

Juha Ranta-Ojala

# ITSESTÄÄN AJAVIEN AUTOJEN HAVAINNOINTITEKNIIKAT KAUPUNKIYMPÄRISTÖSSÄ

Informaatioteknologian ja viestinnän tiedekunta  
Kandidaattitutkielma  
Huhtikuu 2020

# TIIVISTELMÄ

Juha Ranta-Ojala: Itsestään ajavien autojen havainnointitekniikat kaupunkiympäristössä  
Kandidaattitutkielma  
Tampereen yliopisto  
Tietojenkäsittelytieteiden tutkinto-ohjelma  
Huhtikuu 2020

---

Tässä tutkielmassani tarkastelen itsestään ajavien autojen toimintaa kaupunkiympäristössä. Jo useita vuosia uusissa autoissa on ollut paljon erilaista automatiikkaa, joka on tehnyt niiden ajamisesta entistä vaivattomampaa. Keskityn tässä tutkielmassani erityisesti auton ympäristön havainnointia käsitteleviin tekniikoihin. Itsestään ajavan auton kuuluu huomioda muita ajoneuvoja, reagoida liikennevaloihin ja -merkkeihin sekä muun muassa jalankulkijoihin.

Itsestään ajava auto käyttää radiotutkaa eli RADAR-järjestelmää etäisten kohteiden ja niiden nopeuden havaitsemiseksi. Valotutkan eli LIDAR-järjestelmän avulla se muodostaa yksityiskohdaisen kartan auton ympärillä olevasta todellisuudesta ja korkearesoluutioiset kamerat poimivat muun visuaalisen tiedon, kuten esimerkiksi liikennevalon vaihtumisen. Autojen erilaiset hahmontunnistamiseen liittyvät tekniikat kehittyvät koko ajan. Pitkälti tekoälyyn perustuvien tekniikkojen pääasiallisena tarkoituksena on parantaa itsestään ajavien autojen turvallisuutta kaupunkiliikenteessä. Tässä tutkielmassani tarkastellaan erityisesti jalankulkijoiden ja liikenne-merkkien havaitsemiseen liittyviä tekniikoita. Jalankulkijoiden havaitseminen on tärkein turvallisuutta lisäävä ominaisuus itsestään ajaville autoille kaupunkiympäristössä.

Tutkimusten mukaan yli 90 % liikenteessä aiheutuneista onnettomuuksista johtuvat kuljettajista. Itsestään ajavien autojen kohdalla onnettomuusriski pienenee olennaisesti, koska auto pysyy ihmistä nopeammin reagoimaan eteen tuleviin yllättäviinkin tilanteisiin. Itsestään ajava auto pystyy myös havainnoimaan kuljettajaa tarkemmin ympäristöään. Lisäksi auton havainnointikyky ei myöskään heikkene ajon aikana huonon vireystilan takia kuten ihmisillä. Tutkielmassani käyn läpi nykytilannetta itsestään ajavien autojen osalta liittyen nimenomaan niiden turvallisuuteen. Keskityn tutkielmassani uusimpiin tieteellisiin julkaisuihin, koska itsestään ajavien autojen havainnointitekniikat ovat kehittyneet huomasti viime vuosina.

Avainsanat: Itsestään ajavat autot, RADAR, LIDAR, kamerat, havainnointitekniikat

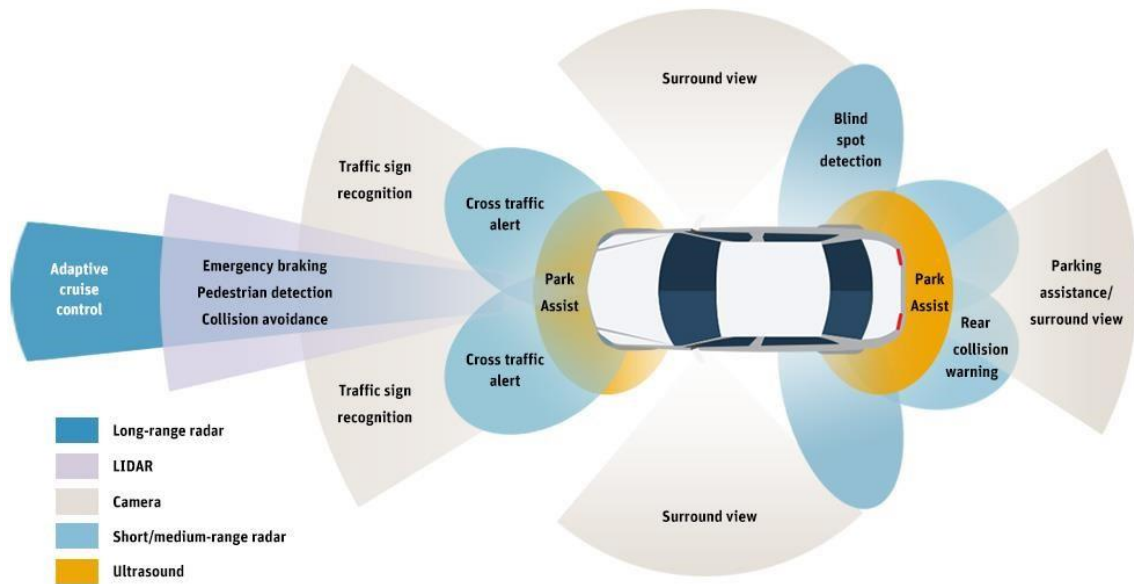
Tämän julkaisun alkuperäisyys on tarkastettu Turnitin OriginalityCheck –ohjelmalla.

## Sisällysluettelo

<b>1</b>	<b>Johdanto .....</b>	<b>1</b>
<b>2</b>	<b>Tutkimusmenetelmä.....</b>	<b>3</b>
<b>3</b>	<b>Itsestään ajavien autojen arkkitehtuurit.....</b>	<b>4</b>
<b>4</b>	<b>Itsestään ajavien autojen kuvantamismenetelmät .....</b>	<b>5</b>
<b>5</b>	<b>Esteiden tunnistusmenetelmät.....</b>	<b>6</b>
	5.1 Radiotutka - RADAR	7
	5.2 Valotutka - LIDAR	8
	5.3 Konenäkö - Kamerateat	9
<b>6</b>	<b>Kuvien tunnistusmenetelmät.....</b>	<b>10</b>
<b>7</b>	<b>Keskustelu .....</b>	<b>12</b>
	<b>Lähdeluettelo.....</b>	<b>13</b>

## 1 Johdanto

On ennustettu, että itsestään ajavat autot tulevat kaupunkiympäristöön viimeistään 2030 (Garza, 2011). Vaikka ne eivät ratkaise kaikkia autoiluun liittyviä ongelmia, niiden on kuitenkin osoitettu olevan turvallisempia kuin autojen, joissa ihminen vastaa niiden hallinnasta (NTHSA, 2008). On arvioitu, että varsinkin taksipalvelut ovat tulevaisuudessa itsestään ajavien autojen yksi tärkeimmistä toiminta-alueista.



Kuva 1. Itsestään ajavien auton havainnointitekniikat RADAR, LIDAR ja kamerat (Carpenter, 2018)

Tämän tutkielmani tarkoituksena on kertoa itsestään ajavien autojen havainnointitekniikoista (RADAR, LIDAR ja kamerat) kaupunkiympäristössä sekä antaa yleisellä tasolla tietoa niiden vaikutuksista turvallisuuteen (Kuva 1). Kuvasta 1 näkyy selvästi, miten erilaisin tavoin itsestään ajava auto pyrkii mallintamaan ympäristöään ja ratkaisemaan etukäteen mahdollisia eteen tulevia tilanteita. Radiotutkalla (RADAR) muodostetaan karkea käsitys kohteen etäisyydestä, jota valotutkalla (LIDAR) tarkennetaan. Erilaisilla kame-roilla saadaan lopuksi tarkempaa tietoa tarkasteltavan kohteen tyypistä. Itsestään ajavan auton havainnointikyky on paljon ihmistä parempi (Shakeel, 2018).

Itsestään ajavan auton täytyy tarkkailla ympäristöään, suunnitella reittejään ja tehdä erilaisia päätöksiä koskien auton eri toimintoja. Sen pitää pystyä yhdistelemään erilaista informaatiota, jota tulee sen lukuisista antureista, sekä ennakoimaan tarvittaessa useita ajon aikaisia tilanteita. Kaiken tämän ensisijaisena tavoitteena on lisätä turvallisuutta liikenteessä. Tällä hetkellä tunnetaan vain yksi itsestään ajavan auton aiheuttama kuolemaan johtanut kolaritilanne (Lubben, 2018). Useissa muissa kolaritilanteissa ihmisen täysin ennakoimaton toiminta on ollut ainakin osasyynä onnettomuuden syntymiseen (Rao

et al., 2018). Tässä tutkielmassa on kerrottu lukuisia syitä, miksi itsestään ajava auto toimii ongelmanratkaisutilanteissa ja miksi se pystyy ennakoimaan ja välttämään ihmistä paremmin mahdolliset ongelmatilanteet.

Dataa tulee erityisen paljon erilaisista autoissa olevista sensoreista. Itsestään ajavien autojen tuottama datamäärä kaupunkiliikenteessä on keskimäärin 25 gigatavua tunnissa (Dmitriev, 2018). Myös autossa olevista erilaisista kameroista tulee valtavan paljon dataa, kun ajonaikaisesti tien varsilla olevia liikennemerkkejä pyritään tunnistamaan. On arvioitu, että autojen tuottama päivittäinen noin yhden teratavun datamäärä tulee olemaan isoin ”pullonkaula” itsestään ajavien autojen yleistymisessä (Dmitriev, 2018). Suuri datamäärä kertyy autoissa käytetystä monianturitekniikasta, joka kerää tietoa mm. kameroiden, tutkien, lasereiden, valojen ja ultraääniantureiden kautta. Kaikkien näiden antureiden antama tieto voi myös toimia niin sanottuna kuudentena aistina eli intuition autille. Tämä käytännössä tarkoittaa, että auto pyrkii ennakoimaan kaikkia mahdollisesti eteen tulevia tilanteita. (Fathi et al., 2018)

Tässä tutkielmassa keskityn myös itsestään ajavien autojen hahmontunnistusta ja kokenäköä koskeviin haasteisiin. On hyvin olennaista saada tietää, millaista estettä auto kulloinkin on lähestymässä, jotta se osaa tehdä kulloinkin tarvittavat oikea-aikaiset toimenpiteet. Yksi itsestään ajavien autojen päävaatimus on, että ne kykenevät havaitsemaan ja tulkitsemaan ympäristöään reaaliajassa. Suuri määrä tietoa kertyy erilaisista antureista, kuten kameroista, radio- ja tutkatiedoista (RADAR) sekä erilaisista valomittauksista (LIDAR). Pääosa älykkäiden ajoneuvojen ympäristön havaitsemiseen liittyvistä toiminnoista liittyy kaistoihin, varsinaiseen ajorataan sekä liikennemerkkien havainnointiin. Inertiaalista navigointijärjestelmää (INS), joka perustuu auton kiihtyvyyksien mittaukseen, käytetään jo yleisesti hyväksi ilman auton lähettämiä paikkatietoja. (Zhu et al., 2017)

Kaikessa tässä kysymys on ennen kaikkea autojen luotettavuudesta, sillä tavoitteena on entistä turvallisempi liikenne kaupunkiympäristössä. Tutkimustavoitteeni oli selvittää, miten tämä käytännössä toteutuisi ja mitä se itsestään ajavilta autoilta vaatisi. Kaikista kriittisin asia itsestään ajavilla autoilla on tunnistaa jalankulkijat luotettavasti kaupunkiliikenteessä (Sarcinelli et al., 2019). Autojen on kyettävä tekemään riittävän nopeasti pysähtymispäätös, jos esimerkiksi jalankulkija syystä tai toisesta tulee tielle.

Tutkimuskysymykseksi valitsin: Miten itsestään ajavat autot parantavat turvallisuutta kaupunkiympäristössä? Tätä asiaa lähdin selvittämään tutustumalla aiheeseen liittyviin uusimpiin tutkimuksiin. Löysin useita uudehkoja tutkimuksia, joissa pystyttiin perusteellisesti kuvaamaan, miten itsestään ajavat autot tänä päivänä käyttäytyvät kaupunkiliikenteessä. Rajasin aiheeni koskemaan kaupunkia, koska ongelmatilanteet liittyvät lähinnä risteyksiin ja muun liikenteen huomioon ottamiseen.

Tutkimuksista kävi myös hyvin ilmi, että ylivoimaisesti haastavinta itsestään ajaville autoille on tunnistaa ja ennakoida jalankulkijoiden toimintaa (Sarcinelli et al., 2019). Merkittävimpänä ongelmana tällä hetkellä oli myös kameroista saadun kuvainformaation käsittely- ja siirtonopeus. Itsestään ajavat autot tuottavat valtavan määrän kuvatietoa, joka pitää käsitellä hyvin nopeasti oikeiden johtopäätösten tekemiseksi. (Fathi et al., 2018). Mikään tutkimuksista ei käsitellyt itsestään ajavan auton käyttäytymistä talviolosuhteissa, joka tietenkin muodostaa erilaisia haasteita esim. liikennemerkkien havaitsemiseen. Tämä aihepiiri rajattiin tässä tutkimuksessa aiheen ulkopuolelle.

Kaikista näistä haasteista huolimatta minulle jäi käsitys, että itsestään ajavat autot parantavat huomattavasti turvallisuutta kaupunkiliikenteessä. Seuraavien lukujen kautta esittelen tarkemmin, mitä erilaisia tekniikoita tässä tarkemmin hyödynnetään. Aluksi selostan tutkimusmenetelmää, jonka jälkeen autojen yleistä arkkitehtuuria. Sen jälkeen keskitytään pääasiassa kaupunkiympäristön kuvantamiseen ja sen sovelluksiin.

## 2 Tutkimusmenetelmä

Lähdin hakemaan vastauksia tutkimuskysymykseeni tutustumalla muutamaa aihetta käsittelevään tutkielmaan ja konferenssijulkaisuun. Hakusanoina käytin seuraavia sanoja tai niiden yhdistelmiä: ”Self-driving cars” AND ”safety”, ”autonomous cars”, ”image recognition”, ”machine vision”, ”pedestrians”, ”urban”. Sain näillä hakusanoilla tai niiden yhdistelmillä n. 50 erilaista tutkimusartikkelia, joista suurin osa oli 2010 -luvulta. Itsestään ajavien autojen tutkimus on aika tuoretta, koska näitä autoja ei ole ollut vielä laajasti edes testikäytössä kuin tällä vuosituohannella. Osa tutkimuksista keskittyi enemmän kuljettajan havainnointiin, mutta tässä tutkimuksessa lähestyin aihetta enemmänkin auton näkökulmasta. Auton lukuisista erilaisista antureista valitsin vielä kamerat, koska niistä saatava data on kaikkein haastavinta käsitellä (Häne et al., 2017).

Käytin pääasiassa Tampereen yliopiston kirjaston tiedonhakupkurssilla suositeltuja tietokantoja ensisijaisille hauilleni, joista sitten valitsin osuvimmat saatavilla olevat tieteelliset lähteet. Hakujen suhteen laitoin niihin useampia erilaisia yo. kriteerejä, jotta olisin saanut parhaat lähteet näkyville. Onnistuin hauissani melko hyvin, toki joitain huomontia lähteitä pääsi aluksi kirjoitusvaiheeseen mukaan. Katsoin kaikista löytämistäni lähteistä tiivistelmän ja sen perusteella tein valinnan, otin ne lopulta tutkielmaani mukaan. Käytän tässä tutkielmassani referensseinä uusimpia tutkimuksia, jotka tähän aihepiiriin liittyvät. Tutkielmassani keskitytään ensisijaisesti esittelemään ne jo olemassa olevat ratkaisut, joiden pohjalta itsestään ajavat autot pystyvät tekemään oikeat johtopäätökset erilaisissa tilanteissa. Keskityn lisäksi jo pääasiassa tuotannossa olevien autojen ratkaisuihin.

Tutkielmaani valituille artikkeleille tein analyysin, kuinka hyvin ne vastaavat sitä yleiskäsitystä, joka itsestään ajaviin autoihin tällä hetkellä liittyy. Tutkielmani kannalta keskeisimmäksi tutkimukseksi valikoitui Lin (2020) *Judgment and optimization of video image recognition in obstacle detection in intelligent vehicle*. Tässä tutkimuksessa tuli parhaiten esille se päättelyketju, jonka itsestään ajava auto ajossa tekee. Osa artikkeleista näytti pohjautuvan erilaisiin hypoteeseihin, joiden sisältöä tarkastelin vielä tarkemmin. Keskityin näistä ainoastaan niihin tutkimuksiin, jotka käsittelivät erilaisia kuvantamistekniikoita. Jonkin verran katsoin myös viittausten määrää tiettyihin artikkeleihin, jotta pystyin varmistumaan siitä, että ne olivat aitoja relevantteja lähteitä.

Selkeä ongelma tutkimusaiheeseen liittyen on, että vertaisarvioitua tutkimustietoa on vielä saatavilla kohtuullisen vähän. Löysin kyllä huomattavan paljon erilaisia artikkeleja, joista muutamia otinkin tähän tutkielmaani mukaan. Selkeä suuntaus näyttää myös olevan, että itsestään ajavien autojen tekniikkaa tuodaan nyt myös muihin markkinoilla oleviin automalleihin erilaisina lisäominaisuuksina (Hengstler et al., 2016).

### **3 Itsestään ajavien autojen arkkitehtuurit**

Itsestään ajavan auton arkkitehtuuri voidaan karkeasti jakaa kahteen pääosaan: Havaintojärjestelmään ja päätöksentekojärjestelmään. Havaintojärjestelmä jaetaan edelleen neljään osaan, jotka vastaavat seuraavista toiminnoista:

1. auton paikallistaminen
2. esteiden kartoitus ja havaitseminen
3. liikkuvien esteiden seuranta
4. muun liikenteen tunnistaminen.

Päätöksentekojärjestelmä jakaantuu kuuteen pääosaan, jotka ovat reitin ja kaistanvaihtojen suunnittelu, auton käyttäytyminen eri tilanteissa, ajoliikkeiden välittäminen, esteiden tunnistaminen ja ajoneuvon hallinta. Kaikkein haastavinta itsestään ajavalle autolle on jalankulkijoiden tunnistaminen, koska ihmisen erilaisia liikemalleja on hyvin vaikea ja joskus lähes mahdotonta ennustaa. (Sarcinelli et al., 2019)

Itsestään ajavat autot sisältävät yleisesti ottaen neljä perustekniikkaa (Zhu et al., 2017):

1. Ympäristön havaitseminen ja mallintaminen,
2. paikallistaminen ja kartan rakentaminen,
3. optimaalisen reitin suunnittelu ja siihen liittyvä päätöksenteko
4. sekä auton liikkeiden hallinta.

Kaistojen ja tien havaitseminen on myös erityisen tärkeä tutkimusalue autoille. Kaistanseurantaominaisuuksia käytetäänkin jo nykyään yleisesti myytävissä älykkäissä autoissa. Auto voi varoittaa kuljettajaa, kun ollaan vaihtamassa ajokaistaa, tai auto voi mitata etäisyyttä edellä ajavaan autoon. Adaptiivinen vakionopeudensäädin säätelee etäisyyttä toiseen autoon tarpeen mukaan. Auto voi myös keskittää itsensä ajamaan keskellä kaistaa etäisyyksimittausten perusteella. (Zhu et al., 2017) Ajokaistalle keskittäminen on erityisen haastava toteuttaa varsinkin lumisissa olosuhteissa. Itsestään ajavien autojen tekniikka ja tunnistusmenetelmät ovat pääasiassa luotu optimiolosuhteisiin, jotka hyvin harvoin toteutuvat arktisissa talviolosuhteissa (Fu et al., 2019). Ihanneolosuhteissa itsestään ajava auto pystyy yhdistämään ympäristön tiedot siihen liittyvällä anturi- ja kameratiedolla. Näillä tiedoilla varustettu auto pystyy tekemään itsenäisiä päätöksiä käyttäytymiseensä liikenteessä. Itsestään ajava auto pystyy havaitsemaan ajonaikaisia esteitä ja reagoimaan niihin riittävän nopeasti. (Li, Q. et al., 2020)

#### **4 Itsestään ajavien autojen kuvantamismenetelmät**

Itsestään ajavista autoista rajasin aiheitani koskemaan hahmontunnistusta ja konenäköä. Autojen on kyettävä tekemään päätöksiä ajon aikana liikennemerkkeistä, ihmisistä tai muista esteistä. Jos esimerkiksi tielle osuu ohipääsemätön este, auton on kyettävä keksimään vaihtoehtoinen reitti määränpään pääsemiseksi. Lisäksi tämä tunnistusmenetelmän on oltava riittävän nopea mahdollisten törmäysten välttämiseksi. Uusissa autoissa on jo nykyisin paljon ennakoivaa tekniikkaa, tarkoittaen esimerkiksi sitä, että ne kykenevät hidastamaan ja kiihdyttämään vauhtia optimaalisesti (Li, Q. et al., 2020). Tämä tarkoittaa sekä polttoaineen säästöä että liikenteen joustavaa sujumista (Urmson, 2008). Lisäksi autoissa on törmäyksistä varoittavaa tekniikkaa auton edessä, takana ja sivuilla. Tätä hyödynnetään itsestään ajavissa autoissa niin, että kohteen etäisyyden mitan ollessa selvillä, auto tekee itsenäisesti johtopäätökset auton jarruttamisesta tai kiihdyttämisestä. Auto pyrkii joka tilanteessa pitämään turvallisen etäisyyden muihin tielläliikkujiin. Auton tulee tuki antaa riittävän ajoissa varoitus mahdollisesta törmäysvaarasta ja myös tarvittaessa reagoida siihen nopeasti. Tällä hetkellä olemme teknologian suhteen siirtymävaiheessa näiden kahden eri käytännön välillä. Vielä nyt useissa autoissa ajonaikainen hallinta on kuljettajalla, joten älykäs tunnistusjärjestelmä lähinnä varoittaa kuljettajaa mm. kaistojen välissä olevien merkintöjen avulla. Siksi kuljettaja pystyy paremmin keskittymään itse ajamiseen mahdollisten eteen tulevien esteiden seuraamisen sijasta (Sarcinelli et al., 2019).

Itsestään ajavissa autoissa hyödynnetään jatkuvaa ympäristön kuvantamista, josta pyritään poimimaan tarvittava informaatio erilaisten päätösten tekemiseksi. Ympäristön kuvista tehdään erilaisia harmaasävy- tai binäärimalleja, joiden perusteella autolle annetaan



selkeitä ohjauskomentoja. On myös mahdollista tehdä hahmontunnistusta esimerkiksi liikennemerkeistä tai liikennevaloista, jolloin myös värien erottelun merkitys korostuu. Kuvien tunnistustekniikka on autojen tärkeä alue tekoälyn yhtenä sovellusalueena (Li, Q. et al., 2020).

## 5 Esteiden tunnistusmenetelmät

Ensisijaisesti aina itsestään ajavat autot pyrkivät välttämään kaikki törmäykset erilaisiin esteisiin. Erityistä huomiota kiinnitetään kaistojen ja tien havaitsemiseen, liikennemerkkien tunnistamiseen ja muiden ajoneuvojen ja tielläliikkujien havainnoimiseen (Zhu et al., 2017). Esteiden havaitsemisessa käytetään yleisesti apuna useita autoissa olevia antureita (Li, Q. et al., 2020).

Advanced Driver Assistance Systems (ADAS) on yleinen menetelmä esteiden havaitsemiseen ja törmäysvaroitusten antamiseen. Tämä menetelmä perustuu ajonaikaisten muodostettujen kuvakehysten tunnistamiseen, joista tehdään johtopäätös mahdollisen esteen tyypistä. Tässä menetelmässä saadaan tarkka tunnistus erilaisissa valaistusolosuhteissa, kuten päivänvalossa, hämärässä, yöllä ja sateessa. Havaitsemisalgoritmien apuna käytetään esimerkiksi risteysalueella kuvattuja videoita, joita voidaan käyttää vertailukohtana tuleville päätöksentekotilanteille. Videot voivat sisältää erilaisia liikenne- ja valaistusolosuhteita, jotka on saatettu saada useista julkisista kaupunkikameroista. (Prakash et al., 2019)

Älykkäissä autoissa oleva esteiden havaitsemistekniikka on parantunut huomattavasti yhä kehittyneempien videokuvien kautta. Erilaisten kuvankeruumenetelmien tukena älykäs ajoneuvo havaitsee esteet tarkasti käyttämällä binäärisointia ja muita menetelmiä kuvan optimoimiseksi. (Li, Q et al., 2020). Nykytekniikka tarjoaa jo nyt tukevan tieteellisen perustan itsestään ajavien autojen esteiden havaitsemiselle ja tarvittavalle reitit suunnittelulle myöhemmässä vaiheessa (Alhajja, et al., 2018).

Esteiden havaitsemisjärjestelmä perustuu ajalliseen tietoon esineestä tai kuvapohjaiseen mallintamiseen kohteesta (Shah et al., 2016). Yksinkertaisimmillaan esteiden havaitsemiseen ja reittien optimoimiseen riittää ajoneuvon asennettu monokulaari kamera, joka toimii myös hämärässä ja pimeässä. Kamerasta saadusta RGB-muotoisesta videovirrasta saatu kuvadata muunnetaan harmaasävykuvaksi. Harmaasävykuva ei vain säilytä ominaisuuksia, vaan vähentää myös datan määrää. Tämä on olennaisen tärkeää, jotta auton tuottama kuvavirta ei kasvaisi liian suureksi. Kamerat ovat tärkeitä antureita itsestään ajaville autoille, koska niillä voidaan käyttää monipuolisesti eri tarkoituksiin, kuten visuaaliseen navigointiin ja erilaisten esteiden havaitsemiseen. (Li, Q et al., 2020) Kamerat ovat myös luontevin valinta mm. kaistamerkkien, liikennemerkkien ja liikennevalojen havaitsemiseen. (Häne et al., 2017)

Yleisesti käytetään myös valoantureita, tutkatekniikkaa (LIDAR), jossa laservalon avulla pyritään mittaamaan etäisyyttä esteisiin. LIDAR -tekniikan ongelma on se, että sillä pystytään pääsääntöisesti mittaamaan vain lyhyitä etäisyyksiä, joten se ei sovellu hyvin muuta kuin kaupunkiolosuhteisiin (Li, J. et al., 2017). Nopeamman ajon aikana käytetäänkin pääasiassa videomittausta, jossa hyödynnetään erilaisia hahmontunnistusmenetelmiä, joista saadun 3D-mallin pohjalta tehdään arvio esteestä (Sarcinelli et al., 2019).

Käänteistä perspektiivikartoitusta (IPS) käytetään tapauksissa, joissa arvio esteen etäisyydestä on arvioitava tarkemmin. Näin saadulla lintuperspektiivillä pystytään arvioimaan ja havaitsemaan este entistä paremmin. (Prakasha et al., 2019). Reaaliaikaista itseohjautuvaa autonavigointia ja esteen välttämistä 3D-laserskannerin ja GNSS:n (Global Navigation Satellite System) avulla käytetään myös useissa uusissa automalleissa (Li, J. et al., 2017).

## **5.1 Radiotutka - RADAR**

Radiotutka on itsestään ajaville autoille esteiden ensisijainen havaitsemisjärjestelmä. Itsestään ajavissa autoissa sitä voidaan käyttää objektien etäisyyden, sijaintikulman tai nopeuden määrittämiseen. Tutkan toimintaan eivät vaikuta erilaiset valaistus- ja sääolosuhteet. (Zhu et al., 2017)

Monet suuret itsestään ajavien autojen valmistajat käyttävät radiotutkaa autoissaan. Näihin kuuluu mm. Tesla, Waymo ja Mercedes Benz (Häne et al., 2017). Tutkalla havainnoidaan karkealla tarkkuudella liikenteessä olevat esineet ja esteet. Sillä voidaan parhaiten mitata myös esineiden nopeus ja suunta. Tutkan etuna on sen mittaussnopeus, jonka takia sillä saadaan nopeimmin arvio esteen etäisyydestä. (Zhu et al., 2017)

Radiotutkatekniikkaa ei kuitenkaan voida yksistään käyttää monimutkaisten kaupunkiympäristöjen mallintamiseen, vaan sitä käytetään yhdessä edistyneiden kameroiden ja valotutkan (LIDAR) kanssa (Li, Q. et al., 2020, Fathi et al., 2018). Radiotutka on kokoelma sensoreita useiden muiden sensoreiden joukossa (Fathi et al., 2018). Etäisyyttä mitattaessa tutkien tärkein ja eniten turvallisuutta parantava ominaisuus on yksinkertaisesti ilmoittaa autolle, että se on tulossa lähemmäksi estettä (Campbell et al., 2010). Käytännössä itsestään ajava auto käyttää RADAR-järjestelmää pääasiassa etäisten esineiden ja niiden nopeuden havaitsemiseksi (Aria, 2019).

Tyypillisesti itse ajavat autot luottavat useisiin antureihin (esim. LiDAR, RADAR tai kameroihin), jotka koostavat tarvittavat tiedot ympäristöstä autolle päätöksentekoa varten eri tilanteissa liikenteessä (Sarcinelli et al., 2019).

## 5.2 Valotutka - LIDAR

Valotutkan avulla voidaan radiotutkaa tarkemmin mitata etäisyyksiä esteisiin varsinkin hyvissä olosuhteissa. Sateisella säällä radiotutka toimii taas paremmin kuin valotutka. Erillisillä ns. näköantureilla, jotka toimivat yleensä kiinteästi radiotutkan ja valotutkan kanssa, voidaan mitata lisäksi erityisesti valon voimakkuutta. Näköantureita on monenlaisia mm. pimeänäköön, infrapunapimeänäköön ja stereonäköön liittyen. (Zhu et al., 2017).

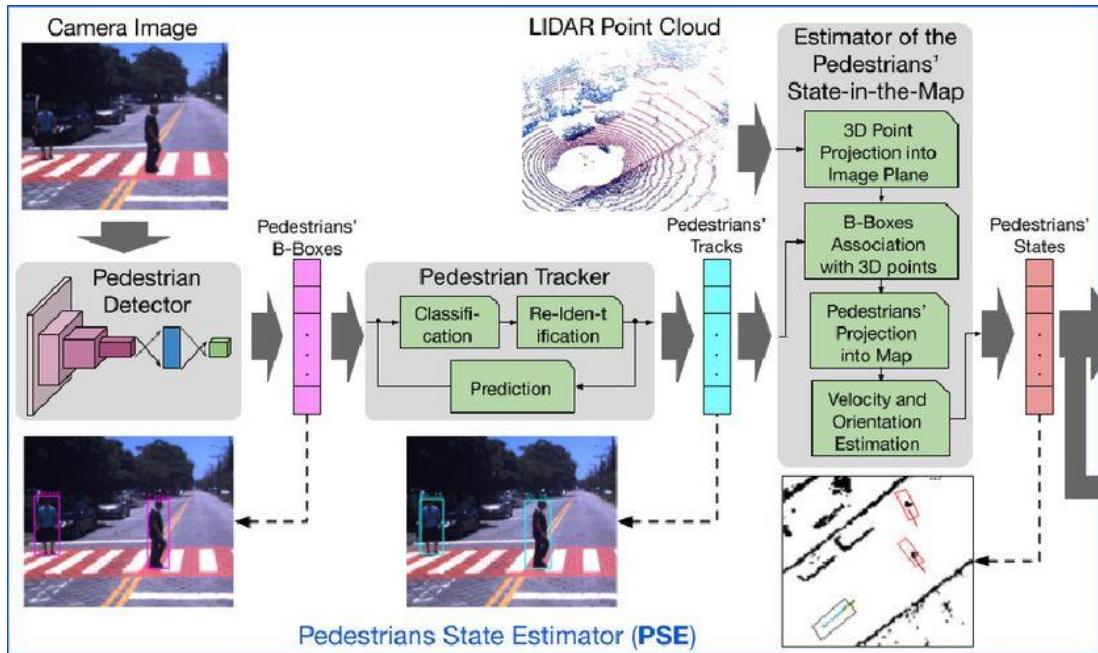
Valotunnistuksen ongelma on sen lyhyt kantama, johon myös vaikuttavat muut valitsevat erilaiset sääolosuhteet, kuten sumu, ilmansaasteet ja sade (Li, Q. et al., 2020). Valotutkan tärkeimmät ominaisuudet ovat (Li, Q. et al., 2020):

1. tarkkuus
2. korkea resoluutio
3. vahva häiriösietoisuus.

Valotutkan pitää pystyä päättelemään myös huonommissa olosuhteissa, millaisesta esteestä kulloinkin on kyse. Itsestään ajavissa autoissa käytetään apuna myös kameroista saatavaa informaatiota, joten täysin itsenäisesti sen ei tarvitse tätä päätöstä tehdä (Fu et al., 2019).

Yksi vaikeimmista asioista tunnistaa itsestään ajaville autoille ovat jalankulkijat. Tähän on kehitetty tekniikka, jolla pyritään ennakoimaan jalankulkijoiden sijainti, nopeus ja suunta (Sarcinelli et al., 2019). Tällä hetkellä tämä onnistuu vain hyvin lyhyen matkan päästä, jolloin auton ennakoinnille jää vain vähän aikaa. Käytössä on tapa, jossa generoidaan 3D-malli jalankulkijasta LIDAR -tekniikalla, jota verrataan olemassa olevaan 2D-malliin, joka on saatu Convolutional Neural Networkista (CNN:stä), jota käytetään visuaaliseen kuvantamiseen (Kuva 4).

Toinen kuvapohjainen havaitsemis- ja seurantamenetelmä on ns. Frenét frames, jossa jokainen objekti määritellään suorakulmaisen kehyksen sisälle. RGB-väriin perustuvassa menetelmässä pyritään erittelemään jokainen pikseli yhteen kolmesta tyypistä: esine, tausta tai varjo. Kahden kehyksen erotuksesta lasketaan liikkuva esine. Ensin siis havaitaan yleisesti esineen ominaisuudet, jotka klusteroidaan. Saadusta kuvasta pyritään tunnistamaan hahmo. (Shah et al., 2016). Näiden menetelmien lisäksi ihmisestä kuvattuja synteettisiä videoita voidaan käyttää ihmisen toiminnan mm. kävelyn tunnistamiseen. Todellisten ja synteettisten kuvien yhtäaikainen käyttö johtavat tietomalleihin, jotka vastaavat paremmin reaali maailman tilannetta (Alhajja et al., 2018).



Kuva 4. Tiellä olevan jalankulkijan tunnistamiseen liittyvä LIDAR –tekniikka (Sarcinelli et al., 2019)

### 5.3 Konenäkö - Kameran

Konenäköön perustuvaa tekniikkaa hyödynnetään autoissa yhdisteltäessä laskentatehoa, tiedonkeruukykyä sekä loogista arviointikykyä (Li, Q. et al., 2020). Tämän tekniikan etuna on se, ettei tarvita esteen havaitsemiseen erillistä konkreettista mallia, jonka pohjalta auto tekee arvionsa. Kuvantamisessa saadaan luotua esteestä hahmotelma, jonka mukaan auto pääättelee esteen tyypin. Kuvavirta voi tulla useamman kanavan kautta, jolloin tarkoitus on rakentaa kohteesta kolmiulotteinen malli, joka lisää mittauksen tarkkuutta ja luotettavuutta (Li, Q. et al., 2020). Ongelmaksi saattaa tulla kuvantamisen hitaus päätöksenteossa, joka voi johtaa virheelliseen tulkintaan. Kuvankäsittely voi antaa joskus epäselviä tuloksia, jolloin avuksi voidaan ottaa koneoppimiseen perustuvia menetelmiä (Kulkarni et al., 2018).

Konvoluutioneuraaliverkkoa (CNN) voidaan myös käyttää parantamaan liikkuvien kohteiden havainnointia. Käytännössä siinä pyritään mallintamaan este erilaisilla valmiilla kuvasuodattimilla nopeasti 3D-avaruudessa perinteisen kaksiulotteisuuden sijasta. Ongelmaksi saattaa tulla kuvankäsittelyn hitaus, joka voi johtaa autoissa virheellisiin tulkkintoihin esteestä. Tarvittaessa voidaan käyttää tukena kuvan prosessoinnissa syväneuroverkkoa (DNN). Syvässä oppimisessa voidaan vähentää laskentaa ja tunnistukseen kuluva aikaa, kunhan valmiit tunnistusmallit on saatu ensin luotua. (Kulkarni et al., 2018).

Lisätty todellisuus voi toimia myös mallintamisen apuna. Käytännössä tämä tarkoittaa todellisen ja synteettisen tiedon yhdistämistä (Alhaja et al., 2018). Matemaattisten mallien avulla pyritään luomaan rasterikartta kolmiulotteisen datatiedon saamiseksi, jotta

etäisyys esteisiin saataisiin tarkasti mitatuksi. Näin saaduista kuvista käsitellään ensin pois turha informaatio ja sen jälkeen valitaan valmiista malleista lähinnä oleva vaihtoehto käyttöön (Li, Q. et al., 2020).

Älykkäällä kuljettajan avustusjärjestelmillä (ADAS) pyritään välttämään ajoneuvojen törmäyksiä esteisiin ja minimoimaan onnettomuuksia. Lisäksi tekniikan avulla on pystytty ennakoimaan erilaisten kulkuneuvojen ja jalankulkijoiden liikkumista. Ensiksi pitää toki pystyä ennustamaan kohteen tila ja muoto olemassa olevien liikemallien perusteella. Toiseksi pitää pystyä saamaan havaintoja kohteesta reaaliaikaisesti. Vasta sitten pystytään luomaan kohteista yksinkertaistettu malli, jonka sen liikeratoja pyritään ennustamaan aikaisemman tiedon perusteella. Lopuksi luodaan erillinen liikemalli, josta pyritään arvioimaan mahdollinen kohteen eteneminen. (Zheng et al., 2018) Ajallisessa tiedossa ennustetaan liikemalli esineelle esim. vertailemalla symmetrisesti kahta erilaista paikkatietoa keskenään. Sen perusteella luodaan mahdollinen vaihteluväli esineelle sen luontaisen liikkeen perusteella. (Shah et al., 2016) Yhtenä käytännön esimerkkinä tästä voidaan ajatella esim. jalankulkijan etenemisnopeutta suojaatiellä.

Uusimmat itsestään ajavat autot hyödyntävät myös syväoppimista. Auto tekee jatkuvasti havaintoja ympäristöstään, jotta se pystyisi tekemään nopeammin ja tarkempia tulkintoja jatkossa toteutuneiden tilanteiden mukaan. Tämä tarkoittaa käytännössä sitä, että sen tulkintakyky mm. erilaisista esteistä paranee, mitä enemmän näitä tulee eteen (Rao et al., 2018). Tätä ominaisuutta voidaan myös tulkita tekoälyn oppimiseksi eli teknologiseksi singulariteetiksi.

## **6 Kuvien tunnistusmenetelmät**

Itsestään ajavien autojen havaitsemismenetelmät on jaoteltu yleisesti ottaen kuvankäsittelypohjaisiksi, koneoppimiseen perustuviksi tai karttapohjiin perustuviksi (Kulkarni et al., 2018). Itsestään ajavien autojen täytyy pystyä tunnistamaan erilaiset liikennemerkkit. Tähän tarkoitukseen voidaan käyttää erityistä kuvakokoelmaa GTSRB (The German Traffic Sign Recognition Benchmark). Kokonaisuudessaan se kattaa yli 50 000 erilaista liikenteessä käytettyä merkkiä (Frag, 2018). Merkit ovat jaoteltu kolmeen eri pääluokkaan, joista on muodostettu alaluokkia, joiden perusteella voidaan autolle myös opettaa merkkien tunnistusta. Ennen kuin merkit voidaan validoida, ne pitää tunnistaa luotettavasti. Käytännössä kuvavirrasta poimittava merkki pitää yksinkertaistaa, jotta laskentateho ei kasva liian suureksi. Tämä onnistuu parhaiten niin, että kuvasta muodostetaan esikäsitelty RGB-kuva, jonka arvot ovat välillä 0.1 -> 0.9 perinteisen 0 -> 255 sijaan. Sen jälkeen RGB-kuvapiste skaalataan harmaasävyiseksi, josta edelleen poistetaan informaatiota skaalaamalla se jälleen yksinkertaisemmaksi. Näin laskentateho saadaan pidettyä sellaisena, että merkit saadaan tunnistettua luotettavasti. (Frag, 2018) Liikennemerkkit

voidaan karkeasti jakaa teksti- ja kuvapohjaisiin liikennemerkkeihin. Näistä kuvapohjaiset merkit ovat helpompia ja nopeampia tunnistaa autoille liikenteessä. Tunnistamista voivat lisäksi vaikeuttaa valaistusolosuhteet, maisema, osittainen peittyminen, variaatiot, haalistuminen sekä mittausepätarokkuudet. Tunnistamiseen liittyy kolme vaihetta, jotka ovat segmentointi, valinta ja havaitseminen. Yleensä liikennemerkit ovat RGB-värikoodattuja, joka on herkin värierottelutapa valaistuksen muutoksille.

Liikennemerkkien tunnistusmenetelmät voidaan jakaa väripohjaisiin ja muotopohjaisiin lähestymistapoihin. Segmentointi tehdään yleensä niiden värien perusteella. Merkin valinta ratkeaa taas muodon perusteella. Niiden havaitseminen tapahtuu taas säteittäisellä symmetriamuunnoksella, jolla voidaan tunnistaa mm. kolmio, neliö tai kahdeksankulmainen liikennemerkki. (Zhu et al., 2017) Autoissa käytetään tekniikkaa, jossa erilaisilla älykkäillä algoritmeilla pystytään tunnistamaan kuvasta liikennemerkit luotettavasti. Tässä hyödynnetään myös konvoluutiohermoverkon (CNN) syvällistä oppimista. Aluksi pyritään tunnistamaan liikennemerkin muoto, jonka jälkeen värierottelulla saadaan tarkempi tieto merkistä. (Frag, 2018)

Liikennemerkit ja -valot muodostavat oman visuaalisen kielen, jota itsestään ajavien autojen olisi kyettävä tunnistamaan (Kulkarni et al., 2018). Kuvien tunnistustekniikka on tärkeä tekoälyn ala. Tekniikalla voidaan tunnistaa esineitä kuvista, joka perustuu konvoluutioverkon (CNN) syvälliseen oppimiseen (Li, Q et al., 2020). Joissain tapauksissa voidaan jopa käyttää termiä tekoälyn oppiminen (teknologinen singulariteetti), koska auto pystyy itse oppimaan tunnistamaan kuvat paremmin.

RPFGE (Robust principal fuzzy subtraction method and gradient partial equation method) -menetelmällä kuvasta täytyy poimia ensin jokainen kuvapikseli erikseen, josta sitten poistetaan taustainformaatio sekä mahdolliset varjot. Tällä menetelmällä saada luettua esimerkiksi liikennemerkkien informaatio hyvinkin nopeasti autojen käyttöön. Tässä tekniikassa hyödynnetään sekä syväoppimista että sumeaa logiikkaa (Shakeel et al., 2018). Tämän tekniikan etuna nopeuden lisäksi on se, että se pystyy poistamaan heijastusten vaikutukset kuvainformaatioon.

Jalankulkijoiden liikkeitä pyritään seuraamaan reaaliaikaisesti moniobjektiseurannan avulla. Jokaisesta mahdollisesta jalankulkijasta luodaan ensin 2D-malli, jota sitten verrataan saatuun 3D-mallista saatuun projektiioon. Ongelmana tässä on etäisyys, sillä saatu tulos on sitä epätarkempi, mitä kauempana mahdollinen jalankulkija on. Lisäksi pyritään arvioimaan jalankulkijan nopeus ja etenemissuunta. Tässä käytetään hyväksi erilaisia matemaattisia malleja, jonka parametreinä käytetään sijaintia, nopeutta ja suuntaa. Näistä tässä käytetty menetelmä on ns. Frenét frames. Nopeudelle lasketaan ensin kuvista saadut 9 kuvasarjaa, joiden perusteella muodostetaan arvio seuraavasta sijainnista. Suunnan ar-

vioimiselle määritellään jalankulkijan asento, josta määritetään kaksi mahdollista vaihtoehtoa. Jos nämä poikkeavat hyvin paljon toisistaan, otetaan huomioon viimeiset yhdeksän sijaintimallia. Tilanne mutkistuu huomattavasti, jos esimerkiksi useampi jalankulkija aikoo ylittää suojatien. Auto pyrkii ennustamaan useiden muuttujien avulla jalankulkijoiden etenemisen suojatielle. Jos auto ehtii saavuttaa risteuksen ennen jalankulkijaa, se pääsääntöisesti olettaa, että jalankulkija ei aio ylittää silloin suojatietä. Ainoat tunnetut ongelmatilanteet ovat tulleetkin silloin, kun kaikesta ennustavuudesta huolimatta jalankulkija on kuitenkin astunut suojatielle aivan viime hetkellä. Itsestään ajavien automatiikka ei välttämättä vielä kykene ennustamaan täysin ihmisen käyttäytymistä. (Sarcinelli et al., 2019)

## 7 Keskustelu

Tutkimukset osoittivat, että hahmontunnistustekniikka erilaisten esteiden tunnistamiseen on kehittynyt hyvin pitkälle. Itse asiassa menetelmät ovat tällä hetkellä käytössä hyvin monissa uusissa autoissa. Kuvantunnistustekniikat kehittyvät edelleen, ja niiden nopeus kasvaa parempien algoritmien ansiosta (Prakash et al., 2019). Tämä tukee sitä oletusta, että itsestään ajavat autot pystyvät ihmistä nopeammin ja tarkemmin havainnoimaan ympäristöään. Tästä taas loogisesti seuraa se, että ne tekevät vähemmän virheitä kuin kuljettajat. Tämä taas vastaavasti tuo lisää turvallisuutta liikenteeseen.

Kaistanseurantatekniikka on myös olemassa ja sen avulla voidaan vähentää mahdollisia törmäystilanteita, joita saattaa syntyä monikaistaisilla teillä. Peruutustutkan, jota on käytetty jo vuosia, on tunnetusti todettu vähentävän peruutuskolareita. Itsestään ajavat autot ovat kiistattomasti parantamassa turvallisuutta kaupunkiliikenteessä. Aika näyttää, miten paljon niiden tulo tulee vaikuttamaan jatkossa myös kaupunkisuunnitteluun. Mobiiliverkkojen nopeutuminen avaa tietä riittävän nopealle tiedonsiirrolle, jota tulee todella paljon erilaisista auton antureista (Dmitriev, 2018). Tämä oli useiden tutkimusten mukaan juuri se suurin ”pullonkaula”, jonka takia itsestään ajavien autojen luotettavuutta vielä epäiltiin. Varmaa kuitenkin on, että tulemme näkemään hyvinkin pian itsestään ajavien autojen invaasion kaupunkiliikenteeseen, kun tämä suuren datamäärän siirtämisen ongelma saadaan ratkaistua.

Tämä tulee vaikuttamaan myös siihen, miten jo nyt kaupungin infrastruktuuria suunnitellaan ja toteutetaan tulevaisuudessa. Euroopassa on jo nyt useita ns. älykkäitä kaupunkeja, joiden risteysalueille on laitettu valmiiksi paljon erilaisia antureita ja tekniikkaa (Caragliu, 2011). Tampere on yksi näistä kymmenistä älykkäistä kaupungeista Euroopassa, jossa tätä infrastruktuuria on jo olemassa (Anttiroiko, 2016). Suomen olosuhteissa on vain hyvä muistaa, että meillä on hyvin paljon erilaisista säistä johtuvia rajoituksia. Itsestään ajavien auton tulee pystyä havainnoimaan ympäristöään hyvinkin tarkasti jopa

talvisissa lumisissa olosuhteissa. Tällä hetkellä on tutkimusnäyttöä, että vielä se voi osoitautua ylivoimaisen vaikeaksi (Shakeel, 2018). Kuvantunnistusmenetelmät toki parantuvat kaiken aikaa ja jää todellakin nähtäväksi, milloin näiden itsestään ajavien autojen yleistyminen maailmanlaajuisesti tulee lopulta tapahtumaan.

Erilaisissa testaustilanteissa itsestään ajavat autot reagoivat ihmistä nopeammin erilaisiin liikenteessä syntyviin tilanteisiin (Campbell et al., 2010). Ihmisen reaktioaika on paljon pidempi kuin erilaisilla antureilla varustetun auton. Lisäksi ihmisen kyky nähdä sivuilleen ja taakseen on paljon rajoittuneempi kuin erilaisilla kameroilla varustetulla autolla (Häne et al., 2017). Itsestään ajavien autojen intuitiivisuus on merkittävästi parantunut viime vuosina, joten auto pystyy entistä paremmin ennakoimaan liikenteessä syntyviä tilanteita (Fathi et al., 2018). Näillä kaikilla yllä mainituilla ominaisuuksilla on huomattavan suuri merkitys sille, että itsestään ajavat autot ovat jo nyt paljon turvallisempia kuin ihmisten kuljettamat autot. Tulevaisuudessa ero tulee vielä korostumaan, kun näihin autoihin tulee lisää tiedonsiirtokapasiteettia ja voidaan yhä tarkemmin mallintaa reaaliaikaisesti kaupunkiympäristöä (Gavanas, 2019). Tällä hetkellä eniten ongelmia erilaisten esteiden tunnistamiseen aiheuttavat haasteelliset sääolosuhteet liikenteessä (Fu et al., 2019). Ihmisen tarkkaavaisuus saattaa heikentyä huonon vireystilan takia, mutta itsestään ajavalla autolla tällaista ongelmaa ei ole olemassa. Tässä tutkielmassa tarkasteltavana olleet tutkimukset kiistattomasti osoittivat, että tulevaisuuden kaupunkiliikenne tulee olemaan huomattavasti nykyistä turvallisempaa.

## Lähdeluettelo

- Alhajja, H. A., Mustikovala, S. K., Mescheder, L., Geiger, A., & Rother, C. (2018). Augmented reality meets computer vision: Efficient data generation for urban driving scenes. *International Journal of Computer Vision*, 126(9), 961–972. <https://doi.org/10.1007/s11263-018-1070-x>
- Anttiroiko, A. V. (2016). City-as-a-platform: The rise of participatory innovation platforms in Finnish cities. *Sustainability*, 8(9), 922.
- Aria, M. (2019). A Survey of Self-driving Urban Vehicles Development. In *IOP Conference Series: Materials Science and Engineering* (Vol. 662, No. 4, p. 042006). IOP Publishing.
- Campbell, M., Egerstedt, M., How, J. P., & Murray, R. M. (2010). Autonomous driving in urban environments: approaches, lessons and challenges. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 368(1928), 4649–4672.



- Caragliu, A., Del Bo, C., & Nijkamp, P. (2011). Smart cities in Europe. *Journal of urban technology*, 18(2), 65–82.
- Carpenter, S. (2018). Autonomous Vehicle Radar: Improving Radar Performance with Simulation. *ANSYS [online]*. Canosburg: ANSYS [cit. 2019-05-01]. Dostupné z: <https://www.ansys.com/about-ansys/advantage-magazine>, 12.
- Dmitriev, S. (2017). Autonomous Cars Will Generate More than 300TB of Data per Year. *Tuxera*. (Haettu 26.2.20)
- Farag, W. (2018). Recognition of traffic signs by convolutional neural nets for self-driving vehicles. *International Journal of Knowledge-based and Intelligent Engineering Systems*, 22(3), 205–214. <https://doi.org/10.3233/KES-180385>
- Fathi, F., Abghour, N., & Ouzzif, M. (2018). From Big Data to Better Behavior in Self-driving Cars. In *Proceedings of the 2018 2nd International Conference on Cloud and Big Data Computing* (pp. 42–46). <https://doi.org/10.1145/3264560.3264572>
- Fu, J., Pertuz, S., Matas, J., & Kämäräinen, J. K. (2019). Performance analysis of single-query 6-DoF camera pose estimation in self-driving setups. *Computer Vision and Image Understanding*, 186, 58–73. <https://doi.org/10.1016/j.cviu.2019.04.009>.
- Garza, A. P. (2011). Look ma, no hands: wrinkles and wrecks in the age of autonomous vehicles. *New Eng. L. Rev.*, 46, 581. (Haettu 11.3.20)
- Gavanas, N. (2019). Autonomous Road Vehicles: Challenges for Urban Planning in European Cities. *Urban Science*, 3(2), 61.
- Hengstler, M., Enkel, E., & Duelli, S. (2016). Applied artificial intelligence and trust—The case of autonomous vehicles and medical assistance devices. *Technological Forecasting and Social Change*, 105, 105–120.
- Häne, C., Heng, L., Lee, G. H., Fraundorfer, F., Furgale, P., Sattler, T., & Pollefeys, M. (2017). 3D visual perception for self-driving cars using a multi-camera system: Calibration, mapping, localization, and obstacle detection. *Image and Vision Computing*, 68, 14–27. <https://doi.org/10.1016/j.imavis.2017.07.003>
- Kulkarni, R., Dhavalikar, S., & Bangar, S. (2018). Traffic Light Detection and Recognition for Self-Driving Cars Using Deep Learning. In *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (pp. 1–4). IEEE. <https://doi.org/10.1109/ICCUBEA.2018.8697819>

- Li, J., Bao, H., Han, X., Pan, F., Pan, W., Zhang, F., & Wang, D. (2017). Real-time self-driving car navigation and obstacle avoidance using mobile 3D laser scanner and GNSS. *Multimedia Tools and Applications*, 76(21), 23017–23039. <https://doi.org/10.1007/s11042-016-4211-7>
- Li, Q., He, T., & Fu, G. (2020). Judgment and optimization of video image recognition in obstacle detection in intelligent vehicle. *Mechanical Systems and Signal Processing*, 136, 106406. <https://doi.org/10.1016/J.YMSSP.2019.106406>
- Lubben, A. (2019). Self-driving Uber killed a pedestrian as human safety driver watched. *Vice News*. (Haettu 27.2.20)
- NHTS (2008). National motor vehicle crash causation survey: Report to congress. *National Highway Traffic Safety Administration Technical Report DOT HS, 811, 059*. (Haettu 10.3.20)
- Prakash, C. D., Akhbari, F., & Karam, L. J. (2019). Robust obstacle detection for advanced driver assistance systems using distortions of inverse perspective mapping of a monocular camera. *Robotics and Autonomous Systems*, 114, 172–186. <https://doi.org/10.1016/j.robot.2018.12.004>
- Rao, Q., & Frtunikj, J. (2018). Deep learning for self-driving cars: chances and challenges. In *Proceedings of the 1st International Workshop on Software Engineering for AI in Autonomous Systems* (pp. 35–38).
- Sarcinelli, R., Guidolini, R., Cardoso, V. B., Paixão, T. M., Berriel, R. F., Azevedo, P., De Souza, A., Badue, C. & Oliveira-Santos, T. (2019). Handling pedestrians in self-driving cars using image tracking and alternative path generation with frenét frames. *Computers & Graphics*, 84, 173–184. <https://doi.org/10.1016/j.cag.2019.08.004>
- Shah, V. R., Maru, S. V., & Jhaveri, R. H. (2016). An obstacle detection scheme for vehicles in an intelligent transportation system. *International Journal of Computer Network and Information Security*, 8(10), 23. <https://doi.org/10.5815/ijcnis.2016.10.03>
- Shakeel, P. M., Arunkumar, N., & Abdulhay, E. (2018). Automated multimodal background detection and shadow removal process using robust principal fuzzy gradient partial equation methods in intelligent transportation systems. *International Journal of Heavy Vehicle Systems*, 25(3–4), 271–285. <https://doi.org/10.1504/IHVS.2018.094824>

- Urmson, C. (2008). Self-driving cars and the urban challenge. *IEEE Intelligent Systems*, 23(2), 66-68. <https://doi.org/10.1109/MIS.2008.34>
- Zheng, X., Huang, B., Ni, D., & Xu, Q. (2018). A novel intelligent vehicle risk assessment method combined with multi-sensor fusion in dense traffic environment. *Journal of Intelligent and Connected Vehicles*. <https://doi.org/10.1108/JICV-02-2018-0004>
- Zhu, H., Yuen, K. V., Mihaylova, L., & Leung, H. (2017). Overview of environment perception for intelligent vehicles. *IEEE Transactions of Intelligent Transportation Systems*, 18(10), 2584-2601. <https://doi.org/10.1109/TITS.2017.2658662>