroon joka olisi tallennettu arrayhin ja tekisi päätelmän onko arvo suurempi vai pienempi. Sen jälkeen se ilmoittaisi tuleeko nopeutta lisätä vai pudottaa.

Yhteensopivuusongelmien selvittämiseen kuluneen ajan vuoksi päätin lopulta karsia demon ominaisuuksia ja tyytyä siihen että tietokone tunnistaisi että kuvassa on nimikkeen mukainen liikennemerkki.

Halusin oppia mitä neuroverkon kouluttamiseen vaaditaan ja miten tietokonenäkö toimii käytännössä, ja sain tämän demon myötä kokemusta vaikka se ei saavuttanutkaan niitä tuloksia mihin alunperin pyrin. Lähdin toteuttamaan demoa ilman aikaisempaa kokemusta Jetson Nanosta, transfer learningista ja PyTorch-ohjelmistokehyksestä, joten oppimiskokemuksena sain projektista paljon irti.

5 Yhteenveto

Tämän tutkimuksen tekeminen oli itselleni merkittävä oppimuskokemus. Olin kiinnostunut selvittämään miltä autonomisten ajoneuvojen kehitystyö näyttää Suomessa, sillä kaikki aiheeseen liittyvät artikkelit joita olin lukenut olivat hyvin keskittyneitä Yhdysvaltoihin ja keski-Eurooppaan. Koin että Suomen haastavat sääolosuhteet, vaihtelevat vuodenaajat ja kovan kuormituksen alla oleva tieverkosto, sekä haja-asutus ja ikääntyvä väestö loivat uniiikkeja haasteita uusien teknologioiden ja sitä kautta myös itseajavien autojen käyttöönotolle.

Tiesin että Suomessa on tehty autonomisiin ajoneuvoihin liittyvää tutkimusta ja olin lukenut VTT Researchin robottiauto Martista, mutta en aikaisemmin tiennyt Sensible 4:n tekemästä kehitystyöstä tai yhteistyöstä Mujin kanssa. Nämä olivat erittäin avartavia havaintoja.

Autonomiset ajoneuvot ovat tulossa ennen pitkää laajaan käyttöön, mutta kysymys kuuluu tulevatko ne olemaan täysin autonomisia, vai tekevätkö autojen valmistajat kompromisseja ja tyytyvät tason 4 automaatioon, jossa ihmiskuljettaja voi edelleen halutessaan ottaa kontrollin autosta.

Mielestäni tämä on todennäköistä erityisesti Suomen kaltaisessa valtiossa, jossa asutuksen keskittyminen muutamiin suurempiin kaupunkeihin ja maaseudun haja-asutus aiheuttavat sen ettei liikenneinfrastruktuurin kehitys ole täysin tasalaatuista koko maassa.

Autonomiset ajoneuvot vaativat latauspaikkoja ja kattavaa verkkoa pystyäkseen kommunikoimaan toistensa kanssa, eivätkä maaseudun harvaan asutut alueet ole etusijalla infrastruktuuri-investoinneista päätettäessä.

On todennäköistä, että isoissa asutuskeskuksissa autonomisia ajoneuvoja tulee olemaan enemmän, sillä näihin asutuskeskuksiin panostetaan enemmän rahallisesti. On mahdollista että maaseudulle jää niin kutsuttuja "taskuja," joissa autokulttuuri laahaa muun yhteiskunnan perässä.

Lisäksi on mielenkiintoista ajatella miten autokulttuuri tulee muuttumaan. Mikäli nykyinen auton omistamisen malli säilyy, on mahdollista että autonomisista ajoneuvoista tulee sähköautojen kaltainen statussymboli. Jos taas leasingiin ja automaattitaksipalveluihin

perustuvat palvelumallit syrjäyttävät auton omistamiseen perustuvan kulttuurin, voi olla että niin sanotut "tyhvät" autot nousevat suosioon keräilijöiden ja varakkaiden keskuudessa.

Muut liikkumisen muodot, kuten sähköpyörät voivat nostaa suosiotaan edullisempänä vaihtoehtona leasing-sopimuksen tekemiselle ja eräänlaisena itsenäisyyden säilyttämisen muotona. Nykyään auton omistamiseen liittyy ajatus itsenäisyydestä ja kyvystä lähteä liikkeelle silloin kuin haluaa. Mikäli autonomiset ajoneuvot tuovat yhteiskuntaan täysin uudenlaisen ymmärryksen auton käytöstä edellä mainittujen palvelumallien muodossa, auton käyttöön tulee liittymään aikaisempaa enemmän suunnitelmallisuutta ja spontaanisuus vähenee.

Liikennekulttuurin muutoksien lisäksi merkittävä uhkakuva on ammattiautoilun poistuminen työmarkkinoilta. Mikäli ihmiskuljettajia ei tarvita, ei taksipalveluiden ole kannattavaa palkata kuljettajia, kun samalla investoinnilla voi rahoittaa lisää ajoneuvoja. Sama pätee rekkakuskeihin ja bussin kuljettajiin. Letka-ajot, joissa ainoastaan johtavalla ajoneuvolla on kuljettaja, tulevat vähentämään rekan kuljettajien tarvetta. Mikäli ajoneuvojen lastaaminen ja kuorman purkaminen saadaan vielä täysin automatisoitua, voi logistiikka-alalla tapahtua merkittävä työntekijöiden vähennys.

Sen sijaan koneoppimiseen ja autonomisten ajoneuvojen kehittämisen alalla työpaikat tulevat todennäköisesti lisääntymään. Mikäli liikennejärjestelmät ja ajoneuvot digitalisoituvat ja itsenäistyvät, jonkun täytyy kuitenkin ylläpitää näitä järjestelmiä ja tätä kautta saattaa syntyä täysin uusia työpaikkoja, joista emme vielä edes tiedä.

Lähteet

- Aho E., Lyly L. & Mero I. 2017. Liikenne- ja viestintäarkkitehtuuri 2030 ja 2050, s. 11-17, 31-34. Liikenne- ja viestintäministeriö. Luettavissa: <https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/79795/Raportit%20ja%20selvitykset%207-2017.pdf> Luettu: 15.12.2020
- Aichi Rapid Transit Co., 2016. Linimo. Luettavissa: <http://www.linimo.jp/language/en/> Luettu: 26.10.2020
- Arola T. & Antikainen P. 2017. Liikenteen automaation ja robotiikan kehittämistoimenpiteiden tiekartta 2017-2019, s. 3-10. Liikenne- ja viestintäministeriö. Luettavissa: <https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/79868/10-2017%20Liikenteen%20automaation%20ja%20robotiikan%20kehittamistoimenpiteiden%20tiekartta%202017-2019.pdf> Luettu: 20.12.2020
- Belt, J., Lämsä V., Savolainen M. & Ehrola E. 2002. Tierakenteen vaurioituminen ja tiestön kunto, s.16-20. Tiehallinnon selvityksiä 15/2002. Luettavissa: <https://www.doria.fi/bitstream/handle/10024/139074/4276tie.pdf?sequence=1> Luettu: 15.12.2020
- DARPA 2014. The DARPA Grand Challenge: Ten Years Later. Luettavissa: <https://www.darpa.mil/news-events/2014-03-13> Luettu: 10.09.2020
- Forrest, A. & Konca M. 2007. Autonomous Cars & Society. Luettavissa: https://digital.wpi.edu/concern/student_works/3t945r08v?locale=en Luettu: 14.04.2020
- Franklin, D. 2020. Collecting your own Classification Datasets. Github. Luettavissa: <https://github.com/dusty-nv/jetson-inference/blob/master/docs/pytorch-collect.md> Luettu: 20.10.2020
- Hearst Autos Research, 2020. Cars with Adaptive Cruise Control: Everything You Need to Know Luettavissa: <https://www.caranddriver.com/research/a31996248/cars-with-adaptive-cruise-control/> Luettu: 10.09.2020
- Hienonen P, 2014. Automatic traffic sign inventory- and condition analysis, s.15. Luettavissa: <https://lutpub.lut.fi/handle/10024/98984> Luettu: 18.10.2020

Hotz G, Comma 2020. Luettavissa: <https://www.youtube.com/c/commaai/videos> Luettu: 15.11.2020

Interesting Engineering 2017. Swarm Intelligence: How autonomous cars might need to learn from ants. Luettavissa: <https://interestingengineering.com/swarm-intelligence-how-autonomous-cars-might-need-to-learn-from-ants> Luettu: 26.03.2020

JetsonHacks, 2019. Jetson Nano – Use More Power! Luettavissa: <https://www.jetsonhacks.com/2019/04/10/jetson-nano-use-more-power/> Luettu: 21.10.2020

KPMG, 2019. 2019 Autonomous Vehicle Readiness Index. Luettavissa: <https://home.kpmg/xx/en/home/insights/2019/02/2019-autonomous-vehicles-readiness-index.html> Luettu: 10.09.2020

KPMG 2020. 2020 Autonomous Vehicle Readiness Index. Luettavissa: <https://assets.kpmg/content/dam/kpmg/uk/pdf/2020/07/2020-autonomous-vehicles-readiness-index.pdf> Luettu: 10.01.2021

Laitinen J. 2018. The VTT robot car Marilyn parks in the furthestmost lot fully autonomously. VTT Research. Luettavissa: <https://www.vttresearch.com/en/news-and-ideas/vtt-robot-car-marilyn-parks-furthestmost-lot-fully-autonomously> Luettu: 10.11.2020

Larochelle H., Bengio Y., Louradour J. & Lamblin P. 2009. Exploring Strategies for Training Deep Neural Networks, s. 15-21. Luettavissa: <https://www.jmlr.org/papers/volume10/larochelle09a/larochelle09a> Luettu: 15.01.2021

Lehtilä, O., Nyström, P., Ronikonmäki N. & Sirviö, T. Tietoturvan ja tietosuojan parantaminen yhteiskunnan kriittisillä toimialoilla, s. 34-36. Liikenne- ja viestintäministeriö. Luettavissa: https://julkaisut.valtioneuvosto.fi/bitstream/handle/10024/162783/LVM_2021_1.pdf?sequence=1 Luettu: 05.02.2021

Lu J., Behbood V., Hao P., Zuo H., Xue S. & Zhang G. 2015. Transfer learning using computational intelligence: A survey. Luettavissa: <https://www.sciencedirect.com/science/article/abs/pii/S0950705115000179> Luettu: 20.12.2020

Mannermaa, A. 2019. Auto on nykyisin rullaava tietokone. Mikrobitti. Luettavissa: <https://www.mikrobitti.fi/uutiset/auto-on-nykyisin-renkailla-rullaava-tietokone-mutta-kenelle-sen-keraama-data-kuuluu-ei-ainakaan-auton-omistajalle/736d8025-b652-4a2c-8417-449913e2527e> Luettu: 16.09.2020

NDC Networks, 2018. Martti ja Marilyn - robottiautot Tampereelta. Luettavissa: <https://www.ndc.fi/post/2018/11/26/martti-ja-marilyn-robottiautot-tampereelta> Luettu: 10.11.2020

Neuromation 2018. How Computer Vision Can Change the Automotive Industry. Luettavissa: <https://medium.com/neuromation-blog/how-computer-vision-can-change-the-automotive-industry-b8ba0f1c08d1> Luettu: 16.03.2020

Nvidia, 2020. Jetson Community Projects. Luettavissa: https://developer.nvidia.com/embedded/community/jetson-projects#dbse_monitor Luettu: 05.11.2020

Nvidia, 2020. Jetson Nano Developer Kit. Luettavissa: <https://developer.nvidia.com/embedded/jetson-nano-developer-kit> Luettu: 05.11.2020

Nvidia Developer Forums, 2020. How to install onnx-tensorrt on Jetson devices? Luettavissa: <https://forums.developer.nvidia.com/t/how-to-install-onnx-tensorrt-on-jetson-devices/155853> Luettu: 22.10.2020

Nvidia TensorRT, 2020. TensorRT Open Source Software. Github. Luettavissa: <https://github.com/NVIDIA/TensorRT/> Luettu: 21.10.2020

Ojanperä T. 2018. 5G-teknologia tuo 3D-näkymät ajoneuvojen väliseen tiedonvaihtoon - liikenneonnettomuudet laskuun. VTT Research. Luettavissa: <https://www.vttresearch.com/fi/uutiset-ja-tarinat/5g-teknologia-tuo-3d-nakymat-ajoneuvojen-valiseen-tiedonvaihtoon> Luettu: 10.11.2020

Rouse, M. 2017. Concept Map. TechTarget, Inc. Luettavissa: <https://whatis.techtarget.com/definition/concept-map> Luettu: 20.10.2020

Salonen T. 2019. "Aivan hullua, auto ilman kuljettajaa!" – Ammattikuljettajien sosiaaliset representaatiot robottiautoista, s.40-51. Luettavissa: https://helda.helsinki.fi/bitstream/handle/10138/302885/Salonen_Tuisku_Pro_gradu_2019.pdf?sequence=2&isAllowed=y Luettu: 10.01.2021

Sanastokeskus TSK ry 2006. Terminologian sanasto. Luettavissa:
<http://www.tsk.fi/fi/info/TerminologianSanasto.pdf> Luettu: 12.12.2020

Sauliala T, 14.5.2020. Meeting the Big Challenges in Autonomous Driving with Remote Control. Luettavissa: <https://sensible4.fi/2020/05/14/meeting-the-big-challenges-in-autonomous-driving-with-remote-control/> Luettu: 14.11.2020

Sauliala T, 17.6.2020. Sensible 4's Positioning – How Our Autonomous Vehicles Know Where They're Going. Luettavissa: <https://sensible4.fi/2020/06/17/sensible4-positioning-how-our-autonomous-vehicles-know-where-theyre-going/> Luettu: 14.11.2020

Sauliala T, 15.7.2020. Obstacle Detection and Tracking System (ODTS) Enables a Smooth, Safe Ride – For Everyone. Luettavissa: <https://sensible4.fi/2020/07/15/obstacle-detection-and-tracking-system-odts-enables-a-smooth-safe-ride-for-everyone/> Luettu: 14.11.2020

Sauliala T, 30.7.2020. The Driverless Car's Invisible Brain: Planning and Control. Luettavissa: <https://sensible4.fi/2020/07/30/the-driverless-cars-invisible-brain-planning-and-control/> Luettu: 14.11.2020

Sensible 4, 2019. Gacha Autonomous Shuttle Bus. Luettavissa: <https://sensible4.fi/gacha/> Luettu: 14.11.2020

Tekniikan Maailma, 2017. Suomalainen robottiauto teki "maailmanennätyksen" – selvisi oikealla lumisella tiellä. Luettavissa: <https://tekniikanmaailma.fi/suomalainen-robottiauto-teki-maailmanennatytksen-selvisi-oikealla-lumisella-tiella/> Luettu: 10.11.2020

Tesla 2019. Tesla Autonomy Day 2019. Katsottavissa:
<https://www.youtube.com/watch?v=Ucp0TTmvqOE> Katsottu: 03.11.2020

Thakur, R. 2016. Scanning LIDAR in Advanced Driver Assistance Systems and Beyond: Building a road map for next-generation LIDAR technology. IEEE Consumer Electronics Magazine, 5(3), s. 48–54. Luettavissa: <https://ieeexplore.ieee.org/document/7539258> Luettu: 16.09.2020

The Innovation Enterprise 2019. The Impact of computer vision on the automotive industry. Luettavissa: <https://channels.theinnovationenterprise.com/articles/the-impact-of-computer-vision-on-the-automotive-industry> Luettu: 26.03.2020

Tilastokeskus 2020. Ajoneuvon määritelmä. Luettavissa: <https://www.stat.fi/meta/kas/ajoneuvo.html> Luettu: 03.11.2020

Toyota Material Handling Australia, 2018. Demonstrating the Driverless Toyota Forklift Luettavissa: <https://www.youtube.com/watch?v=y0mEYIBFOPM> Luettu: 26.10.2020

Traficom, 2020. Käynnissä olevat tutkimukset. Luettavissa: <https://www.traficom.fi/fi/ajankohtaista/kaynnissa-olevat-tutkimukset> Luettu: 10.11.2020

Traficom, 2020. Tutkimus ja kehittäminen Traficomissa. Luettavissa: <https://www.traficom.fi/fi/traficom/tietoa-traficomista/tutkimus-ja-kehittaminen-traficomissa> Luettu: 10.11.2020

Urmson C., 2015. Chris Urmson: How a driverless car sees the road. Luettavissa: <https://www.youtube.com/watch?v=tiwVMrTLUWg> Luettu: 15.11.2020

Väylävirasto, 2020. Liikennemerkkit 1.6.2020 alkaen. Luettavissa: <https://vayla.fi/vaylista/liikennemerkkit> Luettu: 21.12.2020