



Tekoäly liikenneturvallisuuden tukena

Oulun yliopisto
Tietojenkäsittelytiede
LuK-tutkielma
Antte Heatta
2023

Tiivistelmä

Tekoäly on yleistynyt nopeasti nykymaailmassa, ja sitä kehitetään jatkuvasti parempaan ja tehokkaampaan suuntaan. Myös liikenne sekä siinä oleva teknologia lisääntyy vauhdilla, jonka vuoksi liikenneturvallisuus on tekoälyn lisäksi ajankohtainen aihe. Tutkielman tutkimuskysymyksenä oli ”Kuinka tekoäly parantaa liikenneturvallisuutta?”. Tutkimusmenetelmänä hyödynnettiin kirjallisuuskatsausta, jonka avulla tutkittiin erilaisia tekoälyn osa-alueita sekä niiden käyttötarkoituksia ja rooleja liikenneturvallisuuden näkökulmasta. Kirjallisuuskatsauksessa hyödynnettiin tieteellisiä artikkeleita sekä muita tutkielmaan sopivia kirjallisia lähteitä kuten kirjoja. Tutkimuksen tavoitteena oli vastata tutkimuskysymykseen laajasti sekä kerätä tietoa tekoälyn tarjoamista mahdollisuuksista liikenneturvallisuuden edistämiseksi.

Tekoälyä hyödynnetään autoteollisuuden lisäksi monilla muilla aloilla kuten terveydenhuollossa, finanssialalla sekä logistiikassa. Lähtökohtaisesti voidaan sanoa, että tekoälyä on nykyisin lähes kaikkialla sekä sen hyödyntäminen tulee lisääntymään tulevaisuudessa. Liikenneturvallisuudessa suosituimpia tekoälyn osa-alueita oli koneoppimisen muodot kuten ohjattu oppiminen, ohjaamaton oppiminen sekä vahvistusoppiminen. Näiden lisäksi konenäkö sekä syväoppiminen olivat tärkeässä roolissa. Näitä voidaan hyödyntää esimerkiksi liikeradan suunnitteluun kaistanvaihdon aikana, adaptiivisen vakionopeudensäätimen oikeanlaiseen toimintaan sekä muiden tiellä liikkujien liikkeiden ennustamiseen. Myös kuljettajan väsymystilan tunnistaminen on mahdollista tekoälyn avulla. Järjestelmä reagoi asianmukaisesti, mikäli kuljettaja esimerkiksi nukahtaa rattiin. Turvallisuuden lisäksi tekoälyn rooli liikenteessä ulottuu parantamaan yleistä mukavuutta kaupungeissa ja edistämään ekologisuuutta reittien suunnittelulla. Esimerkiksi tekoälyä löytyy myös liikenteenohjausjärjestelmistä sekä älykkäistä kaupungeista, joiden tavoitteena on tehdä liikenteestä mahdollisimman miellyttävää kulkea sekä vähentää ruuhkia.

Avainsanat

Tekoäly, liikenneturvallisuus, auton turvajärjestelmät, liikenteenohjaus, koneoppiminen

Ohjaaja

FT, Apulaisprofessori Marianne Kinnula

Alkusanat

Tutkielman aihe muodostui kiinnostuksestani autoja sekä niissä olevia järjestelmiä kohtaan. Aihe laajeni myöhemmässä vaiheessa muuhun liikenteeseen, sillä liikenne on kokonaisuus, jonka jokaisella tekijällä on vaikutusta turvallisuuteen. Nykyään, lähes kaikkialla on tekoälyä, ja erityisesti autoissa, jonka vuoksi päätin tutkia liikenneturvallisuutta tekoälyn näkökulmasta. Tekoäly on ajankohtainen aihe nykymaailmassa ja liikenteen lisääntyessä myös liikenneturvallisuuteen tulee panostaa.

Tutkielma rakentuu siten, että aluksi tutustutaan tekoälyn osa-alueisiin esimerkkien avulla, jonka jälkeen siirrytään tarkastelemaan tekoälyä liikenneturvallisuudessa sekä eri mahdollisuuksia sitä hyödyntäen. Tulokset keskittyvät kertomaan lukijalle minkälaisia tekoälyn osa-alueita voidaan hyödyntää erilaisissa liikenneturvallisuutta edistävissä ratkaisuisa sekä pohtimaan miten nykyisiä toteutuksia voitaisiin laajentaa.

Haluan kiittää Marianne Kinnulaa erittäin hyvästä ohjaamisesta sekä tuesta, jota sain tutkielmaa työstäessäni.

7.12.2023

Antte Heatta

Sisällysluettelo

Tiivistelmä.....	2
Alkusanat.....	3
Sisällysluettelo	4
1. Johdanto.....	5
1.1 Tutkielman motivaatio	5
1.2 Tutkimuskysymys	6
1.3 Tutkimusmenetelmät.....	6
1.4 Tutkielman rakenne.....	6
2. Tekoäly.....	8
2.1 Koneoppiminen.....	8
2.2 Ohjattu oppiminen.....	9
2.3 Ohjaamaton oppiminen.....	10
2.4 Vahvistusoppiminen	10
2.5 Syväoppiminen.....	11
2.6 Konenäkö	11
3. Tekoäly liikenteessä	13
3.1 Tekoäly ajoneuvoissa	13
3.2 Liikenteenohjaus tekoälyn avulla.....	13
3.3 Liikennedatan analysointi ja ennustaminen tekoälyn avulla	14
4. Sulautetut järjestelmät autoissa	16
4.1 Aktiiviset turvajärjestelmät.....	16
4.2 Passiiviset turvajärjestelmät.....	16
4.3 Edistysellinen kuljettajan avustinjärjestelmä	17
4.3.1 Manipulaatiopohjaiset järjestelmät.....	17
4.3.2 Tietopohjaiset järjestelmät.....	18
5. Tekoäly liikenneturvallisudessa	19
5.1 Koneoppiminen liikenneonnettomuuksien ennustamisessa ja ehkäisyssä	19
5.2 Ohjatun oppimisen menetelmät liikenneturvallisuuden parantamisessa	19
5.3 Ohjaamattoman oppimisen rooli liikenneturvallisuuden kehittämisessä	20
5.4 Vahvistusoppimisen soveltaminen liikenneturvallisudessa	21
5.5 Syväoppiminen liikenneturvallisudessa	22
5.6 Konenäkö liikenteen vaarojen havainnoinnissa	22
6. Pohdinta	25
7. Yhteenveto.....	28
Lähdeluettelo	29

1. Johdanto

1.1 Tutkielman motivaatio

Autoteollisuus kehittyi jatkuvasti ja myös monet teollisuuden osa-alueet kehittyvät parempaan ja turvallisempaan suuntaan. Sähköautojen suhteen on otettu isoja askelia ja useat autovalmistajat ovat laittaneet liiketoiminnan pääpainoksi sähköautot. Samalla kun autot kehittyvät tehokkaammiksi ja mukavammiksi, kehittyi myös niiden sisäinen teknologia älykkäämmäksi helpottaen kuljettajan ajamista sekä lisäämällä turvallisuutta. Nykyään yli 90 % autoihin liittyvistä innovaatioista rakentuvat tietoteknisten laitteiden ja ohjelmistojen ympärille ja huippuluokan autot voivat sisältää jopa 70 prosessoria sekä satoja megatavuja koodia, joita tekniset laitteet hyödyntävät (Wolf ym., 2007). Autoteollisuus tuottaa kymmeniä miljoonia autoja vuosittain, joten liikenne on runsasta ympäri maailmaa. Kun liikennettä on paljon, sattuu myös onnettomuuksia, joista koituu niin henkilö- kuin materiaalivahinkoja. Nämä vahingot kuormittavat julkisia resursseja, luonnonvaroja sekä myös onnettomuuksien osapuolia. Kun panostetaan turvallisuuteen, voidaan vähentää onnettomuuksia sekä onnettomuuksien sivuvaikutuksia ympärillä oleviin asioihin. Liikenneonnettomuudet vievät vuosittain 1,2 miljoonan ihmisen hengen ja itseajavien autojen avulla voidaan pelastaa vuosittain 30 000 henkeä (Soegoto ym., 2019). Suurin osa liikenneonnettomuuksista johtuu inhimillisistä virheistä. Onnettomuuksista noin neljännes johtuu rattiin nukahtamisesta tai kuljettajan keskittymisen herpaantumisesta. Tekoälyllä on tärkeä rooli estää tällaisia onnettomuuksia. (Bergasa ym., 2008.) Itseajavat autot sekä niiden teknologian kehitys tulee säästämään rahaa, vähentämään liikennettä ja sähköiset, itseajavat autot tulevat vähentämään kasvihuonepäästöjä 90 prosenttia. Teknologian kehittyminen parantaa myös liikenneturvallisuutta. Asiantuntijat arvioivat, että liikenneonnettomuudet voivat vähentyä jopa kymmeneen prosenttiin nykytilanteesta, tai parhaassa tapauksessa nolnaan prosenttiin. Itseajavat autot poistavat myös tilanteet, joissa kuljettaja on ajokyvottomässä tilassa tai hänen keskittymisensä on herpaantunut aiheuttaen onnettomuuden. (Ertel, 2017.) Tästä voidaan huomata, kuinka teknologian kehitys ja tekoälyn hyödyntäminen pelastaa ihmishenkiä parantamalla liikenneturvallisuutta.

Aihe on tärkeä tutkimuskohde, sillä parantamalla liikenneturvallisuutta voidaan säästyä materiaalivahingoilta ja jopa parhaimmalla tapauksella pelastaa ihmishenkiä. Tekoäly on myös erittäin suosittu teknologia nykypäivänä ja jatkuvan kehityksen kohteena. Nämä yhdistämällä voidaan luoda turvallinen liikenne jokaiselle kulkijalle. Kun tiedetään, missä osissa tekoälyä hyödynnetään liikenneturvallisuudessa sekä autoteknologiassa, voidaan huomata alueita, joissa on parantamisen varaa tai jopa sellaisia asioita mihin ei olla vielä tekoälyä hyödynnetty. Turvallisuuden lisäksi, tekoälyn hyödyntäminen liikenteenohjauksessa sujuvoittaa liikenteen kulkua, vähentäen ruuhkista aiheutuvia haittoja kuten melua ja päästöjä. Päästöt vähenevät myös siinä, kun autojen navigointilaitteet kykenevät antamaan kuljettajalle mahdollisimman ympäristöystävällisen reitin. Ympäristöystävällisyys on liikenneturvallisuuden ja tekoälyn lisäksi ajankohtainen aihe nykymaailmassa. Hyödyntämällä ja havainnoimalla valmiita materiaaleja, voidaan laajentaa nykyistä tutkimusta sekä mahdollistaa innovatiivisten ratkaisujen keksimisen nykyisten lisäksi.

1.2 Tutkimuskysymys

Tutkielma keskittyy tutkimaan tekoälyn vaikutusta liikenneturvallisuuteen ja on kirjallisuuskatsaus liittyen aihepiiriin. Tutkimuskysymyksenä on:

- Kuinka tekoäly parantaa liikenneturvallisuutta?

Jotta lukija ymmärtäisi tutkimuksen tarkoituksen sekä sitä tukevia lähteitä, käydään tutkielmassa aluksi läpi asioita tekoälystä sekä liikenneturvallisuudesta yleisesti tekoälyn näkökulmasta kattavasti lähteiden avulla. Alkuperäisesti aihe keskittyi autojen liikenneturvallisuutta parantaviin laitteisiin sivuten nykyaikaisten autojen tietoturvallisuuteen liittyviä riskejä. Aihe kuitenkin kehittyi nykyaikaisemmaksi ottaen tekoälyn huomioon liikenneturvallisuudessa. Tekoälyn yleistymisen sekä henkilökohtainen kiinnostus johti tutkielman aiheen muodostumisen siihen mikä se tutkielmassa lopullisesti on. Myös aiempi tutkielman aihe oli suppea sen keskittyessä vain laitteistoihin, jättäen itse tietokoneiden roolin vähälle. Tekoälyn lisääminen aihealueeseen tuo näkökulmaa modernin ohjelmistokehityksen kannalta, siirtäen painopisteen itse laitteistosta enemmän ohjelmistojen puolelle. Tämän lisäksi, nykyaikaisissa ja liikenteessä yleisesti on mittava määrä laitteita, jotka toimivat ohjelmistojen varassa ja näiden ohjauksessa. Aihe olisi ollut myös liian suppea siitä näkökulmasta, mikäli olisi keskitytty vain autojen tekoälyratkaisuihin. Nykyään, autojen lisäksi liikenteenohjauksessa hyödynnetään tekoälyä sekä älykkäät kaupungit ovat keskiössä. Teknologian kehittyessä autot sekä infrastruktuuri voivat toimia yhdessä, minkä vuoksi on olennaista nostaa autot ja ympäristö tutkielman keskiöön.

1.3 Tutkimusmenetelmät

Tutkielma suoritettiin kirjallisuuskatsauksena hyödyntäen erilaisia tietokantoja sekä hakukoneita tiedonhaun tukena. Lähdemateriaalien keräämisessä käytettiin tarkkaa harkintaa niin lähteiden tuoreuden kuin luotettavuuden arviointiin. Pyrkimyksenä on hyödyntää mahdollisimman tuoretta tutkimustietoa mahdollistaen tutkielman hyödyntämisen myös tulevaisuudessa jatkotutkimuksiin.

Lähteitä on haettu Google Scholarista, IEEE Exploresta sekä ACM Digital Librarystä.

Hakusanoina tutkielman lähteitä etsiessä on ollut muun muassa: ”artificial intelligence in automotive safety”, ”artificial intelligence”, ”machine learning”, ”automotive safety systems” ja ”embedded systems in automobiles”.

1.4 Tutkielman rakenne

Tutkielma alkaa esittelemällä tekoälyn konseptia sekä sen muotoja, jotka ovat relevantteja liikenneturvallisuuteen liittyen autojen näkökulmasta. Näihin tutustutaan laajalti tosielämän esimerkkien avulla, jotta lukija saa käsityksen tulevien lukujen asioista. Tekoälyn käsittelyn jälkeen siirrytään käsittelemään tekoälyn roolia liikenteessä esimerkkien avulla. Kolmannessa luvussa käsitellään tekoälyä ajoneuvoissa, älykkäissä liikennematkaisuissa kuten liikennevalo-ohjauksessa sekä älykkäiden kaupunkien mahdollisuuksia. Neljäs luku tutustuu autojen sulautettuihin järjestelmiin erityisesti liikenneturvallisuuden näkökulmasta. Tässä luvussa esitellään autoista löytyviä

sulautettuja turvajärjestelmiä, niiden toiminnallisuuksia sekä sivuaa tekoälyn roolia niissä. Viidennessä luvussa syvennyttään tekoälyn rooliin liikenneturvallisuudessa tutkien, miten tekoäly voi tukea autojen turvajärjestelmiä. Kuudennessa luvussa pohditaan niin tekoälyä yleisesti kuin myös sen roolia liikenneturvallisuudessa. Viimeisessä luvussa tulokset vedetään yhteen ja tarkastellaan tutkielman löytöjä kokonaiskuvasta aiheeseen liittyen.

2. Tekoäly

Tekoäly on nykyisin pinnalla oleva aihe ja teknologian kehittyessä, tekoäly on otettu käyttöön useilla teollisuuden aloilla.

Tekoälyn tarkoituksena on suorittaa tehtäviä ihmistä paremmin ja nopeammin, minkä vuoksi tekoälyä kehitetään siihen suuntaan. Esimerkkinä voidaan ottaa tekoälyn käyttäminen shakkipelissä, jossa tekoäly on jo ylittänyt ihmisen älykkyyden, jolloin sen kehittämistä ei enää vaadita. Kuitenkin, kun ihminen menee uuteen ympäristöön, hän voi havainnoida esineitä ja tehdä päätöksiä ympäristöönsä liittyen, mutta tekoäly ei vielä kykene tähän. Tekoälyn kehittyminen keskittyy juuri näihin asioihin, joissa ihminen on vielä parempi kuin tekoäly. Ihmisen kyky sopeutua erilaisiin ympäristöihin on vahva meidän oppimiskykymme ansiosta. Tämän vuoksi koneoppiminen on yksi tekoälyn osa-alue. (Ertel, 2017.)

Tekoälyä hyödynnetään muun muassa autoteollisuudessa, erityisesti itseajavissa autoissa, palveluroboteissa sekä älykodeissa. Erityisesti itseajavat autot tulevat muuttamaan liikkumista, sillä näiden pohjalta voidaan automatisoida taksiliikenne. Esimerkiksi puhelinsovelluksella voidaan tilata juuri sopiva taksi omaan tarkoitukseen. Tämä voi johtaa siihen, etteivät ihmiset tarvitse enää omaa autoa, joka poistaa yhden kuluerän arjesta. (Ertel, 2017.)

Autoteollisuus hyödyntää tekoälyn useita osa-alueita kuten koneoppimista, syväoppimista ja konenäköä. Itseajavat autot sisältävät myös luonnollisten kielten käsittelyyn tarvittavaa teknologiaa. Tätä hyödyntäen autoa voidaan ohjata ihmisen toimesta käyttäen ääniohjausta, eikä muita ohjaustoimia tarvita. Koneoppiminen on tärkeässä roolissa ja sen algoritmit toimivat moottorin ohjausyksikössä analysoiden ympäristöä jatkuvasti sekä huomaamalla muutoksia. (Ammal ym., 2021.) Koneoppimisen osa-alueita ovat ohjattu oppiminen, ohjaamaton oppiminen, vahvistusoppiminen sekä syväoppiminen, joista kaikkia hyödynnetään autojen turvalaiteissa (Moujahid ym., 2018). Tekoälyn kuvaillaan olevan koneella olevaa älykkyyttä, jota voidaan hyödyntää vaikeidenkin ongelmien ratkaisemiseen. Pääasiassa tekoäly matkii ihmisten kognitiivisia toimintamalleja sekä muita ominaisuuksia. Näiden avulla se kykenee oppimaan, ratkaisemaan ongelmia sekä ajattelemaan itsenäisesti. Artikkelissa mainitaan tekoälyn päätavoitteiksi muun muassa luonnollisen kielen prosessoimien sekä oppimisen. (Vishnukumar ym., 2017.)

Koneoppimisen kerrotaan olevan tärkeä osa auton laitteita, joissa tekoälyä on hyödynnetty. Koneoppimisen tarkoituksena on kehittää algoritmeja, joiden avulla koneet voivat oppia itsestään. Koneoppimisella on vahva yhteys statistiikkaan, sillä koneet hyödyntävät statistiikkaa tunnistaakseen yhteneväisyyksiä datassa. Koneoppimisen avulla voidaan tuottaa luotettavia tuloksia ja löytää uusia oivalluksia hyödyntäen erilaisia aineistoja. (Vishnukumar ym., 2017.)

2.1 Koneoppiminen

Koneoppimista hyödynnetään monissa eri yhteyksissä, kuten hahmontunnistuksessa, konenäössä, avaruusteknologiassa, taloudessa, viihdeessä sekä lääketieteessä. Esimerkiksi syöpien sädehoidossa koneoppimisella voidaan tehostaa hoitoja optimoimalla ja automatisoimalla niitä johtaen parempiin tuloksiin. (Naqa ja Murphy, 2015.) Koneoppimista käytetään ortopediassa massadatan sekä tekoälyn rinnalla, joka

mahdollistaa muun muassa helppojen työtehtävien automatisoinnin. Näiden avulla voidaan myös hyödyntää algoritmeja komplikaatioriskien tunnistamisessa sekä ennustaa lopputuloksia erikseen jokaiselle potilaalle yksilöllisesti. (Helm ym., 2020.) Koneoppiminen on tärkeä osa lääketiedettä, josta voidaan todeta, että koneoppimisen potentiaali ihmisten elämänlaadun ja turvallisuuden parantamisen kannalta on hyvä (Naqa ja Murphy, 2015; Helm ym., 2020). Tätä voidaan soveltaa moniin aloihin, joista autoteollisuus on yksi, kehittäen liikenneturvallisuutta koneoppimisen avulla. Helm ym. (2020) kertovat, että koneoppimisen avulla tietokone pystyy oppimaan ja parantamaan analyysejä hyödyntäen algoritmeja. Algoritmit käyttävät suuria määriä dataa, jotta voidaan huomata erilaisia toistuvuuksia datassa hahmontunnistuksen avulla, joita hyödynnetään oppimisessa ja itsenäisten päätösten tekemisessä (Helm ym., 2020). Koneoppiminen jäljittelee ihmisen älykkyyttä oppimalla ympäristöstä kerätyn datan ansiosta (Naqa ja Murphy, 2015). Kun tietokone on vastaanottanut tarpeeksi dataa, se on kykeneväinen ennustamaan datasta riippuvan lopputuloksen. Tuloksen tarkkuutta voidaan mitata vertailemalla edellisiä tuloksia, ja tätä vertailua hyödynnetään parantamaan algoritmin tarkkuutta entisestään. (Helm ym., 2020.) Koneoppimisesta sanotaan, että se kykenee antamaan koneille kyvyn oppia ilman siihen tarkoitettua ohjelmointia. Toinen merkitys kertoo koneoppimisen olevan tapa ohjelmoida koneet oppimaan esimerkkidatan tai kokemusten avulla. Molemmat merkitykset painottavat, että koneoppimisen tarkoitus on oppia itsenäisesti tuottamaan haluttuja lopputuloksia. (Naqa ja Murphy, 2015.)

Koneoppimisen algoritmeihin syötetään harjoitteludataa sekä haluttuja lopputuloksia, joiden avulla algoritmi oppii toimimaan oikein. Hyvä algoritmi kykenee tuottamaan haluttuja lopputuloksia uudesta datasta yleistämällä sitä. On monia tapoja, joilla algoritmien oppimista voidaan optimoida ja parantaa. Erilaisille analysoitaville datoilta voidaan antaa eri painoarvot, joiden avulla algoritmi osaa antaa tarkempia lopputuloksia. Algoritmit voivat myös hyödyntää dataa ja määrittää todennäköisyysjakuman hyödyntäen sitä lopputuloksen laskemiseen. Koneoppimisen tärkein ominaisuus on kyky oppia syötettyä dataa hyödyntämällä joko opettajan avulla tai itsenäisesti. (Naqa ja Murphy, 2015.)

2.2 Ohjattu oppiminen

Hahmontunnistus on ohjatun oppimisen keskiössä. Esimerkiksi voidaan ottaa kahden esineen, omenan ja appelsiini erottaminen toisistaan. Algoritmille annetaan dataa kuten muoto, väri ja haju. Kohteen mukaan esineelle asetetaan luokituksiksi omena tai appelsiini. Onnistunut algoritmi kykenee erottamaan näiden kahden väliltä eroavaisuuksia sellaisesta datasta, jota se ei ole koskaan nähnyt. Eli, se on oppinut tunnistamaan kahden esineen väliset erot sekä samankaltaisuudet ja on kykeneväinen luokittelemaan ne oikein. Ohjatun oppimisen hyöty tulee siinä, että se voi korvata aikaisemmin ihmisten tekemät työläät ja toistuvat tehtävät. (Naqa ja Murphy, 2015.) Ohjatun oppimisen algoritmit vastaanottavan niin käsiteltävää dataa kuin haluttuja lopputuloksia, joita se harjoittelee eksplisiittisesti. Ohjaamattoman oppimisen päätavoite on tehdä ennustuksia tulevaisuudesta analysoimalla syötettyä dataa. Artikkelissä esitellään kaksi ohjatun oppimisen algoritmia, regression ja luokittelun. Regressiossa tutkitaan syötetystä datasta löytyviä korrelaatioita, joiden perusteella lopputulos luodaan. Luokittelu hyödyntää esimerkkidataa, jossa kohteille on annettu omat luokitukset. Tämän avulla algoritmi kykenee tunnistamaan ja luokittelemaan syötetyn datan. (Ammal ym., 2021.)

Ohjattua oppimista voidaan hyödyntää itseohjautuvassa robotissa, joka oppii sopeutumaan erilaisiin ympäristöihin. Robottien navigoinnissa on yleisesti tehty siten,

että alueesta, jota on tarkoitus kulkea, luodaan kartta ja suunnitellaan reitti sitä pitkin. Tämä lähestymistapa voi kuitenkin johtaa tilanteisiin, joissa vaikeakulkuiseksi luultu alue, ei sitä olekaan. Korkeaa ruohikkoa voidaan luulla alueeksi, jota pitkin reittiä ei kannata suunnitella, tai sitten tasainen alue voi näyttää hyväkulkuiselta, mutta onkin täynnä esimerkiksi töyssyjä. Ohjatun oppimisen avulla, robotti kykenee itsenäisesti oppimaan erilaisia maastonmuotoja keräämällä kuljetuista reiteistä dataa ja sopeutuu kulkemaan opitun datan avulla tehokkaammin tulevaisuudessa. Ohjatun oppimisen haaste tulee robotissa vastaan siinä, että sen on koettava jokin tilanne, kuten törmäys, jotta se oppisi olemaan toistamatta sitä virhettä. Lähestulkoon täysin itsenäisesti oppivan teknologian käyttö soveltuu esimerkiksi robotteihin, joita käytetään kaivoksissa, maataloudessa tai eksyneiden etsimisessä. Sitä ei kuitenkaan voi käyttää turvallisuutta vaativissa asioissa kuten itseajavissa autoissa. Tällaisissa tilanteissa ohjatun oppimisen ei voida antaa oppia virheiden kautta, vaan vaaditaan teknologiaa, johon tarvittava data on jo syötetty. (Kahn ym., 2021.)

2.3 Ohjaamaton oppiminen

Ohjaamattomassa oppimisessa algoritmi harjoittelee lopputulokseen pääsemistä itsenäisesti, eikä se pyri yhdistämään sille syötettyä dataa ja haluttua lopputulosta. Kirjoittajat käyttävät esimerkkinä tikanheittoa. Jos algoritmin on tarkoitus heittää tikka keskelle taulua, se pyrkii harjoittelemaan tikan heittoa sen sijaan että laskisi optimaalisen heittotavan etukäteen. Algoritmi siis keksii oman tavan päästä haluttuun lopputulokseen harjoitusdatan avulla. Ohjaamaton oppiminen kykenee oppimaan ja huomaamaan syötetystä datasta haastavampia samanlaisuuksia kuin ihminen, jossa sen hyöty korostuu. (Naqa ja Murphy, 2015.)

Ohjaamaton oppiminen hyödyntää dataa, jonka kohteille ei ole annettu luokituksia, toisin kuin ohjatussa oppimisessa. Ohjaamattoman oppimisen löytäessään samankaltaisuuksia datasta, se pääosin keskittyy poistamaan turhaa dataa tai järjestelemään sitä samankaltaisuuksien mukaan. Ohjaamattoman oppimisen algoritmeja on useita ja artikkeli esittelee niistä klusteroinnin sekä dimensiovähennyksen. Klusteroinnissa data järjestellään tietämättä siitä ennestään mitään. Toiminta perustuu samankaltaisuuksien identifioimiseen. Dimensiovähennys taas keskittyy turhan datan poistamiseen sekä tärkeän datan säilyttämiseen. (Ammal ym., 2021.)

Ohjaamatonta oppimista voidaan hyödyntää kuvien resoluution parantamisessa. Ohjaamattoman oppimisen algoritmi hyödyntää kuvapareja oppimiseen. Kuvaparit ovat matala- ja korkearesoluutioisia, joista algoritmi kykenee poistamaan melun. Kun resoluution parantamista halutaan käyttää paikoissa, joissa kuvapareja ei ole saatavilla, joudutaan turvautumaan ohjaamattomaan oppimiseen. Oppimiseen käytetään matalaresoluutioisista kuvista bikubisesti interpoloituja kuvia, joiden avulla opitaan luomaan kuvapareja uusista interpoloiduista kuvista. Tämä prosessi edesauttaa algoritmia oppimaan todellisen datan pohjalta ja vähentää interpoloinnista aiheutuvaa melua luomalla selkeämpiä kuvia. (Lugmayr ym., 2019.)

2.4 Vahvistusoppiminen

Vahvistusoppiminen kykenee itseoppimiseen hyödyntämällä agenttia, joka oppii omista ratkaisuksista ja niistä saaduista palautteista. Algoritmi kykenee antamaan palautteen tai rangaistuksen itselleen omien toimien perusteella, joiden avulla se osaa päästä parhaaseen mahdolliseen lopputulokseen hyödyntämällä parhaita toimia. Algoritmin perustaan

kuuluu useita osia kuten ympäristö, tila, palkinto, menettelytapa ja arvo. Ympäristö mukailee todellista maailmaa, josta saadaan palautetta. Menettelytavat määrittävät agentin toiminnan riippuen sen tilasta ja arvo esittää palkintoa, joka saadaan onnistuneesta toiminnosta. (Ammal ym., 2021.) Vahvistusoppimisen algoritmit eivät käytä harjoitteluun valmista dataa. Kirjassa kerrotaan, että vahvistusoppimista käytetään robotiikassa, sillä monesti tehtävät ovat sellaisia, joille on liian monimutkaista ohjelmoida omaa ohjelmaa eikä niille ole harjoitusdataa saatavilla. Vahvistusoppimista verrataan ihmisen kykyyn oppia virheiden kautta. Onnistumisista palkitaan, joka edistää oppimista. Virheistä taas opitaan se, ettei niitä toisteta uudelleen. (Ertel, 2017.)

2.5 Syväoppiminen

Tavallisissa koneoppimisen muodoissa raakaa dataa hyödynnetään poimimalla siitä piirteitä hyödyntämällä eri tekniikoita. Näiden avulla dataa voidaan luokitella siinä esiintyvien samankaltaisuuksien mukaan. Piirteiden poiminta on keskiössä tavallisessa koneoppimisessa, mutta strukturoimattoman datan käsittely on aikaa vievää eikä tavallinen koneoppiminen ole skaalautuvaa. Syväoppimisen hyöty näkyy siinä, että se kykenee poimimaan piirteet raasta datasta ilman tavallisessa koneoppimisessa tarvittavia tekniikoita. Syväoppiminen kuitenkin vaatii paljon laskentatehoa, jotta se voi rakentaa tarvittavan mallin tulosten luomiseksi. Artikkelissa esitellään kaksi yleisintä syväoppimisen mallia. Konvoluutioneuroverkkoihin perustuvia syväoppimisen malleja hyödynnetään pääosin kuvien analysointiin. Nämä rakentuvat useista eri kerroksista, jotka suorittavat erilaisia toimintoja kuten piirteiden poimimista kuvista, näiden analysointia sekä kuvan tyypin ennustamista. Algoritmin tarkkuus paranee sitä mukaan, kun kerrosten toimintoja toistetaan. Takaisinkytketyn neuroverkon päätarkoitus on tunnistaa piirteitä esimerkiksi käsikirjoituksesta, sensorien datasta ja puheesta. Olennaista on, että syötetty data kulkee aika-askelittain eteenpäin. Algoritmi hyödyntää edellisten prosessien tuloksia sen seuraavissa prosesseissa. Näiden neuroverkkojen arkkitehtuuri rakentuu esimerkiksi pitkän lyhytaikaisen muistin varaan, jonka portit kontrolloivat sitä, miten tieto liikkuu. Nämä portit voivat oppia mikä läpimenevästä datasta on tärkeää ja hylätä epäolellaisen datan. (Ammal ym., 2021.) Syväoppimista käytetään asioiden tunnistamiseen kuvissa. Esimerkiksi käsin kirjoitettuja numeroita sekä Google Street Viewistä löytyvien kotiosoitteiden numeroita kyteistä voidaan tunnistaa lähes virheettömästi. Syväoppimisen avulla voidaan myös tunnistaa kuvissa tapahtuvia asioita, ja niistä voidaan kirjoittaa virkkeitä hyödyntämällä neuroverkoja syväoppimisen tukena. Luovissa tehtävissä syväoppimisella on erilaisia käyttökohteita. Sen avulla voidaan luoda musiikkia sekä tekstejä, kuten XML-koodia, lyhyitä ohjelmia eri ohjelmointikielillä sekä LaTeX-tekstiä matemaattisilla kaavoilla. (Ertel, 2017.)

2.6 Konenäkö

Konenäkö on objektien kolmiulotteisten muotojen tunnistamista tietokoneen avulla kuvista. Konenäköä voidaan käyttää 3D-mallien luomiseen hyödyntämällä kuvia halutusta objektista. Tätä teknologiaa kutsutaan tietokonestereonäköksi. Konenäön avulla voidaan myös seurata henkilön liikkeitä monimutkaisia taustoja vasten. Tiettyyn pisteeseen asti konenäkö kykenee tunnistamaan ihmisiä kuvista katsomalla heidän kasvonpiirteitä, vaatteita sekä hiuksia. Kuitenkin konenäkö kohtaa rajoituksia esimerkiksi siinä, että se voisi kaksivuotiaan tavoin laskea kaikki kuvassa olevat eläimet. Konenäkö on kehittynyt pitkälle teknologian kehityksen myötä, mutta päästäkseen ihmisten kaltaiselle tasolle sillä on vielä matkaa. (Szeliski, 2022.)

Konenäköä pidetään haastavana tekoälyn osa-alueena. Kirjassa näköä kuvataan ongelmana, jossa pyritään selvittämään tietyn asian tuntemattomia osia puutteellisilla alkutiedoilla. Tämän takia, konenäössä hyödynnetään erilaisia fysiikkaan ja todennäköisyyksiin perustuvia malleja, joiden avulla voidaan päätellä paras mahdollinen ratkaisu. Kirjassa huomautetaan, että näköön perustuva mallinnus on huomattavasti hankalampaa kuin äänten mallintaminen, sillä käsiteltäviä visuaalisia elementtejä on paljon, sekä ne voivat olla monimutkaisia tietokoneiden käsiteltäväksi. (Szeliski, 2022.)

Konenäköä voidaan hyödyntää monenlaisissa arkipäiväisissä sekä teollisissa ratkaisuisissa. Konenäkö osaa lukea käsin kirjoitettua tekstiä esimerkiksi kirjeistä ja se kykenee lukemaan autojen rekisterikilpiä. Sitä voidaan hyödyntää myös koneiden kuten autojen tai lentokoneiden osien kestävyys tarkastamista varten sekä vikojen löytämiseen teräsvalusta röntgenin avulla. Myös kaupoissa voidaan käyttää konenäköä tunnistamaan tuotteita itsepalvelukassoilla. Konenäköä käytetään 3D-mallien rakentamiseen esimerkiksi maan muodoista hyödyntämällä lentokoneista otettuja kuvia. Lääketieteellisissä ratkaisuisissa konenäöllä voidaan tutkia esimerkiksi ikääntymisen vaikutusta ihmisen aivoihin. Autoteollisuudessa konenäkö auttaa esteiden sekä jalankulkijoiden tunnistamisessa. Konenäön tärkeys painottuu tilanteissa, joissa esimerkiksi lasersäteiden tai radioaaltojen käyttö esteiden tunnistamisessa on haastavaa. (Szeliski, 2022.) Konenäköä käytetään laajasti kasvojen ja silmien tunnistukseen. Täten sitä voidaan hyödyntää autoteollisuudessa kuljettajan vireystilan valvonnassa. Konenäköön käytettävät sensorit voidaan esimerkiksi upottaa kojelautaan tai muihin huomaamattomiin paikkoihin, jotta se ei häiritse kuljettajan ajamista. (Bergasa ym, 2008.) Elokuvateollisuudessa konenäköä käytetään tietokoneella tuotetun grafiikan yhdistämistä oikealla kameralla kuvattuun materiaaliin. Konenäkö käyttää pisteitä videon elementtien tunnistamiseen sekä kameran liikkeen ennustamiseen. Konenäköä voidaan hyödyntää kameravalvonnassa, kuten teiden liikenteen analysointiin sekä uima-altaiden seurantaan hukkuvien ihmisten varalle. Sormenjälkitunnistuksessa sekä biometrinen tietojen varmuudessa voidaan käyttää konenäköä. Näiden pohjalta sitä voidaan myös soveltaa oikeuslääketieteeseen rikollisten löytämiseksi. (Szeliski, 2022.)

3. Tekoäly liikenteessä

3.1 Tekoäly ajoneuvoissa

Autoteknologia kehitty vauhdilla ja nykyautoista löytyy mittava määrä tekoälyä hyödyntäviä ratkaisuja. Nämä ratkaisut vaihtelevat niin kuljettajan viihdyttämisestä muiden tielläliikkujien turvallisuuden edistämiseen. Ajoneuvojen näkökulmasta tekoälyn rooli on laaja sekä sille on useita eri käyttötarkoituksia.

Autoissa voi olla tekoälyä hyödyntäviä virtuaalisia apureita, joilta voi kysyä esimerkiksi reittiohjeita. On myös mahdollista pyytää erilaisia suosituksia perillä olevista kohteista sekä saada tietoa maailmalla tapahtuvista asioista. Tällainen apuri lisää huomattavasti kuljettajan mukavuustasoa erityisesti pitkillä matkoilla, mutta voi olla myös päivittäiskäytössä suuri apu kuljettajalle. (Bharadiya, 2023.) Artikkelissa ehdotetaan tekoälypohjaista ratkaisua, joka parantaa kuljettajan sekä matkustajien viihtyvyyttä. Musiikin soittamisen automatisointia tilanteen mukaan voidaan toteuttaa koneoppimisen avulla. Valittuun musiikkiin vaikuttavat kuljettajan mieltymykset, profiili, ajettava ympäristö sekä edelliset kokemukset, joista algoritmi on oppinut parhaan mahdollisen tavan valita kappale. Artikkelissa mainitsee, että tekoälypohjaisessa musiikinvalinnassa kuljettajan ajotyylit, ajokokemus sekä kuljettajan mieliala vaikuttavat valittuun musiikkiin. (Panagiotopoulos ja Dimitrakopoulos, 2019.)

Viihdyttävyyden lisäksi tekoäly lisää turvallisuutta, tehokkuutta sekä ekologisuutta. Tekoälyn avulla autot voivat sensoreita hyödyntämällä navigoida haastavissakin liikennetilanteissa ilman kuljettajan apua. Turvallisuus lisääntyy liikenteessä erityisesti esteiden tunnistukseen ja kolarien ehkäisyyn käytettävien teknologioiden myötä. Tällaiset ratkaisut lisäävät niin kuljettajien kuin muidenkin tielläliikkujien turvallisuutta. Tekoäly kykenee myös tunnistamaan mahdollisia vikoja autossa ja ympäristössä, vähentäen niistä aiheutuvia riskejä. Kuitenkin teknologian lisääminen autoihin lisää tieturvariskejä, jotka on otettava huomioon tällaisia ratkaisuja hyödyntäessä. (Bharadiya, 2023.) Myös kuljettajan sekä ympäristön tilasta kerättyä dataa voidaan hyödyntää liikenneturvallisuuden edistämässä tekoälyn avulla. Sensoreilla kerättävää dataa voi olla matkustajien määrä, lämpötila niin ulkona kuin auton sisällä, kuorman paino sekä kuljettajan sydämensyke. Kameroiden avulla voidaan taas tarkkailla kuljettajan kasvoja, joista nähdään väsymystaso silmien ja suun asennosta, joiden pohjalta auto voi hälyttää kuljettajan hereille. Kerätty data lähetetään sitten pilvipalveluun käsiteltäväksi. Kun kerättyä dataa voidaan jakaa pilvipalveluiden avulla muille kuljettajille, voidaan luoda turvallinen ympäristö kaikille tielläliikkujille älykkäissä kaupungeissa. (Tarawneh ym., 2023.)

3.2 Liikenteenohjaus tekoälyn avulla

Tässä aluvussa käsitellään tekoälyn roolia liikenteenohjauksessa. Tähän kategoriaan kuuluu älykkäät liikennevalot, ruuhkien hallinta tekoälyn avulla sekä näihin liittyvä ekologinen näkökulma. Tekoälyn monet osa-alueet ovat läsnä edellä mainituissa asioissa, joissa osa on todettu paremmin toimivimmiksi kuin toiset. Tästä huolimatta on olemassa laaja kirjo ratkaisuja, joissa tekoäly kykenee ratkaisemaan ongelmia tehokkaasti helpottaen tielläliikkujien arkea.

Jeon ym. (2018) kirjoittavat mahdollisuudesta hyödyntää tekoälyä ja kuvientunnistusta liikenteenohjauksessa. Vahvistusoppiminen on vahvassa roolissa oppimiseen pohjautuvassa adaptiivisessa liikennevalo-ohjauksessa, sillä se kykenee ratkaisemaan ongelmia reaaliajassa liittyen liikenteenohjaukseen. Vahvistusoppimisen algoritmit soveltuvat yhden tai useamman risteuksen ohjaukseen sekä jatkuvasti oppimaan tehokkaampia tapoja ohjata liikennettä. Artikkelit mainitsevat myös vahvistusoppimisen olevan parempi tehtävään kuin ohjattu oppiminen, sillä vahvistusoppiminen kykenee oppimaan itsegeneroidun datan avulla. Markovin päätösprosessissa agentti pyrkii toimimaan mahdollisimman optimaalisesti seuraten ympäristöä ja toimimaan siitä tulevien asioiden mukaisesti tuottaen parhaan lopputuloksen. Vahvistusoppimisen tehtävänä on ratkaista edellä mainittua prosessia tehokkaasti reaaliajassa. Vahvistusoppimiseen pohjautuvilla algoritmeilla on kuitenkin heikkouksia. Kyseisillä algoritmeilla voi kestää kauan, että ne saavuttavat stabiilin tilan, joka voi johtaa liikenneuhkiin. On mahdollista, että algoritmi lähtee opettelemaan uutta tapaa toimia, jossa kestää kauan saavuttaa paras ratkaisu. Tämän seurauksena risteyksessä odottavat autoilijat voivat joutua odottamaan kauan. Kyseinen ongelma on läsnä jokaisessa vahvistusoppimiseen pohjautuvassa liikennevalojen ohjausta tekevässä tekoälymallissa. Kyseisen ongelman mahdollisuutta voidaan lieventää opettamalla mallille erilaisia tilanteita simulaattorin avulla ennen kuin sitä hyödynnetään oikeassa liikenteessä. Artikkelit kuitenkin mainitsevat, että vahvistusoppimisen malli, jota testattiin simulaattorilla ja jonka toiminta perustuu täysin kuviin, todettiin tehokkaammaksi kuin nykyiset tosielämässä käytössä olevat ratkaisut. Liikenteen keskimääräinen ruuhkaisuus väheni yli 23 % sekä autojen odotusaika risteyksissä väheni huomattavasti. Tällaisen ratkaisun hyödyntäminen tosielämässä, sekä erityisesti isoissa risteyksissä vaatisi useiden konvoluutioneuroverkkojen hyödyntämistä sekä paljon laskentatehoa. (Jeon ym, 2018.) Älykkäiden liikennevalojen lisäksi autojen ja ympäristön yhdistäminen on toteutettavissa sekä siihen voidaan liittää tekoälyä. Tässä ajoneuvot voisivat olla yhteydessä toisiinsa autoihin tai infrastruktuuriin. Tällainen ratkaisu parantaa turvallisuutta sekä liikenteen koordinaatiota ja liikkuvuuden tehokkuutta. (Bharadiya, 2023.)

3.3 Liikennedatan analysointi ja ennustaminen tekoälyn avulla

Tekoälyä voidaan hyödyntää liikenneuhkien ennustamisessa. Liikenneuhkat aiheuttavat vuosittain paljon vahinkoa niin maiden taloudelle kuin asukkaille esimerkiksi terveydellisistä syistä. Liikenneuhkat aiheuttavat päästöjä, vaikeuttavat aikatauluttamista sekä voivat olla myös stressaavia liikenteessä liikkuville ihmisille. Jotta kulkeminen kaupungissa olisi sulavaa, tulee ruuhkien ehkäisemiseen ja ennustamiseen panostaa. Yleisiä parametreja, joita hyödynnetään liikenneuhkien mittaamiseen ovat esimerkiksi liikenteen määrä, sen tiheys sekä matka-aika. On olemassa monia erilaisia lähestymistapoja näiden ongelmien ratkaisuun tekoälyn avulla. Artikkelit mainitsevat keinotekoisien neuroverkkojen olevan suosittuja liikenneuhkien ennustamisessa niiden helppokäyttöisyyden ja tehokkuuden takia. Keinotekoiset neuroverkot ovat rakenteeltaan joustavia sekä ne kykenevät muovautumaan sille syötetylle datalle sopivaksi. Esimerkiksi yleiskäyttöistä mallia voidaan hyödyntää erilaisten tieolosuhteiden kanssa. Keinotekoisien neuroverkkojen mallit ovat ainoita, joita on hyödynnetty kuljettajien käytösten analysointiin liikenneuhkien näkökulmasta. Nämä mallit ovat kuitenkin yleisesti suosittuja liikenteeseen liittyvissä asioissa kuten liikenteen ennustamisessa, ruuhkien hallinnassa, kuljettajan väsymyksessä sekä autojen meluhaitoissa. (Akhtar ja Moridpour, 2021.)

Tukivektorikone on tilastollinen koneoppimisen metodi, jota voidaan hyödyntää liikenteen samankaltaisuuksien tunnistamiseen ja täten liikenneuhkien ennustamiseen.

Sen avulla voidaan esimerkiksi ennustaa matkojen kestoja hyödyntämällä dataa liikenteestä, säästä sekä sosiaalisesta mediasta. Ajoneuvojen nopeudet luokiteltiin, joita käytettiin mallin opettamiseen ja ruuhkien ennustamiseen. Tukivektorikonetta voidaan myös hyödyntää moottoriteiden poistumiskaistojen liikennemäärän ennustamisessa, liikenteen kulun ennustamisessa sekä kulkuvälineiden ekologisuudessa sekä siihen liittyvässä kestävässä kehityksessä. (Akhtar ja Moridpour, 2021.) Sosiaalinen media on vahvassa roolissa liikenteen ennustamisessa sensorien ja GPS-järjestelmien kanssa. Tekoälyä hyödyntäen liikenteen kulkua voidaan hallita paremmin, luoda tehokkaita reittejä reaaliajassa ja tehdä liikenteessä kulkemisesta miellyttävää kaikille liikkujille. Erityisesti artikkeli tukee tekoälyn roolia kestävässä kehityksessä. Koneoppimisen rooli korostuu energiankulutuksen optimoinnissa, joka tukee taloudellisia ajotapoja. Myös koneoppimista voidaan hyödyntää sähkö- ja itseajavien autojen integroinnissa tieverkostoon. Logistiikassa sekä reittien suunnittelussa halutaan painottaa ekologisia ratkaisuja päästöjen vähentämisessä, jonka tukena tekoäly kykenee olemaan. (Bharadiya, 2023.)

Tekoäly voi auttaa liikkuvuuden parantamisessa älykkäissä kaupungeissa. Kaupunkien suunnittelussa halutaan panostaa sulavaan liikenteeseen, jotta matkanteko olisi mahdollisimman turvallista sekä tehokasta ajallisesti. Tämän ratkaisemiseksi voidaan hyödyntää erilaisia sensoreita ja Internet of Things -ratkaisuja. Esimerkiksi kaupungeissa voi liikkua autoja, jotka ovat yhteydessä toisiinsa ja näitä voidaan ohjata etäyhteydellä tai ohjaamisen hoitaa tekoäly. Kuitenkin tällaisen ratkaisun toimimiseksi vaaditaan, että kaikki liikkuvat autot toimivat samassa verkossa ja ovat kykeneviä kommunikoidaan. Artikkelissa painotetaan koneoppimisen olevan tärkeä osa liikenteen analysointia ja ruuhkien minimoimista. Koneoppiminen pystyy oppimaan aiemmin kerätystä datasta ja tekemään päätöksiä itsenäisesti. Datan fuusiota voidaan käyttää entistä parempien päätösten tekemiseen liikenteessä. Siinä dataa hyödynnetään useista eri lähteistä, joiden perusteella tehdään yksi päätös, jonka on tarkoitus olla parempi kuin vain yhtä datan lähdettä käyttäen. (Tarawneh ym., 2023.) Artikkelissa ehdotetaan tekoälypohjaista ratkaisua älykkäiden autojen hallintaan älykkäissä kaupungeissa. Sen voi jakaa kolmeen vaiheeseen, jotka ovat datankeräys, tietoturvallisuuden varmistaminen sekä datan käsittely. Datankeräysvaiheessa hyödynnetään auton sensoreita keräämään dataa kuljettajan, ajoneuvon sekä tien tilasta ja kunnosta. Myös sijaintitietoja voidaan hyödyntää arvioimaan onnettomuuksien todennäköisyyttä kyseisellä alueella ja liikenteen tilannetta. Tietoturvallisuus varmistetaan salaamalla data autosta löytyvällä avaimella. Pilvipalvelu vastaanottaa dataa ja avaa sen, jotta sitä voidaan käsitellä. Käsittelyvaiheen alussa, data puhdistetaan esimerkiksi tyhjästä, turhasta ja toistuvista arvoista. Data muutetaan myös XML-muotoon sen helppolukuisuuden vuoksi. Sen jälkeen data luokitellaan kolmeen kategoriaan, jotka ovat kuljettaja, tie ja auto. Datan luokittelu helpottaa ja nopeuttaa sen prosessointia, sillä alussa saatua dataa on suuri määrä, jonka vuoksi sen käsittelyyn raakana menee kauan. Lopuksi data analysoidaan, jonka pohjalta voidaan tehdä päätöksiä. Mikäli datassa huomataan liikenneturvallisuutta häiritseviä poikkeamia, kuten kuljettajan väsymystä, tilanteen mukaan auto voi ajaa itsestään sivuun tai kytkeä itseajavuuden päälle. Tämän datan avulla voidaan myös valvoa mahdollisia liikenneonnettomuuksia kuten ilman turvavöitä ajamista, puhelimen käyttöä ajaessa sekä ylinopeutta. Sijaintidatan avulla, kuljettajaa voidaan varoittaa vaarallisista alueista ja hätätilanteissa auto voi ajaa itsenäisesti kuljettajan sairaalaan. (Tarawneh ym., 2023.)

4. Sulautetut järjestelmät autoissa

Autot ovat kehittyneet vuosikymmenten aikana niin ajomukavuuden kuin myös turvallisuuden näkökulmasta. Nykyautot, kuten myös vanhemmat autot ovat täynnä sähköisiä varusteita, jotka kattavat moottorin toiminnan tukemisen, turvavarusteet sekä viihdelaitteistot. Kuitenkin nykyautoissa teknologia on kehittyneempää sekä niissä on lähtökohtaisesti laajempi varustustaso. Hyvänä esimerkkinä on nykyaikaiset turvavarusteet kuten automaattinen jarrutus ja kaistavahti, joissa tekoälyn rooli on vahva. Autoissa on useita erilaisia turvajärjestelmiä, jotka voidaan jakaa luokituksestaan passiivisiin ja aktiivisiin (Hamsini ja Kathires, 2021).

4.1 Aktiiviset turvajärjestelmät

Aktiivisiin turvajärjestelmiin kuuluu jarrutusjärjestelmä, vakionopeudensäädin, sähköinen ajonvakautusjärjestelmä, kaistavahti, parkki- sekä peruutustutkat ja oven aukinaisuudesta varoittava järjestelmä. Aktiiviset turvajärjestelmät toimivat siten, että ne estävät onnettomuuksien tapahtumisen. (Hamsini ja Kathires, 2021.) Aktiiviset turvajärjestelmät mukavoittavat tiellä liikkumista erilaisissa olosuhteissa turvallisuuden parantamisen lisäksi. Tilanteissa, joissa kuljettaja joutuu tekemään äkkinäisiä liikkeitä, on tärkeää pitää auto vakaana. Tällaisessa tilanteessa, järjestelmä voi itsenäisesti muuttaa ohjauksen suuntaa, jarrujen käyttöä sekä voimansiirron toimintaa. Tilanteen mukaan, voidaan myös yksittäisten pyörien väännön voimakkuutta säädellä, jotta vakaus säilyy. Jotta tällainen järjestelmä toimii, tulee auton kerätä dataa muun muassa tien liukkaudesta, kääntymisen nopeudesta ja kulmasta. Reaaliaikaisia laskelmoiteja voidaan suorittaa auton tilasta sekä tien kunnosta. Artikkelissa mainitaan myös autojen ympäriajosuojajärjestelmästä, joka estää autoa kaatumasta liikenteessä ja onnettomuustilanteissa. Ympäriajosuojajärjestelmä hyödyntää jarruja, ohjausta ja jousitusta siihen tarkoitetun algoritmin kanssa toimiakseen. Aktiivisten turvajärjestelmien toiminta voidaan jakaa eri kerroksiin. Sensorit, kuten kamerat ja paikkatietojärjestelmät keräävät dataa ympäristöstä. Tämä data käsitellään järjestelmän ”aivoissa”, jossa päätetään, miten toimitaan tilanteen mukaan. Toiminnot voivat vaihdella kuljettajan varoittamisesta järjestelmän itsenäiseen toimintaan asti. Lopuksi toiminnot laitetaan toteen esimerkiksi jarruttamalla tai manipuloidulla voimansiirtoa, jotta onnettomuudelta voidaan välttyä. (Sun ja Chen, 2010.)

4.2 Passiiviset turvajärjestelmät

Passiiviset järjestelmät puolestaan turvaavat kuljettajaa sekä matkustajia kolarin sattuessa. Näihin varusteisiin kuuluvat turvatyyny, turvavyöt sekä tuulilasi, joka ei hajoa pieniksi osiksi törmäyksessä. (Hamsini ja Kathires, 2021.) Turvatyynyjärjestelmän on tarkoitus suojata kuljettajaa sekä matkustajia kolarin sattuessa. Jotta turvatyyny toimivat oikein, artikkeli painottaa turvavöiden käytön tärkeyttä. Turvavöiden avulla kuljettaja pysyy paremmin paikoillaan. Kuitenkin turvatyyny tuovat lisäturvaa sillä on mahdollista, että turvavyöt venyvät, jonka seurauksena kuljettaja tai matkustajat voivat osua esimerkiksi kojelautaan. (Waghe ja Gajjal, 2014.) On olemassa turvavöitä, jotka kiristyvät joko ennen tai juuri kolarihetkellä vähentäen autossa olevan henkilön liikkumavaraa kolaritilanteessa. Joissakin autoissa voi myös olla älykkäitä turvatyynyjä, jotka säätelevät niiden voimakkuutta törmäyksen voiman mukaan. (Sun ja Chen, 2010.) Autoissa voi myös olla hätäpuhelujärjestelmä, joka onnettomuuden sattuessa ilmoittaa hätäkeskukseen tilanteesta ja lähettää samalla sijaintitiedot nopeuttaen avun saantia

(Waghe ja Gajjal, 2014). Turvavöiden ja turvavyöjen lisäksi, autoissa voi olla ylimääräisiä palkkeja onnettomuuksien varalle esimerkiksi ovissa. Erityisesti sivulta tulevissa iskuissa, ovien turvapalkit keskittävät törmäyksestä koituvat energian itseensä. Artikkelissa esitellään pneumaattista järjestelmää turvallisempien penkkien kehittämiseen erityisesti kolareissa, joissa autoon törmätään sivulta. Auton penkkien alle asennetaan pneumaattinen järjestelmä, joka onnettomuuden sattuessa liikuttaa penkkiä pois auton kyljen vierestä ja estää sivulta tulevaa autoa törmäämästä auton sisällä oleviin henkilöihin. Tällaisen järjestelmän tarkoituksena on suojata henkilöiden haavoittuvimpia kehonosia kuten lantiota, rintakehää sekä päätä välttämällä pahimmat vahingot. (Sabarinath, 2021.)

4.3 Edistysellinen kuljettajan avustinjärjestelmä

Moujahid ym. (2018) käsittelee artikkelissaan edistysellistä kuljettajan avustinjärjestelmää, joka koostuu neljästä komponentista. Nämä komponentit ovat pituus- ja lateraalisuuntainen ohjaus, ajovalvontajärjestelmä sekä pysäköintivustin. Pituussuuntaisessa ohjauksessa autossa oleva sensori mittaa pituutta edellä olevaan, samalla kaistalla olevaan autoon. Nykyautoihin on kehitetty adaptiivinen vakionopeudensäädin sekä törmäyksenestojärjestelmä. Näiden avulla kuljettajaa voidaan varoittaa mahdollisista vaaroista ajokaistalla, tehdä korjausliikkeitä tai hidastaa auton vauhtia tarvittaessa. Lateraalisuuntaisessa ohjauksessa auto tunnistaa vaaroja vierekkäisillä kaistoilla. Ohjaus muodostuu kahdesta erilaisesta järjestelmästä, jotka turvaavat kuljettajaa liikenteessä. Ensimmäinen järjestelmä varmistaa, ettei kaistanvaihdon yhteydessä ole vaaratilanteita kuten vastaantulevia autoja. Toisessa järjestelmässä tarkkaillaan kuljettajan ajorataa. Jos kuljettaja poikkeaa kaistalta, auto joko hälyttää varoituksen merkiksi tai tekee korjausliikkeen, jotta vaaratilanteita ei synny. Artikkelissa kirjoitetaan myös ajovalvontajärjestelmästä, jossa kuljettajan olemusta valvotaan. Järjestelmä voi tunnistaa kuljettajan stressi- ja väsymystason sekä ärsyyntyneisyyden (Moujahid ym., 2018). Antony ja Whensh (2021) mainitsevat artikkelissaan, että edellä mainitut järjestelmät sisältävät algoritmeja, jotka reagoivat asianmukaisesti tilanteen mukaan. Tekoäly hyödyntää muun muassa ympäristöstä kerättyä dataa, auton sijaintia sekä kuljettajan olemusta. Moujahid ym. (2018) mainitsee pysäköintivustimen olevan osa edistysellistä kuljettajan avustinjärjestelmää. Pysäköintivustimen avulla auto osaa ajaa itse parkkiruutuun hyödyntämällä sensoreita ja kameroita. Koneoppimisen rooli korostuu tässä turvavarusteessa, sillä ilman sitä tällaiset toiminnot eivät olisi mahdollisia (Moujahid ym., 2018). Antony ja Whensh (2021) kertovat artikkelissaan, että edistyselliset kuljettajan avustinjärjestelmät voidaan luokitella kahteen eri luokkaan.

4.3.1 Manipulaatiopohjaiset järjestelmät

Manipulaatiopohjaiset järjestelmät toimivat vaaroja tunnistavana tekijänä, mutta kykenevät myös toimimaan vaaratilanteissa ilman, että kuljettaja tekee mitään. Järjestelmä aktivoituu pääosin silloin kun tarvittava toiminta on sellaista, johon ihminen ei ehdi reagoida. Kun nopeaa reagoitua vaaditaan tilanteissa, joissa kuljettajaa ei ehditä varoittamaan, auto voi toimia kuljettajan puolesta. Esimerkiksi adaptiivinen vakionopeudensäädin ja törmäyksenestojärjestelmä ovat manipulaatiopohjaisia järjestelmiä, joiden toimintona voi olla automaattinen hätäjarrutus. (Antony ja Whensh, 2021.)

4.3.2 Tietopohjaiset järjestelmät

Tietopohjaiset järjestelmät ovat kuljettajan tukena ajon aikana. Ajon aikana, kuljettajat keskittyvät moneen asiaan kerralla, kuten oikean reitin valitsemiseen, aikataulussa pysymiseen sekä mahdollisen liikenneuhkan määrään. Tietopohjaiset järjestelmät avustavat kuljettajaa näissä asioissa, mutta eivät ohjaa autoa itsestään, kuten manipulaatiopohjaiset järjestelmät tekevät. Tietopohjaiset järjestelmät antavat kuljettajalle tietoa ympäristöstä ja pyrkivät antamaan mahdollisimman hyviä ratkaisuja liikenteessä liikkumiseen. Järjestelmä pyrkii myös valvomaan kuljettajan olemusta. Esimerkiksi kuljettajan tarkkaavaisuutta voidaan mitata erilaisilla sensoreilla ja väsymystasoa voidaan myös tarkkailla. (Antony ja Whinish, 2021.)

5. Tekoäly liikenneturvallisuudessa

Tekoäly hyödyntää sensorien keräämää dataa. Tekoäly on kykeneväinen oppimaan ja ratkaisemaan ongelmia itsenäisesti ja nopeasti. Tämä on erityisen tärkeää autoteollisuudessa, jossa turvallisuus on tärkeä osa autoilua. Erityisesti itseohjautuvissa autoissa, tekoälyn rooli on vahva. Autojen sadat sensorit havainnoivat ympäristöä ja tunnistavat liikenteen vaaroja. Tekoälyn avulla voidaan automatisoida toimintoja. Näihin toimintoihin kuuluvat hätäjarrutus, törmäysten välttäminen sekä jalankulkijoiden tunnistaminen. Tekoälyä hyödynnetään myös kuolleen kulman avustamisessa, vakionopeudensäätitimessä ja automatisoiduissa ohjausliikkeissä, jotta onnettomuuksilta vältytään. (Ammal, 2021.)

5.1 Koneoppiminen liikenneonnettomuuksien ennustamisessa ja ehkäisyssä

Antony ja Whenish (2021) selittävät koneoppimisen hoitavan kuljettajan vireystason tarkkailun. Kuljettajan tilasta kerätään dataa, joka luokitellaan piirteiden poimimisen jälkeen. Tämän avulla edistyskellinen kuljettajan avustinjärjestelmä voi tarvittaessa toimia, mikäli tilanne vaatii sen puuttumista. Kuljettajan tilasta ja suoriutumisesta liikenteessä kerätty data on tärkeää viranomaisille, sillä datan perusteella voidaan arvioida, mikäli kuljettava kykenee jatkamaan ajamistaan, vai joudutaanko ajo-oikeus perumaan. Auton sisäänrakennetut sensorit havainnoivat jatkuvasti kuljettajan liikkeitä kuten etäisyyttä edellä ajavaan autoon, nopeuden tasaisuutta ja kaistan vaihtojen sulavuutta. Väsymyksen tunnistamisessa auttavat myös sensorit, jotka havainnoivat ratin liikettä ja kuljettajan asentoa (Antony ja Whenish, 2021).

Liikenneonnettomuuksista 90 % aiheutuu ihmisten tekemien virheiden takia. Itseajavien autojen avulla, voidaan pienentää onnettomuuksien mahdollisuutta tuhatkertaisesti. Koneoppiminen on tekoälyn osa-alue, jonka rooli liikenneturvallisuudessa korostuu sen kyvystä parantaa järjestelmän suorituskykyä päätösten tekemisessä. Numeeristen ja analyttisten mallien luominen ja automatisointi on mahdollista koneoppimisen avulla. Koneoppiminen mahdollistaa dataan piilotettujen pisteiden tulkinnan ilman erillistä käskyä toteuttaa tiettyä tehtävää hyödyntämällä tilastoita, operaatioanalyysia sekä heuristisia malleja. (Janeera ym., 2021.)

5.2 Ohjatun oppimisen menetelmät liikenneturvallisuuden parantamisessa

Liikenne voi muuttua täysin itseohjautuvan teknologian kehittymisen myötä. Tutkimuksien mukaan, ajoneuvojen järjestelmät, jotka kykenevät hallitsemaan ja päättämään reitit päästäkseen perille, vähentävät välimatkoihin kuluva aika. Artikkelissa esitetään ohjattua oppimista hyödyntävää mallia, joka kykenee itseohjautuvuuteen käyttämällä pelkästään syötettyjä kuvia. Dataa kerättiin Unity-pelimoottorilla rakennetussa simulaattorissa, jossa ihminen ajaa radan alusta loppuun. Kuvamateriaalia kerättiin kolmesta eri kulmasta, joita hyödynnettiin erilaisten mallien opettamiseen. Kerätyn data avulla kyettiin luomaan täysin itseohjautuva ajoneuvo, joka osasi kiihdyttää suorilla teillä sekä jarruttaa mutkiin. Datan tarkkuus määritti, kuinka nopeasti ajoneuvo suoritti radan, mutta korkeimmassa nopeuksissa ajoneuvo alkoi heittelehtimään ja monissa tapauksissa ajoi ulos radalta. Tuloksissa tuli ilmi, että

syöttämällä tasaisemmin ohjattua harjoitusdataa mallille ei vaikuttanut lopputulokseen. Keräämällä dataa kolmesta kuvakulmasta yhden sijaan, se lisäsi ajon vakautta mutta ohjautuvuudesta kerätty data oli virheellisempää. Artikkelit mainitsevat, että käyttämällä monipuolisempaa ajorataa tulevissa testeissä, parantaisi se tuloksia simuloimalla tosimaailman ajo-olosuhteita. Artikkelissa painotetaan myös vahvistusoppimisen hyödyntämistä näiden testitulosten optimointiin. Lisäksi artikkelissa tuli ilmi, että hyödyntämällä pelkästään kuvia ja syöttämällä niitä ohjatun oppimisen malleihin, voidaan saavuttaa itseohjautuvuus ajoneuvoon. Kuvien perusteella voidaan tunnistaa mahdollisia esteitä liikenteessä, ja itseohjautuvuus voi auttaa kuljettajan pois vaaratilanteesta. Kuitenkin on huomattava, että ohjattu oppiminen tulee yhdistää muihin tekoälyn osa-alueisiin, jotta tätä teknologiaa voisi hyödyntää tosimaailmassa sen rajoitusten vuoksi erityisesti korkeissa nopeuksissa. (Katz ym., 2017.)

Ohjattua oppimista voidaan hyödyntää liikenteiden riskien luokitteluun. Riskejä luokittelevat algoritmit parantavat turvallisuutta mahdollistamalla turvalaitteiden oikeanlaisen reagoimisen, kuten hätäjarrituksen tai väistöliikkeen tekemisen tilanteen mukaan. Ohjatun oppimisen algoritmit tarvitsevat harjoitusdataa, jossa erilaiset tilanteet liikenteessä on luokiteltu riskitason mukaan. Tätä dataa voidaan hyödyntää parantamalla tai vertailemalla nykyisten algoritmien suorituskykyä. Harjoitusdatan kerääminen voi tuottaa kuitenkin haasteita, sillä datan tuottaminen harjoitusradoilla on kallista ja vaarallista. Liikenteessä peräänajo on yksi mahdollinen onnettomuus. Ajoneuvo, joka on törmäämässä edellä olevaan autoon, joutuu reagoimaan tilanteen mukaan. Mitä lähempänä ajoneuvo on törmäyksen kohdetta, sitä suurempaa väistöliikettä tarvitaan. Väistöliikkeen tekemisessä joudutaan myös huomioimaan ympärillä oleva liikenne, jotta voidaan valita paras mahdollinen reitti väistöliikkeelle. Tilanteen riskiluokituksen laskemiseen hyödynnetään etäisyyttä sekä ympärillä olevia esteitä ja muita ajoneuvoja. Toiminnot riskien mukaan algoritmien puolesta voivat olla esimerkiksi puuttumattomuus tilanteeseen, audiovisuaalisen varoituksen antaminen, hätäjarrutus tai väistöliikkeen tekeminen. Tietokoneen tekemät päätökset pitää tehdä ajoneuvon ohjausyksikössä reaaliajassa nopeasti. Yleensä ajoneuvojen ohjausyksiköt sisältävät rajoitetun määrän resursseja, joten se hankaloittaa algoritmien tehokkuutta. Artikkelit esittävät ratkaisun yhdistämällä riskien luokituksen laskemisen ohjatun oppimisen avulla tapahtuvaan luokitteluun. Näiden avulla voidaan opettaa luokittelijaa hyödyntämään satunnaisesti luokitinta. Oppinut luokittelija kykenee täten toimimaan erilaisissa liikenteen vaaratilanteissa riskiluokituksista riippumatta nopeasti ja tehokkaasti. (Herrmann ym., 2015.)

5.3 Ohjaamattoman oppimisen rooli liikenneturvallisuuden kehittämisessä

Ohjaamaton oppimista voidaan hyödyntää ympärillä olevien autojen liikkeen ennustamiseen. Tyypillisesti nykyiset turvajärjestelmät autoissa keskittyvät havainnoimaan esteitä, jotka ovat vaikeasti havainnoitavissa. Sensorit näiden tilanteiden varalle sijaitsevat auton etupuolella. Esimerkkinä on adaptiivinen vakionopeudensäädin, joka ohjaa etäisyyttä edellä ajavaan autoon automaattisesti. Ajoneuvon takaosan sensorit ovat pääasiassa tarkoitettu peruuttamiseen ja kuolleen kulman tarkistamiseen. Ne jättävät pääosin huomioimatta liikkuvien esteiden mahdollisuuden ja niiden aktiivisen seuraamisen, kuten muut tiellä liikkujat, jotka ovat auton takana. Auton sensorien keräämä data ympäristöstä sekä kuljettajan tekemistä liikkeistä edesauttavat ennakoimaan kuljettajan tulevia toimia kuten jarrutuksia, käännoksiä ja kaistanvaihtoja. Jotta autolla ajamisesta saisi turvallisempaa, tulee samanlaista havainnointia ja ennakoimista suorittaa

myös muiden ajoneuvojen kohdalla. Tällaisen toiminnallisuuden avulla kuljettajaa voidaan varoittaa muiden kuljettajien tekemistä mahdollisesti vaarallisista liikkeistä. Artikkelellä mainitsee, että tämänkaltaisen ongelman ratkaisuun voidaan hyödyntää ohjaamatonta oppimista. Se toimii siten, että sensorien keräämää dataa hyödynnetään ympärillä olevien kohteiden liikeratojen samankaltaisuuksien havainnointiin. (Morris ja Trivedi, 2009.) Kun takana olevat ajoneuvot on havaittu, niiden liikkeitä havainnoidaan ja tiedot tallennetaan väliaikaisesti. Oppimiseen tarvittavat vaiheet voidaan jakaa osiin. Ensimmäisenä halutaan oppia sijainteja, missä muut ajoneuvot yleensä ovat. Sen jälkeen voidaan luoda yhteyksiä ajoneuvojen sijaintien ja liikeratojen avulla. Näitä hyödyntämällä voidaan rakentaa klustereita eli samankaltaisten liikeratojen ryhmyksiä. Viimeisessä oppimisen vaiheessa liikeratojen väliaikaisilla ja dynaamisilla piirteillä voidaan Markovin piilomallia hyödyntämällä hajottaa kerätty data pieniin osiin. Tästä datasta otetaan tilanteen kesto sekä ajoneuvojen nopeus, joiden pohjalta voidaan luoda malli. Tämän mallin avulla voidaan tunnistaa liikenteessä tapahtuvia asioita, ennustaa niitä sekä erotella poikkeavuuksia. (Morris ja Trivedi, 2009.) Markovin piilomalli koostuu kahdesta stokastisesta prosessista. Ensimmäinen prosessi on Markovin ketju. Tilojen määrä on rajoitettu ja muutos tilojen välillä järjestellään muutosten todennäköisyyksien pohjalta. Toisessa prosessissa, tilojen tapahtumat luetaan ulostuloksi. Nämä riippuvat tilojen todennäköisyysjakaumasta. Mallia sanotaan ”piilomalliksi”, sillä ketjun tilat eivät ole näkyvissä. Stokastiset prosessit, joilla on Markovin ominaisuus, ovat muistittomia. Tämä tarkoittaa sitä, että sen nykytila on riippumaton sen historiasta yhtä edellistä arvoa pidemmälle. (Dymarski, 2011.)

5.4 Vahvistusoppimisen soveltaminen liikenneturvallisuudessa

Vahvistusoppimista voidaan hyödyntää liikenneturvallisuuden edistämiseksi. Järjestelmissä, joissa toimintojen suorittaminen perustuu tiettyihin muuttumattomiin sääntöihin, voidaan kohdata ongelmia haluttujen toimintojen suorittamisessa. Tällä tarkoitetaan sitä, että mikäli sääntöjä seurataan liian tarkasti, voi pienenkin riskin sisältävän toiminnon tekeminen jäädä välistä, vaikka se olisi tilanteessa suotavaa. Vahvistusoppimisen avulla voidaan ratkaista tällaiset tilanteet. (Schmidt ym., 2021.)

Itseohjautuvien autojen liikeradan suunnitteluun on käytetty lukuisia eri keinoja. Perinteiset keinot kuten nopeasti tutkivat satunnaispuut toimivat, mutta kyseinen algoritmi vaatii paljon laskentatehoa sekä lasketut liikeradat eivät ole niin liikenteeseen sopivia mitä halutaan. Myös koneoppimisen metodeja kuten ohjattua oppimista on hyödynnetty. Jäljittelevä oppiminen on toiminut yksinkertaisissa tilanteissa, mutta monimutkaisissa tilanteissa se ei kykene tuottamaan parasta mahdollista lopputulosta. Kuitenkin hierarkkisen vahvistusoppimisen avulla näiden edellä mainittujen ongelmien haittoja voidaan lieventää. Mikäli kyseessä on opittava tehtävä, jolla on useampi alatehtävä, hierarkkisen vahvistusoppimisen avulla voidaan oppia alatehtävien toimintatavat, joita voidaan uudelleen käyttää tulevaisuudessa samankaltaisissa tehtävissä. Hierarkkinen vahvistusoppiminen omaa korkean suppenemisnopeuden, mikä nopeuttaa parhaan mahdollisen toimintatavan oppimista. (Naveed ym., 2021.) Hierarkkista vahvistusoppimista voidaan hyödyntää itseohjautuvien ajoneuvojen liikeratojen määrittämiseen. Artikkelin esimerkkitalanteessa, auton on vaihdettava kaistaa, sillä tiellä on este. Kuitenkin kaistalla, johon auton pitää vaihtaa, liikkuu muita autoja. Artikkelellä mainitsee, että ongelman voi jakaa osiin. Autolla on kaksi mahdollista tapaa toimia, joko jatkaa samalla kaistalla tai vaihtaa kaistaa, jotka luokitellaan korkean tason vaihtoehdoiksi. Kuitenkin nämä kaksi voidaan jakaa vielä pienempiin osiin, joita kutsutaan matalan tason vaihtoehdoiksi. Mikäli kyseessä on kaistalla pysyminen, voi auto toimia kolmella tavalla. Auto voi jatkaa matkaa normaaliin tahtiin, mikäli esteitä ei ole

havaittavissa, mikäli auto havaitsee esteen, se pyrkii välttämään menemästä liian lähelle sitä vaihtamalla kaistaa tai sitten jos este on liian lähellä, voi auto hidastaa vauhtia tai pysähtyä kokonaan. Mikäli auton on tarkoitus vaihtaa kaistaa, voidaan kaistanvaihdot jakaa osiin nopeuksittain sekä käännösten jyrkkyyden perusteella. Mitä nopeammassa vauhdissa kaistanvaihdos tehdään, sitä loivemmin auto kääntyy, jotta liike olisi sulavaa. (Naveed ym., 2019.) Vahvistusoppiminen tukena on myös palkintojärjestelmä, joka jakaa palkitsemisen tai rankaisemisen riippuen toimintojen hyödyllisyyteen. Mikäli auto valitsee väärän toiminnon, esimerkiksi jos autolla olisi mahdollisuus vaihtaa kaistaa, mutta päättääkin jostain syystä jäädä odottamaan turhaan, niin siitä rangaistaan. Muita rangaistavia tekoja ovat turvavälin liiallinen lyhentäminen, turha kaistanvaihtaminen ja liian jyrkät tai loivat kaistanvaihdot. Mikäli auto ei huomaa esteitä omalla ajokaistallaan, palkitaan nopeasta ja loivasta kaistanvaihdosta. Jos auto joutuu odottamaan paikallaan, halutaan kaistanvaihdosta hidas sekä jyrkkä. Näiden avulla voidaan varmistaa ajoneuvon sulava kulkeminen niin omalla kaistalla kuin kaistanvaihtojen yhteydessä. (Naveed ym., 2019.)

5.5 Syväoppiminen liikenneturvallisuudessa

Syväoppimisella on moninaisia hyötyjä liikenneturvallisuudessa. Ajonvakautusjärjestelmien oikeanlainen toiminta vaatii tarkkaa tietoa ajoneuvon liikkumissuunnasta. Kaksi tärkeintä mittaria liittyen ajoneuvon vakauteen on kulma, jossa ajoneuvo liikkuu sivuttaisin sekä ajoneuvon ja tien välinen kitkakerroin. Ajoneuvon sensorit keräävät dataa muun muassa kääntymisnopeudesta, taka- ja etupyörien kulmasta, ajoneuvon nopeudesta, renkaiden pyörimisnopeudesta sekä pituus- ja lateraalisuuntaisesta kiihtyvyydestä. Näiden tietojen avulla, syväoppimisen algoritmit pystyvät ennustamaan ajoneuvon sivuttaiskulman liikkeen. Renkaiden ja tien välisen kitkakertoimen laskemiseen voidaan myös hyödyntää syväoppimista, mutta sen haasteet ilmenevät muuttujien vaihtuvuudessa. Tiet voivat olla esimerkiksi liukkaista tietyissä keliolosuhteissa sekä liukkauden määrä voi vaihdella rajusti. Myös renkaiden kunto sekä kuviointi vaikuttavat laskennan oikeellisuuteen. (Singh ja Arat, 2019.)

Tekoäly kykenee sensorien avulla tunnistamaan ja ennakoimaan mahdollisia vikoja. Ennakoimalla vikoja, voidaan välttää onnettomuuksia sekä kalliita korjauskuluja huoltamalla autoa ennen osien lopullista hajoamista. Dataa voidaan kerätä useilla eri sensoreilla, joka mahdollistaa esimerkiksi akuston, polttoainepumpun sekä käynnistysmoottorin tilan seuraamisen. Erityisesti renkaiden ongelmien seuraaminen tapahtuu hyödyntämällä konvoluutioneuroverkkoihin perustuvia algoritmeja. (Ammal, 2021.)

Syväoppimista voidaan hyödyntää itseohjautuvissa autoissa. Näiden ajoneuvojen useat sensorit keräävät mittavan määrän dataa ja sen käsittelyyn vaaditaan tehokkaita algoritmeja. Itseohjautuvissa autoissa voidaan hyödyntää neuroverkkoja, joihin päätöksentekologiikka on kokonaisuudessaan upotettu. Artikkelissa mainitaan esimerkkinä, että konvoluutioneuroverkot kykenevät oppimaan tien ja kaistan välisen eron ilman näitä erottavia tiemerkeitä. Oppimiseen ei myöskään vaadita semanttista abstraktiota eikä reittien suunnittelua. (Singh ja Arat, 2019.)

5.6 Konenäkö liikenteen vaarojen havainnoinnissa

Edistyksellinen kuljettajan avustinjärjestelmä on tehokas turvajärjestelmä, mutta sen toteutuksessa on otettava huomioon monenlaiset tilanteet. Järjestelmässä täytyy olla

toiminto, joka mahdollistaa auton turvallisen ajamisen vikatilanteissa. Erityisesti autot, jotka eivät ole täysin itseajavia, ovat kuljettajan vastuulla. (Vishnukumar ym., 2017.)

Konenäön liittäminen edistykseen kuljettajan avustinjärjestelmään on ollut haastavaa. Konenäön algoritmit ovat laskentatehoa vaativia, sillä tyypillisesti kuvan laatu sekä ruudunpäivitysnopeus ovat korkeita. Kun tähän lisätään vielä ympäristön vaihteleva valaistus ja vaatimus reaaliaikaisesta videonkäsittelystä, se hankaloittaa toteutusta entisestään. Edistykselliselle kuljettajan avustinjärjestelmälle on myös olennaista olla turvallisuusstandardien, kuten ISO 26262, mukaisia. Autoihin laitettavat järjestelmät kohtaavat myös rajoituksia niin tilan kuin myös energiankulutuksen suhteen. Myös järjestelmien mahdollinen ylikuumentuminen ja viilennysratkaisut tulee ottaa huomioon suunnittelussa. (Mandal ym., 2014.)

Autoihin liitetyt konenäköä käyttävät ratkaisut voidaan jakaa kolmeen tasoon. Matala taso hyödyntää esikäsittelyyn tarkoitettuja algoritmeja syötetylle kuvalle kokonaisuudessaan. Nämä algoritmit käsittelevät kuvaa suorakulman muotoisissa laatikoissa käyttämällä jokaiselle pikselille samaa algoritmia. Kun matalan tason käsittely on suoritettu, siirrytään keskitasoon käsittelyyn. Keskitasolla algoritmit keskittyvät prosessoimaan haluttuja kohtia segmentoinnin avulla riippuen niiden kirkkaudesta, kontrastista ja tekstuurista. Yleisesti, keskitasoon prosessoinnissa hyödynnetään morfologista kuvanprosessointia sekä kuvista löytyvien yhteneväisyyksien analysointia. Halutut kohdat käsitellään syvällisemmin tilastojen ja histogrammien avulla, jotta saadaan laskettua kuvien piirteitä. Korkeimmalla tasolla, prosessoiduista kuvista tunnistetaan halutut piirteet ja esineet. Näiden pohjalta, löytyneet asiat voidaan luokitella halutulla tavalla sekä ennustaa niiden käyttäytymistä. (Kamath ym., 2014.)

Kuljettajan olemuksen voi tunnistaa tekoälyn avulla. Autot, joissa hyödynnetään tekoälyä, voivat tunnistaa esimerkiksi kuljettajan väsymyksen hänen ilmeistään käyttäen kameroita ja infrapunasensoreita. Tämän avulla auto voi automaattisesti herättää kuljettajan, jotta tämä ei nukahda rattiin. Tätä teknologiaa voidaan hyödyntää myös niin kuljettajan kuin matkustajien mukavuuden lisäämiseen. Tekoäly kykenee tunnistamaan autossa olevat henkilöt ja säätämään lämpötilan, istuimet sekä peilit oikeaan asentoon riippuen henkilöstä. (Ammal ym., 2021.) Kuljettajan vireystilan häiriötekijät voidaan jakaa kahteen osaan. Häiriötekijät voivat olla joko kognitiivisia tai visuaalisia. Kognitiiviset häiriötekijät ovat ajamiseen epäsuorasti liittyviä asioita kuten puhelimeen puhuminen tai reitin suunnittelu, jotka voivat aiheuttaa kuljettajan katseen keskittymistä ajoradan keskelle jättäen esimerkiksi tienreunat huomioimatta. Visuaaliset häiriötekijät aiheuttavat kuljettajan katseen ohjautumista pois ajoradasta, kuten viihdelaitteiden säätäminen. (Bergasa ym., 2008.)

Konenäköä voidaan käyttää tunnistamaan kuljettajan olemusta ajon aikana. Artikkelissa mainitaan erilaisia tapoja havainnoida kuljettajan olemusta kuten rannekkeita, jotka mittaavat sykettä tai kypärää, jota käytetään kuljettajan katseen seuraamiseen. Nämä tavat voivat häiritä kuljettajaa ja vaativat kuljettajalta ylimääräistä ponnistelua, jotta olemusta voidaan havainnoida. Konenäköä voidaan kuitenkin hyödyntää kameroiden avulla, eikä täten vaadi puettavia laitteita. Autoissa konenäön avulla voidaan havainnoida monia asioita kuljettajan olemuksesta kuten muutoksia silmien ja pään asennossa sekä kasvojen liikettä. Artikkelissa mainitaan, esimerkki kuljettajan vireystilan alentumisesta. Sen voi huomata silmänräpäysten harventumisessa, silmäluomien liikkumisen hidastumisessa sekä silmien sulkeutumisesta. Muita piirteitä ovat ryhdin huonontuminen, haukottelu sekä katseen muuttuminen yhteen kohtaan tuijottamiseksi. (Bergasa ym., 2008.)

Bergasa ym. (2008) tuovat esille heidän kehittämänsä järjestelmän, joka tunnistaa kuljettajan väsymystilan kasvoista keräämällä dataa esimerkiksi silmien liikkeistä ja ilmeistä. Näiden parametrien avulla luodaan asteikko kuvaamaan kuljettajan vireystilaa. Järjestelmästä kerrotaan myös, että sen avulla voidaan tarkkailla niin visuaalisten ja kognitiivisten häiriötekijöiden vaikutusta ajamiseen. Järjestelmän toiminta perustuu infrapuna-LED-valon heijastukseen, jonka vuoksi ulkoiset valonlähteet kuten katuvalot, muiden autojen valot sekä auringonvalo aiheuttavat häiriöitä. Lähtökohtaisesti tekoälyn avulla saadaan suodatettua ylimääräiset valot, jotka eivät valaise kuljettajan kasvoja suorassa linjassa. Mikäli kuljettajan kasvot valaistetaan suoralla valolla, esimerkiksi vastaantulijan auton toimesta, se voi hankaloittaa järjestelmää huomioimaan kuljettajan pupilleja. Pupillien seuraaminen on tärkeä osa järjestelmän toimintaa, mutta se on myös järjestelmän heikko kohta. Ylimääräisten valonlähteiden lisäksi, silmälasit sekä nopeat liikkeet silmät suljettuina vaikeuttavat pupillien liikkeiden tunnistamista. Silmälasien läpi voidaan tunnistaa pupillit, mutta LED-valo heijastuu myös lasista, vaikeuttaen pupillien tunnistamista. Mikäli kuljettaja liikuttaa päätään silmät suljettuina, järjestelmän täytyy tehdä ylimääräistä työtä pupillien tunnistamiseksi, sillä ne eivät ole oletetussa kohdassa. Tämä johtaa myös siihen, että silmien räpäytysten välinen aika vääristyy. (Bergasa ym., 2008.) Artikkelista voidaan tulkita, että konenäköä voidaan hyödyntää liikenneturvallisuuden parantamisessa, mutta eritoten infrapuna-LED-valot omaavat heikkouksia valoisissa ympäristöissä.

6. Pohdinta

Tekoäly toimii tehokkaasti liikenneturvallisuuden edistäjänä ja pelastaen mittavan määrän ihmisiä vuosittain. Nopeasti kehittyvät tekoälypohjaiset ratkaisut mahdollistavat ihmisille sekä ympäristölle hyvän tulevaisuuden niin turvallisuuden kuin mukavuudenkin puolesta. Liikenneonnettomuuksissa menehtyy vuosittain jopa 1,2 miljoonaa henkeä, joista itseajavat autot voivat pelastaa 30 000 ihmistä vuosittain (Soegoto ym., 2019). Liikenneonnettomuuksien yleisimmät syyt ovat kuljettajien inhimilliset virheet kuten rattiin nukahtaminen tai keskittymiskyvyn herpaantuminen. Noin neljännes onnettomuuksista johtuu edellä mainituista syistä. (Bergasa ym., 2008.)

Tutkielman tarkoituksena oli tutkia tekoälyn roolia sekä sen hyödyntämistä liikenneturvallisuudessa. Aihe on erityisesti nykypäivänä merkittävä, etenkin tekoälyn ajankohtaisuuden vuoksi. Tutkimuskysymyksenä oli ”Kuinka tekoäly parantaa liikenneturvallisuutta?”, johon löytyi useita eri mahdollisuuksia.

Erityisesti liikenneturvallisuudessa tekoälyn rooli on vahvassa asemassa, sillä tekoälyn kehitys on edistynyt nopeaa vauhtia. Useita eri tekoälyn muotoja hyödynnetään autojen turva- ja viihdelaitteissa, joskin herää huoli niiden varmatoimisuudesta ja turvallisuudesta. Nykypäivänä valmistusprosesseja valvotaan tarkkaan etenkin silloin, kun kyse on ihmishenkien turvallisuudesta. Vaikka toteutetut ratkaisut olisivatkin toimivia testiympäristöissä, voivat tulokset olla hyvinkin erilaisia todellisessa liikenteessä. Monet tutkimukset esittivät tekoälymalleja sekä tekoälypohjaisia ratkaisuja liikenneturvallisuuden edistämisen näkökulmasta. Esimerkiksi Katz ym. (2017) toteuttivat ohjatun oppimisen avulla mallin itseohjautuvasta autosta, johon kerättiin dataa Unity-pelimoottorin avulla pyörivässä simulaatiossa. Kerätyn datan avulla auto kykeni suorittamaan radan läpi simulaatiossa hitailla nopeuksilla, mutta korkeimmissa nopeuksissa ulosajon riski kasvoi mittavan suureksi. Herrmann ym. (2015) mainitsevat, että ohjattu oppiminen vaatii dataa oppiakseen, mutta sen kerääminen oikeilla harjoitusradoilla on kallista sekä vaarallista. Haasteista huolimatta, ohjattua oppimista ehdotetaan liikenteen riskien luokittelun laskemiseen. Autojen ohjausyksiköt ovat resurssirajoitteisia ympäristöjä, joissa laskujen pitää tapahtua nopeasti ja tehokkaasti. Ohjattu oppiminen voisi mahdollisesti toimia luokittelun apuna tällaisissa tilanteissa. Konenäön avulla voidaan tunnistaa kuljettajan olemuksesta esimerkiksi väsymystila käyttäen infrapunasensoreita, mutta tällaisessa järjestelmässä kuitenkin vääränlainen valaistus kuten liiallinen auringonvalo tai vastaan tulevien autojen häikäisevät valot voivat johtaa konenäön toiminnan epävarmuuksiin (Bergasa ym., 2021). Tekoälyn vahvuus korostuu erityisesti silloin, kun käyttötarkoitukseen hyödynnetään sen oikeita osa-alueita asiaankuuluviin tehtäviin. Tekoälyn laajuuden avulla, voidaan kehittää lähes kaikkiin tarvittaviin asioihin sitä hyödyntävä malli tai ratkaisu. Esimerkiksi konenäkö kykenee tunnistamaan esteitä ja kuljettajan olemusta, kun taas ohjattu oppiminen pystyy hyödyntämään kerättyä dataa ja tekemään oikeita päätöksiä samalla kun kehitty entistä tehokkaammaksi. Yhdistämällä eri tekoälyn osa-alueita, saadaan luotua innovatiivisia ja turvallisia ratkaisuja. Vaikka useiden tutkimusten pohjalta voidaan huomata, kuinka tekoälyä jatkuvasti kehitetään parempaan suuntaan, niin monissa tapauksissa kehitys on vasta alkuvaiheessa. Kuitenkin tekoälyn suosio on kasvussa kuten myös ihmisten kiinnostus turvallisempaa liikennettä kohtaan. Tästä voidaan päätellä, että tekoäly on tällä hetkellä ja tulee vielä pitkään olemaan ajankohtainen aihe autoteollisuudessa sekä liikenneturvallisuudessa.

Tekoälyllä on kuitenkin muitakin hyötyjä autoteollisuuden kannalta kuin pelkästään liikenneturvallisuuden näkökulmasta. Soegoto ym. (2019) kertoo, että tekoälyn avulla voidaan vähentää liikenteen määrää, sillä tekoäly kykenee laskemaan nopeimman ja lyhimmän reitin kohteeseen. Tämän ansiosta päästöt vähenevät, josta seuraa puhtaampi ympäristö. Kun liikenteestä tulee sulavampaa tekoälyn ansiosta ja ruuhkat vähenevät, jää ihmisille enemmän aikaa elämiseen, mikä näkyy niin fyysisessä kuin psyykkisessä terveydessä (Soegoto ym., 2019). Pidän tärkeänä edistää liikenneturvallisuutta sekä muitakin elämän osa-alueita, jotka vaikuttavat niin terveyteen kuin mukavuuteen. Tekoälyn vaikutukset liikenneturvallisuuteen ovat mittavat, mutta myös tekoälystä johtuvat muut positiiviset sivuvaikutukset ovat tärkeä ottaa huomioon kehittäessä näitä teknologioita.

Älykkäiden kaupunkien konseptit sekä tekoälyn rooli liikenteenohjauksessa ovat myös yleistyneet tekoälyn kehityksen myötä. Adaptiivisen liikennevalo-ohjauksen avulla, jossa vahvistusoppiminen on tärkeässä roolissa, voidaan tehostaa risteyksien liikennevirtaa ja vähentää ruuhkia (Jeon ym., 2018). Yhteyden luomista ajoneuvojen ja infrastruktuurin välille on suunniteltu älykkäisiin kaupunkeihin. Esimerkiksi sähkö- ja itseajavat autot voitaisiin integroida tieverkostoon parantaen liikenteen koordinoitua. Artikkelissa tuodaan myös esille datan kerääminen liikenteestä paikkatietojärjestelmien, sosiaalisen median sekä sensorien avulla. Näitä hyödyntäen liikenteen kulkua voidaan hallita tehokkaasti luomalla esimerkiksi parhaita mahdollisia reittejä kulkijoille sekä samalla hillitä ruuhkia. (Bharadiya, 2023.) Voidaan huomata, että tekoälyä pystyy hyödyntämään tehokkaasti liikenteessä myös muilla tavoilla kuin pelkästään autoista käsin. Tekoäly voi myös tehostaa autottomien kaupunkien liikkuvuutta, erityisesti itseajavien julkisten kulkuvälineiden avulla. Teknologian ja erityisesti langattomien yhteyksien lisääntyessä tietoturvariskit ovat asia, joka on otettava huomioon. Älykkäät kaupungit sekä niihin liittyvät ratkaisut voivat olla kalliita toteuttaa nykyisen infrastruktuurin päälle. Kuitenkin ennen tätä, mahdollisesti toteutettavat ratkaisut pitää suunnitella, kehittää sekä testata, joka voi kokonaisuutena olla aikaa vievää. On hyvä pohtia älykkäiden liikenneratkaisujen hyviä ja huonoja puolia ennen kuin niitä lähdetään toteuttamaan. On todettu, että edellä mainitut ratkaisut vähentävät ruuhkia ja päästöjä sekä lisäävät turvallisuutta, mutta siitä huolimatta tilanteet ovat erilaisia eri paikoissa. Vilkkaimpiin kaupunkeihin ja kaupunginosiin voisi olla hyödyllistä toteuttaa esimerkiksi koordinoitua parantavia ratkaisuja, mutta millaisia tekoälypohjaisia turvallisuutta parantavia ratkaisuja voitaisiin luoda syrjäisimmille seuduille ja valtateille? Erityisesti kylmillä seuduilla talviaikaan routavauriot ja tien luokkaus voivat aiheuttaa riskejä. Tekoälyä voitaisiin hyödyntää teiden kunnan tarkkailussa, jonka avulla autoilijat voivat varautua ennakkoon vaarallisiin kohtiin ja teiden kunnostaminen esimerkiksi routavaurioilta voidaan kohdentaa tehokkaammin. Tämän lisäksi, esimerkiksi konenäköä voidaan hyödyntää villieläinten tunnistamisessa sekä ohjattua oppimista niiden liikkeen ennustamiseen, jonka seurauksena autoilijoille voidaan varoittaa mahdollisista villieläimistä teiden läheisyydessä.

Tutkimuksessa osoitetaan tekoälyn osalta laajasti sen eri osa-alueita, mutta pidättäytyy kuitenkin pintapuolisena syventymättä perusasioita pidemmälle. Tämän avulla lukijalle voidaan luoda yleinen käsitys siitä, mihin tekoälyä käytetään ja voidaan tulevaisuudessa käyttää. Jatkotutkimuksia ajatellen, aihepiiriä voidaan supistaa keskittymällä yhteen tekoälyn osa-alueeseen sekä sen tarjoamiin mahdollisuuksiin liikenneturvallisuuden edistämiseksi. Syventymällä yhteen osa-alueeseen, voidaan luoda kokonaisvaltaisempi kuva sen käyttötarkoituksista, mahdollisuuksista sekä heikkouksista. Vaihtoehtoisesti, voidaan ottaa yksi turvalaite, kuten ajonvakautusjärjestelmä, jonka toimintoja lähdetään tutkimaan syvällisemmin. Luomalla oman tekoälymallin valitsemastaan tekoälyn osa-alueesta tai sitä hyödyntävästä turvalaitteesta, voidaan löytää uusia vahvuuksia ja

heikkouksia kyseisestä toteutuksesta. Turvalaitteisiin voisi myös syventyä laite-asteelle asti ja tutkia komponenttien välisiä riippuvuuksia, niiden tuomia rajoitteita sekä mahdollisuuksia. Liikenneturvallisuus sekä sitä tukevat tekoälypohjaiset ratkaisut ovat laaja aihealue, jota on syytä tutkia monesta eri näkökulmasta, jotta liikenteestä saadaan turvallinen, tehokas sekä kestävä.

7. Yhteenveto

Tekoäly on ajankohtainen aihe autoteollisuudessa sekä liikenneturvallisuudessa, sillä molemmat kehittyvät nopeasti parempaan ja turvallisempaan suuntaan. Erityisesti liikenneturvallisuuteen halutaan panostaa autojen lisääntymisen myötä. Tutkielma keskittyi kirjallisuuskatsauksen muodossa tekoälyn rooliin liikenneturvallisuuden näkökulmasta. Tekoälyä on liikenteessä monissa eri paikoissa kuten autojen turva- ja viihdelaitteissa, jotka tekevät matkustamisesta mukavaa ja turvallista. Myös liikenteenohjausjärjestelmissä voidaan käyttää tekoälypohjaisia järjestelmiä, joiden avulla voidaan tehdä liikenteestä sulavampaa ja ohjata sitä onnettomuustilanteissa.

Erityisesti autoissa, tekoälyä on nykypäivänä hyödynnetty useissa turvalaitteissa. Tekoälyllä on useita eri osa-alueita, joista monia voidaan hyödyntää liikenneturvallisuuden tukena. Erityisesti koneoppimisen eri muodot, ohjattu oppiminen, ohjaamaton oppiminen ja vahvistusoppiminen, ovat suosittuja. Ohjatun oppimisen avulla voidaan esimerkiksi opettaa auto itseohjautuvaksi. Sen avulla auto pystyy kerätyn datan pohjalta oppia tekemään itsenäisiä päätöksiä liikenteessä. Ohjaamatonta oppimista voi hyödyntää muiden tiellä liikkujien liikkeen ennustamiseen sekä vahvistusoppimista hyödyntäen voidaan suunnitella itseajavien autojen liikeratoja esimerkiksi kaistaa vaihtaessa. Näiden lisäksi, syväoppimista käytetään ajonvakautusjärjestelmissä sekä sen avulla voidaan tunnistaa nykyisiä vikoja ja ennustaa tulevia vikoja autoissa. Koneälyn avulla kyetään tunnistamaan kuljettajan olemuksesta esimerkiksi hänen väsymyksensä. Auton turvajärjestelmät voivat kerätyn datan avulla herättää kuljettajan tai toimia itsenäisesti tilanteen sen vaatiessa. Tekoälyä löytyy myös autojen ulkopuolelta. Älykkäissä liikenteenohjausjärjestelmissä, kuten adaptiivisessa liikennevalo-ohjauksessa hyödynnetään vahvistusoppimista. Keinotekoisia neuroverkkoja sekä tukivektorikoneita pystytään käyttämään liikennesuunnitelmien ennustamiseen ja hallintaan. Koneoppimisen avulla voidaan integroida sähkö- ja itseajavat autot tieverkkoon, minkä seurauksena voidaan luoda taloudellisempia reittejä kulkijoille.

Tekoälyn rooli nykymaailmassa on vahva ja sitä tullaan käyttämään yhä enemmän sen kehittyessä. Sitä pystytään käyttämään laajasti eri aloilla kuten autoteollisuudessa, terveydenhuollossa, finanssialalla sekä logistiikassa. Kyseisen teknologian lisääntymisen voi kuitenkin aiheuttaa huolta sen toimintavarmuudesta sekä tietoturvallisuudesta, mutta nykyään lähes kaikki valmistus ja toteutus on tarkan valvonnan alla, että kaikki tapahtuu standardien mukaan.

Lähdeluettelo

- Akhtar, M., & Moridpour, S. (2021). A review of traffic congestion prediction using artificial intelligence. *Journal of Advanced Transportation*, 2021, 1-18. <https://doi.org/10.1155/2021/8878011>
- Ammal, S., Kathiresh, M. & Neelaveni, R. (2021). Artificial Intelligence and Sensor Technology in the Automotive Industry: An Overview. In M. Kathiresh & R. Neelaveni (Eds.), *Automotive Embedded Systems: Key Technologies, Innovations, and Applications*. (s. 145-164). Springer. https://doi.org/10.1007/978-3-030-59897-6_8
- Antony, M. & Whenish, R. (2021). Advanced Driver Assistance Systems (ADAS). In M. Kathiresh & R. Neelaveni (Eds.), *Automotive Embedded Systems: Key Technologies, Innovations, and Applications*. (s. 165-181). Springer. https://doi.org/10.1007/978-3-030-59897-6_9
- Bergasa, L. M., Nuevo, J., Sotelo, M. A., Barea, R., & Lopez, E. (2008). Visual Monitoring of Driver Inattention. In D. Prokhorov (Ed.), *Computational Intelligence in Automotive Applications* (s. 19–37). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-79257-4_2
- Bharadiya, J. (2023). Artificial Intelligence in Transportation Systems A Critical Review. *American Journal of Computing and Engineering*, 6(1), 34-45. <https://doi.org/10.47672/ajce.1487>
- Dymarski, P. (2011). *Hidden Markov Models*. IntechOpen.
- El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? In I. El Naqa, R. Li, & M. J. Murphy (Eds.), *Machine Learning in Radiation Oncology: Theory and Applications* (s. 3–11). Springer International Publishing. https://doi.org/10.1007/978-3-319-18305-3_1
- Ertel, W. (2017). *Introduction to Artificial Intelligence* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-319-58487-4>
- Hamsini, S. & Kathiresh, M. (2021). Automotive Safety Systems. In M. Kathiresh & R. Neelaveni (Eds.), *Automotive Embedded Systems: Key Technologies, Innovations, and Applications*. (s. 1-18). Springer. https://doi.org/10.1007/978-3-030-59897-6_1
- Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffner, J. L., Krebs, V. E., ... & Ramkumar, P. N. (2020). Machine learning and artificial intelligence: definitions, applications, and future directions. *Current reviews in musculoskeletal medicine*, 13, 69-76. <https://doi.org/10.1007/s12178-020-09600-8>
- Herrmann, S., Utschick, W., Botsch, M., & Keck, F. (2015). Supervised learning via optimal control labeling for criticality classification in vehicle active safety. In *2015 IEEE 18th International Conference on Intelligent Transportation Systems* (s. 2024-2031). IEEE. <https://doi.org/10.1109/ITSC.2015.328>

- Janeera, D. A., Gnanamalar, S. S. R., Ramya, K. C., & Kumar, A. A. (2021). Internet of things and artificial intelligence-enabled secure autonomous vehicles for smart cities. In *Automotive Embedded Systems: Key Technologies, Innovations, and Applications* (s. 201-218). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-59897-6_11
- Jeon, H., Lee, J., & Sohn, K. (2018). Artificial intelligence for traffic signal control based solely on video images. *Journal of intelligent transportation systems*, 22(5), 433-445. <https://doi.org/10.1080/15472450.2017.1394192>
- Kahn, G., Abbeel, P., & Levine, S. (2021). Badgr: An autonomous self-supervised learning-based navigation system. *IEEE Robotics and Automation Letters*, 6(2), 1312-1319. <https://doi.org/10.1109/LRA.2021.3057023>
- Kamath, S., Dabral, S., Sankaran, J., Valentine, B., & Kisacanin, B. (2014). Implementation details of mid-level vision on the embedded vision engine (EVE). In *2014 IEEE International Symposium on Circuits and Systems (ISCAS)* (s. 1283-1287). IEEE. <https://doi.org/10.1109/ISCAS.2014.6865377>
- Katz, G., Roushan, A., & Shenoi, A. (2017). Supervised learning for autonomous driving. <https://cs229.stanford.edu/proj2017/final-reports/5243612.pdf>
- Lugmayr, A., Danelljan, M., & Timofte, R. (2019). Unsupervised learning for real-world super-resolution. In *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)* (s. 3408-3416). IEEE. <https://doi.org/10.1109/ICCVW.2019.00423>
- Mandal, D. K., Sankaran, J., Gupta, A., Castille, K., Gondkar, S., Kamath, S., ... & Phipps, A. (2014). An embedded vision engine (eve) for automotive vision processing. In *2014 IEEE International Symposium on Circuits and Systems (ISCAS)* (s. 49-52). IEEE. <https://doi.org/10.1109/ISCAS.2014.6865062>
- Morris, B., & Trivedi, M. (2009). Unsupervised learning of motion patterns of rear surrounding vehicles. In *2009 IEEE International Conference on Vehicular Electronics and Safety (ICVES)* (s. 80-85). IEEE. <https://doi.org/10.1109/ICVES.2009.5400238>
- Moujahid, A., Tantaoui, M., Hina, M., Soukane, A., Ortalda, A., ElKhadimi, A. & Ramdane-Cherif, A. (2018). Machine Learning Techniques in ADAS: A Review, *International Conference on Advances in Computing and Communication Engineering (ICACCE)*, (s. 235-242). IEEE. <https://doi.org/10.1109/ICACCE.2018.8441758>
- Naveed, K. B., Qiao, Z., & Dolan, J. M. (2021). Trajectory planning for autonomous vehicles using hierarchical reinforcement learning. In *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)* (s. 601-606). IEEE. <https://doi.org/10.48550/arXiv.2011.04752>
- Panagiotopoulos, I., & Dimitrakopoulos, G. (2019). Cognitive infotainment systems for intelligent vehicles. In *2019 10th International Conference on Information, Intelligence, Systems and Applications (IISA)* (s. 1-8). IEEE. <https://doi.org/10.1109/IISA.2019.8900712>

- Sabarath, P. (2020). Passive Safety System for Side Impact in Cars. *Shanlax Int. J. Arts Sci. Human*, 7(4), 115-120. <https://doi.org/10.34293/sijash.v7i4.1623>
- Schmidt, L. M., Kontes, G., Plinge, A., & Mutschler, C. (2021). Can you trust your autonomous car? interpretable and verifiably safe reinforcement learning. In *2021 IEEE Intelligent Vehicles Symposium (IV)* (s. 171-178). IEEE. <https://doi.org/10.1109/IV48863.2021.9575328>
- Singh, K. B., & Arat, M. A. (2019). Deep learning in the automotive industry: Recent advances and application examples. *arXiv preprint arXiv:1906.08834*. <https://arxiv.org/pdf/1906.08834.pdf>
- Soegoto, E., Utami, R. & Hermawan, Y. (2019). Influence of artificial intelligence in automotive industry. *Journal of Physics: Conference Series*, 1402(6). <https://doi.org/10.1088/1742-6596/1402/6/066081>
- Sun, Z., & Chen, S. K. (2010). Automotive active safety systems [introduction to the special section]. *IEEE Control Systems Magazine*, 30(4), 36-37. <https://doi.org/10.1109/MCS.2010.937044>
- Szeliski, R. (2022). *Computer vision: algorithms and applications*. Springer Nature. <https://doi.org/10.1007/978-3-030-34372-9>
- Tarawneh, M., AlZyoud, F., & Sharrab, Y. (2023). Artificial Intelligence Traffic Analysis Framework for Smart Cities. In *Science and Information Conference* (s. 699-711). Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-37717-4_45
- Vishnukumar, H., Butting, B., Müller, C. & Sax, E. (2017). Machine learning and deep neural network — Artificial intelligence core for lab and real-world test and validation for ADAS and autonomous vehicles: AI for efficient and quality test and validation. *Intelligent Systems Conference (IntelliSys)*, s. 714-721. <https://doi.org/10.1109/IntelliSys.2017.8324372>
- Waghe, R., & Gajjal, S. (2014). Study of Active and Passive Safety Systems and Rearview Mirror Impact Test. *SSRG International Journal of Mechanical Engineering (SSRG-IJME)*, 1(3). <https://doi.org/10.14445/23488360/IJME-V1I3P103>
- Wolf, M., Weimerskirch, A. & Wollinger, T. (2007). State of the Art: Embedding Security in Vehicles. *EURASIP Journal on Embedded Systems*. <https://doi.org/10.1155/2007/74706>