

# Sensorifuusion vaikutus itseohjautuvien ajoneuvojen havaintokykyyn ja turvallisuuteen

TURUN YLIOPISTO  
Tietotekniikan laitos  
LuK-tutkielma  
Tietojenkäsittelytiede  
Joulukuu 2024  
Fei-Linnea Hakala

TURUN YLIOPISTO

Tietotekniikan laitos

FEI-LINNEA HAKALA: Sensorifuusion vaikutus itseohjautuvien ajoneuvojen havaintokykyyn ja turvallisuuteen

LuK-tutkielma, 33 s.

Tietojenkäsittelytiede

Joulukuu 2024

---

Tässä kirjallisuuskatsauksena toteutetussa kandidaatintutkielmassa tutkitaan sensorifuusion vaikutusta itseohjautuvien ajoneuvojen havaintokykyyn ja turvallisuuteen. Työ keskittyy kolmen sensoriteknologian – kameran, tutkan ja LiDARin – sekä sensorifuusion ominaisuuksien tarkasteluun ja vertailuun. Erityisesti perehdytään siihen, miten sensorifuusio parantaa havaintokyvyn luotettavuutta. Vertailun havainnollistamiseksi tutkielmaan on valittu kaksi tapausesimerkkiä, Tesla ja Waymo, jotka edustavat erilaisia sensoristrategioita autonomisessa ajamisessa. Tärkeimmät lähde- ja Kovel-tietokannoista löytyvät tieteelliset kirjat ja artikkelit.

Työssä havaittiin, että sensorifuusion avulla voidaan yhdistää eri sensoreista saatuja tietoja, mikä mahdollistaa monimutkaisten ympäristöjen tarkemman havaitsemisen haasteellisimmissakin sääolosuhteissa. Lisäksi se vähentää yksittäisten sensorien heikkouksista johtuvia virhearvioita. Sensorifuusion ansiosta ajoneuvon reagoitokyky, objektien tunnistus ja luokittelu sekä etäisyysmittaus paranevat selvästi.

Sensorifuusio hyödyntää pitkälle kehittyneitä syväoppimisalgoritmeja tiedon tehokasta prosessointia varten. Tästä syystä se asettaa kuitenkin uusia haasteita ajojärjestelmälle, sillä se vaatii suurta laskentatehoa, kuluttaa paljon energiaa ja aiheuttaa suuria kustannuksia. Sensorifuusioteknologian jatkokehitys onkin tärkeää energiatehokkuuden kannalta.

Asiasanat: autonominen ajoneuvo, itse ajava, havaitseminen, tietokonenäkö, kone-  
näkö, LiDAR, tutka, kamera, sensori fuusio, Tesla, Waymo, turvallisuus

# Sisällys

<b>1</b>	<b>Johdanto</b>	<b>1</b>
<b>2</b>	<b>Itseohjautuvat ajoneuvot</b>	<b>3</b>
2.1	Autonomisuuden tasot . . . . .	3
2.2	Komponentit . . . . .	5
<b>3</b>	<b>Sensortechnologiat</b>	<b>8</b>
3.1	Kamerat . . . . .	8
3.2	Tutka . . . . .	11
3.3	LiDAR . . . . .	14
<b>4</b>	<b>Sensorifuusio</b>	<b>18</b>
4.1	Toimintaperiaate . . . . .	19
4.2	Edut ja haitat . . . . .	21
4.3	Tapausesimerkit . . . . .	24
4.3.1	Tesla . . . . .	24
4.3.2	Waymo . . . . .	26
<b>5</b>	<b>Vertailua ja pohdintaa</b>	<b>28</b>
<b>6</b>	<b>Yhteenveto</b>	<b>32</b>
	<b>Lähdeluettelo</b>	<b>34</b>

# 1 Johdanto

Sanat kuljettajaton auto, autonominen ajoneuvo, robottiauto tai vielä tutummin itseohjautuva ajoneuvo tarkoittavat kaikki samaa ja näillä sanoilla viitataan nykyajan ja tulevaisuuden huippuluokan teknologiaan, joka tähtää mahdollisimman turvalliseen ja tehokkaaseen ajamiseen. Tällaisten ajoneuvojen tarkoitus on ajaa täysin automaattisesti ilman ihmiskuljettajaa, minkä takia niiden ennustetaankin olevan paljon turvallisempi vaihtoehto kuin perinteinen ajoneuvo. Tästä huolimatta ei voida unohtaa suuria turvallisuushuolia, joita nämä ajoneuvot herättävät, kun kyseessä on erittäin monimutkainen järjestelmä — jos yksi keskeinen sensori vioittuu, ajoneuvon on silti kyettävä minimoimaan riskit [1, Luku 16.3]. Kilpailu on kovaa, ja ajoneuvoteollisuus sekä muut tekniikan alan yritykset investoivat suuria summia, jopa miljardeja dollareita, autonomisten ajoneuvojen kehitystyöhön, jotta ne saataisiin vihdoin suunnitteluasteelta todelliseen tuotantoon. [2, Luku 1],[3, Luku 3.1.1]

Itseohjautuvassa ajoneuvossa on viisi pääkomponenttia, joista keskeisimmät ovat tietokonenäkö ja sensorifuusio. Sensorifuusion avulla yhdistetään tietoja monista eri sensoreista, jotta saadaan kokonaisvaltaisempi käsitys ympäristöstä. [2, Luku 1.1.1] Yleisesti ottaen, mitä enemmän erilaisia sensorilaitteita on, sitä suurempi tarkkuus ja laajempi havaintoalue voidaan saavuttaa. Tärkeimmät ympäristösensarit ovat LiDAR, tutka ja kamerat. [3, Luku 3.1.2.1],[3, Luku 3.1.2] Jokaisella näistä on omat rajoituksensa, ja siksi onkin hyvä pohtia sensorifuusion tuomia mahdollisuuksia luotettavuuden lisäämiseen.

Tämän kirjallisuustutkielman tavoitteena on pohtia sensorifuusion vaikutusta itseohjautuvien ajoneuvojen havaintokykyyn ja turvallisuuteen. Lisäksi tarkastellaan yksittäisten sensoreiden etuja ja haittoja sekä vertaillaan näitä sensorifuusion ominaisuuksiin. Tutkimuskysymykset ovat:

1. Millä tavalla sensorifuusio parantaa itseohjautuvien ajoneuvojen havaintokykyä ja turvallisuutta?
2. Miten eri sensorit eroavat toisistaan?

Tutkielma on toteutettu kartoittavana kirjallisuuskatsauksena. Lähdemateriaaleja on haettu pääosin Volter- ja Knovel-tietokannoista. Keskeisimmiksi lähteiksi ovat valikoituneet tieteelliset kirjat, jotka käsittelevät perusteellisesti autonomisia ajoneuvoja ja sensorteknologioita. Lukuun 4 on kerätty enemmän artikkeleita, jotka tarjoavat tarkempaa tietoa aiheesta. Lisäksi eräitä uutisia on valittu tapausesimerkkien lähteiksi niiden ajankohtaisuuden vuoksi. Tilastollisia lukuja on haettu turvallisuusraporteista ja viranomaisten verkkosivuilta. Hakulausekkeina on käytetty eri avainsanojen yhdistelmiä, ja hakutuloksia on rajattu vuodesta 2020 vuoteen 2024. Tutkielmaan on kuitenkin pyritty valitsemaan mahdollisimman tuoreita lähteitä. Hakulausekkeesta riippuen haut tuottivat usein satoja tuloksia, jolloin rajaus tehtiin otsikoiden ja abstraktien perusteella.

Tutkielman alussa käydään läpi itseohjautuvien ajoneuvojen teoreettista taustaa ja johdatellaan lukija kohti rajatumpaa näkökulmaa. Luvussa kolme käsitellään tarkemmin yksittäisten sensoreiden teknologioita ja tarkastellaan niiden etuja ja haittoja. Luvussa neljä keskitytään sensorifuusion toimintaan ja pohditaan sen etuja ja haittoja. Lopussa esitellään kaksi tapausesimerkkiä. Luku viisi yhdistää näiden aiempien lukujen tiedot ja vertailee yksittäisiä sensoreita sensorifuusioon samalla pohtien turvallisuusnäkökulmaa. Viimeisessä luvussa kootaan yhteen tutkielman pääkohdat ja lopputulokset.

## 2 Itseohjautuvat ajoneuvot

Itseohjautuvat ajoneuvot ovat tällä hetkellä hyvin suosittu tutkimusalue ja niiden odotetaan ratkaisevan monia haasteita, kuten liikennesuhteita ja pysäköinti-ongelmia. Myös energiankulutus, CO<sub>2</sub>-päästöt ja ilmansaasteet tulevat selvästi vähenemään, kun taas liikenneturvallisuus lisääntyy. [4] Erityisesti viime vuosina on havaittu merkittävää kehitystä automaation kannalta ja saavutettu suuria tieteellisiä läpimurtoja [5, Luku 15.1],[2, Luku 1]. Ideaalitulanteessa ajoneuvossa on vain matkustajia, jotka voivat keskittyä rauhassa työntekoon matkan aikana [6]. Ajoneuvoihin on tehty monia ominaisuuksia ja mukavuuksia, kuten turvajärjestelmiä ja laitteita, jotka ovat huomattavasti vähentäneet liikennekuolemia. On arvioitu, että ne tulevat vähentämään liikenneonnettomuuksia jopa 90 %:lla [2, Luku 1]. [7, Luku 1] Itseohjautuvia ajoneuvoja on testattu kokeellisissa ajokokeissa ja niiden testaus onkin yhä käynnissä. Ajoneuvoissa on kuitenkin yleensä turvakuljettaja mukana. Huolimatta suurista edistysaskeleista täysin itseohjautuvien ajoneuvojen salliminen julkiseen liikenteeseen ilman turvakuljettajaa voi viedä vielä monia vuosia. [2, Luku 1],[5, Luku 15.1]

### 2.1 Autonomisuuden tasot

Autoteollisuudelle on vakiintunut käyttöön kansainvälinen automaatioasteikko, jonka on määritellyt Society of Automotive Engineers (SAE) <sup>1</sup>. Luokittelun tarkoituksena on auttaa ihmisiä hahmottamaan, missä kohtaa kehityskulkua ollaan tällä

---

<sup>1</sup>SAE-kotisivu: [https://www.sae.org/standards/content/j3016\\_202104](https://www.sae.org/standards/content/j3016_202104)

hetkellä. Näin ollen luokittelu jakaa ajoneuvot niiden suorituskyvyn perusteella kuuteen eri tasoon. [2, Luku 1.3]

**Taso 0 - manuaalinen auto:** Tämä on kaikista alkeellisin taso, jossa kuljettajalla on täysivaltainen vastuu ajoneuvon hallinnasta. Kuljettajan täytyy itse huolehtia siitä, että pääsee päämääräänsä kaikkien osapuolten turvallisuus huomioiden. Tason 0 ajoneuvossa voi silti olla eräitä turvallisuusominaisuuksia, kuten varoitusjärjestelmä tai automaattinen hätäjarrutus, mutta pääsääntöisesti tämän tason ajoneuvo ei kykene itse omatoimiseen toimintaan. [1, Luku 16.2.1],[2, Luku 1.3]

**Taso 1 - kuljettajan avustus:** Kuljettaja on edelleen päävastuussa tason 1 ajoneuvon hallinnasta, mutta ajoneuvo voi tarjota sekä ohjausapua (kaistanpitoavustin) että kiihdytys- tai jarrutusapua (vakionopeudensäädin) mutta se ei kykene suorittamaan näitä toimintoja yhtä aikaa. Näin ollen ajoneuvo voi avustaa kuljettajaa tietyissä tehtävissä mutta kuljettajan on itse oltava jatkuvasti valppaana ja valmis ottamaan täysi hallinta milloin tahansa. [1, Luku 16.2.1]

**Taso 2 - osittainen automaatio:** Tason 2 ajoneuvo sisältää tason 1 suorituskyvyn mutta kykenee sen lisäksi tarjoamaan jatkuvaa ohjaus-, kiihdytys- ja jarrutusavustusta samanaikaisesti. Kuten aiemmissakin tasoissa, kuljettajan on aina oltava valmiina ottamaan täydellinen hallinta ajoneuvosta. [1, Luku 16.2.1]

**Taso 3 - ehdollinen automaatio:** Ajoneuvot, jotka ovat saavuttaneet tason 3 tai sitä korkeamman luokituksen, suorittavat itse kaiken ympäristön havainnoinnin hyödyntäen eri sensoreita, kuten LiDARia. Tämän tason ajoneuvo kykenee ajamaan autonomisessa tilassa tietyissä tilanteissa, mutta kuljettajan on voitava ottaa hallinta tarvittaessa, jos ajoneuvon oma hallintakapasiteetti ei riitä. [2, Luku 1.3] Ensisijainen ero tason 2 ja tason 3 välillä on se, että tasolla 3 kuljettajan ei tarvitse

jatkuvasti tarkkailla ajoneuvon suorituskykyä sen ollessa autonomisessa tilassa [1, Luku 16.2.1].

**Taso 4 - korkea automaatio:** Tason 4 ajoneuvo pystyy suorittamaan kaikkia ajotehtäviä määrittelemättömän kauan ja kykenee reagoimaan yllättäviinkin tilanteisiin niin, että se pystyy minimoimaan riskit mahdollisimman hyvin. Ihmiskuljettaja voi ottaa ajoneuvosta hallinnan riskitilanteissa tai milloin tahansa halutessaan. Suurin ero tason 4 ajoneuvoissa alemman tason ajoneuvoihin on se, että kenelläkään ei ole tarvetta ottaa hallintaa ajoneuvosta, kun se on käynnissä. [1, Luku 16.2.1]

**Taso 5 - täysi automaatio:** Tasolla 5 kaikki ajotehtävät suorituvat täysin autonomisesti ilman ihmisen vaikutusta. Tällaisissa ajoneuvoissa ei ole tarvetta minkäänlaisille ohjauslaitteille, sillä kaikki ajoneuvossa olevat henkilöt ovat vain matkustajia. Tason 5 ajoneuvo hallitsee kaikki sääolosuhteet, maantietyypit ja poikkeustilanteet. Ihmisen tehtäväksi jää vain määränpään valitseminen. [1, Luku 16.2.1],[2, Luku 1.3]

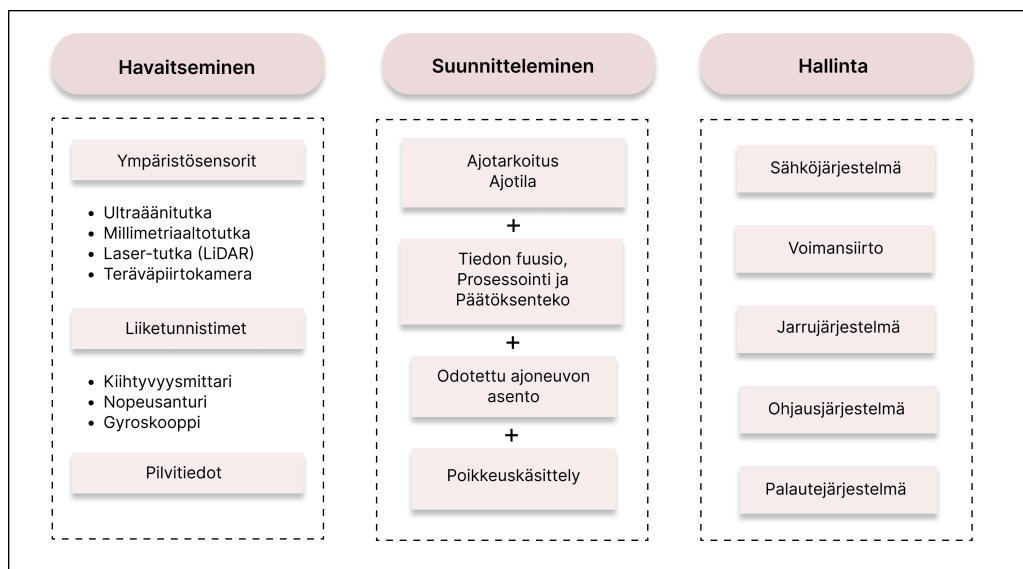
## 2.2 Komponentit

Nopea teknologia-alojen kehitys on mahdollistanut itseohjautuvien ajoneuvojen modernin arkkitehtuurin suunnittelun ja toteuttamisen. Itseohjautuville ajoneuvoille luodaan vahva perusta monien teknologioiden, kuten ajoneuvojen internetin (engl. *Internet of vehicles*, IoV), kehittyneiden sensortechnologioiden ja tekoälypohjaisten algoritmien yhdistelmällä. Esimerkkinä mainittakoon yritykset Google ja Tesla, jotka ovat onnistuneet saavuttamaan hyvin lupaavia tuloksia ajoneuvojen itseohjautuvuudessa. [3, Luku 3.1.1] Näihin esimerkkeihin palataan myöhemmin luvussa 4.

Itseohjautuvan ajoneuvon arkkitehtuuria suunniteltaessa on otettava huomioon samat tekijät, jotka ihmiskuljettajankin täytyy huomioida ajoneuvoa käyttäessään. Nämä tekijät ovat vaihteiden valinta, ohjaus, kiihdytys ja jarrutus. Jotta ajoneuvo

voi olla täysin autonominen, siihen rakennetun teknologian tulee kyetä hallitsemaan kyseiset tekijät sensoreiden ja tietokonejärjestelmien avulla. [1, Luku 16.2] Eräitä autonomiseen ajamiseen vaadittavia kehitysaskelaita on saatu valmiiksi, mutta täydellisen itseohjautuvan ajoneuvon mallia ei ole vielä onnistuttu kehittämään [1, Luku 16.3].

Autonomisten ajoneuvojen viisi pääkomponenttia ovat tietokonenäkö, sensorifuusio, paikantaminen, reitin suunnittelu ja kontrolli [2, Luku 1.1.1]. Itseohjautuvuuden saavuttamiseksi ajoneuvon pitääkin hallita useita hyvin laajoja toiminnallisia kokonaisuuksia [3, Luku 3.1.2]. Kuten kuvasta 2.1 ilmenee, ensimmäisenä tulee havaitseminen, sitten suunnittelu ja päätöksenteko ja vasta näiden moduulien jälkeen koko ajojärjestelmän hallinta. Ympäristösensorit ovat välttämättömiä havainnoinnin kannalta, eikä ilman niitä ajoneuvo voi saavuttaa muita moduuleja. Tässä työssä pääpainona on ajoneuvojen havaintokyky.



Kuva 2.1: Kolme päätoiminnon moduulia. Perustuen lähteeseen [3, Luku 3.1.2].

Havaintojärjestelmän tehtävänä on hankkia ja prosessoida ympäristötietoa reaaliajassa, tulkita ajoneuvon sijainti- ja asentotietoja, tunnistaa ja luokitella objekteja sekä määrittellä etäisyydet eri kohteille. Näiden seikkojen avulla muodostettujen tie-

tojen perusteella ajoneuvo voi luoda tilakäsityksen ympäristöstä. [3, Luku 3.1.2.1],[1, Luku 16.4.2.5] Sensorit keräävät jatkuvasti raakamuotoista tietoa ajoneuvosta ja sen ympäristöstä, mutta tämä raakadata ei ole suoraan käytettävissä sellaisenaan. Ratkaisuna tähän on konvoluutioneuroverkot (engl. *convolutional neural network*, CNN), jotka monien vaiheiden jälkeen muuntavat raakadatan käyttökelpoiseksi tiedoksi. [1, Luku 16.4.2]

Havainnointivaiheen jälkeen itseohjautuvan ajoneuvon pitää tehdä päätös sen seuraavista liikkeistä, jotka se aikoo suorittaa päästäkseen vaadittuun päämääräänsä turvallisesti [1, Luku 16.4.3]. Tässä suunnittelu- ja päätöksentekovaiheessa ajoneuvon järjestelmän on yhdistettävä useita sensoreilta saamia havaintotietoja ja tehtävä näiden pohjalta tehtäväpäätöksiä. Näihin päätöksiin kuuluu muun muassa useiden valinnaisten turvareittien suunnittelu, ja näistä lopulta valikoituu kaikista optimaalisin reitti. Suunnittelutoiminto voidaan jakaa globaaliin ja paikalliseen suunnitteluun. [3, Luku 3.1.2.2] Lisäksi suunnittelumoduulin neljä perustoimintoa, joita sen tulee tukea, ovat kaistanpito, liikennesääntöjen noudattaminen, törmäysten välttäminen ja ajoneuvoreitin suunnittelu [1, Luku 16.4.3].

Ohjausjärjestelmän pääteknologiat ovat ajoneuvon pysty- ja sivuttaisohjaus. Pystyohjauksella tarkoitetaan ajoneuvon ajamisen ja jarruttamisen hallintaa, kun taas sivuttaisohjauksella valvotaan ohjauspyörän kulman säätöä ja rengasvoimaa. Näiden kahden automaattisen ohjausjärjestelmän avulla itseohjautuva ajoneuvo kykenee toimimaan liikenteessä. Järjestelmän on myös hankittava yksityiskohtaiset tiedot tien dynaamisesta tilasta sekä ympäröivistä liikenneolosuhteista. Itseohjautuvien ajoneuvojen toteutumisen kannalta reaaliaikainen liikennetietojärjestelmä, luotettavat ajoneuvosensorit ja älykäs ohjausjärjestelmä ovatkin välttämättömiä teknisiä edellytyksiä. [3, Luku 3.1.2.3]

## 3 Sensoritekniologiat

Tässä luvussa syvennyttään tarkemmin ympäristösensoreihin sekä niiden etuihin ja haittoihin. Aluksi esitellään kamerat ja niiden yleisimmät tyypit. Tämän jälkeen tarkastellaan tutkaa ja sen kahta yleisintä tyyppiä itseohjautuvissa ajoneuvoissa. Lopuksi käsitellään LiDAR-teknologiaa. Luvussa tarkastellaan myös jokaisen sensorin haavoittuvuuksia, sillä teknologian yleistyessä vihamieliset hyökkäysyritykset lisääntyvät, mikä heikentää turvallisuutta.

### 3.1 Kamerat

Kamerat toimivat itseohjautuvien ajoneuvojen silminä, jolloin niiden tarkoitus on jäljitellä ihmissilmän kykyä havainnoida ympäristöä visuaalisesti [7, Luku 4.1.1.1]. Suurin osa ajoon käytettävästä tiedosta saadaan juuri kameroiden kuvantunnistuksen avulla, minkä vuoksi ne ovatkin pakollisia sensoreita itseohjautuvissa ajoneuvoissa. [3, Luku 3.4] Riippuen valmistajasta, eräät autonomiset ajoneuvomallit, kuten Tesla, käyttävät videokameroita ensisijaisina sensoreina ulkoisen ympäristön tarkkailuun. Näillä videokameroilla onkin hyvin samankaltaisia ominaisuuksia kuin kuluttajakäyttöön suunnatuilla digitaalisilla videokameroilla. Autonomiseen ajoneuvoon tarkoitettulla videokameralla on oltava korkea kuvatarkkuus eli resoluutio, joka on yleensä 1920 x 1080 pikseliä. [1, Luku 16.4.1.2] Tällaisia korkearesoluutioisia videokameroita kutsutaan teräväpiirtokameroiksi (engl. *Hi-Definition*, HD). HD-kameroita

on olemassa hyvin laaja joukko erilaisia malleja ja tyyppejä, jolloin ne voidaankin jakaa monokulaari-, binokulaari- ja panoraamakameraan [3, Luku 3.4].

**Monokulaarikamerassa** on vain yksi kamera, jolloin puhutaan mononäköjärjestelmästä (engl. *mono-vision system*). Tällainen järjestelmä tuottaa vain kaksiulotteisia digitaalisia kuvia, jolloin etäisyyksien arviointi on haasteellisempaa. [7, Luku 4.1.1.1],[1, Luku 16.4.2.4] Monokulaarikamera käyttää ainoastaan yhtä optista järjestelmää ja kiinteässä tilassa olevaa kuvantamislaitetta jatkuvien kuvien tuottamiseen. Toimintaperiaatteena on, että kameran on ensin tunnistettava kohde vertailemalla ja sovittamalla vastaavanlaisia kuvia yhteen ja sen jälkeen arvioida etäisyys kuvan koon perusteella. [3, Luku 3.4]

Yhdistettäessä useampia kameroita saadaan stereonäköjärjestelmä (engl. *stereo-vision system*), joka mahdollistaa kolmiulotteisten digitaalisten kuvien muodostamisen ja etäisyysmittaukset. Näiden 3D-kuvatietojen käsittely vaatii huomattavasti kehittyneempien ja monimutkaisempien algoritmien käyttöä kuin 2D-kuvissa. [7, Luku 4.1.1.1] **Binokulaarikamerat** ovat hyvä esimerkki stereonäöstä, ja niiden suunnittelu pohjautuu ihmisenäköjärjestelmän tutkimukseen. Niiden toiminta perustuu binokulaarisen kolmiomittauksen periaatteeseen, jossa etäisyys edessä olevaan kohteeseen mitataan laskemalla kahden kuvan parallaksi eli kulma ilman, että arvioidaan, millainen este edessä on. [3, Luku 3.4]

**Panoraamakameraa** käytetään katunäkymien kuvantamiseen, ja se koostuu kuudesta samanlaisesta kamerasta, jotka kuvaavat samanaikaisesti. Tämän jälkeen kuvat korjataan ja yhdistetään, jolloin saadaan panoraamakuvia samanaikaisesta kuvauksesta. Nämä kamerat tarjoavat itseohjautuville ajoneuvoille lisäapua kohteiden tunnistamiseen. [3, Luku 3.4]

### Edut ja haitat

Vaikka kamerat ovat ehdottomia sensoreita itseohjautuvan ajoneuvon toiminnan kannalta ja niillä on monia vahvuuksia ja etuja, ne ovat samalla kaikista alttiimpia erilaisille häiriötekijöille verrattuna muihin sensoreihin. Tämä rajoittaa jonkin verran niiden sovelluksia itseohjautuviin ajoneuvoihin. [7, Luku 4.1.1.2],[3, Luku 3.4]

Verrattuna aktiivisiin sensoreihin, kuten tutkaan ja LiDARiin, kamera on passiivinen sensori, jolloin sen ei tarvitse lähettää signaaleja kerätäkseen tietoja. Päivänvalossa kameralla on hyvä havaintoalue, joka on selkeä ja ylittää 100 metriä. Toisin kuin tutkalla, kameramittauksella voidaan saavuttaa hyvinkin korkea resoluutio. Lisäksi tärkeänä ominaisuutena kamerat voivat erottaa väritietoja ympäristöstä. Erityisesti värintunnistuksen ja resoluution ansiosta kameroiden objektien tunnistuskapasiteetti on selvästi parempi verrattuna muihin sensoreihin. [7, Luku 4.1.1.2],[1, Luku 16.4.1.3] Kameroiden suosiota lisää myös niiden matala hinta ja sovellettavuus, sillä itseohjautuviin ajoneuvoihin on saatavilla monia kamerajärjestelmiä, jotka taas mahdollistavat eri toimintojen toteuttamisen. Kolmen kameran käyttö, niin kutsuttu monikamerajärjestelmä, voi kattaa entistä pidemmän matkan ja laajemman näkökentän, jolloin havaintotarkkuutta ja turvallisuutta voidaan parantaa huomattavasti. [3, Luku 3.4]

Kuten aiemmin mainittiin, kameroilla on silti monia rajoituksia. Ympäristön monimuotoisuuden ja vaihtelevien sääolosuhteiden vuoksi ne ovat erittäin alttiita monille epävarmoille tekijöille, kuten valaistukselle, kuvakulmille, varjoille ja taustahäiriöille. [3, Luku 3.1.2.1] Myös rankkasade, lumisade ja tiheä sumu johtavat usein epäonnistumiseen [1, Luku 16.4.1.3]. Jos saaduissa kuvissa ilmenee virheitä, lopulliset kameroiden tuottamat tulokset tulevat olemaan hyvin viallisia [3, Luku 3.4]. Näin ollen kamera on hyvin altis häiriöille, eikä täysin ihanteellista kamerasensoria ole olemassa. [3, Luku 3.1.2.1] Kameroihin liittyvä ohjelmisto on myös ongelmallinen, sillä eräät kehittyneet tietokonenäköalgoritmit vaativat suurta käsittelyaikaa ja

-tehoa, mikä aiheuttaa haasteita havaintoalgoritmien reaaliaikaiselle toteuttamiselle. Tämä lisää puolestaan ajoneuvojen energiankulutusta. [7, Luku 4.1.1.2]

Kokonaan omaksi ongelmaluokaksi muodostuu teknologioiden haavoittuvuudet. Mahdollinen hyökkääjä voi yrittää häiritä HD-kameran toimintaa erilaisilla laitteilla, joiden tarkoitus on heikentää kameran näytön laatua käyttäen sähkömagneettisia häiriöitä, taajuus- tai heijastushäiriöitä. Lisäämällä kameran tuottamaan kuvaan enemmän viivoja ja kohinaa hyökkääjä voi saada luotua onnistuneen harhavaikutelman. Yksi tunnettu hyökkäysmenetelmä on sokaiseva hyökkäys, jossa voimakasta valonlähdettä suunnataan kohti kameraa. Jo kahden tai kolmen sekunnin kestoinen sokeuttaminen voi aiheuttaa vakavia seurauksia ajoneuville. [3, Luku 3.4.3]

## 3.2 Tutka

Tutka (engl. *radio detection and ranging*, radar) on kohteiden havaitsemisjärjestelmä, joka hyödyntää Dopplerin ilmiötä kohteiden etäisyyksien ja liikkeiden määrittämiseksi. Järjestelmä koostuu lähettimestä, aaltoputkesta, duplekserista, vastaanottimesta ja signaaliprosessorista. Nämä osat ovat tarpeellisia Dopplerin ilmiön aikaansaamiseksi. Antennin kautta lähetetään ensin radioaalto, joka heijastuu kohteesta ja palaa takaisin tutkaan. Tämän jälkeen heijastunut aalto vastaanotetaan ja ohjataan vastaanottimeen, jossa signaali käsitellään. Lopuksi heijastuneen aallon ajoitus ja ominaisuudet määrittelevät kohteen sijainnin ja nopeuden. Tutka luokitellaankin time-of-flight (TOF) -sensoreihin, joiden tehtävänä on mitata aikaa, jonka esine, hiukkanen tai aalto kulkee tietyn matkan väliaineen läpi. [7, Luku 4.1.2.1] Tutkajärjestelmän koko riippuu sen käyttötarkoituksesta, sillä sopiva radiotaajuus säädetään havaintotarkoituksen ja vaaditun havaintoalueen mukaan. Havaitsemiseen suunniteltu tutka on tyypillisesti suhteellisen pieni. [7, Luku 4.1.2.2] Tarkastellaan seuraavaksi kahdenlaista tutkaa, joita itseohjautuvat ajoneuvot hyödyntävät.

Ensimmäinen on **ultraäänitutka**, jota yleisesti hyödynnetään pysäköinnissä. Se koostuu usein sensoreista, ohjaimista ja näyttölaitteista. Ajoneuvon takaosaan tai etuosaan asennettu tutkasensori lähettää ohjaimen hallitsemana ultraäänipulsseja, jotka havaitsevat esineet mittaamalla aikaa, joka kuluu kaikupulssin heijastumiseen esteestä. 40, 48 ja 58 kHz sensorit ovat yleisimmin käytetyt, mutta näistä 40 kHz sensori on suosituin. Ultraäänitutka voidaan vielä jakaa ultraäänipysäköintiavustimeen (engl. *ultrasonic parking assist*, UPA) ja automaattipysäköintiavustimeen (engl. *auto parking assist*, APA). Kummankin järjestelmän tarkoituksena on mitata esteiden etäisyyksiä ajoneuvoon nähden, mutta erona on laitteiden sijainnit. UPA asennetaan auton etu- ja takaosaan, kun taas APA asennetaan auton sivuille mittaamaan esteiden etäisyyksiä sivultapäin. UPA:n havaintoalue on noin 15–250 cm ja APA:n puolestaan 30–500 cm. Näin ollen APA-sensorilla on pidempi havaintoalue, jolloin se on myös kalliimpi ja tehokkaampi kuin UPA-sensori. [3, Luku 3.2.1],[3, Luku 3.2.2]

Toinen on **millimetriaaltotutka**, joka on itseohjautuvien ajoneuvojen yksi keskeisimmistä komponenteista. Millimetriaaltoteknologia on mahdollistanut merkittäviä edistysaskeleita autojen tutkajärjestelmien suorituskyvyssä. Ne voivat mitata etäisyyden, kulman ja suhteellisen nopeuden tutkan ja kohteen välillä. Tutka havaitsee kohteen lähettämällä sähkömagneettista aaltoa ja vastaanottamalla heijastunutta kaikua. Näitä tutkia on saatavilla 24, 60, 77 ja 79 GHz:n taajuuksilla. Käytettävissä olevat taajuusalueet ovat kuitenkin yleensä 24 GHz ja 77 GHz, joista ensimmäistä käytetään lyhyen ja keskipitkän matkan mittauksiin ja toista pitkän matkan mittauksiin. Erityisesti pitkän kantaman millimetriaaltotutka on selvästi parantanut nopeuden mittausta ja etäisyystarkkuutta. Sen koko on myös pienentynyt, mikä helpottaa tutkan asentamista ajoneuvoihin. Lisäksi se kattaa laajemman havaintoalueen, mutta samalla havaintotarkkuus heikkenee. Siksi useiden erilaisten tutkien yhdistelmä onkin hyvin suositeltavaa paremman tuloksen saavuttamiseksi. Millimetriaaltotutkaa käytetään pääasiassa huippuluokan autoissa, ja se soveltuu

hyvin myös nopeampiin ajoneuvoihin. Lisäksi sitä voidaan hyödyntää monissa kehittyneissä ajoavustusjärjestelmien (engl. *advanced driving assistance system*, ADAS) toiminnoissa. [8, Luku 2],[3, Luku 3.3.2],[3, Luku 3.3.2]

### **Edut ja haitat**

Tutkajärjestelmät pystyvät monissa tilanteissa korvaamaan kameroiden puutteita, ja täten ne täydentävät niiden toimintaa. Vahvan läpäisykyvyn ansiosta tutka toimii heikkenemättä monissa huonoissa sääolosuhteissa, joissa videokamerat usein epäonnistuvat [3, Luku 3.3.3],[1, Luku 16.4.1.3]. Se pystyy myös havaitsemaan kohteen liikkeen 250 metrin etäisyydeltä ja tehokkaimmat yksiköt jopa 1000 metrin etäisyydeltä, kun taas kameroilla tämä jää paljon alhaisemmaksi. Kohteiden sijainnin ja nopeuden havaintotarkkuus on myös paljon korkeampi kuin kameroilla, sillä tutka pystyy suoraan mittaamaan suhteellista nopeutta, kun taas kameroilla tämä saavutetaan käsittelemällä ja vertailemalla peräkkäisiä kuvia. Tutkan lähettäessä omia signaaleja se ei ole riippuvainen ympäröivästä valaistuksesta eikä ole altis häikäisylle. Näin ollen se kestää hyvin erilaisia häiriötekijöitä [3, Luku 3.1.2.1]. [7, Luku 4.1.2.2] Lisäksi tutkan suosiota lisää sen halpa hinta verrattuna LiDARIin ja alhainen energiankulutus. [3, Luku 3.2.1]

Tutka ei myöskään ole täydellinen, sillä vaikka monia erilaisia tutkia olisi asennettuna ajoneuvoon, ei ole silti mahdollista ratkaista kaikkia heijastuksen, savun ja pölyn sekä huonojen sääolosuhteiden tuomia haasteita. [3, Luku 3.1.2.1] Tutkalla on selvästi sumeampi näkymä ja alhaisempi kuvatarkkuus verrattuna videokameroihin, ja ne ovat alttiita kohinaisille mittauksille, mikä heikentää niiden tarjoaman tiedon luotettavuutta. [1, Luku 16.4.1.3] Tutka ei välttämättä kykene muodostamaan yksityiskohtaista 3D-karttaa tai edes selkeää 2D-kuvaa. On olemassa myös signaalihäiriöriski, sillä aktiiviset sensorit voivat joutua muiden lähellä olevien signaalilähteiden vaikutuksenalaisiksi. Näiden seikkojen vuoksi tutkan käyttötapaukset

saattavat rajoittua vain esineiden ja tienkäyttäjien havaitsemiseen. [7, Luku 4.1.2.2] Verrattuna kameroihin tutka on puolestaan kalliimpi valinta. [2, Luku 1.2.2]

Tutkatyypistä riippuen niillä voi olla erilaisia haavoittuvuuksia. Häirintä- ja huijaushyökkäykset tulevat mahdollisiksi, jos onnistutaan toteuttamaan hyökkäysjärjestelmä, joka tuottaa samantaajuista ultraääniaaltoja kuin ajoneuvon ultraäänitutka. Myös ultraäänikohinan lähettäminen tutkaan johtaa helposti virhearvioihin ja suorituskyvyn heikkenemiseen. Kun ajoneuvojärjestelmä johdetaan harhaan, se aiheuttaa virrehälytyksen [3, Luku 3.2.3]. Näillä hyökkäyksillä voidaan tuottaa vakavia liikenneonnettomuuksia. [3, Luku 3.2.3.2] Millimetriaaltotutkaa on paljon vaikeampi murtaa kuin ultraäänitutkaa. Laitteiden hinta, joilla tätä voidaan yrittää häiritä vastaa melkein kolmea Tesla Model S -auton hintaa, joten hyökkäys ei useinkaan ole kannattavaa. Kuitenkin, jos millimetriaaltotutkan ominaisuudet tiedetään, voidaan signaaligeneraattorilla luoda samalla taajuualueella oleva elektromagneettinen aalto, joka häiritsee tutkajärjestelmää. Tämä voi johtaa siihen, että autopilottijärjestelmä joko menettää havaintonsa kohteesta tai luulee virheellisesti, että edessä on auto. Lisäksi huijaushyökkäykset voivat muuttaa kohteen mitattua etäisyyttä ajoneuvosta. [3, Luku 3.3.3]

### 3.3 LiDAR

Valotutka eli optinen tutka (engl. *light detection and ranging*, LiDAR) on etäisyyden mittausteknologia, jolla on useita keskeisiä yhtäläisyyksiä aiemmin esitetyn tutkan kanssa, mutta se käyttää eri osaa sähkömagneettisesta spektristä. Toisin kuin perinteinen tutka, LiDAR-yksikkö pyörii ja lähettää jatkuvasti laserpulsseja ympäristöönsä kerätäkseen tietoja eri pinnoilta ja kohteilta saaduista heijastussignaaleista. Korkeataajuinen laser voi saada suuren määrän sijaintipisteitä sekunnissa ja tehdä tämän tiedon perusteella kolmiulotteista mallinnusta. Tällöin LiDARin havaitessa laserin heijastuksen pinnalta ohjelmisto generoi pistepilven (engl. *point cloud*), joka

edustaa 3D-tilaa, jossa heijastukset on todettu tapahtuneen. Erityisten ohjelmistojen tai algoritmien avulla voidaan sujuvasti yhdistää näitä pisteitä, mikä mahdollistaa kohteen muodon määrittämisen ja tunnistamisen. Esineiden havaitsemisen ja paikantamisen lisäksi LiDAR pystyy määrittämään niiden liiketilän, kuten nopeuden ja asennon sekä ajoneuvon sijainnin ja suunnan. Monet suuret yritykset, kuten Google, Baidu ja Uber, ovat valinneet juuri LiDARin yhdeksi tärkeimmäksi sensoriksi itseohjautuvien ajoneuvojen kehittämiseksi. Poikkeuksena tästä on Teslan perustaja Elon Musk, jonka mukaan kaikki, jotka turvautuvat LiDARiin tulevat epäonnistumaan [2, Luku 1.2.2]. [3, Luku 3.5.1],[7, Luku 4.1.3],[1, Luku 16.4.1.4]

LiDAR koostuu kolmesta osasta, jotka ovat lähetys-, vastaanotto- ja tietojenkäsittelyjärjestelmä. Sen havaintoalue kattaa noin 200 metrin matkan [7, Luku 4.1.3]. Laserlaite muuntaa sähköpulssein optiseksi pulssiksi, minkä jälkeen optinen vastaanotin muuntaa kohteesta heijastuneen optisen pulssin takaisin sähköpulsseiksi. Pulsstit noudattavat TOF-periaatetta samalla tavalla kuin tavallisen tutkan radioaaltoakin. [3, Luku 3.5.2]

### **Edut ja haitat**

Kuten aiemmin todettiin, LiDAR-tekniikkaa pidetään yhtenä tärkeimmistä itseohjautuvien ajoneuvojen tekniikoista sen huomattavien etujen vuoksi. Näitä ovat tarkkuus, nopeus ja tehokkuus. LiDARilla on korkea etäisyystarkkuus, vahva suuntaavuus ja nopea reagointikyky. LiDAR kykenee havaitsemaan ympäristössään olevat esineet niiden väristä riippumatta, kun taas kamera ei välttämättä pysty tunnistamaan kohdetta, jos kohteen havaittu väri ei erotu riittävästi ympäristöstään [1, Luku 16.4.2.4]. Laser-signaalin heijastuvuuden perusteella se voi määrittellä jopa esineiden materiaalit. Näiden lisäksi LiDARilla on kaksi erittäin keskeistä roolia itseohjautuvissa ajoneuvoissa. Ensinnäkin se voi luoda korkean resoluution 3D-digitaalikartan ajoneuvon ympäristöstä laserskannauksen avulla ja toiseksi se voi saavuttaa visuaali-

sen samanaikaisen paikannuksen ja kartoituksen (SLAM), mikä parantaa ajoneuvon navigointi- ja paikannustarkkuutta. [3, Luku 3.5.1],[7, Luku 4.1.3],[2, Luku 4.2.4]

Vaikka LiDAR on hyödyllinen, se ei korvaa kameroita, sillä se ei pysty näkemään valoja ja värejä. LiDARilla on alhaisempi resoluutio kuin kameroilla, mikä tarkoittaa sitä, että se ei aina välttämättä tunnista havaittua kohdetta. [2, Luku 1.4.1] Se on melko altis monille ympäristökiteijöille, kuten sumulle ja rankkasateelle. LiDARin paikannusjärjestelmä toimii vain ympäristöissä, jotka on tarkasti kartoitettu. Koska ajoneuvon käytössä on oltava tietokanta, joka sisältää karttatiedot, edellyttää se jatkuvaa investointia kartoitusdatan keräämiseen teiltä. Tätä kartoitusprosessia on toistettava, jotta voidaan huomioida mahdolliset muutokset ympäristössä. [1, Luku 16.4.2.4] Näin ollen 3D-ympäristön rakentaminen vaatii paljon laskentatehoa ja energiaa. Suurin haittapuoli on korkea hinta verrattuna kameroihin ja tutkaan. Sensorina se voi olla kookas ja hauras sekä kestävyydeltään ja luotettavuudeltaan heikko. Lisäksi LiDAR on altis näkymäesteille lasersäteiden lyhyen aallonpituuden vuoksi, jolloin säteet eivät pysty läpäisemään esteitä. [7, Luku 4.1.3]

LiDARilla on hyvin pitkälti samankaltaisia haavoittuvuuksia kuin perinteisellä tutkallakin. Lasersignaalit eivät ole koodattuja tai salattuja, joten hakkereiden on mahdollista toistaa signaaleja milloin tahansa. Häiritäkseen LiDARin toimintaa hyökkääjän pitää lähettää lasersignaali takaisin LiDARille oikeaan aikaan, jotta syntyy illuusio siitä, että lasersignaali heijastuu esteestä. Tällöin itseohjautuva ajoneuvo vastaanottaa väärän signaalin ja tulkitsee sen esteeksi. Tämän tarkoituksena on saada ajoneuvo luulemaan, että edessä on jokin este, ja näin pakottaa se hidastamaan. [3, Luku 3.5.3.1] Toinen tapa LiDARin toiminnan estämiseksi on huijaushyökkäys, jossa tavoitteena on simuloida useiden esteiden, kuten autojen ja jalankulkijoiden signaalien heijastuksia. Hyökkääjä voi samalla kloonata useita signaalikopioita, mikä johtaa harhaluuloon, että esteet liikkuvat. Näiden lisäksi LiDARin seuranta järjestelmä voi joutua palvelunestohyökkäyksen kohteeksi, jolloin järjestelmä lamautetaan

eikä tällöin voi lähettää lasersignaaleja tai vastaanottaa heijastuneita signaaleja. Mikäli näin tapahtuu, LiDAR on täysin toimintakyvytön. [3, Luku 3.5.3.2]

LiDAR-teknologia hyödyntää pistepilvien lisäksi syviä neuroverkkoja (engl. *deep neural networks*, DNNs) saavuttaakseen huipputason 3D-kohteentunnistuksen. Mallien tehokkuus on vahvasti riippuvainen niiden kyvystä kestää hyökkäyksiä, jotka kohdistuvat suoraan malliin itseensä. Tällaisia hyökkäyksiä kutsutaan vihamielisiksi oppimishyökkäyksiksi. EVAA (engl. *Exchange Vanishing Adversarial Attack*) on uusi hyökkäysmenetelmä, joka kohdistuu LiDAR-pistepilviin itseohjautuvissa ajoneuvoissa. Tarkoituksena on huijata pistepilviä kohdistetulla kohinalla, mikä vaikuttaa tietyissä kohteissa, kuten ajoneuvoissa tai ajoteissä saaden nämä katoamaan tai vääristymään. Lisäämällä kohinaa luokiteltuihin pisteisiin ja vaihtamalla pisteiden paikkoja pyritään sekoittamaan luokittelu ja muuttamaan LiDARin tuottamaa 3D-mallia. Onnistuessaan hyökkäys voi vaikuttaa kohtalokkaasti ajoneuvon päätöksentekoon. [9]

## 4 Sensorifuusio

Jokainen luvussa 3 esitetty sensori on kehitetty tiettyyn sille määrättyyn tehtävään, jolloin sensoreiden alkuperäiset suunnittelutarkoitukset ovat erilaiset. Sensoreiden sisäinen yhteys tietojen välillä katkeaa, ja osa ympäristötiedoista voi kadota, jos näitä tietoja käsitellään täysin erillään. Siksi useiden sensoreiden yhdistäminen monitunnisteisen eli multimodaalisen havainnon saavuttamiseksi onkin lupaava suuntaus itseohjautuvien ajoneuvojen havaintokyvyssä. Sensorifuusio määritellään prosessiksi, jossa hallitaan ja käsitellään useista lähteistä tulevaa dataa tavoitteena parantaa tiettyjä kriteerejä ja datan ominaisuuksia halutussa toiminnossa. Se voidaan luokitella multimodaaliseksi fuusiomenetelmäksi, jossa yhdistetyt tiedot saadaan kahdesta tai useammasta erityyppisestä sensorista. Sensorifuusio parantaa koko ajojärjestelmän luotettavuutta ja resilienssiä lisäämällä tiedonvälitystä sekä laajentamalla eri sensorien ajallista ja alueellista kattavuutta. [10],[11, Luku 7.1],[12] Esimerkiksi kameroiden ja LiDARin yhdistäminen voi parantaa havaintotarkkuutta ympärivuorokautisesti monenlaisissa ympäristöissä [11, Luku 7.2.5]. Tällä hetkellä teollisuustason autonomisessa ajamisessa suositaan sensorifuusiostrategiaa, joka on todistettu olevan tehokas. Tästä huolimatta havaintokykyyn liittyvissä fuusiotekniikoissa on yhä haasteita, ja lisää tutkimusta aiheesta tarvitaan. [10]

## 4.1 Toimintaperiaate

Sensorifuusiomenetelmille on olemassa lukuisia luokittelujärjestelmiä. Tässä tarkastellaan vain kaikista yleisimpiä luokkia. Tutkan, LiDARin ja kameroiden tietojen yhdistämiseen käytetään kolmea lähestymistapaa (näiden terminologia voi hieman vaihdella lähteestä riippuen). Ensimmäinen luokka on matalan tason fuusio (engl. *low-level fusion*, LLF / *early fusion*), jossa datafuusio tapahtuu jo raakadatatasolla, jolloin ominaisuuksia ei ole vielä eroteltu sensoridatasta. Tällöin kaikki informaatio säilytetään, mikä voi mahdollisesti parantaa esteiden havaitsemisen tarkkuutta. Toinen luokka on keskitason fuusio (engl. *mid-level fusion*, MLF / *halfway fusion*), jossa ominaisuudet poimitaan sensoridatasta ja piirteiden analysoinnin jälkeen nämä yhdistetään fuusioverkon puolivälissä. Viimeinen luokka on korkean tason fuusio (engl. *high-level fusion*, HLF / *late fusion*), jossa jokainen sensori suorittaa kohteen tunnistuksen tai käyttää seuranta-algoritmia itsenäisesti päätöksiä varten. Tämän jälkeen suoritetaan vasta fuusio ja tehdään lopullinen päätös. [12], [13]

Eräs luokittelutapa on jakaa sensorifuusio kilpailevaan, täydentävään tai yhteistyöhön perustuvaan luokkaan. Kilpailevasta luokasta puhutaan, kun sensorit tuottavat toisistaan riippumattomia mittauksia samasta fyysisestä ilmiöstä. Täydentävästä luokasta on kyse silloin, kun sensorit eivät ole suoraan riippuvaisia toisistaan, mutta ne yhdistetään kattavamman kuvan saamiseksi tutkittavasta ilmiöstä. Yhteistyöhön perustuvassa luokassa sensorit yhdistävät tietoja yksittäisistä sensoreista tuottaakseen sellaista tietoa, jota yksittäiset sensorit eivät pystyisi tuottamaan. [14, Luku 14.3.2]

Sensorifuusiotekniikat ja -algoritmit voidaan jakaa klassiseen lähestymistapaan ja syväoppimiseen perustuvaan lähestymistapaan. Näistä juuri syväoppimisessa saavutetut edistysaskeleet ovat osoittaneet suurta potentiaalia edistämään itseohjautuvien ajoneuvojen onnistunutta toimintaa [7, Luku 6.5.1]. Syväoppimisalgoritmeja on hyödynnetty monissa erilaisissa ajoneuvojen järjestelmissä, kuten havainnoinnis-

sa, kartoituksessa ja päätöksen teossa. Näihin perustuvien sensorifuusioalgoritmien tutkimus on selvästi yleistynyt, ja erityisesti konvoluutioverkkoja (CNN) ja toistuvia neuroverkkoja (engl. *recurrent neural networks*, RNN) hyödyntävät algoritmit ovat saavuttaneet suurimman suosion itseohjautuvissa ajoneuvoissa. CNN on erittäin tehokas löytämään yhteyksiä kuvapikselien välillä. Sitä sovelletaan tietokonenäössä, kun taas RNN:n vahvuus on peräkkäisten tietojen käsittely, jota sovelletaan tietojen ennustamiseen. [12] Lisäksi tietokonenäön nopean kehityksen myötä LiDARiin perustuvat syväoppimisalgoritmit ajoneuvojen havaitsemiseen osoittavat ylivoimaisuutta havaintonopeudessa ja tarkkuudessa. Useimmat näistä menetelmistä käyttävät niin kutsuttua end-to-end-lähestymistapaa, jonka tarkoitus on parantaa reaaliaikaisen havainnoinnin tehokkuutta. [10] Esimerkkeinä tällaisista lähestymistavoista mainittakoon You Only Look Once (YOLO), Bird's-Eye View (BEV) ja LiDAR Range-View (RV) [13], [15].

Useimmat nykyiset tietojen yhdistämismenetelmät käyttävät havaintojen ja prosessien todennäköisyyspohjaisia kuvauksia tiedon yhdistämiseen. Yksi suosituimmista yhdistämismenetelmistä on Kalman-suodatinalgoritmi, jota käytetään yhdistämään eri sensoreilta saatuja tietoja. Tarkoitus on arvioida dynaamisen järjestelmän tilaa nykyisyydessä, menneisyydessä ja tulevaisuudessa, jotta voidaan seurata esimerkiksi liikkuvan jalankulkijan sijaintia ja nopeutta ajan mittaan sekä määrittää näihin liittyvä epävarmuus. Lisäksi toinen yleinen menetelmä on Bayesin sääntö, joka tarjoaa peruslogiikan datafuusioon. [2, Luku 12.3],[14, Luku 14.3.2]


Kuten edellä havaittiin, sensorifuusion malleja ja algoritmeja on useita eri luokkia. Sama pätee myös sen arkkitehtuurin suunnitteluun. Ei ole olemassa yhtä ainoaa arkkitehtuuria, joka soveltuisi kaikkiin tarkoituksiin. Järjestelmän rakenne tulisi suunnitella siten, että huomioidaan saatavilla olevat sensorit, järjestelmän yleinen tavoite ja järjestelmää rajoittavat tekijät. [7, Luku 6.3]

Sensorifuusio voidaan jakaa arkkitehtuurin perusteella kolmeen tyyppiin, jotka ovat keskitetty, hajautettu ja hybridifuusioarkkitehtuuri. Keskitetty fuusioarkkitehtuuri (matalan tason fuusio) on näistä kolmesta tyyppistä kaikista yksinkertaisin. Ominaista on se, että kaikkien sensoreiden tiedot käsitellään yhdessä keskusprosessorissa. Tällöin virheellisten tietojen havaitseminen on helppoa, koska tietojen käsittelyyn osallistuu vähemmän prosessoreita ja kaikki raakadata käsitellään yhdessä. Hajautetussa fuusioarkkitehtuurissa (korkean tason fuusio) sensoreilta saadut tiedot käsitellään paikallisesti, minkä jälkeen saatu tulos siirretään keskusprosessorille yhdistämistä varten. Hybridifuusioarkkitehtuuri (ominaisuustason fuusio) yhdistää puolestaan ominaisuuksia, kuten reunoja, kulmia, viivoja, tekstuureja ja sijainteja ominaisuuskartaksi, jota voidaan käyttää segmentointiin ja tunnistamiseen. Tämä lähestymistapa hyödyntää sekä keskitettyjen että hajautettujen arkkitehtuurien vahvuuksia tehokkuuden lisäämiseksi. On kuitenkin huomioitava, että tässä mallissa arkkitehtuurin monimutkaisuus kasvaa selvästi. [7, Luku 6.3],[12]

## 4.2 Edut ja haitat

Monissa tapauksissa järjestelmän kokonaissuorituskyky paranee huomattavasti, kun eri aallonpituuksilla toimivat monet sensorit asetetaan toimimaan yhteistyössä, jolloin ne tuottavat yhdistetyn tuloksen. Kuva 4.1 havainnollistaa tätä sensoreiden tuottamaa tulosta. Tärkeää onkin pyrkiä päihittämään yksittäisten sensoreiden rajoitukset ja puutteet. [12] Yleisesti ottaen sensorifuusio voidaan luokitella stereonäköön perustuvaan fuusioon, tutka-kamera-fuusioon, LiDAR-kamera-fuusioon sekä monisensoreihin perustuvaan fuusioon. [13]

Tavalliset näköön perustuvat (engl. *vision-based*) järjestelmät eivät pysty tarjoamaan tarvittavaa syvyytietoa 3D-ympäristön mallintamiseen. Siksi yhtenä ratkaisuna tähän on stereonäkö, joka koostuu useista eri paikoissa sijaitsevista kameroista, jolloin saadaan tallennettua samanaikaisesti kuvia kohteesta eri näkökulmista ja



Kuva 4.1: Erilaisten sensoreiden mallinnus itseohjautuvassa ajoneuvossa. Muokattu lähteestä [3, Luku 3.1.2.1]. Autokuva: Peeyush.ciit, CC BY-SA 4.0 Wikimedia Commons.

luotua näin riittävä syvyys- ja sijaintitieto kohteesta. Toisaalta stereonäkö on edelleen hyvin altis ulkoisille ympäristöolosuhteille. Tähän ratkaisuna ovat tutkan ja LiDARin fuusiot. [12], [13]

Tutka–kamera-fuusiossa yhdistyvät tutkan vahva sopeutumiskyky monimutkaisiin ympäristöihin ja kameroiden korkean resoluution kuvantamisominaisuudet. Tutka kykenee mittaamaan kohteen pituussuuntaista etäisyyttä tarkasti, kun taas kamera tarjoaa laajemman näkökentän. Lisäksi tutka tarjoaa tietoa ajoneuvon liikkeitä ja syvyydestä. Kalmanin suodatinta hyödyntämällä voidaan saavuttaa tasapaino suorituskyvyn ja energiatehokkuuden välillä, mikä osoittaa ohjelmisto–laitteisto-ekosysteemin kilpailukykyisyyden. Lisäksi sopivalla optimoinnilla voidaan saavuttaa tasapaino ajoneuvon havaintotarkkuuden ja nopeuden välillä. Hienosäätämällä yhdistelmää oikeilla algoritmeilla voidaan merkittävästi vähentää väärin havaintojen määrää. Näin ollen tutka–kamera-fuusio on tehokas kohteen tunnistus-, seuranta- ja luokittelutehtävissä parantaen järjestelmän tarkkuutta ja luotettavuutta. [13]

LiDAR–kamera-fuusiota pidetään yhtenä parhaimmista menetelmistä ympäristön havainnoinnissa [13]. Vaikka näköön perustuvat tekniikat ovat hyvin luotettavia jalankulkijoiden havaitsemisessa, ne eivät silti pysty mittaamaan etäisyyttä riittä-

vän tarkasti. LiDARin erittäin tarkka etäisyysmittaus korvaa tämän puutteen, kun taas kameroiden hyvä esineiden luokittelukyky korvaa tässä tilanteessa LiDARin. [16] Yhdistämällä LiDARin tuottamat 3D-syvyystiedot kameroiden korkearesoluutioiseen visuaaliseen dataan saadaan entistä parempi käsitys ympäristöstä. Fuusio mahdollistaa myös vahvan suorituskyvyn heikossa valossa, sillä valaistus ei vaikuta LiDARin havaintokykyyn. Lisäksi ajoneuvojen reaaliaikainen suorituskyky paranee huomattavasti, koska syväoppimismenetelmät mahdollistavat nopean reaaliaikaisen kohteentunnistuksen ja seurannan. LiDAR-kamera-fuusiolla ja YOLO-algoritmillä voidaan korkean tason fuusiovaiheessa saavuttaa vahvat reaaliaikaiset ja adaptiiviset ominaisuudet sekä vahva häiriönsietokyky. Tutkimusten mukaan soveltamalla sopivia algoritmeja ja malleja voidaan saavuttaa optimaalinen havaintotarkkuus, jossa autot havaitaan 97 % ja jalankulkijat 95 % tarkkuudella päivänvalossa. Yöllä lukemat ovat 94 % ja 93 %. [13]

Yhteenvedona voidaan todeta, että sensorifuusiolla on keskeinen rooli ajoneuvojen havaintotarkkuuden ja luotettavuuden vahvistamisessa monimutkaisissa ympäristöissä. Se vähentää virhearvioita ja lisää turvallisuutta. Yhdistämällä kaikki sensorit saadaan vahva suorituskyky erilaisissa sääolosuhteissa. Syväoppimis pohjainen sensorifuusio hyödyntää end-to-end-lähestymistapaa, joka on erikoistunut nopean reaaliaikaisen havainnoinnin ja ennustetarkkuuden parantamiseen. Tämä vaatii myös nopeaa tietojenkäsittelyprosessia. [10], [17]

Vaikka sensorifuusiolla on selkeitä etuja yksittäisiin sensoreihin nähden, sen perusongelmana on yhdistää tiedot oikein eri aikajaksoilta, erityyppisistä sensoreista ja erilaisista näkökulmista. Yksi suurimmista ongelmista on tasapaino kaiken tarvittavan tiedon keräämisen ja käsittelyn välillä siten, että se tapahtuu riittävän tehokkaasti reaaliaikaisen prosessoinnin mahdollistamiseksi. Tiedon liian suuri määrä voi johtaa ylitsepääsemättömiin tietojenkäsittelyvaatimuksiin, jotka kuormittavat laskentaa. Ilman riittävän tehokasta laskentaa automatisoidut ajotehtävät epäonnistu-

vat. Lisäksi pistepilvistä ja tutkista saatu tieto on epäsäännöllistä, harvapiirteistä ja järjestäytymätöntä, kun taas kameran antama tieto on säännöllistä, tiheää ja järjestäytyntä. Näiden eri tietojen esitysmuotojen yhteensovittaminen on haastavaa ja voi aiheuttaa vinoumia. On vaikeaa myös varmistaa, että erilaiset sensorit keräävät dataa samanaikaisesti. Ongelmana on myös suuret laskennalliset kustannukset ja kalliit sensortechnologiat [12]. Korkealaatuisten tietoaisteiden puute rajoittaa jonkin verran sensorifuusiomenetelmien kehittämistä, mikä tuo lisähaastetta tutkimuksille. [7, Luku 6.8],[11, Luku 7.4.1]

Tärkeää on myös huomioida syväoppimismallien tuomat läpinäkymättömyys- haasteet. Erityisen ratkaisevaa on tutkia tarkemmin turvallisuuden validointimenetelmiä ja hermoverkkojen tulkittavuutta ennen kuin näitä malleja otetaan käyttöön itseohjautuvissa ajoneuvoissa. Harjoitusaineistojen ylioppimista tulee myös välttää. Kuten mikä tahansa sensori, myös syväoppimismallit ovat alttiita vihamielisille hyökkäyksille. Hyökkääjät voivat manipuloida kuvia niin, että ne sisältävät pieniä muutoksia, jotka syötettäessä syväoppimisjärjestelmiin johtavat kohteiden väärään luokitteluun korkeilla luottamuspisteillä. [18]

## 4.3 Tapausesimerkit

Siinä missä Tesla keskittyy vahvasti kamerapohjaisten ajoneuvojärjestelmien kehittämiseen, muut autonvalmistajat ovat valinneet päinvastaisen lähestymistavan ja luottavat kameroiden, tutkan ja LiDARin yhdessä tuottamiin tuloksiin [19]. Tässä luvussa tarkastellaan kahta tapausesimerkkiä, Teslaa ja Waymoa.

### 4.3.1 Tesla

Vuoden 2020 lopussa Tesla julkaisi beta-version täysin itsestään ajavasta (engl. *Full Self-Driving*, FSD) tietokoneestaan, joka on osoittanut vaikuttavia kykyjä automaa-

tion kannalta. Vanhemmissa malleissa Tesla hyödynsi kameroiden yhdistelmiä, tutkaa ja ultraäänisensoreita auton valmistuksessa, mutta vuonna 2022 se luopui kokonaan ultraäänisensoreista ja tätä ennen jo tutkan käytöstä. Sen päämääränä on keskittyä nykyään vain kameroihin perustuvaan konenäköön (engl. *Tesla Vision*). Teslan tavoitteena onkin rakentaa kustannustehokas ja hyvältä näyttävä ajoneuvo, minkä vuoksi se on edennyt kohti edullisempaa sensorifuusiojärjestelmää. Uusimassa Model 3 -versiossa on kahdeksan kameraa, jotka kattavat 360° näkökentän ajoneuvon ympärillä. Näiden lisäksi siinä on kaksi Teslan suunnittelemaa FSD-sirua, jotka keskittyvät suurien neuroverkkojen laskentaan. Nämä sirut ovat kasvattaneet Teslan tietokonekapasiteettia jopa 2100 %. Ideana onkin täysin uudenlainen lähestymistapa, jossa supertietokoneen avulla parannetaan Tesla Vision -järjestelmää. On silti korostettava, että FSD-toiminto on edelleen testausvaiheessa ja sen todellinen toiminnallinen suorituskyky on vielä arvioimatta. LiDARin käytön määrätietoista vastustamisesta tunnettu Elon Musk on myöntänyt sen potentiaalin, mutta sensorin korkea hinta ja suuri koko eivät sovi Teslan tavoitteisiin. [7, Luku 5.4.2],[2, Luku 1.2.2],[19], [20]

Tutkan poistaminen uusimmista malleista on herättänyt nopeaa vastareaktiota monilta tahoilta. Yhdysvaltain liittovaltion tie- ja ajoneuvoturvallisuusvirasto (engl. *National Highway Traffic Safety Administration*, NHTSA) on poistanut ajoneuvoilta aiemmin ansaitut viiden tähden törmäysturvallisuusmerkinnät, kun taas kuluttajareportit (engl. *Consumer Reports*, CR) ja kolariturvallisuutta testaava IIHS (engl. *the Insurance Institute for Highway Safety*) ovat kumonnet Model 3:lle myönnettyt omat turvallisuusluokituksensa. Tutkimusten mukaan Tesla-ajoneuvot ovat törmänneet pysäköityihin ajoneuvoihin, vaikka autopilotti oli aktivoituna. Teslan turvallisuusraporttien vuosien 2018–2021 tilastojen mukaan autopilotti vähensi onnettomuuksia keskimäärin 3,6 % mailimäärää kohden, mutta joissain tapauksissa onnettomuusluvut kasvoivatkin [21]. Monien alan asiantuntijoiden ja tutkijoiden mukaan

tutkan poistaminen tekee Teslan ajojärjestelmästä entistä epäluotettavamman. [19] Yhtenä esimerkkinä tästä on marraskuussa 2023 kuolemaan johtanut onnettomuus, jossa Teslan FSD-toiminto epäonnistui ja törmäsi toiseen ajoneuvoon aiheuttaen ketjukolarin [20].

### 4.3.2 Waymo

Verrattuna Teslaan, joka tähtää asteittain automaation saavuttamiseen, Googlen emoyhtiön Alphabetin tytäryhtiö Waymo, joka irrotettiin omaksi yhtiökseen vuonna 2016, tunnetaan sen tavoitteista saavuttaa suoraan tason 4 automaatio monipuolisen sensorifuusion avulla [7, Luku 5.4.2]. Waymo onkin jo pitkään tunnettu yhtenä itseohjautuvien ajoneuvojen kehityksen kärkinimistä sen oman laitteisto- ja ohjelmistosuunnittelun ansiosta. Yritys valmistaa ja myy omia LiDAR-sensoreitaan, joiden hintaa on saatu radikaalisti laskettua vuoteen 2019 mennessä. Juuri hiljattain lanseeratussa kuudennen sukupolven versiossa ajoneuvo sisältää 13 kameraa, neljä LiDARia, kuusi tutkayksikköä ja ulkoisia audiovastaanottimia. Laitteisto tarjoaa päällekkäisen 360° ympäristön näkökentän, ja se pystyy tunnistamaan 500 metrin päässä olevat kohteet pimeässä tai huonoissa sääolosuhteissa. Waymon mukaan sensoriteknologian kehitys ja sensorien strateginen sijoittelu mahdollistavat niiden kokonaismäärän vähentämisen ja kustannusten merkittävän laskun. Samalla ylläpidetään kuitenkin korkean tason redundanssia ja turvallisuusjärjestelmiä. Toisaalta Waymo ei myöskään ole täydellinen, sillä se joutui esimerkiksi vetämään takaisin 672 ajoneuvoa havaittuaan, etteivät ne kyenneet väistämään pylväitä tai vastaavia esineitä. [2, Luku 1.2.2], [7, Luku 5.4.1],[7, Luku 6.7.1],[22]

Waymo ja Swiss Re, joka on yksi maailman johtavista jälleenvakuuttajista, ovat tehneet tiivistä yhteistyötä vuonna 2022 kehittääkseen riskien arviointimenetelmiä ja lähestymistapoja autonomisten ajoneuvojen turvallisuuden arviointiin. Swiss Re -yrityksen johtama tutkimus on saanut laajaa näkyvyyttä, sillä se osoittaa, että Way-

mon autonomiset ajoneuvot ovat merkittävästi turvallisempia kuin ihmiskuljettajat. [23] Tutkimusta varten Waymoa on testattu monissa erilaisissa simulaatioissa, joissa toistetaan tosielämän onnettomuuksia. Testien tarkoituksena on osoittaa itseohjautuvien ajoneuvojen turvallisuuspotentiaali. Erityistä huomiota halutaan kiinnittää ajoneuvojen kykyyn huomata muiden tienkäyttäjien tekemät virheet ja reagoida näihin tavalla, joka välttää törmäykset. Tutkimuksen tietoaaineisto koostui 72 kolariista ja 91 ajoneuvotoimijasta (52 alullepanijaa ja 39 reagoijaa). Testeissä havaittiin, että Waymon ollessa onnettomuuden alullepanijana se onnistui estämään kaikki törmäykset noudattamalla pelkästään liikennesääntöjä ja säilyttämällä turvalliset välimatkat ilman äkillisiä väistöliikkeitä. Reagoijan roolissa Waymo kykeni estämään 82 % onnettomuuksista ja lieventämään niistä 10 %. [24], [25]

Tutkimus ei kuitenkaan ollut kokonaisvaltainen, sillä simulaatiot toteutettiin vain San Franciscon ja Arizonan alueilla, jolloin ne edustavat vain näitä tiettyjä toimintaympäristöjä. Tutkimuksen lupaavat tulokset tulisi vielä saada yleistettyä kaikille ympäristöalueille. Huolimatta siitä, että inhimilliset virheet poistetaan, tutkimus ei voi ottaa huomioon uusia tuntemattomia tekijöitä, joita ajoneuvot saattavat kohdata liikenteessä. [23], [24]

## 5 Vertailua ja pohdintaa

Tähän asti työssä on syvennytty yksittäisten sensoreiden ja sensorifuusion toiminnallisuuksiin ja näiden tuomiin etuihin ja haasteisiin itseohjautuvissa ajoneuvoissa. Tämän luvun tarkoituksena on vertailla ja koota yhteen löydettyjä havaintoja sekä analysoida niitä eri näkökulmista. Pääpaino on ajoneuvojen havaintokyvyn ja turvallisuuden analysoinnissa.

Taulukkoon 5.1 on koottu kameran, LiDARin ja tutkan tärkeimpiä ominaisuuksia ja muita ulkoisia tekijöitä, jotka vaikuttavat olennaisesti itseohjautuvien ajoneuvojen suorituskykyyn. Taulukko havainnollistaa jokaisen sensorin heikkoudet ja vahvuudet ja osoittaa samalla, kuinka sensorifuusio täydentää ajojärjestelmää.

Taulukko 5.1: Kameran, LiDARin, tutkan ja fuusion vertailua teknisten ominaisuuksien ja muiden ulkoisten tekijöiden perusteella. ”-” -symboli kuvastaa kohtalaista, ”✗” huonoa ja ”✓” asianmukaista. Perustuen lähteeseen [18].

<b>Tekijä</b>	<b>Kamera</b>	<b>LiDAR</b>	<b>Tutka</b>	<b>Fuusio</b>
Kantama	-	-	✓	✓
Resoluutio	✓	-	✗	✓
Etäisyyden tarkkuus	-	✓	✓	✓
Nopeus	-	✗	✓	✓
Väriin havaitseminen, esim. liikennevalot	✓	✗	✗	✓
Objektin tunnistus	-	✓	✓	✓
Objektin luokitus	✓	-	✗	✓
Kaistan tunnistus	✓	✗	✗	✓
Esteen reunan tunnistus	✓	✓	✗	✓
Sietokyky valaistukselle	✗	✓	✓	✓
Sietokyky sääolosuhteille	✗	-	✓	✓

Yllä olevan esityksen lisäksi taulukko 5.2 tuo tiivistetysti esille luvussa 4.2 käsitellyjen stereonäön, tutka-kamera-fuusion ja LiDAR-kamera-fuusion merkittävimpiä etuja. Molemmat taulukot osoittavat tarkkuuden ja luotettavuuden paranemista itseohjattuvien ajoneuvojen havaintokyvyssä.

Taulukko 5.2: Eri sensorifuusioiden etujen vertailua yksittäisiin sensoreihin nähden.

Lähde	Yhdistetyt sensorit	Rajoitukset ilman fuusiota	Fuusion edut
[7, Luku 4]	Stereonäkö	Ei tarvittavaa syvyyystietoa yksittäisestä kamerasta; monokamera ei havaitse etäisyyksiä tarkasti. Tuottaa vain 2D-kuvia.	Mahdollistaa syvyystiedon laskemisen eri kulmista otetuista kuvista; parantaa objektien havaitsemista tarkan 3D-kuvan avulla.
[3, Luku 3] [7, Luku 4] [1, Luku 16] [13]	Tutka-kamera	Kamera on altis valaistus- ja sääolosuhteille; tutkan alhainen resoluutio ja sumea näkymä tuottavat heikkoja kuvia.	Yhdistää kamerasen korkean resoluution ja tutkan kyvyn havaita liikkuvia kohteita pääosin kaikissa olosuhteissa; vähentää väärin havaintojen määrää ja parantaa ajoneuvon havaintotarkkuutta.
[7, Luku 4] [2, Luku 1] [3, Luku 3] [13], [16]	LiDAR-kamera	Kamera ei mittaa etäisyyttä riittävän tarkasti; LiDAR ei tunnista värejä; sillä on alhainen resoluutio ja rajoittunut luokittelukyky.	Tarjoaa tarkkaa etäisyydestä ja korkearesoluutioiden visuaalisen 3D-näkymän; mahdollistaa paremman objektien tunnistuksen myös heikossa valaistuksessa; reaaliaikainen suorituskky paranee.

Voidaan suoraan havaita, että sensorifuusion korvatussa yksittäisten sensoreiden heikkoudet ja yhdistäessä niiden vahvuudet, sillä on merkittäviä mahdollisuuksia lisätä itseohjattuvien ajoneuvojen turvallisuutta erilaisissa tilanteissa ja monipuolisissa ympäristöolosuhteissa. Fuusiopohjainen järjestelmä on paljon kestävämpi erilaisia häiriötekijöitä ja sääolosuhteita vastaan. Kameroiden hyvä resoluutio ja värientunnistus tarkentavat LiDARin ja tutkan tuottamia tuloksia. Tutkan vakaa toiminta vaihtelevissa sääolosuhteissa sekä LiDARin tarkka etäisyyden mittaaminen ja 3D-mallinnus lisäävät ajojärjestelmän ominaisuuksia ja suorituskkyä verrattuna pelkkiin kameroihin. Havaintokyky paranee huomattavasti sensoreiden täydentäessä toinen toisiaan, ja tämä vastaavasti korreloi turvallisuuden kanssa.

NHTSA:n sivustojen<sup>1</sup> mukaan 42 514 ihmistä kuoli vuonna 2022 ajoneuvojen kolareissa, joista 13 524 johtui rattijuopumuksesta, 12 151 ylinopeudesta ja 693

<sup>1</sup>NHTSA-kotisivu: <https://www.nhtsa.gov/>

uneliaisuudesta. Yksi automaation suurimmista luvatuista eduista on ajoneuvojen turvallisuus, sillä korkeamman tason automaatiojärjestelmistä on poistettu ihmiskuljettaja kokonaan [26]. Onnettomuustilastojen valossa ihmiskuljettajat näyttävätkin olevan suurin riskitekijä liikenteessä. Lisäksi automatisoitujen ajojärjestelmien vuoden 2022 törmäysraportin [27] mukaan 130 törmäystä raportoitiin 11 kuukauden ajalta. Kaikista näistä törmäyksistä vain yhdestä tapauksesta aiheutui vakavia vammoja ja suurimmasta osasta törmäyksistä ei aiheutunut lainkaan vammoja. Nämä tilastot tukevat vahvasti ennustetta, jonka mukaan itseohjautuvat ajoneuvot tulevat selvästi lisäämään liikenneturvallisuutta tulevaisuudessa.

Havaintokyvyn lisäksi on tärkeää huomioida sensoreiden aiheuttamat kustannukset sekä niiden energiankulutus ja alttius erilaisille haavoittuvuuksille. Taulukko 5.3 kokoaa näitä tekijöitä yhteen tarkastelun helpottamiseksi.

Taulukko 5.3: Kameran, LiDARin, tutkan ja fuusion vertailua eri tekijöiden perusteella. ”-” -symboli kuvastaa kohtalaista, ”✗” kielteistä suhteessa muihin sensoreihin ja ”✓” myönteistä.

<b>Tekijä</b>	<b>Kamera</b>	<b>LiDAR</b>	<b>Tutka</b>	<b>Fuusio</b>
Korkea hinta	✗	✓	-	✓
Suuri energiankulutus	✗	✓	✗	✓
Vaatii paljon laskentatehoa	-	✓	✗	✓
Altis haavoittuvuuksille	✓	✓	-	✓
<b>Lähde</b>	[3, Luku 3] [7, Luku 4] [1, Luku 16]	[7, Luku 4] [9]	[3, Luku 3] [2, Luku 1] [7, Luku 4]	[7, Luku 6] [12], [13], [18]

Voidaan huomata, että sensorifuusion monista eduista huolimatta sen korkea hinta ja energiankulutus sekä sen vaatima suuri laskentateho aiheuttavat uusia ongelmia ajojärjestelmien toteuttamiselle. Koska sensorifuusio hyödyntää paljon syväoppimismenetelmiä, jotka ovat melko alttiita vihamielisille hyökkäyksille [18], järjestelmän häiriönsietokyky ei huomattavasti parane. Toisaalta yhteen sensoriin kohdistettu hyökkäys ei vielä välttämättä vahingoita koko järjestelmän toimivuutta. Sensorifuusio kasvattaa ajojärjestelmän kokoa ja monimutkaisuutta, mikä puolestaan herättää kysymyksen tarvittavista laskentaresursseista suurten tietojoukkojen

---

reaaliaikaista käsittelyä varten. Suuri haaste on myös havaintotarkkuuden ja päätelynopeuden välinen tasapaino sekä nykyisten havainnointiin perustuvien mallien kehittymättömyys mukautua kaikkiin mahdollisiin ajotilanteisiin [28]. Näin ollen fuusiotekniikkaa ei kuitenkaan voida pitää täydellisenä ratkaisuna itseohjautuvien ajoneuvojen ongelmiin.

## 6 Yhteenveto

Täysin luotettavaa autonomista ajojärjestelmää ei ole vielä onnistuttu kehittämään ajoympäristön monimutkaisuuden vuoksi. Tästä huolimatta itseohjautuvien ajoneuvojen tutkimuksessa käydään parhaillaan kovaa kilpailua, sillä varsinkin tekoälyn ja syväoppimisen nopea kehitys on mahdollistanut merkittäviä edistysaskeleita tietokonenäössä. Esimerkiksi LiDARiin perustuvilla syväoppimisalgoritmeilla on onnistuttu selvästi parantamaan ajoneuvojen reaaliaikaista havaintonopeutta ja -tarkkuutta. Itseohjautuvien ajoneuvojen onnistunut toiminta on vahvasti riippuvainen tietokonenäköjärjestelmien, monien erilaisten sensoreiden sekä sensoridatan käsittelyalgoritmien huolellisesta suunnittelusta.

Tässä tutkielmassa tarkasteltiin kameroiden, tutkan ja LiDARin sekä näiden yhdistelmien eli sensorifuusion toimintaa itseohjautuvissa ajoneuvoissa. Yksittäisten sensoreiden ja sensorifuusion merkitystä ajoneuvojen havaintokykyyn pohdittiin etuja ja haittoja tarkastelemalla. Lopuksi esitetyt havainnot koottiin taulukoihin sekä vertailtiin ja analysoitiin niiden tuloksia.

Keskeistä oli pohtia sitä, millä tavalla sensorifuusio parantaa itseohjautuvien ajoneuvojen havaintokykyä ja turvallisuutta. Pohdinnan tueksi tarvittiin ensin tietoa siitä, miten eri sensorit eroavat toisistaan. Kameroilla on erittäin korkea resoluutio ja ne havaitsevat värejä, mutta niiden huono etäisyyden mittausta ja alhainen sietokyky erilaisille ympäristöolosuhteille tekevät niistä epäluotettavia. Tutkan toiminta ei puolestaan ole riippuvainen ympäristöolosuhteista. Lähettäessään radioaaltoja se

pystyy määrittämään hyvin kohteiden etäisyydet ja liikkeet, mutta sen resoluutio on silti alhainen. LiDARin vahvuutena on tarkan 3D-mallin luominen ympäristöstä, mikä parantaa objektien tunnistusta, mutta samalla se vaatii paljon laskentatehoa ja energiaa.

Näin ollen sensorifuusio vaikuttaa potentiaaliselta ratkaisulta yksittäisten sensorien haasteisiin, sillä siinä yhden sensorin puutteet korvataan toisen sensorin vahvuuksilla. Järjestelmä ei tällöin ole riippuvainen vain yhden sensorin toiminnasta, jolloin sen resilienssi ja luotettavuus paranevat. Fuusion ansiosta ajoneuvon havaintotarkkuus, objektien tunnistus ja etäisyysmittaus paranevat kaikissa ympäristöolosuhteissa. Reaaliaikaisen korkearesoluutioisen 3D-kartan ja syväoppimisalgoritmien avulla voidaan saavuttaa optimaalinen havaintotarkkuus, joka parantaa huomattavasti ajojärjestelmän turvallisuutta.

Vertailun konkretisoimiseksi työssä on käytetty kahta tapausesimerkkiä, Teslaa ja Waymoa, jotka ovat ottaneet erilaiset lähestymistavat itseohjautuvien ajoneuvojen kehittämiseksi. Teslan Elon Musk on vastustanut ajatusta, jonka mukaan pelkkien kameroiden käyttäminen autonomisessa ajamisessa ei ole turvallista, mutta kaikki muut ajoneuvojen valmistajat ovat yksimielisesti todenneet kameroiden, tutkan ja usein myös LiDARin yhdistelmän paremmaksi ratkaisuksi [20]. Esitetyssä vertailussa tarkasteltiin ajankohtaisimpia teknologiaratkaisuja täyden automaation saavuttamiseksi ja näytettiin niiden tilastollisia tuloksia. Tässä tutkielmassa ei syvennytty Teslan kehittämään FSD-tietokoneeseen, joka on avainasemassa Teslan omalle viisille. Siksi FSD-tietokoneen ja sen etujen tutkiminen itseohjautuvissa ajoneuvoissa voisikin olla mahdollinen jatkokehitys tälle tutkielmalle.

# Lähdeluettelo

- [1] J. Ledin, *Modern Computer Architecture and Organization (2nd Edition) - Learn x86, ARM, and RISC-V Architectures and the Design of Smartphones, PCs, and Cloud Servers*. Packt Publishing, 2022, ISBN: 978-1-80323-451-9. url: <https://app.knovel.com/hotlink/toc/id:kpMCAOLAR1/modern-computer-architecture/modern-computer-architecture>.
- [2] S. Ranjan ja S. Senthamilarasu, *Applied Deep Learning and Computer Vision for Self-Driving Cars*. Packt Publishing, 2020, ISBN: 978-1-83864-630-1. url: <https://app.knovel.com/hotlink/toc/id:kpADLCVSDC/applied-deep-learning/applied-deep-learning>.
- [3] J. Liu ja A. Benslimane, *Intelligent and Connected Vehicle Security*. River Publishers, 2021, ISBN: 978-87-7022-367-6. url: <https://app.knovel.com/hotlink/toc/id:kpICVS0002/intelligent-connected/intelligent-connected>.
- [4] A. H. Radwan ja A. A. G. Morsi, "Autonomous vehicles and changing the future of cities: Technical and urban perspectives", *Journal of urban regeneration and renewal*, vol. 16, nro 1, s. 85–108, 2023, ISSN: 1752-9638. DOI: 10.69554/NVPL8330.
- [5] H. Wei, *International Conference on Transportation and Development 2022 - Other Modes - Rail, Transit, and Aviation*. American Society of Civil Engineers (ASCE), 2022, ISBN: 978-0-7844-8437-1. url: <https://app.knovel.com/hotlink/toc/id:kpICVSDC/international-conference-on-transportation-and-development-2022>.

- knovel.com/hotlink/toc/id:kpICTDOMR2/international-conference/international-conference.
- [6] G. Hirte, R. Laes ja R. Gerike, "Working from self-driving cars", *Transportation research. Part A, Policy and practice*, vol. 176, s. 103 785, 2023, ISSN: 0965-8564. DOI: 10.1016/j.tra.2023.103785.
- [7] J. Wishart, Y. Chen, S. Como, N. Kidambi, D. Lu ja Y. Yang, *Fundamentals of Connected and Automated Vehicles*. Warrendale: SAE International, 2022, ISBN: 978-0-7680-9980-5. url: <https://app.knovel.com/hotlink/toc/id:kpFCAV0001/fundamentals-connected/fundamentals-connected>.
- [8] M. Markel, *Radar for Fully Autonomous Driving*. Artech House, 2022, ISBN: 978-1-63081-896-8. url: <https://app.knovel.com/hotlink/toc/id:kpRFAD0006/radar-fully-autonomous/radar-fully-autonomous>.
- [9] C. Vishnu, J. Khandelwal, C. K. Mohan ja C. L. Reddy, "EVAA-Exchange Vanishing Adversarial Attack on LiDAR Point Clouds in Autonomous Vehicles", *IEEE transactions on geoscience and remote sensing*, vol. 61, s. 1–10, 2023, ISSN: 0196-2892. DOI: 10.1109/TGRS.2023.3292372.
- [10] L. Liang, H. Ma, L. Zhao et al., "Vehicle Detection Algorithms for Autonomous Driving: A Review", *Sensors*, vol. 24, nro 10, 2024, ISSN: 1424-8220. DOI: 10.3390/s24103088.
- [11] I. K. Sethi, *Autonomous Vehicles and Systems - A Technological and Societal Perspective*. River Publishers, 2023, ISBN: 978-87-7022-885-5. url: <https://app.knovel.com/hotlink/toc/id:kpAVSATSPA/autonomous-vehicles-systems/autonomous-vehicles-systems>.
- [12] J. Fayyad, M. A. Jaradat, D. Gruyer ja H. Najjaran, "Deep Learning Sensor Fusion for Autonomous Vehicle Perception and Localization: A Review", *Sensors*, vol. 20, nro 15, s. 4220, 2020. DOI: 10.3390/s20154220.

- [13] Z. Dai, Z. Guan, Q. Chen, Y. Xu ja F. Sun, "Enhanced Object Detection in Autonomous Vehicles through LiDAR—Camera Sensor Fusion", *World Electric Vehicle Journal*, vol. 15, nro 7, 2024, ISSN: 2032-6653. DOI: 10.3390/wevj15070297.
- [14] S. Y. Nof, *Springer Handbook of Automation (2nd Edition)*. Springer Nature, 2023, ISBN: 978-3-030-96728-4. url: <https://app.knovel.com/hotlink/toc/id:kpSHA00011/springer-handbook-automation/springer-handbook-automation>.
- [15] S. Fadadu, S. Pandey, D. Hegde et al., "Multi-View Fusion of Sensor Data for Improved Perception and Prediction in Autonomous Driving", teoksessa *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 2022, s. 3292–3300. DOI: 10.1109/WACV51458.2022.00335.
- [16] J. Alfred Daniel, C. Chandru Vignesh, B. A. Muthu, R. Senthil Kumar, C. Sivaparthipan ja C. E. M. Marin, "Fully convolutional neural networks for LIDAR—camera fusion for pedestrian detection in autonomous vehicle", *Multimedia tools and applications*, vol. 82, nro 16, s. 25 107–25 130, 2023.
- [17] C. Xiang, C. Feng, X. Xie et al., "Multi-sensor Fusion and Cooperative Perception for Autonomous Driving: A Review", *IEEE intelligent transportation systems magazine*, vol. 15, nro 5, s. 2–24, 2023, ISSN: 1939-1390.
- [18] D. J. Yeong, G. Velasco-hernandez, J. Barry ja J. Walsh, "Sensor and sensor fusion technology in autonomous vehicles: A review", *Sensors (Basel, Switzerland)*, vol. 21, nro 6, s. 1–37, 2021, ISSN: 1424-8220.
- [19] P. Bigelow, "Tesla's radar shift leaves safety picks in question; Groups revoke marks after automaker drops sensors", *Automotive News*, vol. 95, nro 6988, s. 3, 2021, ISSN: 0005-1551.

- [20] A. Nedelea. "Tesla Bet On 'Pure Vision' For Self-Driving. That's Why It's In Hot Water". (2024), url: <https://insideevs.com/news/738204/tesla-pure-vision-camera-only/> (viitattu 29.10.2024).
- [21] N. J. Goodall, "A note on Tesla's revised safety report crash rates", *Traffic Safety Research*, vol. 6, e000058, 2024. DOI: 10.55329/11f17748.
- [22] E. Walz. "A look inside the sixth-generation Waymo Driver". (2024), url: <https://www.automotivedive.com/news/waymo-6th-generation-driver-autonomous-driving-hardware-robotaxi-lidar-ai/725519/> (viitattu 29.10.2024).
- [23] The Waymo & Swiss Re Teams. "Waymo's autonomous vehicles are significantly safer than human-driven ones, says new research led by Swiss Re". (2023), url: <https://waymo.com/blog/2023/09/waymos-autonomous-vehicles-are-significantly-safer-than-human-driven-ones/> (viitattu 30.10.2024).
- [24] P. Bigelow, "Waymo replays real-life crashes in study, avoids most; Simulation shows safety potential of self-driving cars", *Automotive News*, vol. 95, nro 6977, s. 5, 2021, ISSN: 0005-1551.
- [25] J. M. Scanlon, K. D. Kusano, T. Daniel, C. Alderson, A. Ogle ja T. Victor, "Waymo simulated driving behavior in reconstructed fatal crashes within an autonomous vehicle operating domain", *Accident Analysis and Prevention*, vol. 163, s. 106454, 2021, ISSN: 0001-4575. DOI: <https://doi.org/10.1016/j.aap.2021.106454>.
- [26] National Highway Traffic Safety Administration. "Automated Vehicles for Safety". (2022), url: <https://www.nhtsa.gov/vehicle-safety/automated-vehicles-safety> (viitattu 04.11.2024).

- 
- [27] National Highway Traffic Safety Administration. "Summary Report: Standing General Order on Crash Reporting for Automated Driving Systems". (2022), url: <https://www.nhtsa.gov/sites/nhtsa.gov/files/2022-06/ADS-SGO-Report-June-2022.pdf> (viitattu 04. 11. 2024).
- [28] Z. Liang ja Y. Huang, "Survey on deep learning-based 3D object detection in autonomous driving", *Transactions of the Institute of Measurement and Control*, vol. 45, nro 4, s. 761–776, 2023. DOI: 10.1177/01423312221093147.