

Perttu Huntus

**TEKOÄLYN HYÖDYNTÄMINEN LIIKENTEEN HAL-
LINNASSA JA ENNAKOINNISSA**



JYVÄSKYLÄN YLIOPISTO
INFORMAATIOTEKNOLOGIAN TIEDEKUNTA
2020

TIIVISTELMÄ

Huntus Perttu

Tekoälyn hyödyntäminen liikenteen hallinnassa ja ennakoinnissa

Jyväskylä: Jyväskylän yliopisto, 2020, 30 s.

Tietojärjestelmätiede, kandidaatin tutkielma

Ohjaaja(t): Clements Kati

Tässä tutkimuksessa tutkitaan tekoälyn hyödyntämistä liikenteen hallinnassa ja ennakoinnissa. Tekoäly on käsitteenä vanha, mutta sen tekniikat ovat kehittyneet valtavasti viime vuosina ja sitä käytetään yhä useammilla aloilla, kuten liikenteen hallinnassa. Liikennettä hallitaan liikenteenhallintajärjestelmillä. Liikenteen kasvava ongelma, varsinkin suurkaupungeissa, on ruuhkautuminen, joka aiheuttaa matkanopeuksien hidastumista, matka-aikojen kasvamista, suurempaa polttoaineen kulutusta, hallinnollisia kuluja sekä ilmastopäästöjä verrattuna ruuhkattomaan liikenteeseen. Tutkimuksessa on tarkoitus löytää keinoja, joilla tekoälyn eri sovelluksia voidaan hyödyntää liikenteen hallinnassa, ennakoinnissa ja sen sujuvoittamisessa liikenteenhallintajärjestelmien tukena. Pääasialliseen tarkasteluun rajataan koneoppiminen sekä neuroverkot. Tutkimukselle on tarvetta, koska tekoäly on ottanut viime vuosina suuria harppauksia ja sillä olisi potentiaalia ratkaista myös liikenteessä ilmeneviä ongelmia. Liikenteen uudistaminen on kallista, joten hyvälle ennakoinnille on tarvetta uusia investointeja tehdessä. Tutkimuksen tuloksina havaittiin, että tekoälyn eri sovelluksilla on mahdollisuus parantaa liikenteen ennakoinnin tarkkuutta ja eri sovelluksilla on erilaisia vahvuuksia ja heikkouksia eri tilanteissa. Lisäksi todettiin, että älykäs liikenteenhallintajärjestelmä vähentää ruuhkautumista tehokkaasti ja tekee järjestelmästä proaktiivisen reaktiivisen sijaan. Tutkimus toteutettiin tieteellisenä kirjallisuuskatsauksena.

Asiasanat: tekoäly, liikenne, liikenteenhallintajärjestelmä, koneoppiminen, neuroverkot

ABSTRACT

Huntus, Perttu

Artificial Intelligence In Traffic Management And Forecasting

Jyväskylä: University of Jyväskylä, 2020, 30 pp.

Information Systems, Bachelors Thesis

Supervisor(s): Clements, Kati

This study investigates the use of artificial intelligence in traffic management and forecasting. Artificial intelligence is an old concept, but its technologies have developed tremendously in recent years and are being used in different fields, such as traffic management. Traffic is managed by traffic management systems. A growing problem in traffic, especially in big cities, is congestion, which causes slower speeds, longer travel times, higher fuel consumption, administrative costs and climate emissions compared to non-congested traffic. The aim of the study is to find ways to utilize different applications of artificial intelligence in traffic management, forecasting and streamlining in support of traffic management systems. The main focus is on machine learning and neural networks. Research is needed because artificial intelligence has made great strides in recent years and has the potential to solve traffic problems as well. Modernizing transport is expensive, so good anticipation is needed when making new investments. As a result of the study, it was found that different applications of artificial intelligence have the potential to improve the accuracy of traffic prediction and different applications have different strengths and weaknesses in different situations. In addition, it was found that the intelligent traffic management system effectively reduces congestion and makes the system proactive rather than reactive. Research was carried out as a scientific literature review.

Keywords: Artificial intelligence, traffic, traffic management system, machine learning, neural networks

KUVIOT

Kuvio 1 Tekoälyn, koneoppimisen ja neuroverkkojen suhde toisiinsa (Kotsiantis, Zaha-rakis, Pintelas, 2007)	9
Kuvio 2 Koneoppimisen perusprosessi (mukaelma Ertel (2017) kuviosta)	10
Kuvio 3 Neuroverkko (mukaelma Sze ym., (2017) kuviosta)	12
Kuvio 4 Ruuhkautumisen syyt (mukaelma Papageorgiou, ym., (2003) kuviosta).	14
Kuvio 5 Ohjauspiiri (mukaelma Papageorgiou, ym., (2003) kuviosta)	15

TAULUKOT

TAULUKKO 1 Neuroverkkojen ja koneoppimisen edellytykset liikenteenvirtojen ennakoinnissa	19
TAULUKKO 2 Neuroverkkojen ja koneoppimisen edellytykset liikenneonnettomuuksien ennakoinnissa	22
TAULUKKO 3 Tekoälyn tuomat hyödyt liikenteenhallintajärjestelmiin.....	24

SISÄLLYS

TIIVISTELMÄ	2
ABSTRACT	3
KUVIOT	4
TAULUKOT	4
SISÄLLYS.....	5
1 JOHDANTO.....	6
2 TEKOÄLY.....	8
2.1 Mitä on tekoäly?.....	8
2.2 Koneoppiminen.....	9
2.3 Neuroverkot ja syväoppiminen.....	11
3 LIIKENNE JA LIIKENTEEN HALLINTAJÄRJESTELMÄ	14
3.1 Liikenne.....	14
3.2 Liikenteenhallintajärjestelmä	15
4 TEKOÄLY LIIKENTEEN ENNAKOINNISSA JA HALLINNASSA	17
4.1 Liikennevirtojen ennakoinnissa	17
4.2 Liikenneonnettomuuksien ennakoinnissa	20
4.3 Tekoälyn hyödyt liikenteenhallintajärjestelmissä.....	22
5 YHTEENVETO	25
LÄHTEET	27

1 JOHDANTO

Tekoäly (eng. Artificial Intelligence) on koneellista oppimista, jolla pyritään jäljittelemään ihmiselle ominaista kykyä oppia ja käyttäytyä (Kaplan 2016). Tekoäly on tällä hetkellä yksi polttavimmista aiheista teknologiabisneksessä ja sitä hyödynnetään yhä useammilla eri aloilla. Tractican raportin mukaan tekoälyllä oli vuonna 2018 9,51 miljardin dollarin markkinat ja vuonna 2025 markkinat voisivat olla jopa yli 120 miljardia dollaria. (Kirkpatrick, Kaul, 2019). Raportti antaa hyvän käsityksen tekoälymarkkinoiden kehityksestä ja siitä, että aihe on tällä hetkellä erityisen ajankohtainen ja kiinnostava.

Tekoäly luo mahdollisuuksia myös liikenteen saralla. Sen avulla liikenteestä voitaisiin saada sujuvampaa ja tehokkaampaa. Tekoälyn avulla pystytään luomaan tarkempia ennusteita liikennevirroista kuin perinteisillä menetelmillä. (Karlaftis, Vlahogianni, 2011.) Näitä ennusteita pystytään käyttämään liikenteenhallintajärjestelmien tukena. Liikenteenhallintajärjestelmällä pystytään hallitsemaan esimerkiksi liikenteen nopeuksia ja kuljettajille tarjottavaa informaatiota. (Papageorgiou, Diakaki, Dinopoulou, Kotsialos, Wang, 2003.) Tässä tutkimuksessa tutkitaan, miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin ja toimivatko tekoälyllä toimivat liikenteenhallintajärjestelmät paremmin kuin perinteiset. Tutkimukseen rajataan tekoälystä koneoppiminen, josta käsitellään vielä tarkemmin neuroverkot.

Tälle tutkimukselle on tarvetta, sillä tekoäly on ottanut suuria harppauksia viime vuosina ja sitä käsitellään yhä enemmän tieteellisessä kirjallisuudessa. Tekoälyn hyödyntämistä liikenteen suunnittelussa, hallinnassa ja ennakoinnissa on tutkittu jo 1990-luvulta ja tässä tutkimuksessa on tarkoituksena selvittää, miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin ja hallintaan liikenteenhallintajärjestelmien avulla. Huonosti hallittu ja ruuhkautuva liikenne aiheuttaa jatkuvasti ylimääräisiä kustannuksia yksilöille, yrityksille ja yhteiskunnalle ja päästöjä luonnolle, joten senkin puolesta tutkimukselle on tarvetta. Tekoälyn jatkuvan kehittymisen ja toimivan liikenteen tarpeen vuoksi tutkimus on myös ajankohtainen. Tutkimus on suunnattu tahoille, jotka vastaavat liikenteestä

sekä yrityksille, jotka näkevät liikenteen ja tekoälyn yhdistämisessä liiketoimintamahdollisuuksia.

Tutkimuksen tavoitteena onkin vastata seuraaviin kysymyksiin:

- Miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin?
- Mitä hyötyä tekoäly tuo liikenteenhallintajärjestelmiin?

Näihin kysymyksiin pyritään vastamaan suorittamalla tieteellinen kirjallisuuskatsaus. Tavoitteena oli löytää useita eri lähteitä, jotta niitä pystytään vertaamaan kriittisesti. Tutkielmaan kerätyt lähteet on kerätty pääasiassa seuraavista tietokannoista: Google Scholar, JYKDOK ja ScienceDirect. Toisen luvun pääasiallisina hakutermeinä käytettiin "artificial intelligence", "machine learning", "support vector machine" ja "artificial neural network". Kolmannessa luvussa hakusanoina käytettiin "road traffic management system", "congestion" ja "active traffic management". Neljännessä kappaleessa käytettiin hakusanoina "artificial intelligence in traffic management", "neural networks in traffic control" ja "artificial intelligence in traffic forecast". Tuloksista on valittu lähteitä julkaisuvuoden, viittausten määrän tai lähteen ja julkaisun laadun mukaan.

Luvut tässä tutkielmassa rakentuvat niin, että toisessa luvussa käsitellään tekoälyä, sen historiaa ja yleisimpiä sovelluksia. Tarkemmin käsitellään neuroverkot ja syväoppiminen, sillä ne ovat tutkimuksen kannalta mielenkiintoisia termejä. Seuraavassa luvussa käsitellään liikennettä ja liikenteenhallintajärjestelmää. Neljännessä luvussa käydään läpi, miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin ja mitä tekoäly tuo liikenteenhallintajärjestelmiin. Neljännessä luvusta löytyvät vastaukset tutkimuskysymyksiin "Miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin?" ja "Toimivatko tekoälyllä toimivat liikenteenhallintajärjestelmät paremmin kuin perinteiset hallintajärjestelmät?". Viimeisessä kappaleessa on yhteenveto, jossa esitetään myös jatkotutkimuskysymykset.

2 TEKOÄLY

Tässä luvussa käydään läpi tekoälyn termistöä ja sen muotoja, keskittyen koneoppimiseen, josta tarkemmin neuroverkkoihin. Luku alkaa tekoälyn yleisestä määrittelystä ja etenee sen jälkeen tarkemmin koneoppimisen kautta neuroverkkoihin.

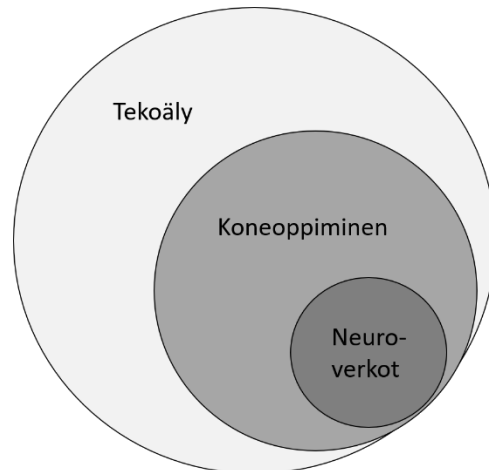
2.1 Mitä on tekoäly?

Tekoäly juontaa juurensa pitkälle historiaan, sillä jo useat filosofit ovat pohtineet älykkäiden koneiden mahdollisuutta pitkin historiaa, lähinnä kuitenkin apuna meidän oman ihmisyytemme määrittelyyn. Tästä ajatukset ovat kuitenkin koko ajan kehittyneet kohti sitä, että oikeasti voitaisiin luoda älykkäitä koneita. Vasta kuitenkin 1950-luvun aikana ja sen jälkeen laskennallinen teho ja ohjelmointikielet ovat olleet sillä tasolla, että on ollut mahdollista tehdä kokeellisia testejä älykkyydestä. Termi tekoäly (Artificial Intelligence, AI), sai nimensä vuonna 1956 Dartmouthin konferenssissa. (Buchanan, 2005.) Tämän jälkeen tekoäly on ottanut suuria askelia eteenpäin. Tekoäly (IBM:n Deep Blue) esimerkiksi voitti shakin maailmanmestarin vuonna 1997 shakkiottelussa ja vuonna 2014 ensimmäinen tekoälysovellus läpäisi Turingin testin. (BBC, 2014.) Mutta mitä tekoäly oikeasti on?

Tekoälyä määritellään useilla eri tavoilla. Suurin osa määritelmistä kuitenkin pyörii karkeasti saman aiheen ympärillä, eli tietokoneiden tai koneiden luomista, joiden käyttäytyminen on sellaista, että sitä voidaan luulla ihmiseksi. (Kaplan, 2016). Vuonna 1955 John McCarthy totesi, että tekoälyn tavoite on luoda koneita, jotka käyttäytyvät niin kuin ne olisivat älykkäitä. Tässä määritelmässä on kuitenkin omat haasteensa, sillä ”älykkyyttä” on hankala määritellä universaalisti. Elaine Richin määritelmän mukaan tekoälyä tutkimalla tutkitaan sitä, miten tietokoneet saadaan tekemään asioita, joissa ihmiset ovat vielä parempia, kuten esimerkiksi kuvantunnistuksessa. Tätä määritelmää voidaan pitää parempana ja sen uskotaan olevan voimassa vielä vuonna 2050. (Ertel, 2017.)

Tekoälyä voidaan määritellä myös sen tietoisuuden tasojen mukaan ja se voidaan jakaa tietoisuuden mukaan heikkoon ja vahvaan tekoälyyn (Coppin, 2004). Suurin osa tämänhetkisistä tekoälysovelluksista on heikkoa tekoälyä. Heikko tekoäly (tai kapea tekoäly) pystyy suorittamaan yksittäisiä ja hyvin määriteltäviä tehtäviä, kuten esimerkiksi ajamaan itseohjautuvaa autoa. Vahva tekoäly taas omaa tietoisuuden ja mielen ja pystyy olemaan älykäs useammassa kuin yhdessä spesifissä asiassa. (Siau & Yang, 2017.) Monet tutkijat ja filosofit pitävät vahvaa tekoälyä mahdottomana. Älyllisen ja tunteita omaavien robottien mahdollisuutta tutkitaan usein science fictionissa, mutta sitä harvemmin pidetään

tekoölyn todellisena maalina. (Coppin, 2004.) Heikko tekoäly on tämän tutkimuksen kannalta relevantimpi, sillä seuraavaksi käsiteltävät termit, koneoppiminen sekä neuroverkot, jotka ovat yksi koneoppimisen osa-alue, ovat heikkoa tekoälyä. Termien suhdetta toisiinsa kuvataan tarkemmin kuviossa 1.



Kuvio 1 Tekoölyn, koneoppimisen ja neuroverkkojen suhde toisiinsa (Kotsiantis, Zaha-rakis, Pintelas, 2007)

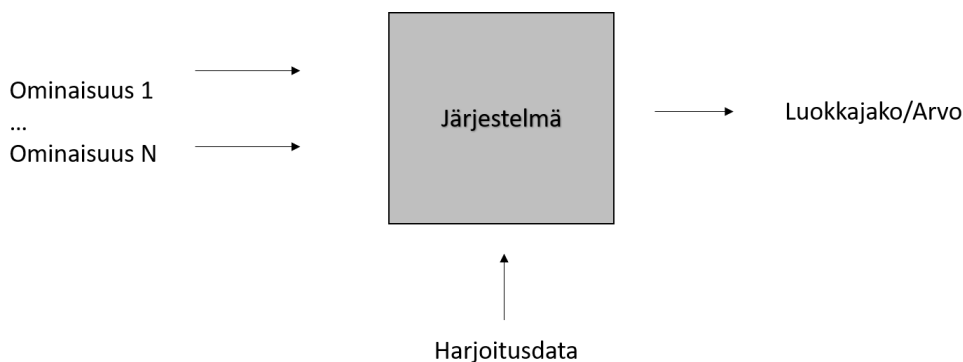
2.2 Koneoppiminen

Oppiminen on monivaiheinen ilmiö. Oppiminen sisältää uuden tiedon, kognitiivisten ja motoristen taitojen oppimista ohjeistuksen ja yrittämisen kautta, sekä uuden tiedon ja teorioiden luomista havaintojen ja kokeilemisen kautta. (Michalski, Carbonell & Mitchell, 2013.) Ihmisten oppiminen on kuitenkin todella hidasta. Meiltä kestää noin kuusi vuotta siihen, että pystymme aloittamaan koulunkäynnin ja yli 20 vuotta siihen, että voimme olla akateemisesti koulutettuja. (Simon, 1983.) Tästä syystä koko tietokoneiden aikakauden tämän edellä mainitun ongelman ratkaisu on ollut yksi mielenkiintoisimmista pitkän ajan tärkeistä tekoölyn saralla (Michalski, ym., 2013).

Yksi tekoölyn osa-alueista on koneoppiminen. Koneoppimisen tarkoitus on siis mallintaa ihmiselle ominaista oppimista, eli tiedon hankintaa ja taidon jalostusta. Tiedon hankinnalla tarkoitetaan sitä, että mitä enemmän henkilöllä on tietoa aiheesta ja mitä laajemmalla näkyvyysalueella (scope) hän tietoaan tarkastelee, sitä tarkemmin ja perustellummin hän pystyy osoittamaan tietoutta aiheesta ja huomaamaan korrelaatioita eri asioiden välillä. Taidon jalostus taas on olemassa olevan taidon hiomista ja parantamista. (Michalski, ym., 2013.)

Saatavilla olevan datan määrä on viime vuosikymmenen aikana kasvanut valtavasti ja koneoppimista on otettu käyttöön useilla eri aloilla, kuten esimerkiksi lääketieteessä, astronomiassa ja biologiassa (Qiu, Wu, Ding, Xu, Feng, 2016). Koneoppimisessa on tarkoitus opettaa järjestelmä luokittelemaan syötearvoja eri

luokittelujoukkoihin. Yleensä järjestelmä on varustettu harjoitusdatalla, jonka perusteella järjestelmä pyrkii oppimaan ja luokittelemaan uutta tietoa, jota se ei ole ennen tavannut. (Coppin, 2004.) Ertel (2017) määrittelee koneoppimisen seuraavasti: järjestelmä on oppiva järjestelmä, jos se parantaa suorituskykyään (mitattuna sopivilla kriteereillä) uuden, tuntemattoman datan kanssa (kun se on nähnyt tarpeeksi harjoitusesimerkkejä) (Ertel, 2017). Koneoppimisen perusprosessi kuvataan kuviossa 2.



Kuvio 2 Koneoppimisen perusprosessi (mukaelma Ertel (2017) kuvioista).

Tällaista valmiiksi luokitellun harjoitusdatan avulla tapahtuvaa oppimista kutsutaan ohjatuksi oppimiseksi. Suurin osa koneoppimisen sovelluksista on ohjattua oppimista, mutta on olemassa myös ohjaamatonta oppimista. Ohjaamattomassa oppimisessä järjestelmälle ei kerrota ollenkaan valmiita vastauksia, vaan sen pitää yrittää löytää datasta vastauksia täysin itsenäisesti. (Sebag, 2014.) Koska suurin osa koneoppimisesta on ohjattua, keskitytään tässä tutkielmassa siihen. Ohjatusta oppimisesta voidaan erottaa kolme keskeisintä sovellusta, jotka ovat päätospuuoppiminen (decision trees), tukivektorikone sekä keinotekoiset neuroverkot (Kotsiantis, Zaharakis, Pintelas, 2007).

Päätospuut mainittiin alan kirjallisuudessa ensimmäisen kerran jo 1970-luvulla (Sebag, 2014). Päätospuuoppimisessa on tarkoitus luoda malli ja ennustaa kohteen arvo järjestelmälle useista syötteistä. Tästä syntyy puumainen malli, jossa näkyy tehdyt päätökset ja mahdolliset tulokset. Visuaalisuus onkin yksi tämän mallin isoista eduista. Päätospuuoppimista käytetäänkin paljon datan louhinnassa (eng. data mining), koska se pystyy luokittelemaan hyvin suuria määriä dataa. Päätospuuoppiminen voidaan jakaa kahteen luokkaan: luokittelupuihin ja regressiopuihin. Luokittelupuissa tulokset kuuluvat selkeästi johonkin luokkaan, esimerkiksi pankista saatava laina voidaan luokitella joko turvallisesti tai riskiksi. Regressiopuissa taas tulokseksi voidaan saada oikea luku, esimerkiksi populaation kasvuennuste. Päätospuu voi sisältää myös molemmat edellä mainitut, jolloin puhutaan niin sanotusta CART-oppimisestä (Classification and Regression Trees). (Gupta, Rawat, Jain, Arora, Dhama, 2017). Päätospuihin liittyy myös Random Forest-algoritmi. Random Forest-algoritmissa kasvatetaan useita

sattumalla valittuja päätöspuita yhdeksi ”metsäksi”, joiden tuloksista saadaan paljon tarkempi lopputulos. (Breiman, 2001.)

Tukivektorikone (eng. Support Vector Machine) on tilastollinen koneoppimisen menetelmä. Tukivektorikoneen tarkoitus on luoda kahden näytejoukon väliin sellainen taso, että sen kanssa yhdensuuntaisten marginaalitasojen välimatka on mahdollisimman suuri. Tarkoitus on, että yksikään näyte ei saa jäädä näiden marginaalitasojen väliin ja harjoittamisen jälkeen tukivektorikone pystyy luokittelemaan datan luokkiin. Tukivektorikone soveltuu hyvin tilanteisiin, joissa harjoitusdataa on saatavilla vähän varsinaiseen analysoitavaan dataan verrattuna. Myös tukivektorikone pystyy luokittelu- ja regressioanalyysiin. (Kotsiantis, Zaharakis, Pintelas, 2007.)

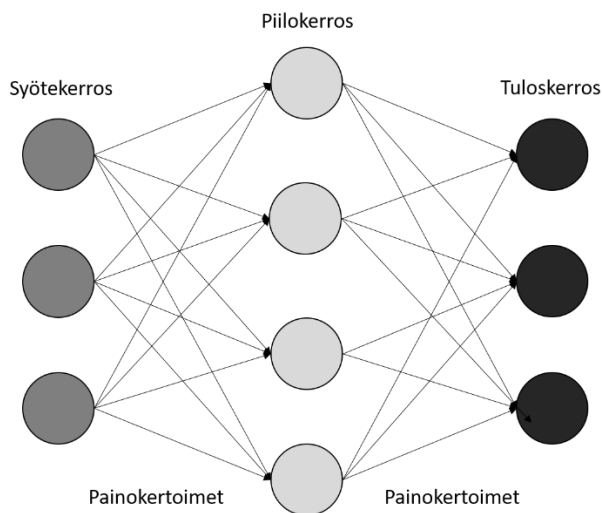
Keinotekoiset neuroverkot ovat tämän tutkimuksen kannalta erityisen kiinnostavia, koska niitä käytetään paljon liikenteen ennakkoinnissa, analysoinnissa ja hallinnassa. Tämän takia niitä käsitellään tarkemmin kappaleessa 2.3.

Koneoppimisella on myös heikkouksia. Yksi heikkous on oppimisessa käytetyn datan laatu. Oikean maailman data on yleensä epätäydellistä, meluista ja epäjohdonmukaista. Tällöin etsittävät asiat saattavat hukkuu datan sekaan. Tällöin data tarvitsee huomattavaa esikäsitelyä. (Zhang, Zhang, Yang, 2003.) On myös mahdollista käsitellä kaikki käytettävissä oleva data, mutta silloin voi lähinnä toivoa löytävänsä relevanttia tietoa datan seasta. Myös oikean sovelluksen valitseminen tietyn ongelman ratkaisuun on haaste. Huonosti valittu sovellus ei anna luotettavia ennusteita. (Kotsiantis, Zaharakis, Pintelas, 2007.)

2.3 Neuroverkot ja syväoppiminen

Keinotekoiset neuroverkot (Artificial Neural Networks), joita kutsutaan myös vain neuroverkoiksi, ovat yksi koneoppimisen muoto. Neuroverkko koostuu toisiinsa kytketyistä keinotekoisista neuroneista. Neuroverkot ovat olleet viime vuosikymmeninä paljon tutkittu aihe, koska ne mahdollistavat monimutkaisten ongelmien ratkaisun. Neuroverkkoihin liittyy myös termi syväoppiminen. Syväoppimisella tarkoitetaan neuroverkkoja, joissa on useita eri kerroksia. Syväoppimisen tarkoituksena on löytää piilossa olevia yleistyksiä suurista määristä dataa. Se hyödyntää hermoverkkojen tapaa oppia. (Li, Jiang, Yang, & Wu, 2018.) Neuroverkkoja on kehitelty ensimmäisen kerran 1960-luvulla, mutta syväoppivia neuroverkkoja alettiin tutkia kunnolla vasta 1980-luvun ja 1990-luvun vaihteessa. Kuitenkin vasta tällä vuosituhanella syväoppivat neuroverkot ovat alkaneet ohittaa tehokkuudessa perinteisiä koneoppimisen metodeja. (Schmidhuber, 2015.) Syväoppivat neuroverkot ovat saavuttaneet paljon esimerkiksi lääketieteessä ja syöpäsolujen tunnistamisessa (Esteva ym., 2017), monimutkaisten pelien pelaamisessa (Silver ym., 2016) sekä myös liikennevirtojen ennakkoinnissa (Xiaolei ym., 2017).

Syväoppiminen on siis parhaimmillaan, kun yritetään löytää sääntöjä ja piilotettuja yhteyksiä suuresta määrästä dataa. Syväoppivat neuroverkot pystyvät oppimaan myös sille entuudestaan tuntemattomasta datasta ja tuntemattomassa ympäristössä. Tämä on isoin ero aiempiin sovelluksiin, jotka tarvitsivat asiantuntijoiden käsin tekemiä valmiita harjoitusmalleja tietyn ongelman ratkaisemiseen. Kuviossa 3 kuvataan syväoppivien neuroverkkojen perusrakennetta. Syväoppivat neuroverkot koostuvat syötekerroksesta (input layer), piilokerroksista (hidden layers) ja tuloskerroksesta (output layers). Piilokerroksia voi olla syötteiden ja tulosten välissä useita, syväoppivissa neuroverkoissa yleensä viidestä jopa tuhanteen. Kaikki kerrokset koostuvat solmuista, joiden kautta tieto kulkee syötekerroksesta, johon data syötetään, piilokerrosten kautta kohti tuloskerrosta, joka esittää käyttäjälle tulokset, jotka neuroverkko saa aikaan. Kerroksien välillä kulkee synapseja, joita kutsutaan usein painotuksiksi. Painotuksia muuttamalla saadaan aikaan haluttuja tuloksia. Oppiminen toteutetaan yleensä niin sanotulla evoluutiolla (backpropagation). Siinä tuloskerroksen tuloksia verrataan haluttuihin tuloksiin, jonka jälkeen niitä palautetaan neuroverkossa taaksepäin ja muokataan painotuksia, jotta saadaan tulokset vastaamaan haluttuja tuloksia. (Sze, Chen, Yang, Emer, 2017.)



Kuvio 3 Neuroverkko (mukaelma Sze ym., (2017) kuvioista)

Edellä mainittu on ohjattua oppimista, ja se onkin yleisin tapa harjoittaa neuroverkkoja. Ohjatussa oppimisessa järjestelmälle annetaan syötteitä, jotka on valmiiksi luokiteltu, esimerkiksi kuvia taloista, autoista ja ihmisistä. Tämän jälkeen järjestelmä itse muuttaa omia sisäisiä painotuksiaan saadakseen halutun lopputuloksen. Näin järjestelmän algoritmeja ei tarvitse itse manuaalisesti käsitellä, vaan se itse pystyy niitä muuttamaan ja täten oppimaan. Heikkoutena tässä kuitenkin on se, että järjestelmä vaatii usein suuren määrän ihmisen lajittelemaa pohjadataa toimiakseen oikein. Jos verrataan ihmiseen, niin ihminen pystyy tekemään päätöksiä huomattavasti vähemmällä määrällä taustatietoa aiheesta. (LeCun, Bengio & Hinton, 2015.) Oppimista voidaan toteuttaa myös

ohjaamattomasti, jossa järjestelmälle ei anneta valmiiksi luokiteltua dataa. Tällöin tarkoituksena on löytää rakenteita tai ryhmiä datasta, joita ei perinteisillä menetelmillä onnistuta löytämään. On olemassa myös hybridioppimista, jossa vain pieni osa datasta on valmiiksi luokiteltua. Tällöin luokittelemattomasta datasta voidaan etsiä rakenteita ja luokiteltua dataa käyttää luokkien nimeämiseen. (Sze ym., 2017.)

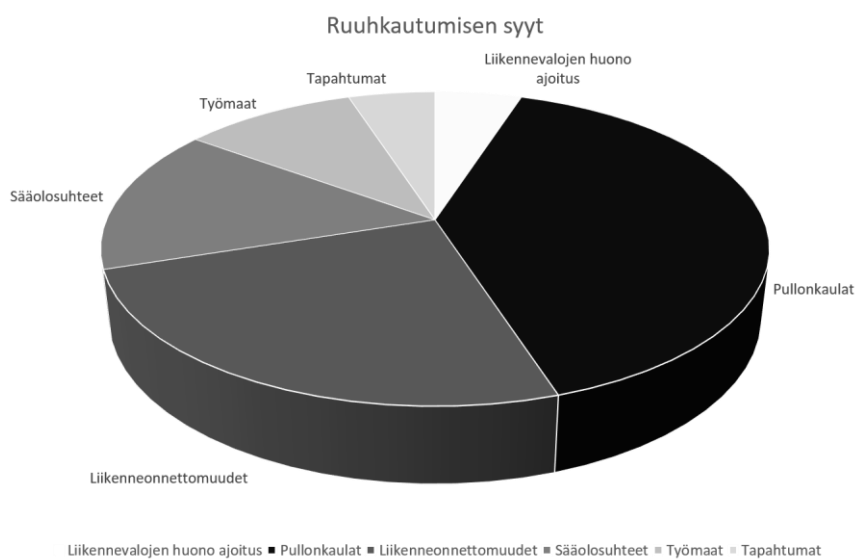
Neuroverkkojen heikkoutena voidaan pitää sitä, että ne toimivat niin sanottu mustan laatikon periaatteella. Sillä tarkoitetaan sitä, että emme voi tietää algoritmia, jolla neuroverkko lopputuloksensa saa. Tutkimuksissa yleensä siis painotetaan pelkästään ennustetarkkuutta, eikä niinkään neuroverkon sisäisen mekanismin toimintaa. Myös datan laatu on tärkeässä roolissa neuroverkkojen kanssa. (Wu, Tan, Qin, Ran, Jiang, 2018.)

3 LIIKENNE JA LIIKENTEEN HALLINTAJÄRJESTELMÄ

Tässä luvussa määritellään liikenne, käsitellään ruuhkautumista, miksi ruuhkia syntyy sekä määritellään liikenteenhallintajärjestelmä, sekä miten se toimii.

3.1 Liikenne

Liikenne on aina ollut tärkeä osa sivilisaatiota. Liikenne voidaan määritellä ajoneuvoiksi, jalankulkijoiksi, laivoiksi ja lentokoneiksi, jotka liikkuvat erilaisia reittejä pitkin (Merriam-Webster, 2019). Tässä tutkimuksessa keskitytään maalla liikkuviin ajoneuvoihin, eli käytännössä autoliikenteeseen. Liikennettä hallitaan ja ennakoitaan, koska viime vuosisadan puolivälistä alkanut yksityisautoilun ja ylipäätään matkustamisen tarpeen lisääntyminen on aiheuttanut ruuhkautumista, joka aiheuttaa käytössä olevan infrastruktuurin alisuoriutumista tehtävästään. Ruuhkautuminen aiheuttaa viivästyksiä matka-ajoissa, turvallisuusriskejä ja ylimääräistä kuormitusta luonnolle. Tärkeimmät syyt liikenteen ruuhkautumiselle nähdään kuviossa 4. Liikenteen ennakkoinnin ja hallinnan kehittäminen on itsessään myös tärkeää, koska ns. "brute force"-lähestyminen asiaan, eli jatkuva liikenneinfrastruktuurin kehittäminen, ei ole ratkaisu, koska teiden rakentaminen on hidasta ja kallista. (Papageorgiou, Diakaki, Dinopoulou, Kotsialos, Wang, 2003.)

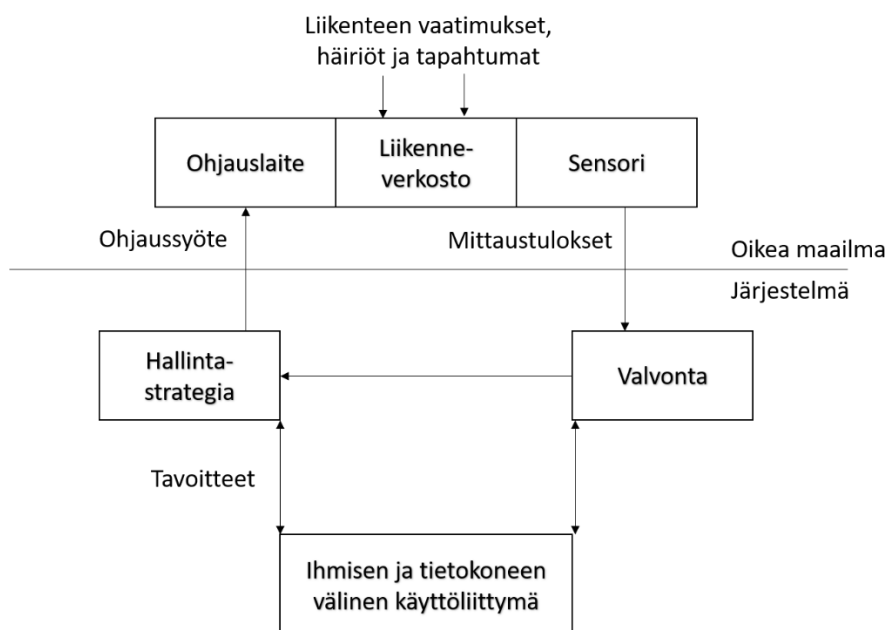


Kuvio 4 Ruuhkautumisen syyt (mukaelma Papageorgiou, ym., (2003) kuviosta).

Suurimpaan osaan kuviossa 4 nähdyistä ongelmista voidaan vaikuttaa liikenteenhallinnalla ja ennakoinnilla. Teknologian avulla liikenteen ennakoinnissa on mahdollista ottaa huomioon esimerkiksi muuttuvat sääolosuhteet ja erilaisia yleisötapahtumia, joissa käy paljon ihmisiä (Polson, Sokolov, 2017), kuin myös tiedottaa ihmisiä liikenteessä, jolloin he voivat tehdä reittivalintoja tiedon perusteella (Papageorgiou, ym., 2003). Myös liikenneonnettomuuksia voidaan vähentää aktiivisella liikenteen hallinnalla (Huang, Wang, Sharma, 2020).

3.2 Liikenteenhallintajärjestelmä

Aktiivisella liikenteen hallinnalla tarkoitetaan tapahtuvan ja tulevan ruuhkautumisen hallintaa. Liikenteen hallinnalla pystytään varmistamaan tieverkoston maksimaalinen suorituskyky. Lisäksi sillä pystytään vähentämään liikenteessä tapahtuvia onnettomuuksia. Nykyinen teknologia mahdollistaa nopeamman reagoinnin liikenteen tapahtumiin, kuin mitä manuaalisesti hallitsemalla. (Mirshahi, ym., 2007.) Liikennettä pystytään nykyään hallitsemaan tietojärjestelmien avulla. Näiden järjestelmien avulla voidaan hallita nopeusrajoituksia, liikennevaloja ja informaatiota, jota liikenteen käyttäjille tarjotaan, jolloin liikenteen käyttäjä voi tehdä esimerkiksi reittivalintoja tietoon perustuen. Ohjauspiiri (eng. control loop), joka kuvataan kuviossa 5, kuvaa tietojärjestelmää, jolla liikennettä hallitaan. Liikenteestä kerätään dataa erilaisilla sensoreilla ohjauspiiriin kuuluvalle käyttäjälle, joka pystyy



Kuvio 5 Ohjauspiiri (mukaelma Papageorgiou, ym., (2003) kuvioista)

reagoimaan liikenteessä tapahtuviin muutoksiin esimerkiksi laskemalla moottoriteillä korkeimman sallitun nopeuden rajaa. Liikenteessä on jatkuvasti erilaista kysyntää ja tapahtumia (kuten onnettomuuksia), joiden perusteella on tehtävä ratkaisuja liikenteen hallintaan liittyen. Ohjauspiirin käyttäjä voi olla ihminen, jolloin puhutaan manuaalisesta ohjausjärjestelmästä, mutta ohjauspiiriä voi käyttää myös algoritmi, jolloin puhutaan automaattisesta ohjausjärjestelmästä. (Papageorgiou, Diakaki, Dinopoulou, Kotsialos, Wang, 2003.) Liikenteestä kerätään erilaisten sensorien avulla valtavia määriä dataa, kuten esimerkiksi liikenteen volyymin (ajoneuvoa/tunnissa) ja keskimääräistä liikenteen nopeutta (Huang, Wang, Sharma, 2020).

Kaikki valinnat, joita käyttäjä tekee, perustuvat hallintastrategiaan. Hallintastrategian tarkoituksena on varmistaa paras mahdollinen lopputulos, riippumatta eri liikenteen häiriötekijöistä. Tavoitteena voi olla esimerkiksi, että jokainen liikenteen käyttäjä tarvitsee käyttää liikenteessä mahdollisimman vähän aikaa. Ohjausjärjestelmän tehokkuus perustuu hyvin pitkälle ohjausstrategian tarkoituksenmukaisuuteen, jonka takia ohjausstrategiat pitäisi aina suunnitella huolellisesti tehokkaita ja systemaattisia optimointimenetelmiä käyttäen, tietoon ja oikeaan dataan perustuen. Myös automaattisten ohjausjärjestelmien käyttäminen olisi aina suotavaa niiden nopean laskentatehon vuoksi. (Toint, Labbe, Tanczos, Laporte, 1998.) Edelleen kuitenkin monet maat ja kaupungit käyttävät vanhanaikaisia ja huonosti optimoituja hallintastrategioita. Vaikka hallintajärjestelmä olisi itsessään moderni liikenteeseen reagoiva järjestelmä, huono hallintastrategia estää järjestelmää ulosmittaamasta parasta suorituskykyään. Tällöin yleensä kallis investointi ei tule olemaan hintansa arvoinen. Varsinkin moottoriteillä tämä on ongelma. Hyvällä hallintajärjestelmällä, hyvillä sensoreilla moottoriteiden rampeilla ja hyvällä hallintastrategialla voitaisiin vähentää jopa 50 % käytetystä ajasta liikenteessä. (Papageorgiou, ym., 2003.)

Liikennettä tehokkaasti hallitsemalla voidaan siis selkeästi vähentää matka-aikoja, mutta siinäkin on heikkoutensa. Liikenne toimii kysynnän ja tarjonnan lain mukaan. Jos tarjolla on nopeampi reitti paikasta toiseen, sen reitin kysyntä kasvaa, eli sitä myös käytetään enemmän. (Morris, 1977.) Jos siis jonkun liikenneverkoston osuuden läpikulkemiseen käytetty aika lyhenisi huomattavasti, sen kysyntä nousisi, jolloin liikenteen määrä vastaavasti nousisi. Tästä ei ole vielä tarkkaa tutkimustietoa, mutta on huomattu, että pahimmassa tapauksessa matka-ajan parannukset, jotka on saavutettu liikenteen hallinnalla, vähenevät osittain syntyvän kysynnän vuoksi. Siksi on tärkeää pystyä maksimoimaan liikenteen suorituskyky liikenneverkoston joka osassa. (Papageorgiou, ym., 2003.)

4 TEKOÄLY LIIKENTEEN ENNAKOINNISSA JA HALLINNASSA

Tässä kappaleessa käydään läpi, miten esiteltyjä tekoälyn sovelluksia on eri tutkimusten mukaan käytetty liikenteen ennakoinnissa ja hallinnassa sekä miten nämä sovellukset soveltuvat kyseiseen tehtävään.

Liikenteen ennakointi on aiheuttanut 2000-luvulla haasteita alan ammattilaisille, sillä liikenteestä on tullut monimutkaisempaa tieverkostojen ja ajoneuvojen määrien kasvaessa. Asiantuntijoiden on kuitenkin tarjottava turvallista, tehokasta ja luotettavaa liikennettä, samalla minimoiden vahingot luonnolle ja yhteisöille. Tämän vuoksi tekoälyn sovelluksia on myös tuotu liikenteen ennakointiin ja hallintaan jo jonkun aikaa. Liikenteessä on ominaisuuksia, jotka sopivat hyvin tekoälyn eri sovelluksille. Esimerkiksi liikenteessä ollaan tekemisissä usein niin monimutkaisten systeemien kanssa, että niiden mallintaminen perinteisin menetelmin on erittäin hankalaa. Tällöin empiiristen mallien rakentaminen perustuen kerättyyn dataan on usein ainut järkevä keino, ja tekoäly on ominaisuuksiensa ansiosta tähän hyvin soveltuvia. (Sadek, 2007.) Tekoälyn liittämistä liikenteen konseptiin onkin tehty jo vuosikymmeniä. 1990-luvulla on julkaistu useita artikkeleita aiheeseen liittyen. Esimerkiksi neuroverkkojen hyödyntämistä on tutkittu paljon. Jo tällöin neuroverkkojen potentiaali tunnistettiin, mutta todettiin myös, että laajoja tutkimuksia aiheesta tarvittiin lisää, esimerkiksi selvittämään neuroverkkojen evoluutioita ja vertailemaan perinteisiä tilastollisia menetelmiä ja neuroverkkoja. (Dougherty, 1995.)

Tekoälyä ja sen sovelluksia käytetään tutkimusten mukaan useisiin eri käyttötarkoituksiin. Sitä hyödynnetään esimerkiksi liikennevirtojen ennakointiin alueellisilla ja ajallisilla muuttujilla (Wu, Tan, Qin, Ran, Jiang, 2018), liikennenopeuksien ennakointiin (Ma, Dai, He, Ma, Wang, Wang, 2017) ja reaaliaikaiseen liikenneonnettomuuksien riskin arviointiin (Yu, Abdel-Aty, 2013). Kaikkea tätä analysoitua dataa voitaisiin käyttää aktiivisen liikenteenhallinnan ja -hallintajärjestelmien tukena. Seuraavaksi käsitellään tekoälyn sopivuutta tehtäviin liikennevirtojen ja liikenneonnettomuuksien ennakoinnin sekä liikenteen hallinnan parissa.

4.1 Liikennevirtojen ennakoinnissa

Liikennevirtojen ennakointia hyödynnetään aktiivisten liikenteen hallintajärjestelmien kanssa ruuhkautumisen estämisessä, esimerkiksi nopeusrajoituksia säätelemällä ja Yhdysvalloissa tietullien hinnoittelun tukena (Polson, Sokolov, 2017). Liikennevirtojen ennakointia hyödynnetään aktiivisen liikenteenhallinnan

lisäksi usein myös esimerkiksi navigointisovelluksissa, jotka arvioivat liikenteen ruuhkautumista ja tarjoavat käyttäjilleen näin informaatiota, jonka perusteella käyttäjät voivat tehdä reittivalintoja (Microsoft Research, 2016).

Liikennevirtojen ennakoinnissa käytetään paljon varsinkin neuroverkkoja. Neuroverkkojen kyky käsitellä valtavia määriä moniulotteista dataa, niiden mallintamisen joustavuus sekä niiden oppiminen ja yleisesti hyvä ennakoititarkkuus antavat niille mahdollisuuden olla toimiva työkalu myös liikenteen parissa. (Karlaftis, Vlahoghianni, 2011). Neuroverkot pystyvät hyvin ennustamaan liikennevirtoja kuvista. Liikenteestä voidaan luoda ajan ja paikan perusteella kuvaajia, joista neuroverkot voivat tehdä ennusteita. Tämän toteavat tutkimuksessaan Xiaolei ym. (2017). Heidän tutkimuksessaan neuroverkko oli parempi kuin muut koneoppimisen menetelmät, kuten esimerkiksi tukivektorikone. (Xiaolei ym., 2017). Polson ja Sokolov (2017) tutkivat tutkimuksessaan syväoppivan neuroverkon kykyä ennustaa lyhyen aikavälin liikennevirtoja. Heidän hypotesinsa mukaan syväoppiva neuroverkko voi tuottaa hyvin paikkaansa pitävän ennusteen seuraavaksi 40 minuutiksi. Se pystyy ottamaan huomioon myös erikoiset olosuhteet, kuten esimerkiksi alueella tapahtuvan suuren urheilutapahtuman tai lumimyrskyn ja käyttäen ennemmin nimenomaan mahdollisimman reaaliaikaista dataa (esimerkiksi viimeinen 40 minuuttia), kuin historiallista dataa (esimerkiksi yli 24 tuntia vanhaa dataa). Tutkimuksessa verrattiin syväoppivan neuroverkon tuloksia yksinkertaiseen neuroverkkoon, jossa oli vain yksi piilokerros sekä perinteisempään vektorimalliin. Tulokset osoittivat, että syväoppiva neuroverkko toimi yleisesti paremmin kuin yksinkertainen neuroverkko. Syväoppiva neuroverkko toimi pääasiassa myös paremmin kuin vektorimalli. Syväoppiva neuroverkko pystyi pitämään ennustetarkkuutensa myös erikoisissa olosuhteissa. Vektorimalli pystyi ennustamaan hyvällä tarkkuudella normaaleissa olosuhteissa, mutta esimerkiksi ruuhka-aikojen ennusteet eivät olleet tarkkoja, toisin kuin syväoppivalla neuroverkolla. Neuroverkkokkaan ei kuitenkaan pystynyt ennustamaan ruuhka-aikoja täydellisesti. Se pystyi ennustamaan hyvin ruuhkien alkamisajan, mutta antoi virheellisiä ennusteita ruuhkan hiipumisajankohdasta. Heikkoutena Polson ja Sokolov nostavat kuitenkin syväoppivan neuroverkon heikon kyvyn selittää tuloksiaan. (Polson, Sokolov, 2017.) Wu, Tan, Qin, Ran ja Jiang (2018) kuitenkin osoittivat omassa tutkimuksessaan, että syväoppivan neuroverkon on mahdollista tuottaa myös selitys saamilleen liikennevirtojen ennusteille niiden monimutkaisuudesta huolimatta. He haastavat ajatuksen, että neuroverkot toimivat pelkästään mustan laatikon periaatteella, sillä he analysoivat neuroverkon sisäistä mekanismia ennustetarkkuuden lisäksi. Tällainen ajattelu-tapa toisi heidän mielestään uusia tapoja ajatella liikennevirtojen ennakoitintia ja liikennevirtojen data-analyysiä. Näitä keinoja heidän mielestään täytyy kuitenkin tutkia lisää. (Wu, ym, 2018.)

Monet tutkimukset vertailevat syväoppivien neuroverkkojen suorituskykyä ja sopivuutta liikenteen ennakointiin muihin koneoppimisen sovelluksiin ja toteavat ne paremmiksi (Polson, Sokolov, 2017; Wu, ym., 2018; Xiaolei, ym., 2017). Kuitenkin myös muita metodeja on tutkittu ja todettu toimiviksi. Wang ja Shi (2013) tutkivat hybridimallisen tukivektorikoneen kykyä ennakoita lyhyen

aikavälin liikennenopeuksia. He tunnistavat tukivektorikoneen ongelman, eli datan oikeanlaisen alkukäsittelyn merkityksen ja oikean kernel-funktion valinnan, jotta tukivektorikone pystyy toimimaan täydellä potentiaalilla. He kuitenkin esittävät juuri liikenteen ennakointiin sopivia metodeja, joilla saadaan mallinnettua lyhyen aikavälin liikenteen ominaisuuksia. Nämä menetöt nostavat tutkimuksen mukaan ennustetarkkuutta huomattavasti ja auttavat tulevaisuuden tutkimuksissa. (Wang, Shi, 2013.) Myös päätöspuita on tutkittu. Päätöspuut ja CART-algoritmi saavuttivat Pitombon, de Souzan ja Lindtnerin (2017) tutkimuksessa n. 82 % ennustetarkkuuden, kun tarkoituksena oli selvittää matkustajan matkan kohde. (Pitombo, de Souza, Lindner, 2017).

Näitä eri tutkimuksia vertaamalla voidaan tehdä johtopäätöksiä siitä, miten eri tekoälyn sovellukset sopivat liikennevirtojen ennakointiin. Monet tutkimuksista nostavat syväoppivat neuroverkot parhaaksi tavaksi ennakoida liikennevirtoja. Tämä perustellaan sillä, että ne pystyvät käsittelemään paremmin dataa useista eri lähteistä, jolloin niillä on käytössään enemmän tietoa, johon perustaa ennusteensa. Ne pystyvät esimerkiksi ottamaan huomioon poikkeavat tapahtumat paremmin, kuten yllättävät sääolosuhteet. Heikkoutena syväoppivilla neuroverkoilla on kuitenkin niiden huono kyky selittää omia tuloksiaan. Myös tekoälyn muilla sovelluksilla, kuten tukivektorikoneilla, pystytään saamaan hyviä tuloksia, mutta niiden käyttö rajoittuu enemmän yhteen todella spesifiin tehtävään ja vaatii tarkkaa datan alkukäsittelyä. Seuraavassa taulukossa on tiivistetty tekoälyn sovelluksien edellytyksiä liikennevirtojen ennakoinnissa.

TAULUKKO 1 Tekoälyn sovelluksien hyödyt ja edellytykset liikenteenvirtojen ennakoinnissa

Tekoälyn sovelluksien hyödyt ja sopivuus liikennevirtojen ennakoinnissa	Lähteet
Parantavat liikennevirtojen ennustetarkkuutta	Karlaftis, Vlahoghianni, 2011; Pitombo, de Souza, Lindner, 2017; Polson, Sokolov, 2017; Xiaolei, ym, 2017; Wang, Shi, 2013
Tukivektorikoneet toimivat hyvin hyvän datan käsittelyn jälkeen	Wang, Shi, 2013
Päätöspuita voidaan käyttää tieliikenteen käyttäjän määränpään ennustamiseen	Pitombo, de Souza, Lindner, 2017
Neuroverkot pystyvät käyttämään monilähteistä dataa ja toimivat parhaiten poikkeavissa olosuhteissa	Karlaftis, Vlahoghianni, 2011; Polson, Sokolov, 2017
Neuroverkoilla on huono kyky selittää tuloksiaan, mutta aihetta lisää tutkimalla selityskykyä voitaisiin parantaa	Wu, ym, 2018

4.2 Liikenneonnettomuuksien ennakoinnissa

Aktiivinen liikenteen hallinta (Active Traffic Management) sisältää usein isossa roolissa myös reaaliaikaisia onnettomuusriskien arviointimalleja. Näitä malleja käytetään ennakoimaan kolarien riskejä, jolloin voidaan proaktiivisesti parantaa liikenteen turvallisuutta. (Yu, Abdel-Aty, 2013.) Tekoäly on ottanut jatkuvasti isompaa roolia aktiivisen liikenteen hallinnan saralla. Vaikka aihetta on tutkittu aktiivisesti, ei riskien ja onnettomuuden vakavuuden välistä suhdetta ole vielä pystytty identifioimaan. (Rezaie Moghaddam, Afandizadeh, Ziyadi, 2010.) Näiden riskien ennakoinnissa on käytetty neuroverkkoja, että koneoppimisen muita sovelluksia, pääasiassa kuitenkin tukivektorikoneita. Yu ja Abdel-Aty (2013) tutkivat omassa tutkimuksessaan tukivektorikoneen avulla tehtävää liikenneonnettomuuksien ennakointia, koska he huomasivat, että esimerkiksi neuroverkot toimivat liikaa mustan laatikon tavoin ja tätä myöten mukautuvat dataan liian hyvin, eivätkä enää anna luotettavia tuloksia. Tutkimuksessa käytettiin reaaliaikaista dataa (nopeus, käyttöaste, volyyymi) ja sitä verrattiin jo kerättyyn dataan onnettomuuksista. Tukivektorikone opetettiin etsimään yhtenäisyyksiä harjoitteludatasta, jonka jälkeen harjoitteludatasta saatuja tuloksia verrattiin tulosdataan ja tukivektorikoneen tuloksia verrattiin muilla tavoilla analysoituihin tuloksiin. Tutkimuksessa huomattiin, että tukivektorikone on parempi kuin muut tutkimuksessa käytetyt menetelmät. Huomion arvoista oli myös se, että tukivektorikoneen ennakointitarkkuus parani, mitä pienemmällä määrällä dataa se toimi. Tutkimuksen mukaan tukivektorikone toimii erittäin hyvin liikenneonnettomuuksien ennakoinnissa. (Yu, Abdel-Aty, 2013.) Saman ovat todenneet myös Li, Lord, Zhang ja Xie (2008) omassa tutkimuksessaan, jossa he vertailivat perinteistä tilastollista menetelmää ja tukivektorikoneita. He huomasivat tutkimuksessaan myös, että tukivektorikoneen harjoittaminen ja käyttäminen tuo tuloksia neuroverkkoja nopeammin. Molemmat tekevät myös huomion, että tukivektorikoneella ei ole samoja ongelmia kuin neuroverkoilla, eli tukivektorikone ei mukautu dataan liikaa. (Yu, Abdel-Aty, 2013; Li, Lord, Zhang, Xie, 2008.)

Myös neuroverkkoja ja syväoppimista on tutkittu paljon liikenneonnettomuuksien ennakointiin liittyen. Neuroverkkojen ja syväoppimisen etuna on niiden kyky käyttää monilähteistä dataa. Ne voivat ottaa huomioon isomman määrän erilaisia muuttujia. Syväoppivat neuroverkot ovatkin tuottaneet hyviä tuloksia tutkimuksissa, joissa järjestelmä saa syötteenä dataa useista eri lähteistä. (Bao, Liu, Ukkusuri, 2019.) Bao, Liu ja Ukkusuri (2019) tutkivat tutkimuksessaan, miten neuroverkkojen avulla voitaisiin ennustaa lyhyen aikavälin onnettomuusriskejä kaupunkialueella. Tutkimus toteutettiin Manhattanin alueella New Yorkissa, jossa tutkimusalue jaettiin eri kokosiin alueisiin. Tarkoituksena oli selvittää, kuinka tarkasti paikallisesti ja ajallisesti, eli spatiotemporaalisesti, neuroverkko pystyy laskemaan onnettomuusriskiä. Ajallisesti tutkittiin tunnin, päivän ja viikon jaksoja ja niiden onnettomuusriskin tarkkuutta. Tuloksia verrattiin tämän jälkeen perinteisiin ekonometrisiin menetelmiin sekä neljään yksinkertaisempaan koneoppimisen metodiin. Tutkimuksessa huomattiin, että syväoppivat

neuroverkot toimivat kokonaisuudessaan paremmin kuin edellä mainitut menetelmät. Huomattavaa oli kuitenkin, että mitä tiheämpi spatiotemporaalisuus oli (eli pieni alue ja lyhyt aikaväli), sitä huonompi ennustettavuus oli. Onnettomuudet ovat kuitenkin satunnainen tapahtuma, joten lyhyen välin ennustettavuuden lasku on ymmärrettävää, koska myös dataa on tarjolla vähemmän. (Bao, ym., 2019.) Samantyyllisiä tuloksia tutkimuksessaan saivat myös Huang, Wang ja Sharma (2020), jotka tutkivat tutkimuksessaan syväoppivien neuroverkkojen onnettomuusriskin ennustamiskykyä moottoriteillä. Hekin toteavat tutkimuksessaan, että syväoppivat neuroverkot toimivat onnettomuusriskin ennakoinnissa, mutta luotettavasti vain, jos dataa on tarjolla riittävästi ja se on hyvin luokiteltu. Tutkimuksessa nostetaan myös ilmi, että usein onnettomuuksista tarjolla oleva data on hyvin homogeenistä, mikä voi vaikuttaa ennustettavuustarkkuuteen. He myös huomasivat, että matalammat syväoppimisen mallit tuottavat parempaa suorituskykyä. (Huang, Wang, Sharma, 2020.)

Iranitalab ja Khattak (2017) vertailivat tutkimuksessaan eri koneoppimisen sovelluksia siinä, miten hyvin ne ennustavat tieliikenneonnettomuuksien vakavuutta. Tutkimuksen isoin huomio oli, että koska vakavat liikenneonnettomuudet ovat harvinaisia, niiden ennakointi on vähäisestä datan määrästä johtuen hyvin hankalaa. Niiden ennustettiin tapahtuvan harvemmin kuin todellisuudessa ja usein ne luokiteltiin vähemmän vakaviksi, kuin mitä ne todellisuudessa olivat. Tällöin myös tieliikenneonnettomuuksien kokonaiskustannukset arvioitiin todellista matalammiksi. Tutkimuksessa myös ryhmiteltiin testidataa siten, että sitä oli sekä alkuperäisessä muodossaan, että kahdessa ryhmässä, joissa data oli sisäisesti homogeenistä, mutta heterogeenistä muihin ryhmiin verrattuna. Datan ryhmittely nosti ennustetarkkuutta suurimmissa osissa tapauksia, lopuissa se kuitenkin laski sitä. (Iranitalab ja Khattak 2017.) Tutkimus osoittaa hyvin, kuinka tärkeässä roolissa data on tekoälyn avulla tehtävässä ennakoinnissa.

Mielenkiintoisen löydön tutkimuksessaan tekivät myös Zhang, He, Gao ja Ni (2018). He tutkivat sosiaalisesta mediasta saatavan datan analysointia tekoälyn sovelluksilla ja voidaanko sitä hyödyntää liikenneonnettomuuksien havaitsemisessa. Heidän tutkimuksensa osoittaa, että oikein analysoituna Twitteristä saatava data pystytään yhdistämään tapahtuviin liikenneonnettomuuksiin ja liikenteen poikkeaviin käyttäytymisiin, kuten yllättäviin ruuhkautumisiin. Tutkimus avaa uusia mahdollisuuksia liikenneonnettomuuksien havaitsemiseen ja ennakointiin. Zhang ym. kuitenkin korostavat, että tämä aihe tarvitsee paljon lisää tutkimusta, eikä sitä voida käyttää kuin korkeintaan päätöksenteon tukena, sillä sosiaalisesta mediasta saatava data voi olla epäluotettavaa ja se on muutenkin hyvin meluisaa. (Zhang, ym, 2018.)

Näitä tutkimuksia ja niiden tuloksia vertaamalla voidaan todeta, että tekoälyn eri sovelluksilla on potentiaalia toimia tehokkaasti liikenneonnettomuuksien ennakoinnissa, mutta eri muuttujista riippuen eri sovelluksilla on erilaisia vahvuuksia ja heikkouksia. Seuraavassa taulukossa on tiivistetty tekoälyn edellytyksiä ennakoida liikenneonnettomuuksia.

TAULUKKO 2 Tekoälyn hyödyt ja edellytykset liikenneonnettomuuksien ennakoinnissa

Tekoälyn sovelluksien hyödyt ja so- pivuus liikenneonnettomuuksien ennakoinnissa	Lähteet
Tekoälyn avulla pystytään ennustamaan liikenneonnettomuuksia entistä tehokkaammin ja täten ehkäisemään niitä	Bao, Liu, Ukkusuri, 2019; Huang Wang, Sharma, 2020; Li, Lord, Zhang, Xie, 2008; Yu, Abdel-Aty, 2013
Varsinkin tukivektorikoneet toimivat hyvin, koska ne toimivat luotettavasti vähällä määrällä dataa	Li, Lord, Zhang, Xie, 2008; Yu, Abdel-Aty, 2013
Tukivektorikoneet oppivat nopeammin kuin neuroverkot	Li, Lord, Zhang, Xie, 2008
Neuroverkot toimivat hyvin, jos dataa on tarjolla tarpeeksi	Bao, Liu, Ukkusuri, 2019; Huang, Wang, Sharma, 2020
Tekoäly mahdollistaa myös liikenneonnettomuuksien vakavuuden ja kustannusten ennakoinnin	Iranitalab, Khattak 2017
Onnettomuuksista kuitenkin dataa tarjolla vähän, koska ne ovat niin harvinainen tapahtuma, joten vakavuuden ennakointi ei välttämättä ole luotettavaa	Iranitalab, Khattak 2017
Tekoälyn avulla dataa voidaan myös hyödyntää uusista lähteistä, kuten sosiaalisesta mediasta	Zhang, ym, 2018

4.3 Tekoälyn hyödyt liikenteenhallintajärjestelmissä

Analysoituja liikennevirtoja voidaan hyödyntää useilla tavoilla. Tärkein, mitä liikennedatalla analysoimalla ja sitä aktiivisen liikenteen hallinnan tukena käyttämällä pystytään tekemään, on ruuhkautumisen estäminen. Ruuhkautuminen aiheuttaa matkanopeuksien madaltumista, joka taas aiheuttaa pidentyneitä matkustusaikoja, suurempaa polttoaineen kulutusta, enemmän muita hallinnollisia kuluja ja ympäristöpäästöjä verrattuna ruuhkattomaan liikenteeseen (Bull, 2003). Richard Arnottin ja Kenneth Smallin artikkelin mukaan Yhdysvalloissa metropolialueilla, joissa on yli miljoona asukasta, vuosittainen ruuhkien aiheuttama ylimääräinen ajoaika on yli kuusi miljoonaa ajotuntia, ja sen aiheuttamat kustannukset ovat useita kymmeniä miljoonia dollareita. Tämä summa ei laske vielä mukaansa ylimääräistä bensiinin tarvetta, onnettomuuksia tai ilman saasteita. (Arnott, Small, 1994.) Tekoälyn mukaan tuominen

liikenteenhallintastrategioiden suunnitteluun ja liikenteenhallintajärjestelmien päätöksentekoon kuitenkin tuo niille selkeää lisäarvoa (Hernandez, Ossowski, Garcia-Serrano, 2002). Esimerkiksi Lin, Al Hassanin, Shahidehpourin, Bahramiradin ja Khodaein (2018) tutkimuksessa todettiin, että älykäs liikenteenhallintajärjestelmä pystyi hallitsemaan liikennettä itsenäisesti ja proaktiivisesti, myös erikoisissa tilanteissa, joita on hankala ennakoita. Se pystyi vähentämään ruuhkautumista ja nopeuttamaan liikennevirtoja paremmin kuin perinteinen liikenteen hallintajärjestelmä. (Li, ym., 2018.) Myös McCluskey ja Vallati (2017) toivat tutkimuksessaan hyvin ilmi tekoälyllä toimivan liikenteenhallintajärjestelmän etuja sekä myös heikkouksia. Heidän mielestään tekoälyllä toimivan liikenteenhallintajärjestelmän isoin etu on se, että se pystyy luomaan reaaliajassa liikenteenhallintastrategiaa, joka pystyy vastaamaan alati muuttuviin olosuhteisiin. Tekoälyllä toimiva järjestelmä pystyy myös käyttämään dataa useista eri lähteistä, jolloin sillä on paljon enemmän dataa, jonka perusteella tehdä päätöksiä. Perinteisemmät järjestelmät ovat riippuvaisia pelkästään omista, teihin upotetuista sensoreistaan. Kuitenkin tutkijat nostivat esiin vielä selkeitä kehityskohteita. Näitä olivat data, oikeiden arvojen määrittäminen, tavoitteiden asettaminen ja teknologioiden yhdistäminen. Kuten aiemminkin on tullut ilmi, datan rooli tekoälyn harjoittamisessa ja tulosten saamisessa on erityisen tärkeää. Jos data on sellaista, että sen avulla ei pystytä selvittämään haluttuja asioita, antaa tekoälyllä toimiva liikenteenhallintajärjestelmä huonoja ennusteita. Datasta on myös osattava löytää merkitykselliset arvot. Tutkimuksessa huomattiin, että aluksi raja-arvoina käytettiin arvoa (ajoneuvojen lukumäärä alueella), joka ei ollut yhtä relevantti kuin myöhemmin käytetty arvo (risteysten määrä alueella). Tämä valinta toi tuloksina yltiöoptimistisia arvioita. Myös tavoitteiden asettaminen loi järjestelmälle ongelmia. Pelkästään yhdellä alueella parasta mahdollista lopputulosta ajava järjestelmä antoi huonoja alueellisia optimointeja muilla alueilla. Tulevat järjestelmät tarvitsevat tutkimuksen mukaan rikkaampia tavoitemalleja. Teknologioiden yhdistäminen tuotti tässä tutkimuksessa myös ongelmia. Uusien järjestelmien yhdistäminen vanhoihin tuotti hankaluuksia. Myös eri tiimien toimiminen eri aikaan järjestelmää kasatessa aiheutti ongelmia. Lopputuloksena tässä tutkimuksessa sen ongelmista huolimatta oli kuitenkin McCluskeyn ja Vallatin (2017) mukaan ensimmäinen onnistunut kaupungin liikenteenhallinnasta vastaava tekoälyllä toimiva liikenteenhallintajärjestelmä. (McCluskey, Vallati, 2017.) Dunkel, Fernandez, Ortiz ja Ossowski (2011) nostavat kuitenkin omassa tutkimuksessaan tekoälyllä toimivan liikenteenhallintajärjestelmän ongelmaksi sen arkkitehtuurin. Tutkimuksessa todetaan, että jotkut tekoälypohjaiset järjestelmät ei pysty tuottamaan analyysejä datasta tarpeeksi nopeasti. Vaikka ongelma voidaan kiertää ja tuottaa riittävän nopea vasteaika, se vaikeuttaa järjestelmän skaalaimista. (Dunkel, ym., 2011.)

Vieläkin liikennealalla ammattilaiset ovat jakautuneet kahtia perinteisen tilastoinnin metodien käyttäjien sekä laskennallisen älykkyyden käyttäjien kesken. Vaikka tavoitteet ovatkin samat, on tutkijoiden välinen kommunikointi ollut heikkoa. (Karlaftis, Vlahogianni, 2011.) Tämän kirjallisuuskatsauksen perusteella tekoälyllä tehdyn liikenteen analysoinnin hyödyt ja tekoälyllä toimivien

liikenteenhallintajärjestelmien edut tehostaisivat liikenteen hallintaa ja vähentäisivät liikenteen hättävähäikutuksia verrattuna perinteisempiin menetelmiin. Seuraavassa taulukossa on tiivistetty tekoälyn tuomia hyötyjä liikenteenhallintajärjestelmiin.

TAULUKKO 3 Tekoälyn tuomat hyödyt liikenteenhallintajärjestelmiin

Tekoälyn tuomat hyödyt liikenteenhallintajärjestelmiin	Lähteet
Tekoäly mahdollistaa järjestelmän proaktiivisen toiminnan	Li, ym., 2018
Älykäs liikenteenhallintajärjestelmä estää ruuhkautumista tehokkaammin	Hernandez, Ossowski, Garcia-Serrano, 2002, Li, ym., 2018, McCluskey, Vallati, 2017
Älykäs liikenteenhallintajärjestelmä pystyy toimimaan itsenäisesti	Li, ym., 2018; McCluskey, Vallati, 2017
Älykäs liikenteenhallintajärjestelmä toimii paremmin poikkeavissa olosuhteissa, kuin perinteinen järjestelmä	McCluskey, Vallati, 2017
Älykkäällä liikenteenhallintajärjestelmällä enemmän tietoa käytettävissä, mihin perustaa ratkaisut	McCluskey, Vallati, 2017

5 Yhteenveto

Tässä tieteellisessä kirjallisuuskatsauksessa tutkittiin eri tieteellisten lähteiden avulla, miten tekoälyn eri sovellukset sopivat liikenteen hallintaan ja ennakointiin, sekä voidaanko niitä hyödyntää liikenteenhallintajärjestelmissä. Kahdessa ensimmäisessä käsittelyluvussa käsiteltiin tärkeimmät termit, tekoäly, sekä liikenne ja liikenteenhallintajärjestelmä. Kolmannessa käsittelyluvussa pyrittiin siten vastaamaan seuraaviin tutkimuskysymyksiin:

- Miten tekoälyn eri sovellukset soveltuvat liikenteen ennakointiin?
- Mitä hyötyä tekoäly tuo liikenteenhallintajärjestelmiin?

Ensimmäisenä käsiteltiin tieteellisen kirjallisuuden avulla tekoälyä, sen historiaa ja eri sovelluksia. Kappale alkaa lyhyellä tekoälyn historialla, jonka jälkeen termi määriteltiin. Kirjallisuudessa tekoälylle ei löydy selkeää universaalialia määrittelyä, mutta eri lähteiden avulla se pystyttiin tähän tutkielmaan määrittelemään. Tämän jälkeen käytiin läpi tekoälyn tietoisuuden tasot, joita ovat heikko ja vahva tekoäly. Suurin osa nykyisestä tekoälystä on heikkoa tekoälyä, koska vahvaa tekoälyä ei vielä pystytä tekemään ja monen tutkijan mielestä se on jopa mahdotonta. Seuraavaksi käytiin läpi yhtä tekoälyn aluetta, koneoppimista. Koneoppiminen on tekoälyn perusta ja siksi sitä käytiin tarkasti läpi, erottaen siitä kolme tärkeintä sovellusta, jotka ovat päätöspuut, tukivektorikone ja keinotekoiset neuroverkot. Neuroverkkoja käsiteltiin vielä tarkemmin, koska ne ovat tämän tutkielman kannalta erittäin kiinnostavia, koska niitä käytetään paljon liikenteen ennakoinnissa ja hallinnassa. Myös sekä koneoppimisen, että neuroverkkojen yleisimmät heikkoudet käytiin läpi.

Seuraavassa kappaleessa käsiteltiin lyhyesti termit liikenne, ruuhkautuminen ja liikenteenhallintajärjestelmä. Kuvattiin, millainen tietojärjestelmä liikenteenhallintajärjestelmä yleensä on, mitä siihen kuuluu ja millaista hyötyä siitä on. Lisäksi lyhyesti tuotiin ilmi myös liikenteen hallinnan heikkoutta.

Neljännessä kappaleessa käytiin läpi, miten tekoälyä hyödynnetään liikenteen ennakoinnissa ja miten tätä ennakointikykyä voidaan hyödyntää liikenteen hallintajärjestelmissä. Ensimmäisessä tutkittiin tekoälyn eri sovellusten sopivuutta liikennevirtojen ennakointiin. Niissä käytetään eniten keinotekoisia neuroverkkoja ja syväoppimista, mutta myös esimerkiksi tukivektorikoneita ja päätöspuita. Varsinkin neuroverkot todetaan liikennevirtojen ennakoinnissa toimiviksi, koska niillä on kyky käyttää monilähteistä dataa. Ne pystyvät ottamaan huomioon esimerkiksi dataa säästä, jolloin ne voivat ennakoida myös erikoisten sääolosuhteiden vaikutuksia liikennevirtoihin. Tutkimuksista nousi ilmi myös, että neuroverkot pystyvät ennustamaan hyvin, kun käytössä on mahdollisimman reaaliaikaista dataa. Reaaliaikaista dataa käyttäen neuroverkot pystyvät ennustamaan hyvin lyhyen aikavälin liikennettä. Todettiin myös, että neuroverkko, jossa on useampia kerroksia, toimii paremmin kuin matalakerroksinen neuroverkko.

Verrattuna perinteiseen matemaattiseen vektorimalliin, neuroverkko toimii luotettavammin myös erikoisissa olosuhteissa. Neuroverkot siis toimivat hyvin liikenteen ennakoinnissa. Myös muita tekoälyn sovelluksia on tutkittu. Esimerkiksi myös tukivektorikoneita käytetään liikenteen ennakoinnissa. Niiden tehtävien on kuitenkin oltava paljon spesifimpiä, koska ne eivät voi käyttää niin monipuolista dataa ja ne vaativat huomattavasti parempaa datan esikäsittelyä, kuin neuroverkot. Voidaan siis todeta, että tekoälyn eri sovelluksilla on potentiaalia toimia liikenteen ennakoinnissa.

Seuraavaksi käsiteltiin liikenneonnettomuuksien ennakointia. Liikenneonnettomuuksien ennakoinnissa käytetään paljon neuroverkkoja, mutta niiden heikkoutena pidetään niiden huonoa kykyä selittää tuloksiaan. Tutkimusten mukaan tukivektorikoneet ovat tehokkaita liikenneonnettomuuksien ennakoinnissa. Niiden etuna on esimerkiksi se, että ne eivät välttämättä tarvitse niin paljoa dataa toimiakseen luotettavasti. Niiden ennakointitarkkuus jopa paranee, mitä vähemmän dataa niillä on käytettävissä. Tämä on suuri etu, sillä liikenneonnettomuuksista ei ole tarjolla dataa niin paljoa, koska onnettomuudet ovat kuitenkin suhteellisen harvinaisia. Tämä tuottaa hankaluuksia neuroverkoille, koska ne tarvitsivat paljon dataa ennustakseen luotettavasti liikenneonnettomuuksia. Tekoälyä voidaan käyttää myös ennustamaan mahdollisten liikenneonnettomuuksien vakavuutta, mutta se vaatii tarkkaa datan käsittelyä, juuri siksi että liikenneonnettomuudet ovat niin harvinaisia. Tekoälyn eri sovelluksia voidaan siis hyvällä määrittelyllä käyttää myös liikenneonnettomuuksien ennakoinnissa.

Tämän jälkeen tuotiin ilmi esimerkkejä älykkäästi toimivista liikenteenhallintajärjestelmistä ja todettiin, että niissä on suurta potentiaalia vähentää liikenteen ja ruuhkautumisen aiheuttamia ongelmia. Ne pystyvät hallitsemaan liikennevirtoja tekoälyllä analysoidun datan perusteella ja näin vähentämään ruuhkautumista. Tämä tuottaa suuresti lisäarvoa, sillä ruuhkautuminen on yhteiskunnalle todella kallista. Älykäs liikenteenhallintajärjestelmä pystyy muokkaamaan omaa hallintastrategiaansa alati muuttuvissa olosuhteissa. Tämän mahdollistaa datan saaminen ja analysoiminen useista eri lähteistä. Perinteiset liikenteenhallintajärjestelmät käyttävät pelkästään omia teihin upotettuja sensoreita. Tämä tekee älykkäistä liikenteenhallintajärjestelmistä proaktiivisempia ja tehokkaampia. Niissä on kuitenkin vielä kehitettävää. Oikea datan käsittely, tavoitemäärittelyt ja teknologioiden yhdistäminen tuottaa vielä hankaluuksia ja vaatii lisää tutkimusta.

Tekoälyä on pyritty hyödyntämään liikenteen ennakoinnissa ja hallinnassa jo pitkään, mutta se ei ole kuitenkaan vielä käytössä laajalti, varsinkaan liikenteenhallintajärjestelmissä. Laskentatehon ja teknologian jatkuva kehittyminen kuitenkin mahdollistaisivat tekoälyn laajemman käyttöönoton liikenteen hallinnassa. Ala vaatii kuitenkin vielä lisää tutkimusta. Jatkotutkimusaiheina voisi olla liikenteenhallintajärjestelmien ja tekoälyn yhteisen arkkitehtuurin parempi määrittely sekä älykkäiden liikenteenhallintajärjestelmien tavoitteiden määrittelyn tutkimista.

LÄHTEET

- Arnott, R., Small, K. (1994). The economics of traffic congestion. *American Scientist*, 82(5), 446-455. Haettu osoitteesta: <http://www.jstor.org/stable/29775281>
- Bao, J., Liu, P., & Ukkusuri, S. V. (2019). A spatiotemporal deep learning approach for citywide short-term crash risk prediction with multi-source data
- BBC. (2014,). AI: 15 key moments in the story of artificial intelligence. Haettu osoitteesta: <https://www.bbc.co.uk/teach/ai-15-key-moments-in-the-story-of-artificial-intelligence/zh77cqt>
- Breiman, L., Random Forests, 2001, s. 1-2.
- Buchanan, B. (2005). A (very) brief history of artificial intelligence.
- Bull, A. (2003). Traffic congestion the problem and how to deal with it. *Cepal*.
- Coppin, B. (2004). Artificial intelligence illuminated .
- Dougherty, M. (1995a). *A review of neural networks applied to transport*
- Dougherty, M. (1995b). *A review of neural networks applied to transport*
- Dunkel, J., Fernández, A., Ortiz, R., & Ossowski, S. (2011). Event-driven architecture for decision support in traffic management systems
- Ertel, W. (2017). Introduction to artificial intelligence. Haettu osoitteesta: <http://www.hs-weingarten.de/~ertel/aibook/aibook-ertel-slides.pdf>
- Esteva, A., Kuprel, B., Novoa, R. et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115–118.
- Gupta, B., Aditya, R., Akshay, J., Arpit, A., Naresh, D. (2017) Analysis of Various Decision Tree Algorithms for Classification in Data Mining. *International Journal of Computer Applications*
- Huang, T., Wang, S., & Sharma, A. (2020). Highway crash detection and risk estimation using deep learning
- Iranitalab, A., & Khatkhat, A. (2017). Comparison of four statistical and machine learning methods for crash severity prediction

- Kaplan, J., (2016). Artificial intelligence: What everyone needs to know
- Karlaftis, M. G., & Vlahogianni, E. I. (2011). Statistical methods versus neural networks in transportation research: Differences, similarities and some insights
- Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging Artificial Intelligence Applications in Computer Engineering*, 160, 3-24.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Li, Y., Jiang, W., Yang, L., & Wu, T. (2018). On neural networks and learning systems for business computing
- Li, X., Lord, D., Zhang, Y., & Xie, Y. (2008). Predicting motor vehicle crashes using support vector machine models
- Merriam Webster. Definition of traffic (entry 1 of 2). Haettu osoitteesta: <https://www.merriam-webster.com/dictionary/traffic>
- Michalski, R. S., Carbonell, J. G. & Mitchell, T. M. (Eds.). (2013). Machine learning: An artificial intelligence approach. *Springer Science & Business Media*
- Microsoft Research (2011), Predictive Analytics For Traffic. Haettu osoitteesta: <https://www.microsoft.com/en-us/research/project/predictive-analytics-for-traffic/?from=http%3A%2F%2Fresearch.microsoft.com%2Fen-us%2Fprojects%2Fclearflow%2F>
- Mirshahi, M., Obenberger, J., Fuhs, C. A., Howard, C. E., Krammes, R. A., Kuhn, B. T., . . . Stone, C. J. (2007). No title. Active Traffic Management: The Next Step in Congestion Management
- Papageorgiou, M., Diakaki, C., Dinopoulou, V., Kotsialos, A., & Yibing Wang. (2003). Review of road traffic control strategies
- Pitombo, C. S., de Souza, A. D., & Lindner, A. (2017). Comparing decision tree algorithms to estimate intercity trip distribution
- Polson, N. G., & Sokolov, V. O. (2017). Deep learning for short-term traffic flow prediction
- Qiu, J., Wu, Q., Ding, G., Xu Yuhua, & Shuo Feng. (2016). A survey of machine learning for big data processing. *EURASIP Journal on Advances in Signal*

Processing, 67 Haettu

osoitteesta: <https://link.springer.com/article/10.1186/s13634-016-0355-x#citeas>

- Rezaie Moghaddam, F., Afandizadeh, S., & Ziyadi, M. (2011). Prediction of accident severity using artificial neural networks. *International Journal of Civil Engineering*, 9(1), 41-48.
- Sadek, A. W. (2007). Artificial intelligence applications in transportation. *Artificial Intelligence in Transportation: Information for Application*, 1-6.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview
- Sebag, M. (2014). A tour of machine learning: An AI perspective. *AI Communications*, 27(1), 11-23
- Siau Keng, L., & Yang Yin. (2017). Impact of artificial intelligence, robotics, and machine learning on sales and marketing. *MWAIS 2017 Proceedings*, 48 Haettu
osoitteesta: <https://aisel.aisnet.org/cgi/viewcontent.cgi?article=1047&context=mwais2017>
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., . . . Lanctot, M. (2016). Mastering the game of go with deep neural networks and tree search. *Nature*, 529(7587), 484.
- Simon, H. A. (1983). In Michalski R. S., Carbonell J. G. and Mitchell T. M.(Eds.), 2 - why should machines learn?. San Francisco (CA): Morgan Kaufmann.
- Sze, V., Chen, Y., Yang, T., & Emer, J. S. (2017). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2295-2329.
- Toint, P., Labbe, M., Tanczos K., Laporte, G., (1998) "Automatic control methods in traffic and transportation" in *Operations Research and Decision Aid Methodologies in Traffic and Transportation Management*, New York:Springer-Verlag, pp. 46-83.
- Wang, J., & Shi, Q. (2013). Short-term traffic speed forecasting hybrid model based on Chaos-Wavelet analysis-support vector machine theory
- Wu, Y., Tan, H., Qin, L., Ran, B., & Jiang, Z. (2018). A hybrid deep learning based traffic flow prediction method and its understanding
- Xiaolei Ma, Zhuang Dai, Zhengbing He, Jihui Ma, Yong Wang, & Yunpeng Wang. (2017). Learning traffic as images: A deep convolutional neural

network for large-scale transportation network speed prediction. *Sensors*. Haettu osoitteesta: <https://www.mdpi.com/1424-8220/17/4/818/htm#>

Yu, R., & Abdel-Aty, M. (2013). Utilizing support vector machine in real-time crash risk evaluation

Zhang, S., Zhang, C., Yang, Q. (2003) Data preparation for data mining, *Applied Artificial Intelligence*, 17:5-6, 375-381

Zhang, Z., He, Q., Gao, J., & Ni, M. (2018). A deep learning approach for detecting traffic accidents from social media data