

# **Sensorit autonomisissa autoissa**

Tietotekniikka  
Tietotekniikan laitos, Teknillinen tiedekunta  
Kandidaatintutkielma

Laatija:  
Joni Korkalainen

Joulukuu 2024

Turun yliopiston laatujärjestelmän mukaisesti tämän julkaisun alkuperäisyys on tarkastettu  
Turnitin OriginalityCheck -järjestelmällä.

**Kandidaatintutkielma**  
**Tietotekniikan laitos, Teknillinen tiedekunta**  
**Turun yliopisto**

**Tutkinto-ohjelma:** Tietotekniikka  
**Tekijä:** Joni Korkalainen  
**Otsikko:** Sensorit autonomisissa autoissa  
**Sivumäärä:** 21 sivua, 4 liitesivua  
**Päivämäärä:** Joulukuu 2024

Autonomiset autot kykenevät liikkumaan liikenteessä täysin itsenäisesti pitkälti sensorien ansiosta. Tutkielmassa perehdytään autonomisiin autoihin, niiden sensoreihin, sensoreiden rooleihin ajotehtävissä sekä autojen kohtaamiin haasteisiin. Tutkielma on suoritettu kirjallisuuskatsauksena, jonka aineistot ovat pääosin tutkimusartikkeleja ja konferenssijulkaisuja. Täysin autonomista autoa ei ole kehitetty, mutta useimmissa uusissa autoissa esiintyy jonkin tasoista autonomiaa. Auton ajojärjestelmässä on alettu hyödyntää tekoälyn alahaaraa, syväoppimista. Autonomisten autojen uskotaan lisäävän liikenteen turvallisuutta, sillä inhimillisistä ajovirheistä johtuvia liikenneonnettomuuksia ei tapahdu.

Tutkielmassa tarkastellut sensorit ovat valotutka, tutka, ultraäänisensori, maailmanlaajuinen satelliittipaikannusjärjestelmä, inertiaalinen mittaussyksikkö sekä kamera eri versioineen. Jokaisella sensorilla on omat vahvuudet, heikkoudet sekä käyttökohteet. Ajotehtävistä suoriutumiseen autonominen auto tarvitsee usean eri sensorin käyttöä. Autonomisessa autossa sensoreiden tuottama data yhdistetään sensorifuusiolla, jolloin yksittäisten sensorien heikkoudet voidaan ehkäistä. Sensorifuusio on autonomisen ajamisen toteuttamiseksi pakollista, sillä mikään yksittäinen sensorityyppi ei suoriudu yksin kaikista ajotehtävistä.

**Asiasanat:** Autonominen auto, sensori, sensorifuusio

# **Sisällysluettelo**

<b>1</b>	<b>Johdanto</b>	<b>1</b>
1.1	Tutkimuskysymykset	1
1.2	Metodologia	2
<b>2</b>	<b>Autonomisissa autoissa käytetyt sensorit</b>	<b>3</b>
2.1	Kamera	5
2.2	Valotutka	7
2.3	Tutka	9
2.4	GNSS	10
2.5	Ultraäänisensori	11
2.6	Inertiaalinen mittausyksikkö	12
<b>3</b>	<b>Sensoreiden hyödyntäminen autonomisissa autoissa</b>	<b>13</b>
3.1	Haasteita autonomisten autojen kehityksessä	16
3.2	Syväoppiminen	17
<b>4</b>	<b>Yhteenveto</b>	<b>20</b>
	<b>Lähteet</b>	<b>22</b>

# 1 Johdanto

Tietyn tasoisia autonomisia ajoneuvoja esiintyy jo liikenteessä. Autolla tarkoitetaan tutkielmassa henkilöautoa, mikäli sitä ei ole muuten mainittu. Autonomisten ajoneuvojen kehitys kulkee kohti täysin autonomisten autojen luomista. Tällaiset ajoneuvot pystyisivät toimimaan kaikissa tilanteissa täysin itsenäisesti, ilman kuljettajan väliintuloa. Yhtenä tärkeimpänä motiivina aiheen tutkimukselle ovat liikenneonnettomuudet. Liikenneonnettomuudet ovat kahdeksanneksi suurin ei-luonnollisista kuolinsyistä maailmanlaajuisesti (Yeong ym. 2021). Euroopassa vuosittain tapahtuvista liikenneonnettomuuksista 90 % johtuu ihmisten tekemistä virheistä (Yeong ym. 2021). Autonomisia autoja pidetään erinomaisena ratkaisuna liikenneonnettomuuksien ehkäisemiseksi. Autonomisten autojen avulla ammattiliikenteen kuljetuskustannuksia saadaan vähennettyä. Tällaiset taksit ja rekat eivät tarvitse kuljettajaa, jolloin henkilöstökulut vähenevät. Täysi autonomia mahdollistaa myös esimerkiksi liikuntarajoitteisten ihmisten kulkemisen omalla autonomisella autollaan.

Sensorit luovat välttämättömän pohjan autonomisten autojen toiminnalle. Tutkielmassa käsiteltävät sensorit ovat laitteita, joilla autonomiset autot havainnoivat ympäristöään ja auton eri tiloja. Sensorit muuntavat havainnoimiansa tapahtumia numeerisiksi mitoiksi, joita voidaan puolestaan prosessoida (Ignatious ym. 2022). Sumalatha (ym. 2024) toteaa, että autonomiset autot käyttävät useita erityyppisiä sensoreita autonomian saavuttamiseksi. Heidän mukaansa osa sensoreista toimii loistavasti tietyissä tehtävissä, kun taas joihinkin tehtäviin ne eivät sovellu.

Tutkielmassa käydään läpi autonomisten autojen toimintaa, niissä esiintyviä sensoreita sekä niiden toimintaa. Tutkielma on suoritettu kirjallisuuskatsauksena käyttäen aiheeseen liittyvää kirjallisuutta. Käytetyt lähteet ovat lähtökohtaisesti tieteellisiä artikkeleja, konferenssijulkaisuja sekä muita aiheesta tehtyjä kirjallisuuskatsauksia. Tutkielman 2 luvussa käsitellään edellytyksiä ja tehtäviä autonomisen auton toiminnalle. Auton toiminta edellyttää sensorien käyttöä ja luvussa on käsitelty myös tarkasteltavien sensorien tyyppejä sekä tehtäviä. Luvussa 3 tarkastellaan sensoreita, joiden avulla saavutetaan autonomiaa. Sensorien toimintaa, käyttökohteita sekä heikkouksia tarkastellaan sensorikohtaisesti. Käsittelyssä ovat kamera, valotutka, tutka, ultraäänisensori, maailmanlaajuinen satelliittijärjestelmä ja inertiaalinen mittausyksikkö. Luku 4 keskittyy käsittelemään autonomisten autojen toimintaa ja sensorien hyödyntämistä autonomian saavuttamiseksi. Luvussa käsitellään myös syväoppimista ja autonomista autoa kohtaavia haasteita.

## 1.1 Tutkimuskysymykset

Tutkielma keskittyy käsittelemään markkinoilla olevia sensoreita, niiden toimintaa ja tehtäviä, mahdollisia sensoriratkaisuja sekä sensoreiden hyödyntämistä autonomisissa autoissa.

Tutkielman tutkimuskysymykset:

TK1: Minkälaisia sensoreita autonomisissa autoissa on, miten ne toimivat ja mitä tehtäviä niillä on?

Autovalmistajien päätökset eri sensorien käytöstä vaihtelevat. Tutkielmassa käydään läpi yleisimmin käytössä olevat autonomisten autojen sensorit, niiden toiminta ja annetaan taustaa erilaisille sensorivalinnoille.

TK2: Miten sensoreita hyödynnetään autonomisissa autoissa?

Sensorit itsessään ovat vain laitteita, joilla voidaan havainnoida ympäristöä ja erilaisia tiloja, mutta vasta niiden yhteiskäyttö mahdollistaa autonomian autoissa. Eri sensoreilla on eri tehtävät ja sensortyyppäjä yhdistelemällä saadaan monimuotoisempaa dataa ja tietoisuutta.

## 1.2 Metodologia

Aineistojen etsimiseen käytin pitkälti Volteria sekä IEEE:n (Institute of Electrical and Electronics Engineers) nettisivuja. Joukossa on myös muualta löydettyjä lähteitä, kuten Traficomin tiedonantosisivu. Päähakulausekkeeni oli ”autonomous vehicles AND sensor fusion”, jonka avulla löysin pääaineistoni. Muiden aineistojen etsimiseen käytin hakusanoja ”autonomous vehicles”, jonka perään lisättynä kulloinkin tarkasteltavan asian aihepiiri.

## 2 Autonomisissa autoissa käytetyt sensorit

Autonomisella autolla tarkoitetaan ajoneuvoa, joka pystyy liikkumaan erilaisissa ympäristöissä täysin itsenäisesti. Tämä edellyttää ympäristön havainnointia, tietoa omasta tilasta sekä itsenäistä päätöksentekoa. Ympäristön havainnointi kuin myös tietoisuus omasta tilasta tapahtuu mittaamalla dataa erilaisilla sensoreilla. Auton järjestelmä tulkitsee ja prosessoi tätä dataa tekoälyn sekä erilaisten algoritmien avustuksella ja tekee sen pohjalta itsenäisiä päätöksiä liikenteessä. (Yeong ym. 2021)

Autot voidaan autonomisten ominaisuuksiensa mukaan lajitella eri luokkiin. Luokittelu alkaa tavallisista autoista, jotka ovat täysin kuljettajansa ohjaamia. Luokittelu jatkuu porrastetusti aina täysin autonomisiin autoihin saakka. Luokittelun on laatinut SAE (Society of Automotive Engineers) ja se on havainnollistettu kuvassa 2.1. Monissa uusissa autoissa on vain tason 1 sekä 2 autonomiaa johtuen rajoitteista ja markkinoilla olevien sensoreiden korkeista hinnoista (Brummelen ym. 2018). Vain murto-osa liikenteessä olevista autoista sisältää tason 3 tai korkeampaa autonomiaa (Sethi ym. 2023). Waymo tarjoaa tason 4 taksipalveluita ja heidän autoillaan tapaturmaan johtaneita kolareita syntyi 0.6 miljoonaa ajettua mailia kohti (Kusano ym. 2024). Tilastoista myös selviää, että ihmiskuljettajalla tämä luku on 2.8, joka on lähestulkoon viisi kertaa korkeampi. Tason 4 autot ovat vain taksikäytössä ja tason 5 autonomista autoa ei ole vielä toteutettu.

Taulukko 2.1: Autonomisen ajamisen tasot. Muokattu lähteistä (SAE International 2021, Yeong ym. 2021)

SAE taso	Tason nimi	Kuljettajan rooli	Kuvaus	Ominaisuuksia
0	Ei automaatiota	Täysi vastuu ajamisesta	Kuljettaja on täysin vastuussa auton ajamisesta eli jarruttamisesta, ohjaamisesta, kiihdyttämisestä sekä ympäristön tarkkailusta.	Lukkiutumattomat jarrut (engl. anti-lock braking system, ABS), luistonesto (engl. traction control system, TCS)
1	Kuljettajaa avustavat	Lähes täysi vastuu ajamisesta	Kuljettaja huolehtii joko auton pituussuuntaisesta tai poikittaisesta ohjaamisesta.	Mukautuva vakionopeuden-säädin tai kaistavahti
2	Osittainen automaatio	Täytyy valvoa järjestelmän toimintaa	Auto huolehtii pituussuuntaisesta sekä poikittaisesta ohjaamisesta.	Mukautuva vakionopeuden-säädin ja kaistavahti
3	Kohtalainen automaatio	Täytyy olla valmiina ottamaan ohjat, mikäli järjestelmä ilmoittaa	Auto pystyy ajamaan itsenäisesti tietyissä, rajoitetuissa olosuhteissa.	Autonomisuus moottoreilla, ruuhka-ajon avustin
4	Korkea automaatio	Ajaminen on enää pelkästään vaihtoehto	Auto pystyy ajamaan itsenäisesti, kunhan ajoympäristö on määritelty ja rajattu.	Autonomisuus poissulkien vaikeat ja tuntemattomat ympäristöt
5	Autonominen	Ei tarvita	Auto pystyy ajamaan täysin itsenäisesti, missä tahansa tilanteissa sekä olosuhteissa.	Auton autonominen ajaminen kaikissa olosuhteissa

Yeong (ym. 2021) jakaa autonomisten autojen sensorit kahteen kategoriaan niiden toimintaperiaatteensa mukaan: sisäiset sensorit vahtivat ja mittaavat auton sisäistä tilaa ja ulkoiset sensorit puolestaan auton ulkopuolista ympäristöä. Heidän mukaansa sisäiset sensorit mittaavat esimerkiksi pyöräkuormaa (engl. wheel load), akun jännitettä sekä kulmanopeutta (engl. angular rate). Tällaisia sensoreita ovat inertiaa mittaavat (engl. Inertia Measurement Units, IMU) kiihtyvyyssanturit, gyroskoopit ja magnetometrit sekä paikannukseen käytettävän satelliittipaikannusjärjestelmän (engl. Global Navigation Satellite Systems, GNSS) vastaanottimet. Tässä työssä tarkoitan inertialla auton kykyä vastustaa liiketilan muutoksia.

Yeongin (ym. 2021) kategorisoinnin mukaan ulkoiset sensorit mittaavat ja havainnoivat auton ulkopuolisia asioita. Ne mittaavat muun muassa etäisyyksiä muihin objekteihin, kuten toisiin ajoneuvoihin, jalankulkijoihin ja rakennuksiin. Autonomisissa autoissa käytettäviä ulkoisia sensoreita

ovat kamerat, valotutkat (engl. Light Detection and Ranging, LiDAR), tutkat (Radio Detection and Ranging, Radar) sekä ultraäänisensorit. Käsittelen sisäiset sekä ulkoiset sensorit tarkemmin tulevissa aliluvuissa 2.1–2.6.

Ulkoisen ja sisäisen kategorian lisäksi sensorit voidaan jakaa vielä passiivisiin tai aktiivisiin sensoreihin. Jaottelu perustuu sensorin vuorovaikutukseen ympäristönsä kanssa. Passiiviset sensorit vastaanottavat ympäristöstä tulevaa energiaa, kuten lämpösäteilyä ja valoa. Vastaanotetun energian avulla luodaan mittatuloksia ja päätöksiä. Aktiiviset sensorit lähettävät energiaa ympäristöönsä ja mittaavat ympäristön reaktion lähetettyyn energiaan. Lähetetty energia on riippuvainen tarkastellusta sensorista. Valotutkat lähettävät laservaloa, tutkat radioaaltoja ja ultraäänisensorit ääniaaltoja. (Yeong ym. 2021) Oman tulkintani mukaan eroavaisuudeksi voidaan katsoa aktiivisten sensoreiden olevan vuorovaikutuksessa ympäristönsä kanssa siinä missä passiivisten sensoreiden kohdalla vuorovaikutus on vain yhdensuuntaista.

Autonominen auto vaatii toimiakseen useita eri tyyppin sensoreita. Yhden yksittäisen tyyppin sensorit eivät riitä, sillä ympäristöstä ja auton sisäisestä tilasta tulee mitata paljon monimuotoista dataa. Xiangin (ym. 2023) mukaan useamman kuin yhden sensorin datan yhdistämistä kutsutaan sensorifuusioksi. Heidän mukaansa fuusioalgoritmeissa on yleistä yhdistää 2D-kuvadataa sekä tutkilla saatua 3D-pistedataa. Tutkielmassa esitellään myös kameran sekä tutkan fuusio, jossa kameran värikäs, korkeatekstuurinen ja kohteita kategorisoiva kuva yhdistetään tutkan antamiin muotoihin ja etäisyyksiin. Näiden tietojen perusteella voin todeta, että sensorifuusion avulla auton ympäristöstä saadaan luotua moniulotteisempi kuva.

## 2.1 Kamera

Kamera on passiivinen sensori, joka havaitsee ympäristöstä saapuvaa valoa, josta muodostetaan kaksiulotteisia kuvia (Yao ym. 2023). Oikealla ohjelmistolla kamerat voivat tunnistaa liikkuvia sekä staattisia kohteita (Yeong ym. 2021). Autonomisissa autoissa kameraa käytetään tunnistamaan liikennemerkkejä ja -valoja, tiemerkintöjä ja erilaisia tiellä esiintyviä esteitä (Yeong ym. 2021, Yao ym. 2023). Kamerat ovat halpoja sensoreita, minkä takia niitä käytetään laajasti autojen massatuotannossa (Ignatiou ym. 2022, Yao ym. 2023).

Yhtenä kameran heikkoutena voidaan pitää sen kykyä muodostaa pelkästään kaksiulotteisia kuvia. Kahden kameran avulla voidaan kuitenkin muodostaa kolmiulotteisia kuvia, ja tällaiseen pystyvää kameraa kutsutaan stereokameraksi. Stereokamera jäljittelee eläinten syvyysnäköä. Siinä käytetään kahta kameraa, jotka kuvaavat samaa asiaa eri suunnista, tietyn etäisyyden päässä toisistaan. Stereokameralla luodaan eroavaisuuskarttoja, joita puolestaan käytetään syvyyskarttojen luomiseen. Eroavaisuuskartoissa verrataan kahden eri kuvan eroavaisuuksia, kun tarkasteltavaa asiaa katsotaan eri

kulmista. Syvyyskartoista pystytään tulkitsemaan eri kohteiden välisiä etäisyyksiä, sillä kartan pikselien väliset etäisyydet tiedetään. (Yeong ym. 2021)

Kameralta ei kuitenkaan aina vaadita 3D-näkymän luomista. Tällöin Yaon (ym. 2023) mukaan todelliseksi heikkoudeksi muodostuvat vaihtelevat sääolosuhteet. He jatkavat kertomalla huonojen sääolosuhteiden, kuten myrskyjen ja sateen sekä huonon valaistuksen vaikuttavan merkittävästi kuvien laatuun ja tarkkuuteen. Julkaisussa myös kerrotaan, että sääolosuhteet voivat luoda myös vääristymiä kameroiden näkökenttiin, jolloin niistä saatu data on myös vääristynyttä. Mikäli auto tekee nopeita liikkeitä, kameran on vaikea saada tarkkaa kuvaa (Li ym 2023). Heidän mukaansa ongelma esiintyy kaikissa perinteisissä kameroissa ja siitä käytetään nimitystä liikkeen sumentuminen (engl. motion blur).

Ympäristön havainnointiin käytetään usein myös kalansilmäkameraa. Tällaisen kameran etuna on sen tuottama laajempi kuvakulma. Neljällä kalansilmäkameralla saadaan kuvattua 360 asteen näkymä. Ultralaajan linssin seurauksena kameralla kuvattu data on vääristynyttä, eikä sitä voida suoraan käyttää. Vääristymät liittyvät havainnoitujen objektien mittasuhteisiin ja etäisyyksiin. Mittasuhteiden korjaamiseksi kamera vaatii jatkuvaa kalibrointia. (Yeong ym. 2021)

Infrapunakameran toimintaperiaate poikkeaa aikaisemmin käsitellyistä kameroista. Infrapunakamerat toimivat hyödyntämällä infrapunasäteitä, kun tavalliset kamerat puolestaan käyttävät näkyvää valoa. Infrapunakameroiden käyttämä aallonpituus on 780 nanometristä 1 millimetriin. Edukseen infrapunakamerat ovat huonoissa sääolosuhteissa. Infrapunakamerat toimivat tavallisia kameroita paremmin tilanteissa, joissa valoisuus on todella suurta, kuten esimerkiksi tunnelista poistuttaessa. Tämä johtuu siitä, että niiden toiminta ei perustu näkyvään valoon. Käyttökohteita infrapunakameralle ovat sen lämpötilantunnistuksen ansiosta ihmisten sekä eläinten tunnistus ja kategorisointi. (Vargas ym. 2021) Li (ym.) toteaa, että infrapunakameralla voidaan tunnistaa myös elottomia asioita, kuten vastaantulevia autoja, joiden moottoreista säteilee lämpöä.

Infrapunakameraa käytetään tarkkailemaan kuljettajan tilaa auton sisällä. Euroopassa hyväksyttiin autojen turvallisuutta koskeva lakiesitys General Safety Regulation vuonna 2019. Vuodesta 2022 lähtien valmistetuissa autoissa tulee olla kuljettajan tilaa valvova järjestelmä (engl. driver monitoring system, DMS). Infrapunakamera on keskeisessä roolissa tämän järjestelmän toteuttamisessa. Autoissa olevat infrapunakamerat eivät ole haitallisia ihmissilmälle ja niiden avulla seurataan kuljettajan naamaa ja etenkin silmiä. DMS-järjestelmä on tärkeä, sillä täysin autonomisia autoja ei vielä ole ja keskimäärin 25 % liikenneonnettomuuksista johtuu kuljettajan tarkkaamattomuudesta. Järjestelmä keskittyy kuljettajan vireystilaan sekä katseen seurantaan. (Li ym 2023)

Perinteisillä kameroilla saadaan korkean resoluution kuvaa ja videota, jotka kertovat tietoa ympäristön väreistä sekä tekstuureista. Kalansilmä-, stereo- ja infrapunakameroilla on puolestaan omat ominaisuutensa. Riippuvuus hyvistä sääolosuhteista koituu kuitenkin useimpien kameroiden haitaksi. Kamerat ovat kuitenkin hyvin yleisiä ja Yeongin (ym. 2021) mukaan eri tyyppin kameroita on kaikissa

autonomisissa ajoneuvoissa. He myös painottavat, että luotettavan ja oikeellisen datan tuottamiseksi kameroiden data yhdistetään usein muiden, kuten tutkan sekä valotutkan kanssa.

## 2.2 Valotutka

Valotutka (engl. Light Detection and Ranging, LiDAR) on aktiivinen sensori ja pystyy toteutustavasta riippuen havainnoimaan ympäristöään jopa 360 asteen näkyvyydellä, 0.3–245 metrin etäisyydellä jopa 2 senttimetrin tarkkuudella (Ignatious ym. 2022). Yeongin (ym. 2021) mukaan valotutkan toiminta perustuu siitä lähetettyihin valopulsseihin ja toimintaperiaatteesta käytetään nimeä lentoajan mittaaminen (engl. Time-of-Flight, ToF). He jatkavat kertomalla valotutkan toimintaperiaatteen. Siinä järjestelmä lähettää laserdiodistaan valopulsseja ympäristöönsä ja tämän jälkeen järjestelmä vastaanottaa valopulssit niiden heijastuessa takaisin. Lentoaika mitataan ja kuluneen ajan perusteella saadaan laskettua matka mitattuun objektiin. Menetelmä on havainnollistettu tekemässäni kuvassa 2.3.

Ignatious (ym. 2022) jakaa valotutkan lähettämät valopulssit infrapuna- ja lasersäteisiin. He kertovat valotutkan tuottaman datan koostuvan yksittäisistä mittapisteistä, jotka muodostavat pistepilviä (engl. point cloud data). Yeong (ym. 2021) sekä Ignatious (ym. 2022) kertovat pistepilvien sisältävän skannattujen objektien x-, y-, ja z-koordinaatit sekä heijastusten intensiteettitiedot. Ignatiouksen (ym. 2022) mukaan intensiteettitiedot kertovan kuinka voimakkaalla intensiteetillä objektit heijastavat valopulssit takaisin järjestelmän lähettimeen. Eri materiaalien kerrotaan heijastuvan eri intensiteeteillä, minkä avulla objektit voidaan kategorisoida intensiteettitietojensa perusteella. Kumarin (ym. 2023) julkaisussa tuodaan esille valotutkan soveltuvan ympäristöistä muodostettavien 3D-karttojen luomiseen sen pistepilvityyppisen datan ansiosta.

Valotutkat voidaan kategorisoida rakennustapansa mukaan kahteen luokkaan. Staattiset tutkat (engl. solid-state LiDAR) ovat kiinnitetty autonomisissa autoissa esimerkiksi auton keulaan, ja ne skannaavat ympäristöään vain tiettyyn, ennalta määriteltyyn suuntaan. Mekaaniset tutkat (engl. mechanical LiDAR) ovat kiinnitetty pyörivään moottoriin, jonka avulla järjestelmällä voidaan skannata vaakatasossa auton ympäristö täysin. (Vargas ym. 2021) Voidaan huomata, että autonomiseen autoon tulisi valita joko staattinen tai mekaaninen valotutka. Tämä johtuu siitä, että mekaaninen valotutka pystyy itsessään jo havainnoimaan kaikkiin suuntiin.

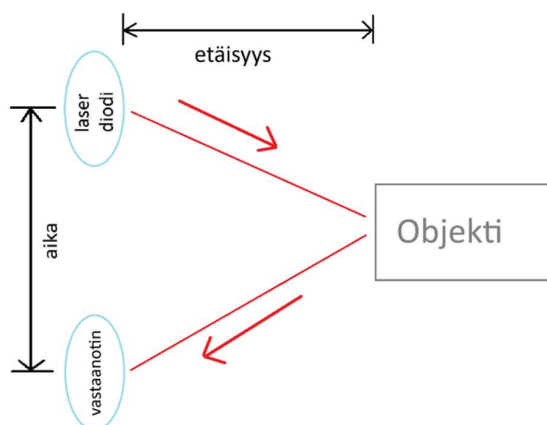
Mekaaninen valotutka on suosituin pitkän matkan havainnoimiseen käytetty sensori (Yeong ym. 2021). Vargasin (ym. 2021) mukaan sen moottori pyörii noin 300–900 kierrosta minuutissa, ja pyörivän moottorin ansiosta lasersäteillä saadaan muodostettua 360-asteen näkyvyys vaakatasossa. Pyörimisen takia sen kerrotaan olevan melko altis mekaanisille vioille. Yeong (ym. 2021) jatkaa kertomalla näkökentän olevan pystysuunnassa vain noin 27–41-astetta. Nam (ym. 2021) kertoo mekaanisen valotutkan olevan hyvin kallis. Yeong (ym. 2021) toteaa, että korkeasta hinnasta huolimatta tämä ympäristönsä täysin skannaava valotutka on autonomisiin autoihin yleisemmin valittu

versio. Lopuksi valinnan syiksi kerrotaan laajempi havainnointikenttä, pidempi havainnointietäisyys sekä parempi syvyyksien havainnointi.

Nam (ym. 2021) sekä Vargas (ym. 2021) toteavat, että mekaanisesta versiosta poiketen staattinen valotutka ei pyöri, vaan on suunnattu yhteen suuntaan. Namin (ym. 2021) mukaan tämä mahdollistaa halvemman valmistushinnan, sillä mekaanisia komponentteja ei ole. Yeongin (ym. 2021) julkaisusta selviää, että staattisen version näkökenttä on vaakasuunnassa sensorivalmistajasta ja mallista riippuen enintään 120-astetta ja pystysuunnassa 25-astetta. Li (ym. 2021) kertovat monen autovalmistajan kehittävän ja suunnittelevan staattisia valotutkia autoihinsa. Heidän mukaansa autovalmistajat perustelevat valintaansa mekaanisesti kestävämmällä rakenteella, sekä halvemalla valmistushinnalla. Aiemman perusteella voidaan todeta, että ilman mekaanisia komponentteja staattinen tutka on vähemmän altis vioille.

Kameroihin verrattuna valotutkat eivät tulkitse värejä ympäristöstä, ja valotutkat ovat myös sellaisenaan riittämättömiä kohteentunnistuksessa (Li ym. 2020). Yao (ym. 2023) sekä Yeong (ym. 2021) toteavat myös saman ja kertovat kameran ja valotutkan yhteiskäytön eli fuusion tulleen suosituksi viime vuosina. Bastos (ym. 2021) kertoo autonomisissa autoissa käytettävien valotutkien tehonkäytön olevan rajoitettu, jotta lasersäteet eivät vahingoittaisi silmiä. Heidän mukaansa tehonkäyttöä joudutaan rajoittamaan myös liiallisen virrankulutuksen ehkäisemiseksi.

Sumalathan (ym. 2024) sekä Yaon (ym. 2023) toteavat valotutkien olevan sensoreina kalliita, mikä on puolestaan vaikeuttanut niiden käyttämistä autonomisissa autoissa. Sumalatha (ym. 2024) huomauttaa, että sensorin optimaalinen toiminta estyy huonoissa sääolosuhteissa, sekä ympäristöissä, joissa heijastuspinnat ovat huonot. Aikaisemmassa aliluvussa todettiin myös kameran kärsivän huonoista sääolosuhteista. Tämä tarkoittaa, että autonomiset autot tarvitsevat sääolosuhteista riippumattoman sensorin toimiakseen täysin autonomisesti.



Kuva 2.2: Valotutkaan sovellettava lentoaika (ToF). Muokattu lähteestä (Vargas ym. 2021)



Kuva 2.3: Velodynen valmistama mekaaninen valotutka HDL-64E (Lidar, 2016)

## 2.3 Tutka

Tutka tunnistaa ympäristöstään objekteja ja niiden nopeuksia käyttäen radioaaltoja. Sen lähettämien radioaaltojen osuessa kohteisiin radioaallot heijastuvat takaisin tutkan vastaanottiin. Valotutkan tavoin etäisyyksien laskeminen tapahtuu lentoaikaa mittaamalla, mutta valotutkasta poiketen lähetetyt signaalit ovat radioaaltoja. Tutka mahdollistaa kohteiden suhteellisten nopeuksien mittaamisen Doppler-ilmiön avulla. Mikäli kohde ja tutka liikkuvat suhteessa toisiinsa, kohteesta heijastuneen aallon taajuus eroaa lähetetyn aallon taajuudesta ja kohteen suhteellinen nopeus voidaan laskea näiden avulla. (Yao ym. 2023)

Trafficom (2023) kertoo tutkien olevan laajalti käytössä edistyksellisten kuljettajaa avustavien järjestelmien (engl. Advanced Driving Assistance Systems, ADAS) sovelluksissa. Järjestelmän kerrotaan sisältävän törmäyksienestojärjestelmän, mukautuvan vakionopeudensäätimen, kaistavahdin ja automaattisen hätäjarrutuksen. Totean tutkan olevan aktiivinen sensori, sillä se lähettää ympäristöönsä radioaaltoja.

Autonomisten autojen tutkat toimivat 24, 74, 77 ja 79 GHz:n taajuuksilla. Taajuudet ovat jaettu käytettäväksi lyhyen (engl. short-range, SRR), keskipitkän (engl. medium-range, MRR) sekä pitkän (engl. long-range, LRR) kantaman tutkissa. Pisimmän kantaman tutkaa käytetään havaitsemaan kaukana sekä auton edessä olevia asioita ja mukautuvassa vakionopeudensäätimessä. Lyhyen kantaman tutkaa käytetään pysäköinnin avustuksessa sekä törmäysten varoittimissa. Keskipitkän kantaman tutkalla vahditaan mahdollisia auton sivusta ja takaa tulevia kolareita, sekä auton kuollessa kulmassa (engl. blind-spot) olevia autoja. (Vargas ym. 2021, Yeong ym. 2021)


Autonomisissa autoissa tutkien sijainnit sekä kiinnitykset ovat kriittisiä oikeiden havaintojen varmistamiseksi. Auton tuotantovaiheessa tutkien asennuskulmien ja paikkojen oikeellisuudesta pitää olla varmoja. Pienetkin heitot voivat johtaa vakaviin seurauksiin, kuten ympäristön vääriin tulkintoihin. Väärät tulkinnat voivat johtaa onnettomuuksiin ja kolareihin. Tutkat onkin usein piilotettu pois näkyvistä autoa tarkasteltaessa ulkoapäin. Tässä yhteydessä piilottaminen suojaa sensoreita erilaisilta osumilta sekä liikahtamisilta. Tutkat sijaitsevat yleisesti tuulilasin yläreunassa ja etu- sekä takapuskurissa. (Yeong ym. 2021)

Tutkien sähkömagneettiset aallot eivät juuri vaimene ilmakehässä ja ne läpäisevät hyvin sadetta, savua ja pölyä. Tutkilla on kuitenkin myös omat heikkoutensa. Niissä on matala resoluutioinen erotuskyky, joka puolestaan vaikeuttaa lähellä toisistaan olevien objektien tunnistamista. Havainnoista muodostetut pistepilvet sisältävät vain vähän pisteitä, minkä vuoksi objektien ääri viivoja ei pystytä muodostamaan. Tutkan, valotutkan ja kameran tuottamaa dataa on esitetty kuvassa 2.4. Kuvasta voidaan huomata, että valotutkan tuottama pistepilvi on paljon informatiivisempi ja siitä voi ihmissilmällä päätellä kohteen olevan ihminen. Valotutkan muodostamassa pistepilvessä näkyy objektin selkeitä ulkorajoja, kun taas tutkan pistepilvi on hyvin epämääräinen. Tutkien tuottamassa datassa esiintyy paljon kohinaa, joka vaikeuttaa datan


tulkitsemista. Kuvassa 2.4 kohinaa ei kuitenkaan juuri esiinny, sillä tilanne on taltioitu sisätiloissa. Kohinalle on useita syitä, kuten muista sähkölaitteista tulevat häiriöt sekä radiosignaalien ei-halutut heijastumiset. Lisäksi tutkat ovat huonoja paikallaan olevien objektien tunnistamisessa. (Yao ym. 2023)



(a)



(b)



(c)

Kuva 2.4: Kameran kuva sekä tutkan ja valotutkan pistepilvet samasta kävelijästä samalla ajanhetkellä. (Cheng ym. 2021)

## 2.4 GNSS

Maailmanlaajuinen satelliittipaikannusjärjestelmä (engl. Global Navigation Satellite System, GNSS) on käytetyin teknologia tarkan paikkatiedon hankkimiselle ja niistä tunnetuin on Yhdysvaltojen Global Positioning System (GPS) (Campbell ym. 2018). Muita merkittäviä järjestelmiä ovat venäläinen GLONASS, eurooppalainen Galileo sekä kiinalainen BeiDou (Joubert ym. 2020). Vargasin (ym. 2021) mukaan paikkatiedon saamiseksi GPS-vastaanottimen tulee muodostaa yhteys vähintään neljään satelliittiin. He toteavat, että onnistuneen yhteydenmuodostuksen jälkeen vastaanotin voi määrittää sijaintinsa trilateraation avulla. Campbell (ym. 2018) kuvaa trilateraatiota prosessina, jossa määritellään pisteiden suhteellinen tai absoluuttinen sijainti mittaamalla etäisyyksiä ympyröiden, kolmioiden tai pallojen geometriaa hyödyntäen. Heidän mukaansa satelliittipaikannusjärjestelmässä vastaanotin laskee sijaintinsa mittaamalla kiertävien satelliittien etäisyyksiä sekä niiden lähettämien signaalien ajoituksia. Tämän sensorin kohdalla huomataan sen vastaanottavan satelliittien signaaleja, joka tekee vastaanottimesta passiivisen sensorin.

Campbell (ym. 2018) kertovat GPS-vastaanottimien vaativan suoran näköyhteyden satelliitteihin ja korkeiden rakennusten, puiden sekä tunnelien haittaavan signaalien kulkua. Jatkona todetaan, että riippuvuus suorasta näköyhteydestä estää GPS:n käytön sisätiloissa ja tunneleissa. Vargas (ym. 2021) toteavat myös auton tuulilasinyyhkimien aiheuttavan katkoksia signaalien

kulussa. He jatkavat, etteivät lyhyet katkokset kuitenkaan ole tiedonkulun kannalta kriittisiä, mutta yksittäisten signaalien data voi olla käyttökelvotonta. Lopuksi todetaan, etteivät sääolosuhteet juurikaan vaikuta satelliittijärjestelmien toimintaan, mikä johtuu järjestelmien käyttämästä noin 1.575 GHz taajuusalueesta.

Virheitä ja vääristymiä syntyy ulkopuolisten tekijöiden lisäksi satelliittijärjestelmästä itsestään. Eroavaisuudet satelliittien atomikellojen ja vastaanottimen kvartsikellon välillä aiheuttavat ajoitusvirheitä. Signaalit kärsivät viivästyksistä, joita syntyy signaalien kulkiessa ilmakehän kerrosten lävitse. Signaalit voivat heijastua useilta eri pinnoilta, jolloin ne eivät kulkeudu satelliitista suoraan vastaanottimeen. Satelliittien lentoradoissa tapahtuu vaihteluita, jotka aiheuttavat virheitä satelliittien paikannuksessa. (Vargas ym. 2021)

Järjestelmästä johtuvien virheiden ja vääristymien korjaamiseen on luotu kaksi menetelmää. Nämä menetelmät ovat PPP (engl. Precise Point Positioning) ja RTK (engl. Real-Time Kinematic). PPP perustuu globaaleihin satelliittikorjauksiin ja RTK alueelliseen tukiasemaverkkoon. Muutaman viimeisen vuoden aikana on myös kehitelty PPP-RTK virheenkorjaus, missä päästään eroon molempien menetelmien heikkouksista. (Hou ym. 2023, Joubert ym. 2020)

Maailmanlaajuinen satelliittipaikannusjärjestelmä pystyy saavuttamaan 35 cm tarkkuuden 95 % saatavuusajalla. PPP-virheenkorjauksella saadaan noin 30 cm tarkkuus globaalilla tasolla. RTK on virheenkorjausmenetelmistä tarkin ja sillä voidaan saavuttaa 2 cm tarkkuus. RTK:n käyttöä edellyttää, että alueella on paikallisia tukiasemaverkkoja. PPP-RTK väliversion tarkkuus on 10 cm luokkaa. (Joubert ym. 2020)

Aikaisemman perusteella voidaan huomata kulloinkin tarkasteltavissa olevan ympäristön vaikuttavan virheenkorjausmenetelmän valintaan. PPP-virheenkorjausta voidaan käyttää syrjäisemmissä ympäristöissä ja RTK:n käyttö vaatii puolestaan tarvittavan infrastruktuurin toimiakseen. PPP:llä ei päästä aivan RTK:ta vastaaviin tarkkuuksiin, mutta maantieteellisesti PPP on laajemmin saatavissa.

## 2.5 Ultraäänisensori

Vargas (ym. 2021) esittävät, että ultraäänisensorit havainnoivat ympäristöään äänimuuntimista (engl. sonic transducer) lähettämillään ääniaalloilla. He toteavat autonomisissa autoissa käytettyjen sensoreiden taajuusalueen olevan 40–70 kHz. Tämän jälkeen he toteavat ultraäänisensoreiden käytön olevan ihmiselle harmitonta, sillä taajuusalue sijoittuu ihmisen kuuloalueen yläpuolelle. Nesti (ym. 2023) kertovat sensorin laskevan kuluneen ajan ääniaallon lähetyksestä sen vastaanottamiseen. Näiden perusteella voin todeta ultraäänisensorin olevan aktiivinen sensori, jonka toimintaperiaate pohjautuu valotutkan ja tutkan tavoin lentoajan mittaamiseen. Lopuksi Nesti (ym. 2023) perustelee

ultraäänisensorin soveltuvan erittäin hyvin lyhyen matkan sensoriksi. Syiksi luetellaan sen halpa hinta, kestävyys sekä vahva tunnistuskyky.

Ultraäänisensoria käytetään autonomisissa autoissa lähtökohtaisesti vain pysäköinnin avustimissa (Nesti ym. 2023). Olen huomannut, että autoissa olevat ultraäänisensorit ilmoittavat esteistä varoitusäänellä, jonka äänentaajuus nopeutuu mitä lähempänä sensoria oleva este on. Sensorit sijaitsevat autonomisissa autoissa lähtökohtaisesti etu- sekä takapuskurissa ja niiden kantama on noin 25–400 cm (Taraba ym. 2018). Ilmakehän vaihtelevat olosuhteet, kuten ilmanpaine ja -kosteus, sekä lämpötila vaikuttavat ultraäänisensorin toimintaan (Nesti ym. 2023, Vargas ym. 2023). Tämä on johtanut muiden sensorien, kuten lyhyen kantaman tutkan suosimiseen ultraäänisensorien sijaan (Vargas ym. 2021). Ultraäänisensorit kärsivät kohinasta ja rajallisten toiminta-alueiden vuoksi kuolleista kulmista (Nesti ym. 2023).

## 2.6 Inertiaalinen mittaussyksikkö

Inertiaalinen mittaussyksikkö on yhdistelmä inertiaa mittaavia sensoreita. Nämä sensorit ovat kiihtyvyyssanturi, gyroskooppi ja magnetometri. Kiihtyvyyssanturi mittaa lineaarista kiihtyvyyttä ja gyroskooppi muutoksia kulma-asennoissa. Magnetometri mittaa ja vertaa paikallista magneettikenttää suhteessa maapallon magneettikenttään. (Raveena ym. 2020)

Campbell (ym. 2018) kertoo, että mittaussyksikköä käytetään yleisesti autonomisen auton ohjauksessa ja navigoinnissa. Heidän mukaansa navigoinnissa sijaintitieto hankitaan usein GPS:n avulla, sillä IMU-laitteet eivät itse pysty antamaan tietoa auton todellisesta sijainnista, vaan pelkästään sen liikkeistä. Larey (ym. 2020) toteavat, että satelliittipaikannusjärjestelmän signaalit eivät kulkeudu tunneleissa tai parkkihalleissa ja tällaisissa tilanteissa auton navigointi on riippuvainen IMU:sta. Analysoin, että signaalien estymisen voidaan todeta johtuvan tilojen rakenteiden paksuuksista ja materiaaleista.

IMU kärsii mittavirheiden kasautumisesta (Campbell ym. 2018, Larey ym. 2020). Campbell jatkaa, että tyypillinen ratkaisu on käyttää satelliittipaikannusta korjaamaan IMU:n tekemiä mittavirheitä. Larey puolestaan ehdottaa virheenkorjaukseen useamman IMU-laitteen käyttöä. Lopuksi totean IMU:n sensoreiden olevan passiivisia, sillä ne eivät lähetä ympäristöönsä energiaa.

### 3 Sensoreiden hyödyntäminen autonomisissa autoissa

Autonomisissa autoissa sensoreita hyödynnetään pitkälti sensorifuusion kautta. Yksittäiset sensorit, kuten parkkisensorit eivät kuitenkaan tarvitse fuusiota toimiakseen. Sensorifuusiossa useiden sensoreiden data yhdistetään, jotta yksittäisten sensorien heikkoudet ja tunnistusvirheet voidaan ehkäistä (Yeong ym. 2021). Taulukossa 3.1 on vertailtu sensoreiden teknisiä ominaisuuksia ja toiminnallisuuksia ajotehtävissä. Ultraäänisensori on jätetty taulukosta pois, sillä se toimii lähinnä parkkeerauksen avustimissa. Taulukosta huomataan, ettei yksikään sensori ole täysin kykenevä hoitamaan kaikkia ajamiseen liittyviä toimintoja. Sensorifuusio on täten pakollista autonomisen ajamisen saavuttamiseksi.

Taulukko 3.1: Yleisimpien sensoreiden toiminnallisuudet eri autonomiselle ajamiselle kohdennetuissa tehtävissä. Muokattu lähteestä (Yeong ym. 2021).

✓ = Sensori pystyy toimimaan täydellisesti, ~ = kohtalainen suorituskyky, x = heikko tai ei suorituskykyä.

Toiminto	Kamera	Valotutka	Tutka	Fuusio
Kantama	~	~	✓	✓
Resoluutio	✓	~	x	✓
Etäisyystarkkuus	~	✓	✓	✓
Nopeus	~	x	✓	✓
Värien havaitseminen	✓	x	x	✓
Kohteiden havaitseminen	~	✓	✓	✓
Kohteiden luokittelu	✓	~	x	✓
Kaistaviivojen havaitseminen	✓	x	x	✓
Esteiden reunojen havaitseminen	✓	✓	x	✓
Valaistusolosuhteet	x	✓	✓	✓

Autonomisen auton tehtävät ovat ympäristön havainnointi, paikallistaminen (engl. localization), kartoitus, reittisuunnittelu ja ohjaus. Paikallistamisella tarkoitetaan tietoisuutta ajoneuvon suhteellisesta sekä absoluuttisesta sijainnista. Kartoitus tarkoittaa auton ympäristön mallintamista, missä on esitetty esimerkiksi infrastruktuuri sekä rakennukset. Ympäristön havainnointi kattaa muiden autojen, jalankulkijoiden, tienpinnan, tiemerkintöjen sekä liikennemerkkien havainnoinnin ja seuraamisen. Reittisuunnittelussa pyritään selvittämään turvallisin ja optimaalisin reitti hyödyntäen paikallistamista, kartoitusta sekä ympäristön havainnointia. Reitin valitsemisen jälkeen ohjauselementti huolehtii auton kiihdyttämisestä, väännöstä (engl. torque) ja ohjauskulmista. (Fayyad ym. 2020)

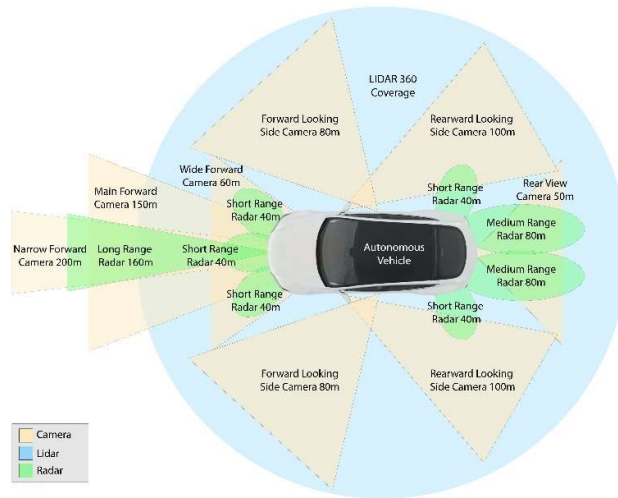
Paikallistaminen voidaan jakaa kolmeen pääkategoriaan: perinteiseen, koneoppimiseen perustuvaan ja yhteistyöhön perustuvaan paikannukseen. Perinteisen paikannuksen pohjana ovat

valmiit korkean tarkkuuden (engl. high definition, HD) kartat ja satelliittipaikannus. Nämä yhdistetään yleisesti kameran tai valotutkan sensoridatan kanssa, jolloin auton järjestelmä kykenee paikantamaan itsensä tarkasti. Koneoppimiseen perustuvassa paikannuksessa sensoridataa käytetään luomaan dynaamisia karttoja auton ympäristöstä. Menetelmässä ei käytetä perinteistä karttaa, vaan siinä luodaan dynaamisia pistepilvikarttoja, joissa esiintyy myös liikkuvia ajoneuvoja, jalankulkijoita ja esteitä. Pistepilvikartat luodaan yleisimmin mekaanisen valotutkan sensoridatasta. Uusien karttojen luominen vie tätä paikannusmenetelmää osittain kartoittamisen puolelle. Karttojen analysoimisessa hyödynnetään syväoppimista sekä neuroverkkoja. Näitä käsitellään tarkemmin aliluvussa 3.2. Yhteistyöhön perustuvassa paikannuksessa auto on langattomasti yhteydessä muihin autoihin, jalankulkijoihin, infrastruktuureihin ja internetiin. Menetelmässä auto vaihtaa sijainti-, suunta- ja etäisyystietojaan muun liikenteen kanssa. Auto saadaan paikannettua hyödyntämällä muiden osapuolten paikkatietoja. (Kumar ym. 2023)

Reittisuunnittelu koostuu globaalista sekä paikallisesta suunnittelusta. Globaalissa suunnittelussa muodostetaan karkea reitti auton lähtö- ja päätepisteiden välille. Tämän muodostamiseen käytettävät suunnittelumenetelmät voidaan luokitella graafipohjaisiin, älykkäisiin ja koneoppimiseen pohjautuviin menetelmiin. Tunnetuimmat globaaleista menetelmistä ovat A\*- ja Dijkstran algoritmi. Globaali reittisuunnittelu on jo varsin kehittyntä, mutta paikallisilla reittisuunnittelualgoritmeilla on edelleen haasteita. Suurin haaste on dynaamiseen ympäristöön sopeutuminen. (Zhang ym. 2023)

Zhangin (ym. 2023) mukaan paikallinen reittisuunnittelu perustuu auton hetkelliseen sekä ajankohtaiseen sijaintiin. He jatkavat toteamalla, että sen tavoitteena on luoda lähiympäristön kattava reitti, joka voidaan kulkea kolaroimatta. Paikallisen reitinsuunnittelun yleisimmiksi menetelmiksi kerrotaan potentiaali-, sääntö- ja näytteistyspohjaiset menetelmät. Sahiba (ym. 2022) toteavat paikallisen reittisuunnittelun pohjautuvan sensoreista saatuun dataan. He huomauttavat, että ympäristön ollessa epäselvä tai kohteiden ollessa kaukana, sensorit eivät yksinään riitä reitin luomiseen. Tutkijoiden näkemyksen mukaan globaali ja paikallinen suunnittelu tuleekin yhdistää parhaimman lopputuloksen saamiseksi.

Olen huomannut ympäristön havainnoinnin olevan kaikista autonomisen auton tehtävistä sensoripainotteisin. Yeongin (ym. 2021) mukaan siihen käytetään valotutkaa, tutkaa, ultraäänisensoria sekä kameraa ja sen eri versioita. He mainitsevat yleisimmiksi esteiden havainnointiin käytettäviksi fuusiopareiksi seuraavat yhdistelmät: kamera-tutka, kamera-valotutka tai kamera-tutka-valotutka. He täsmentävät, että ympäristön havainnoinnissa käytetyin on kamera-tutka pari. Lopuksi perustellaan, että kameran avulla ympäristöstä saadaan korkea resoluutioista kuvaa ja tutkalla etäisyyksiä sekä kohteiden nopeuksia. Nestin (ym. 2023) mukaan ultraäänisensorin käyttö ympäristön havainnoinnissa rajoittuu vain parkkiavustimiin. Kuvassa 3.2 on havainnollistettu ympäristön havainnointiin käytetyt sensorit pois lukien ultraäänisensori. Ultraäänisensori on jätetty pois sen rajallisten käyttökohteiden vuoksi.



Kuva 3.2: Ympäristön havainnointiin käytetyt sensorit, sekä niiden sijoitukset, kantamat ja havainnointialueet. (Sharian ym. 2019)

Sensoridatan yhdistäminen tapahtuu lähtökohtaisesti kolmella eri tavalla. Jaottelu perustuu vaiheeseen, jossa fuusio tehdään. Matalan tason fuusiossa (engl. low-level fusion) sensoreiden dataa ei käsitellä ennen fuusiota. Keskitason fuusiossa (engl. middle-level fusion) sensoridatasta on eritelty havainnoitavien asioiden piirteitä ennen itse fuusiota. Korkean tason fuusiossa (engl. high-level fusion) fuusio tapahtuu sensoreiden muodostamista piirre- sekä objektilistoista. (Senel ym. 2023)

Senel (ym. 2023) jaottelee fuusioalgoritmit perinteisiin algoritmeihin ja syväoppimisalgoritmeihin. Kuutti (ym. 2020) kertoo syväoppimisen käytön lisääntyneen autonomisissa autoissa merkittävästi. Tutkijoiden mukaan syväoppimismenetelmien avulla on saavutettu poikkeuksellisen hyviä tuloksia monimutkaisissa auton ohjausta koskevissa ongelmissa. Suosion syiksi kerrotaan myös niiden kyky soveltaa aikaisemmin opittuja sääntöjä uusiin tilanteisiin.

Perinteiset fuusioalgoritmit perustuvat määrättyihin sääntöihin tai painotettuihin arvoihin. Syväoppimisalgoritmit suoriutuvat tehtävistään perinteisiä algoritmeja paremmin etenkin haastavissa tilanteissa, kuten yöllä sekä huonoissa sääolosuhteissa. Näissä olosuhteissa sensorien luotettavuus vaihtelee ja tämä on perinteisten algoritmien toiminnalle hyvin epäsuotuisaa. Perinteiset algoritmit suoriutuivat syväoppimisalgoritmeja huonommin kohteentunnistuksessa eri ympäristöissä päivisin ja öisin. Niiden operaatiot vaativat myös enemmän laskentatehoa sekä aikaa. Perinteiset algoritmit ovat hyvin huonoja käsittelemään sensoreiden virhetiloja. Kameran kuvan ollessa sumea tai tutkan kärsiessä kohinasta syväoppimisalgoritmit voivat vaihtaa datalähteeksi toisen sensorin. Dynaamisuuden puutteen vuoksi perinteiset algoritmit joutuvat käyttämään kärsinyttä dataa. (Sumalatha ym. 2024)

### 3.1 Haasteita autonomisten autojen kehityksessä

Autonomisten autojen kehitys kohtaa useita erinäisiä ongelmia. Sähkönkulutus, kalliit komponentit, tietoturva- sekä kyberturvallisuusriskit, käyttövoima ja autojen testaaminen ovat huomioonotettavia ja jatkotutkimuksen arvoisia haasteita. Sensoreiden jatkuva havainnointi sekä auton järjestelmän tekemät toimenpiteet käyttävät paljon sähköä. Täysin sähköisten autonomisten autojen laskentajärjestelmän tehonkulutus voi vähentää ajomatkaa jopa 30 % (Liu ym. 2020). Auton kokonaistehonkulutus kaikkine komponentteineen voi ylittää helposti 1000 wattia (Liu ym. 2020). Wu (ym. 2024) toteavat, että päätöksentekoon, sensorifuusioon ja datan prosessointiin reaaliaikaisesti vaaditaan prosessoria (engl. central processing unit) sekä näytönohjainta (engl. graphics processing unit). Prosessorin kerrotaan suoriutuvan hyvin auton hallintalogiikan hallinnasta ja useiden samanaikaisten tehtävien suorituksesta. Näytönohjainta kerrotaan käytettäväksi kuvantunnistuksessa ja syväoppimisessa, sillä se pystyy prosessoimaan suuria määriä dataa rinnakkain.

Liu (ym. 2020) kertoo markkinoilla olevan valmiita kehitysalustoja, jotka tarjoavat tarvittavat resurssit laskentaan ja päätöksentekoon. Tutkielmassa esitellään maailman tehokkain järjestelmäpiiri, Nvidia Drive ATX, tarjoaa laitteiston sekä ohjelmistot autonomisen auton kehittämiseen. Piiri mahdollistaa korkeimpaan autonomisen ajamisen tasoon vaadittavan laskentatehon. Se maksaa 30 000 Yhdysvaltojen dollaria ja sisältää 16 prosessoria sekä kaksi näytönohjainta. Tulkitani mukaan pelkkä järjestelmäpiiri maksaa enemmän kuin osa tällä hetkellä markkinoilla olevista uusista autoista. Tämän takia kalliit komponentit hidastavat autonomisten autojen pääsyä kuluttajamarkkinoille.

Hintava sekä energiankulutukseltaan raskas järjestelmä kärsii myös tietoturvaan sekä kyberturvallisuuteen liittyvistä haasteista. Autonomiset autot haalivat sensoreidensa avulla todella paljon dataa. Testivaiheessa olevat autonomiset autot tuottavat noin 30 teratavua sensoridataa päivässä (Fireman ym. 2018). Tämä vastaa tuntitasolla noin 0.383–5.17 teratavua (Yeong ym. 2021). Taghavi (ym. 2020) kertovat sensoridatan sisältävän kuvia jalankulkijoiden naamoista ja muiden autojen rekisterikilvistä. Heidän mukaansa tämä on ongelmallista, sillä se loukkaa ihmisten yksityisyyttä. Tutkielmassaan he esittävät ongelman ratkaisuksi EdgeMask-tekniikan, jossa ihmisten kasvot ja muu arkaluontoinen materiaali sumennetaan tai poistetaan. Euroopassa yleisellä tietosuojasetuksella (engl. General Data Protection Regulation, GDPR) asetetaan vaatimuksia henkilötietojen keräämiseen, säilytykseen ja hallintaan (Europa 2022, Mulder ym. 2021). Tässä yhteydessä asetuksessa esitettyjen ehtojen noudattaminen jää autovalmistajien huolehdittaviksi. Autonomiset autot tuottavat arkaluontoista dataa myös käyttäjistään, sillä autosta saatavan datan perusteella käyttäjän elämästä voidaan tehdä päätelmiä (Mulder ym. 2021). Tämän pohjalta tulkitseen, että tällainen data on arvokasta rikollisille. Sitä voidaan esimerkiksi käyttää apuna kotiryöstöissä, sillä datan avulla tiedetään milloin henkilö ei ole kotona.

Osittain autonomiset autot kohtaavat jo kyberturvallisuushaasteita. Tämä tekee täysin autonomisista autoista vielä alttiimpia uhille, sillä järjestelmästä löytyy vielä enemmän haavoittuvia

komponentteja. Auton hallinta on mahdollista kaapata langattomien verkkojen kautta, sillä useimmat autot käyttävät Bluetooth- ja internet-yhteyksiä sekä avaimetonta käynnistystä. Muita keskeisiä uhkia ovat GNSS-järjestelmien signaalien väärentäminen sekä sensorien manipulointi häirinnällä. Kirkkailla valoilla voidaan sokaista kameroita, ja tutkaa sekä ultraäänisensoria voidaan häiritä lähettämällä radioaaltoja ja ultraääntä. (Taeihagh ym. 2019)

Litiumionista valmistetut akut ovat vakioituneet sähköistyneen liikenteen virtalähteiksi. Litiumioniakut ikääntyvät käytössä, mikä rajoittaa sähköautojen laajamittaista käyttöönottoa. Täyssähköisten autojen suurimmat rajoitteet ovat toimintamatka, suhteellisen hitaat lataukset ja järjestelmän kallis hinta verrattuna polttoaineella toimiviin autoihin. Kalliin hinnan taustalla on auton akuston käyttöikä. Akuston käyttöikä on paljon lyhyempi kuin auton käyttöikä, jolloin akusto joudutaan vaihtamaan auton toiminnan takaamiseksi. (Sabatini ym. 2018)

Täysin sähköiset autot eivät pysty toimimaan ympärivuorokautisesti, sillä niitä tarvitsee ladata. On kuitenkin selvää, että autonomisen auton tulee olla vähintään sähköhybridi toimiakseen, sillä ajojärjestelmä kuluttaa paljon sähköä. Iso osa markkinoiden uusista autoista on täyssähköisiä. Ennustan tämän saman suuntauksen heijastuvan hyvin pitkälti autonomisiin autoihin.

Simuloinnin ja liikenteessä testaamisen välissä on ratatestaukseksi (engl. track testing) kutsuttu välivaihe. Se pitää sisällään autonomisten autojen testauksen rakennetussa ympäristössä. Ympäristö on rakennettu muistuttamaan oikeaa liikennettä ja se sisältää liikkuvia mallinukkeja sekä muita autoja. Ratatestaus mahdollistaa autolla ajamisen ympäristöissä, jotka voidaan rakentaa kuvastamaan vaikeita ajotilanteita ja olosuhteita. (Fremont ym. 2020)

Olen havainnut, että autonomisten autojen testaamiseen liittyy ongelmakohtia. Useissa lukemissani julkaisuissa autojen testivaiheet ovat olleet rajattuja ja tapahtuneet rakennetuilla alueilla. Todellisessa liikenteessä esiintyy kuitenkin lähes lukematon määrä erilaisia tilanteita, eikä niitä kaikkia voida missään testaamisen vaiheessa mallintaa. Ongelma nousee esiin myös aiheesta tehdyissä tutkimuksissa. Osassa läpikäymissäni julkaisuissa tutkimukset oli suoritettu testiympäristöissä todellisen liikenteen sijasta.

## 3.2 Syväoppiminen

Syväoppimista pidetään tekoälyn sekä koneoppimisen alahaarana, jonka tavoitteena on jäljitellä ihmisaivojen toimintaa. Tekoälyn kehityksen, sekä näytönohjainten tehokkuuden kasvaessa syväoppiminen on tullut hyvin suosituksi. Syväoppiminen perustuu keinotekoisii neuroverkkoihin, jotka puolestaan pohjautuvat ihmisaivojen hermoverkkojen toimintaperiaatteeseen. Syväoppimisalgoritmeissa luodaan monikerroksisia neuroverkkoja, mitkä mahdollistavat sensoreista saadun raakadatan käsittelyn ja erilaisten mallien tunnistamisen. Autonomisissa autoissa suosituimmat

algoritmit ovat konvoluutioverkko (engl. convolutional neural network, CNN) ja takaisinkytketty neuroverkko (engl. recurrent neural network, RNN). (Fayyad ym. 2020)

Konvoluutioverkoja käytetään kuvantunnistuksessa ja ne koostuvat syötekerroksesta, piilokerroksista sekä tuloskerroksesta. Syötekerroksessa verkko saa raakadatan valituilta sensoreilta. Piilokerroksissa, joita kutsutaan myös konvoluutiokerroksiksi, tapahtuu piirteiden tunnistus ja asioiden luokittelu käyttäen suodattimia. Suodattimien avulla kuvasta voidaan tunnistaa muotoja ja tekstuureja. Konvoluutiokerroksia on monia ja kerroksien välillä edetessä tunnistettujen asioiden luokittelu etenee varmemmaksi. Konvoluutioverkko vaatii toimiakseen suuren koulutusaineiston, joka sisältää leimattua dataa. Leimatussa datassa on kuvia ja tietoa mitä kuvassa esiintyy. Tuloskerroksessa verkko esittää todennäköisyydet kuvassa esiintyvillä asioilla. (Fayyad ym. 2020)

Tulkintani mukaan autonomisten autojen kohdalla leimattu data sisältää esimerkiksi kuvia jalankulkijoista, autoista sekä liikennemerkeistä. Edellisessä lähteessä esitetään, että konvoluutioverkko pystyy esittämään todennäköisyyksiä. Käytännössä tämä tarkoittaa sitä, että konvoluutioverkko voi ennustaa, että kuvassa esiintyvä asia on 80 % varmuudella henkilöauto.

Preetin (ym. 2024) mukaan suurin osa autonomisten autojen kehittäjistä käyttävät kohteentunnistuksessa semanttista segmentointia (engl. semantic segmentation). He kuvaavat sen prosessina, jossa kuvan jokainen pikseli luokitellaan kuuluvaksi johonkin luokkaan. Li (ym. 2024) jakavat kuvadatan segmentoinnin perinteisiin menetelmiin ja syväoppimis pohjaisiin lähestymistapoihin. Heidän mukaansa perinteiset menetelmät pohjautuvat manuaalisesti suunniteltuihin ominaisuuksiin, kun taas syväoppimis pohjaiset menetelmät oppivat tunnistettavat asiat automaattisesti. Tutkimuksessaan he esittävät, että syväoppimiseen pohjautuvalla segmentoinnilla on saavutettu parempia tuloksia.

Kuvadatan segmentointi on ratkaisevassa roolissa ympäristön havainnoinnissa ja paikallistamisessa. Sen avulla voidaan hahmottaa ajokelpoiset alueet, jalankulkijat, esteet sekä muut ajoneuvot. Autonomisten autojen kohdalla konvoluutioverkot ovat onnistuneesti korvanneet perinteiset algoritmit semanttisessa segmentoinnissa. Konvoluutioverkkoihin perustuvan segmentoinnin reaaliaikainen suorituskyky on kuitenkin voimakkaasti riippuvainen tehokkaasta laskentajärjestelmästä. (Jung ym. 2024)

Min (ym. 2019) mukaan takaisinkytketty neuroverkko on kehitetty analysoimaan peräkkäistä dataa. Sen avulla pyritään ennustamaan mitä lähitulevaisuudessa tapahtuu (Fayyad ym. 2020). Jeongin (ym. 2020) mukaan yksi sovelluskohde on muiden tiellä ajavien autojen liikeratojen ennustaminen. Tutkielmassaan autonomisen auton takaisinkytketty neuroverkko opetettiin ennustamaan muiden autojen liikeratoja monikaistaisessa risteyksessä. Auto onnistui ennustamaan tilanteita tarkasti ja esimerkiksi autolla kiihdyttäminen oli hyvin ihmismäistä.

Fayyad (ym. 2020) tutkimuksessa kerrottiin lähitulevaisuuden tapahtumien ennustaminen. Voidaan siis ajatella, että takaisinkytketty neuroverkko pyrkii ennustamaan sensoridatasta ylittääkö jalankulkija suojatien. Ennustaminen tapahtuu seuraamalla jalankulkijan nopeutta ja sen muutoksia

ennen suojaetelulle siirtymistä. Mikäli aikaisemmissa askeleissa ei näy hidastumista, voidaan peräkkäisen datan avulla olettaa, että jalankulkija ei ole pysähtymässä.

Monet yritykset tutkivat autonomista ajamista syväoppimisen avulla. Yritykset eivät halua jakaa koulutusdataa ja tutkimustyötään yrityksen ulkopuolelle, sillä se voisi heikentää heidän kilpailukykyään alalla. Tämä on ongelmallista, sillä syväoppimisalgoritmien kouluttamiseen tarvitaan valtava määrä koulutusdataa. Koulutusdatan avulla autonomisen auton tulisi oppia toimimaan kaikissa mahdollisissa tilanteissa. Suuret koulutusaineistot eivät kuitenkaan sellaisenaan ole ratkaisu ongelmaan. Aineistojen tulee olla monimuotoisia, jotta ne sisältävät toimintaohjeita eri ajotilanteisiin. Monimuotoisuuden varmistamiseksi valittuja aineistoja tarvitsee läpikäydä. Pääpaino koulutusaineistoissa tulisi kuitenkin olla yleisimmissä ajotilanteissa ja liikenteen tapahtumissa. Syväverkkojen kouluttamiseen vaadittu aika ja suuri datamäärä ovat menetelmän suurimmat haittapuolet. (Kuutti ym. 2020)

## 4 Yhteenveto

Teknologian kehitys on mahdollistanut autonomisten autojen kehityksen. Autonomisten autojen keskiössä ovat ajojärjestelmä sekä sensorit, jotka ovat tutkielman pääaihe. Autonomisia toimintoja voidaan saavuttaa eri sensorivalinnoin. Autolta vaaditut tehtävät ovat ympäristön havainnointi, paikallistaminen, ohjaus, kartoitus sekä reittisuunnittelu. Tehtävien suorittamiseksi käytetään useita sensoreita samanaikaisesti. Tätä kutsutaan sensorifuusioksi ja se on edellytys autonomiselle ajamiselle. Ympäristön havainnointiin käytetyt sensorit ovat valotutka, tutka, kamera, ultraäänisensori. Näistä suosituimmat ovat kamera-tutka sekä kamera-valotutka parit. Paikallistamiseen ja kartoitukseen käytetään satelliittipaikannusta, mutta myös kameraa sekä valotutkaa. Reittisuunnittelu tapahtuu paikallistamisen, kartoituksen sekä ympäristön havainnoinnin avulla. Reitin ollessa selvä, järjestelmän ohjauselementti huolehtii auton kuljettamisesta autonomisesti.

Sensorit voidaan jakaa toimintaperiaatteensa mukaan kahteen kategoriaan. Sisäiset sensorit keskittyvät auton sisäisen tilan vahtimiseen ja ulkoiset auton ulkopuoliseen ympäristöön. Tämän jaottelun lisäksi sensorit kuuluvat joko passiivisiin tai aktiivisiin sensoreihin. Passiiviset sensorit vastaanottavat energiaa ympäristöstään ja aktiiviset puolestaan lähettävät sitä. Aktiivisia sensoreita autonomisissa autoissa ovat valotutka, tutka ja ultraäänisensori. Passiivisia puolestaan maailmanlaajuisen satelliittijärjestelmän vastaanottimet, kamera ja inertiaalisen mittaussyksikön sensorit. Sisäisiä sensoreita ovat inertiaalisen mittaussyksikön sensorit ja satelliittijärjestelmän vastaanottimet. Ulkoisia puolestaan kamera, valotutka, tutka ja ultraäänisensori.

Autonomisissa autoissa käytettyjen sensoreiden hinnat vaihtelevat paljon. Kamera ja ultraäänisensori ovat halvimpia sensoreita ja valotutka puolestaan kallein. Sensorien toimintaperiaatteista valotutkan, tutkan sekä ultraäänisensorin toiminta pohjautuu lentoajan mittaamiseen. Eri sensoreilla on keskenään samoja käyttötarkoituksia ja monilla niistä on useita käyttökohteita. Valotutkalla voidaan luoda pistepilvikarttoja, auttaa autoa paikantamisessa sekä tunnistaa muiden tielläliikkujien nopeuksia. Ultraäänisensorin käyttö puolestaan rajoittuu käytännössä parkkiavustimiin.

SAE:n laatiman luokituksen mukaista täysin autonomista autoa ei ole kehitetty. Useissa uusissa autoissa on kuitenkin autonomisia ominaisuuksia, kuten mukautuva vakionopeudensäädin, kaistavahti, ruuhka-ajon avustin sekä autonominen ajaminen moottoriteillä. SAE:n luokittelun perusteella uusien autojen autonomiset ominaisuudet yltävät vain tasolle 3 ja suurimman osan vain tasoille 1–2. Tason 4 autonomisia autoja on vain taksikäytössä ja niiden esiintyminen on hyvin vähäistä. Korkeimmalle, täysin autonomiselle tasolle ei olla vielä päästy.

Autonomisten autojen kehitystyön motiivina on tehdä liikenteestä turvallisempaa, taloudellisempaa sekä saavutettavampaa. Noin yhdeksän kymmenestä kolarista johtuu ihmisten tekemistä ajovirheistä. Tason 4 autonomisia autoja esiintyy liikenteessä ja niiden on todettu olevan lähes viisi kertaa vähemmän alttiita liikenneonnettomuuksille. Tämän tasoisia ajoneuvoja on tosin

hyvin vähän, mutta niiden sulauttaminen ja toiminta liikenteessä on ollut hyvinkin onnistunutta. Täysin autonominen ajoneuvo ei vaadi kuljettajaa, jonka vuoksi se on loistava vaihtoehto liikuntarajoitteisille. Kuljettajan poissaolo vähentää myös ammattiliikenteen henkilöstökuluja. Kuljettajille ei tarvitse maksaa palkkaa, eikä ihmiskuljettajille määrättyt lepotauot hidasta logistisia kuljetuksia.

Autonomisten autojen päätöksenteko perustuu perinteisiin algoritmeihin sekä syväoppimiseen. Syväoppimisalgoritmit ovat jättäneet perinteiset algoritmit varjoonsa. Syväoppimisalgoritmien toiminta on dynaamista, tarkempaa sekä laskennallisesti tehokkaampaa. Syväoppimisalgoritmit tulee kouluttaa oikeanlaisilla aineistoilla, jotta auton järjestelmä oppii halutusti. Koulutettu järjestelmä pystyy esimerkiksi ennustamaan muun liikenteen muutoksia, tekemään päätöksiä aiempien tietojen perusteella ja havainnoimaan ympäristöään. Auton laskentajärjestelmän tehonkulutus voi pienentää ajomatkaa jopa kolmanneksen. Laskentajärjestelmän tehonkulutuksen optimointi on tärkeä jatkotutkimusaihe ennen autojen saattamista kuluttajamarkkinoille.

Autonomisten autojen kehityksessä on useita haasteita, jotka hidastavat ja toimivat esteinä täysin autonominen auton kehityksessä. Autot kohtaavat kyberturvallisuusriskejä, sillä niiden järjestelmät ovat riippuvaisia verkkoyhteyksistä sekä digitaalisista teknologioista ja ohjelmistoista. Tiettyjen sensoreiden kohdalla haasteina ovat kalliit hinnat sekä sääolosuhteiden vaikutus sensorien toimintaan. Autonominen autojen testaaminen on ongelmallista, sillä testaamista ei voida aloittaa liikenteen seassa turvallisuussyistä. Autojen sekä sensorien toiminnallisuutta testataan testiympäristöissä, jotka eivät kuitenkaan täysin vastaa todellisen liikenteen toimintaa. Osa aiheesta tehdyistä tutkimuksista on myös toteutettu testiympäristöissä. Tämä jättää tulkinnanvaraa ja epäluottamusta autojen toimivuudesta todellisissa ympäristöissä.

## Lähteet

- Bastos, D., Monteiro, P. P., Oliveira, A. S., & Drummond, M. V. (2021, February). An overview of LiDAR requirements and techniques for autonomous driving. In *2021 Telecoms Conference (ConfTELE)* (pp. 1-6). IEEE.
- Campbell, S., O'Mahony, N., Krcpalcova, L., Riordan, D., Walsh, J., Murphy, A., & Ryan, C. (2018, June). Sensor technology in autonomous vehicles: A review. In *2018 29th Irish Signals and Systems Conference (ISSC)* (pp. 1-4). IEEE.
- Cheng, Y., & Liu, Y. (2021). Person reidentification based on automotive radar point clouds. *IEEE Transactions on Geoscience and Remote Sensing*, *60*, 1-13.
- Europa (2022, July 6) *Yleinen tietosuoja-asetus* [https://europa.eu/youreurope/business/dealing-with-customers/data-protection/data-protection-gdpr/index\\_fi.htm](https://europa.eu/youreurope/business/dealing-with-customers/data-protection/data-protection-gdpr/index_fi.htm)
- Fayyad, J., Jaradat, M. A., Gruyer, D., & Najjaran, H. (2020). Deep learning sensor fusion for autonomous vehicle perception and localization: A review. *Sensors*, *20*(15), 4220.
- Fireman, M. (2018). Capturing, analyzing and storing terabytes of vehicle-generated data. *Automotive Industries*, *197*(1), 52–52.
- Fremont, D. J., Kim, E., Pant, Y. V., Seshia, S. A., Acharya, A., Brusco, X., Wells, P., Lemke, S., Lu, Q., & Mehta, S. (2020). *Formal Scenario-Based Testing of Autonomous Vehicles: From Simulation to the Real World*. <https://doi.org/10.48550/arxiv.2003.07739>
- Hou, P., Zha, J., Liu, T., & Zhang, B. (2023). Recent advances and perspectives in GNSS PPP-RTK. *Measurement Science and Technology*, *34*(5), 051002.
- Ignatious, H. A., & Khan, M. (2022). An overview of sensors in Autonomous Vehicles. *Procedia Computer Science*, *198*, 736-741.
- Jeong, Y., Kim, S., & Yi, K. (2020). Surround vehicle motion prediction using LSTM-RNN for motion planning of autonomous vehicles at multi-lane turn intersections. *IEEE Open Journal of Intelligent Transportation Systems*, *1*, 2-14.
- Joubert, N., Reid, T. G., & Noble, F. (2020, October). Developments in modern GNSS and its impact on autonomous vehicle architectures. In *2020 IEEE Intelligent Vehicles Symposium (IV)* (pp. 2029-2036). IEEE.
- Jung, J., Kim, S., Jang, W., Seo, B., & Lee, K. J. (2024). An Energy-Efficient, Unified CNN Accelerator for Real-Time Multi-Object Semantic Segmentation for Autonomous Vehicle. *IEEE*

*Transactions on Circuits and Systems. I, Regular Papers*, 71(5), 2093–2104.

<https://doi.org/10.1109/TCSI.2024.3349588>

Kumar, D., & Muhammad, N. (2023). A Survey on Localization for Autonomous Vehicles. *IEEE Access*, 11, 1–1. <https://doi.org/10.1109/ACCESS.2023.3326069>

Kusano, K. D., Scanlon, J. M., Chen, Y. H., McMurry, T. L., Chen, R., Gode, T., & Victor, T. (2024). Comparison of Waymo rider-only crash data to human benchmarks at 7.1 million miles. *Traffic Injury Prevention*, 1-12.

Kuutti, S., Bowden, R., Jin, Y., Barber, P., & Fallah, S. (2020). A survey of deep learning applications to autonomous vehicle control. *IEEE Transactions on Intelligent Transportation Systems*, 22(2), 712-733.

Larey, A., Akin, E., & Klein, I. (2020). Multiple inertial measurement units—an empirical study. *IEEE Access*, 8, 75656-75665.

Li, Y., Fang, A., Guo, Y., & Wang, X. (2024). Image Fusion Via Mutual Information Maximization for Semantic Segmentation in Autonomous Vehicles. *IEEE Transactions on Industrial Informatics*, 20(4), 5838–5848. <https://doi.org/10.1109/TII.2023.3341263>

Li, Y., & Ibanez-Guzman, J. (2020). Lidar for autonomous driving: The principles, challenges, and trends for automotive lidar and perception systems. *IEEE Signal Processing Magazine*, 37(4), 50-61.

Li, Y., Moreau, J., & Ibanez-Guzman, J. (2023). Emergent visual sensors for autonomous vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 24(5), 4716-4737.

Lidar, V. (2016). HDL-64E. *Velodyne Lidar, San Jose, CA, USA, Tech. Rep.*

Liu, L., Lu, S., Zhong, R., Wu, B., Yao, Y., Zhang, Q., & Shi, W. (2020). Computing systems for autonomous driving: State of the art and challenges. *IEEE Internet of Things Journal*, 8(8), 6469-6486.

Liu, S., Tang, J., Zhang, Z., & Gaudiot, J. L. (2017). Computer architectures for autonomous driving. *Computer*, 50(8), 18-25.

Min, K., Kim, D., Park, J., & Huh, K. (2019). RNN-based path prediction of obstacle vehicles with deep ensemble. *IEEE Transactions on Vehicular Technology*, 68(10), 10252-10256.

Mulder, T., & Vellinga, N. E. (2021). Exploring data protection challenges of automated driving. *The Computer Law and Security Report*, 40, 105530-<https://doi.org/10.1016/j.clsr.2021.105530>

Nesti, T., Boddana, S., & Yaman, B. (2023). Ultra-sonic sensor based object detection for autonomous vehicles. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 210-218).

Preeti, & Rana, C. (2024). Artificial intelligence based object detection and traffic prediction by autonomous vehicles – A review. *Expert Systems with Applications*, 255, 124664-.  
<https://doi.org/10.1016/j.eswa.2024.124664>

Raveena, C. S., Sravya, R. S., Kumar, R. V., & Chavan, A. (2020, November). Sensor fusion module using IMU and GPS sensors for autonomous car. In *2020 IEEE International Conference for Innovation in Technology (INOCON)* (pp. 1-6). IEEE.

Sabatini, S., & Corno, M. (2018, June). Battery aging management for fully electric vehicles. In *2018 European Control Conference (ECC)* (pp. 231-236). IEEE.

Sabiha, A. D., Kamel, M. A., Said, E., & Hussein, W. M. (2022). Real-time path planning for autonomous vehicle based on teaching–learning-based optimization. *Intelligent Service Robotics*, 15(3), 381–398. <https://doi.org/10.1007/s11370-022-00429-3>

SAE International Recommended Practice, Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, SAE Standard J3016\_202104, Revised April 2021, Issued January 2014, [https://doi.org/10.4271/J3016\\_202104](https://doi.org/10.4271/J3016_202104).

Senel, N., Kefferpütz, K., Doycheva, K., & Elger, G. (2023). Multi-sensor data fusion for real-time multi-object tracking. *Processes*, 11(2), 501.

Sethi, I. K., & Sethi, I. K. (2023). *Autonomous Vehicles and Systems: A Technological and Societal Perspective* (1st ed.). River Publishers. <https://doi.org/10.1201/9781032629537>

Shahian Jahromi, B., Tulabandhula, T., & Cetin, S. (2019). Real-Time Hybrid Multi-Sensor Fusion Framework for Perception in Autonomous Vehicles. *Sensors (Basel, Switzerland)*, 19(20), 4357-.  
<https://doi.org/10.3390/s19204357>

Sumalatha, I. P. P. A., Chaturvedi, P., Patil, S., Thethi, H. P., & Hameed, A. A. (2024, May). Autonomous Multi-Sensor Fusion Techniques for Environmental Perception in Self-Driving Vehicles. In *2024 International Conference on Communication, Computer Sciences and Engineering (IC3SE)* (pp. 1146-1151). IEEE.

Taeihagh, A., & Lim, H. S. M. (2019). Governing autonomous vehicles: emerging responses for safety, liability, privacy, cybersecurity, and industry risks. *Transport Reviews*, 39(1), 103–128.  
<https://doi.org/10.1080/01441647.2018.1494640>

- Taghavi, S., & Shi, W. (2020, November). EdgeMask: An edge-based privacy preserving service for video data sharing. In *2020 IEEE/ACM Symposium on Edge Computing (SEC)* (pp. 382-387). IEEE.
- Taraba, M., Adamec, J., Danko, M., & Drgona, P. (2018, May). Utilization of modern sensors in autonomous vehicles. In *2018 ELEKTRO* (pp. 1-5). IEEE.
- Traficom (2023, September 13) *Mitä ovat ADAS-järjestelmät ja mitä ADAS-järjestelmiä autoissa on?* <https://www.traficom.fi/fi/liikenne/autoilijalle/mita-ovat-adas-jarjestelmat-ja-mita-adas-jarjestelmia-autoissa>
- Van Nam, D., & Gon-Woo, K. (2021, January). Solid-state LiDAR based-SLAM: A concise review and application. In *2021 IEEE International Conference on Big Data and Smart Computing (BigComp)* (pp. 302-305). IEEE.
- Vargas, J., Alswiss, S., Toker, O., Razdan, R., & Santos, J. (2021). An overview of autonomous vehicles sensors and their vulnerability to weather conditions. *Sensors*, *21*(16), 5397.
- Wu, H. (2024). A Comprehensive of CPU and GPU Performance and Applications in Autonomous Vehicles. *Science and Technology of Engineering, Chemistry and Environmental Protection*, *1*(9).
- Xiang, C., Feng, C., Xie, X., Shi, B., Lu, H., Lv, Y., ... & Niu, Z. (2023). Multi-sensor fusion and cooperative perception for autonomous driving: A review. *IEEE Intelligent Transportation Systems Magazine*.
- Yao, S., Guan, R., Huang, X., Li, Z., Sha, X., Yue, Y., ... & Yue, Y. (2023). Radar-camera fusion for object detection and semantic segmentation in autonomous driving: A comprehensive review. *IEEE Transactions on Intelligent Vehicles*.
- Yeong, D. J., Velasco-Hernandez, G., Barry, J., & Walsh, J. (2021). Sensor and sensor fusion technology in autonomous vehicles: A review. *Sensors*, *21*(6), 2140.
- Zhang, Y., Liu, K., Gao, F., & Zhao, F. (2023). Research on Path Planning and Path Tracking Control of Autonomous Vehicles Based on Improved APF and SMC. *Sensors (Basel, Switzerland)*, *23*(18), 7918-. <https://doi.org/10.3390/s23187918>