

Siirto-oppiminen liikennemerkkien tunnistuksessa

Tietotekniikka
Tietotekniikan laitos, Teknillinen tiedekunta
Kandidaatintutkielma

Laatija:
Valtteri Virta

Toukokuu 2025

Kandidaatintutkielma

Tietotekniikan laitos, Teknillinen tiedekunta

Turun yliopisto

Tutkinto-ohjelma: Tietotekniikka

Tekijä: Valtteri Virta

Otsikko: Siirto-oppiminen liikennemerkkien tunnistuksessa

Sivumäärä: 26 sivua

Päivämäärä: Toukokuu 2025

Liikennemerkkien tunnistus on keskeinen komponentti autonomisten ajoneuvojen ja älykkäiden kuljetusjärjestelmien turvallisuuden varmistamisessa. Liikenteen turvallisuuden parantaminen ja onnettomuuksien ehkäisy edellyttävät luotettavaa ja tarkkaa liikennemerkkien tunnistamista, mikä tekee aiheesta erittäin ajankohtaisen ja merkityksellisen.

Tässä kandidaatintutkielmassa tarkastellaan siirto-oppimisen hyödyntämistä liikennemerkkien tunnistuksessa ja verrataan sen suorituskykyä perinteisempään suoraan kouluttamiseen. Tutkielmassa selvitetään, miten siirto-oppimisen eri menetelmät, erityisesti hienosäätö ja piirteiden poiminta, vaikuttavat tunnistusjärjestelmän tarkkuuteen verrattuna mallien suoraan kouluttamiseen. Näistä hienosäätö osoittautuu huomattavasti tehokkaammaksi kuin pelkkä piirteiden poiminta, ja siirto-oppimismallit saavat parhaimmillaan mAP50-metriikalla mitattuna jopa 98 % tarkkuuden, kun taas suoraan koulutetut mallit jäävät selvästi heikommiksi. Tulokset kuitenkin vaihtelevat merkittävästi tutkimusten ja tehtävien mukaan. Mallit saavuttavat yleisesti liikennemerkkien luokittelussa huomattavasti parempia tuloksia kuin tunnistettaessa liikennemerkkejä liikenteestä otetuista laajemmista kuvista.

Siirto-oppimisen suurimpana hyötynä havaitaan olevan sen tarvitsema pienempi liikennemerkkiaineiston määrä, sillä mallit hyödyntävät esikoulutuksessa opittuja yleisiä piirteitä. Keskeisiksi haasteiksi tutkielmassa tunnistettaan aineistojen epätasainen luokkajakauma, negatiivinen siirto sekä eri tutkimusten vaihtelevat tulokset. Tulokset kuitenkin korostavat siirto-oppimisen merkittävää roolia ja tarjoavat tärkeän pohjan luotettavien ja tehokkaiden liikennemerkkien tunnistusratkaisujen jatkokehitykselle.

Asiasanat: siirto-oppiminen, liikennemerkkien tunnistus, syväoppiminen, mAP50, hienosäätö, piirteiden poiminta

Sisällysluettelo

1	Johdanto	5
2	Siirto-oppiminen	7
2.1	Neuro- ja konvoluutioverkot	7
2.2	Siirto-oppimisen perusteet	10
2.3	Siirto-oppimisen menetelmät	11
2.4	Datan laatu	13
3	Siirto-oppimisen hyödyntäminen liikennemerkkien tunnistuksessa	15
3.1	Tulosten arviointi	15
3.2	Tutkimustuloksia siirto-oppimisesta	18
4	Siirto-oppimisen ja suoraan kouluttamisen vertailu	23
5	Pohdinta	25
6	Yhteenveto	30
	Lähteet	31

1 Johdanto

Koneoppimismenetelmien nopea kehitys viime vuosina on edistänyt myös sitä soveltavien alojen kehitystä. Koneoppimisen perusidea on automatisoida tietty laskennallinen tehtävä kouluttamalla tietokoneohjelma, eli algoritmi, opetusdatan avulla. Yksi tutkituimmista sovelluskohteista on itseohjautuvat ajoneuvot, joita on kehitelty jo vuosikymmenien ajan. Ensimmäiset hankkeet käynnistettiin jo 1980-luvulla, jolloin EUREKA-hanke alkoi kehittää tehtävään tarvittavia teknologioita [1]. Kuitenkin, edes osittain autonomiset ajoneuvot ovat tulleet liikenteeseen vasta äskettäin.

Ajoneuvojen itsenäinen toiminta edellyttää ympäristön tarkkaa tulkintaa. Yksi ympäristön keskeisistä asioista ovat liikennemerkkit, jotka kertovat tärkeitä tietoja ja sääntöjä tiellä liikkujille. Liikennemerkkien tunnistaminen ei kuitenkaan ole helppo tehtävä niiden koon ja ulkonäön vaihtelevuuden vuoksi [2]. Ilman liikennemerkkien tarkkaa tunnistamista autonomisten ajoneuvojen turvallinen toiminta on kuitenkin lähes mahdotonta. Vaikka tavoitteena ei aina olisikaan täysin itsestään ajava ajoneuvo, liikennemerkkien tunnistaminen on kuitenkin yhä useammin osa kuljettajaa avustavaa järjestelmiä.

Liikennemerkkien tunnistamiseen liittyy monia muuttujia, minkä vuoksi koneoppimismenetelmien käyttö on yleistynyt viime vuosina. Eräs yleisesti käytetty menetelmä on neuroverkkojen kouluttaminen haluttuun tehtävään [3]. Neuroverkot ovat matemaattisia malleja, joiden toiminta jäljittelee ihmisaivojen toimintaa. Ne soveltuvat erityisen hyvin kuvantunnistukseen ja ovatkin nykyisin hyvin suosittuja erilaisissa konenäköön liittyvissä tehtävissä.

Vaikka neuroverkot ovat osoittautuneet erinomaisiksi kuvantunnistuksessa, on niiden hyödyntämisessä myös haasteita. Merkittävin haaste on koulutukseen tarvittavan laadukkaan datan määrä, sillä sitä ei ole saatavilla riittävästi. Vaikka Euroopasta onkin saatavilla muutamia avoimia ja laadultaan kohtuullisia aineistoja, niiden rajallinen koko ei riitä luotettavaan mallikoulutukseen. Vastaavasti monista maista kuten Yhdysvalloista ei ole saatavilla tarpeeksi isoja ja laadukkaita vapaasti käytössä olevia data-aineistoja. Myös suurempia data-aineistoja on olemassa, mutta ne ovat autonomista ajamista kehittävien yritysten hallussa, eivätkä näin ole avoimesti saatavilla. [4]

Datan tarpeen vähentämiseksi on kehitetty erilaisia menetelmiä. Yksi tällainen menetelmä on siirto-oppiminen. Sen ideana on hyödyntää koulutuksessa suurempaa data-aineistoa, jonka ei

tarvitse olla liikennemerkkejä, jolloin liikennemerkeistä tarvitaan vähemmän dataa. Koulutuksen alussa neuroverkko esikoulutetaan tällä suurella data-aineistolla, jonka jälkeen malli uudelleen koulutetaan haluttuun tehtävään. Pienemmän datan tarpeen lisäksi sen avulla voidaan saavuttaa jopa parempia tuloksia kuin suoraan kouluttamalla. [4]

Tämän kirjallisuuskatsauksen tarkoituksena on selvittää, miten siirto-oppimista voidaan hyödyntää liikennemerkkien tunnistustehtävissä ja miten sen suorituskyky vertautuu perinteiseen suoraan kouluttamiseen. Täsmälliset tutkimuskysymykset ovat:

TK1: Millä tavoin siirto-oppimista kannattaa hyödyntää liikennemerkkien tunnistamiseen?

TK2: Parantaako siirto-oppiminen liikennemerkkien tunnistamisen tarkkuutta?

Tutkimuskysymyksiin pyritään vastaamaan käsittelemällä siirto-oppimista yleisesti sekä analysoimalla alan tutkimusten tuloksia.

Tiedonhaku tehtiin pääosin IEEE Xplore -tietokannasta käyttämällä hakusanoja ”*transfer learning and traffic sign*”. Hakutulokset rajattiin alkamaan vuodesta 2020, koska tutkielmassa keskityttiin uusimpia menetelmiä käyttäviin tutkimuksiin. Näillä hakuehdoilla tietokannasta löytyi 164 tulosta, joista valittiin otsikon ja sisällön perusteella tarkempaan tarkasteluun 25 tutkimusta. Yleistä tietoa liikennemerkkien tunnistamisesta sekä menetelmiä koskevaa vertailutietoa haettiin samasta tietokannasta hakusanalla ”*Traffic sign detection*”. Eri menetelmien teknistä taustatietoa on haettu tietokannasta hakemalla tekniikan nimellä tai ”*tekniikan nimi and review or survey*”. Lähteitä etsittiin myös läpikäytyjen artikkeleiden lähteistä.

Työ rakentuu seuraavasti: luvussa 2 käsitellään metodologista perustaa, neuro- ja konvoluutioverkkoja, näistä tehtyjä laajennoksia sekä siirto-oppimisen perusteita. Luvussa 3 käydään läpi alan tutkimusten tuloksia sekä miten niitä voidaan vertailla keskenään. Luvussa 4 verrataan siirto-oppimista suoraan kouluttamiseen alan tutkimuksissa saatujen tulosten perusteella. Luvussa 5 pohditaan läpikäytyjä tuloksia sekä niihin vaikuttaneita tekijöitä.

2 Siirto-oppiminen

Siirto-oppiminen tarjoaa joustavan tavan soveltaa valmiiksi opittuja kuvantunnistusmalleja uusiin tehtäviin, mutta sen tehokas käyttö edellyttää sekä mallin teknisten ominaisuuksien ymmärtämistä että kohdedatan huolellista valmistelua. Tässä luvussa tarkastellaan, miten neuro- ja konvoluutioverkot toimivat pohjana siirto-oppimiselle, mitä eri siirto-oppimisen menetelmiä on olemassa, ja millainen data tukee parhaiten mallin yleistyskykyä. Lisäksi käydään läpi tapoja soveltaa siirto-oppimista käytännössä ja pohditaan, miten esikoulutettuja neuroverkkoja voi lähteä soveltamaan liikennemerkkien tunnistukseen.


2.1 Neuro- ja konvoluutioverkot

Neuroverkot ovat matemaattisia malleja, joiden tarkoituksena on oppia havaitsemaan ja mallintamaan datan piirteiden välisiä riippuvuuksia. Ne koostuvat useista neuroneista, jotka on järjestetty kerrostettuun rakenteeseen. Yksittäinen neuroni saa yleensä useita signaaleita syöteinä, joista jokaisella on oma painoarvonsa. Painoarvojen avulla se laskee painotetun summan, joka toimii aktivointifunktion syötteenä. Aktivaatiofunktio on matemaattinen funktio, joka määrittää neuronin lähtösignaalin arvon syötteiden perusteella. Tyypillisessä arkkitehtuurissa neuronit ovat yleensä yhteydessä joko kaikkiin tai tiettyihin edellisen sekä seuraavan kerroksen neuroneista, mikä mahdollistaa informaation kulun verkossa. [5]

Yksinkertaisimmillaan neuroverkko koostuu kolmesta kerroksesta: syötekerroksesta, piilokerroksesta ja ulostulokerroksesta. Syötekerros ottaa vastaan mallin käsiteltävän datan, piilokerrokset suorittavat varsinaisen laskennan ja piirteiden tunnistamisen, ulostulokerros tuottaa lopullisen ennusteen. Neuroverkkoja, joissa piilokerroksia on useita, kutsutaan syväoppiviksi neuroverkoiksi. Kuvassa 1 on esitetty yksinkertaisen syväoppivan neuroverkon rakenne. Suuret syväoppivat neuroverkot ovat usein rakenteeltaan monimutkaisia ja voivat sisältää jopa satoja piilokerroksia. Näin suurien verkkojen kouluttaminen edellyttää merkittäviä laskentaresursseja sekä laajoja data-aineistoja, jotta verkon painoarvot saadaan optimoituja tehokkaasti. [5]

Suuri osa neuroverkkoja on niiden koulutus. Koulutuksessa jokainen neuroni saa aluksi satunnaiset painoarvot, mikä estää kaikkien neuronien oppimisen täysin samankaltaisiksi. Koulutuksessa data syötetään verkkoon erissä (batch), ja koko datasetti käydään läpi useita kertoja (epoch). Koulutuksessa neuroneiden painoarvojen päivittäminen tapahtuu määritellyn

oppimisnopeuden mukaan. Oppimisnopeus määrittää kuinka paljon painoarvoja muokataan jokaisella erällä. Usein se myös pienentyy koulutuksen edetessä. [5]



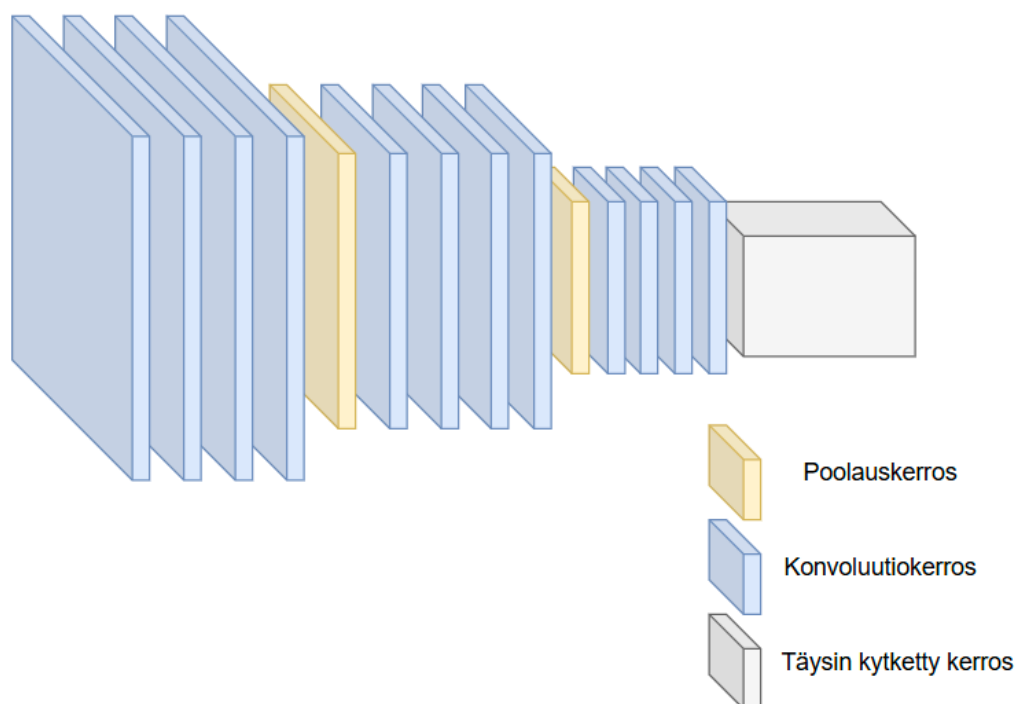
Kuva 1. Yksinkertainen syväoppiva neuroverkko. Syötekerros muuntaa datan verkon käyttämään muotoon. Piilokerrokset tunnistavat datasta piirteitä ja ulostulokerros tuottaa todennäköisyysjakauman eri liikennemerkkien esiintymiselle kuvassa.

Konvoluutioverkot ovat eräänlaisia syväoppivia neuroverkkoja, joita käytetään laajasti erilaisissa kuvantunnistustehtävissä. Ne soveltuvat erityisen hyvin liikennemerkkien tunnistamiseen, koska ne pystyvät havaitsemaan yksinkertaisia paikallisia piirteitä, kuten reunoja ja värieroja. Näitä yksinkertaisia piirteitä yhdistämällä pystyy neuroverkko oppimaan monimutkaisempia kuvioita, kuten ympyröitä ja kolmioita. Konvoluutioverkkojen arkkitehtuuri koostuu yleensä kolmesta erilaisesta kerroksesta: konvoluutio-, poolaus- ja täysin kytketyistä kerroksista. Yksinkertaisen konvoluutioverkon rakenne on esitetty kuvassa 2. Konvoluutiokerroksissa konvoluutiomatriisi liikkuu koko syötteen yli ja laskee samalla eri alueiden painotettuja summia, jotka ilmaisevat missä kuvassa esiintyy tiettyjä piirteitä. Konvoluutiomatriisien koko on asetettava parametri, joka vaikuttaa havaittaviin piirteisiin. Suuremmat konvoluutiomatriisit mahdollistavat monimutkaisempien ja suurempien piirteiden tunnistamisen, mutta samalla ne kasvattavat verkon kokoa. Poolauskerrokset pienentävät mallin piirre-esitysten ulottuvuuksia, mikä vähentää laskennallista kuormaa ja ehkäisee

verkon ylisovittumista. Täysin kytketyt kerrokset puolestaan tekevät lopullisen luokittelun käyttämällä konvoluutio- ja poolauskerrosten tuottamia piirre-esityksiä. Näiden kerrosten yhteistyön ansiosta konvoluutioverkot kykenevät oppimaan ja yleistämään kuvien sisältämiä piirteitä yksinkertaisista reunoista aina monimutkaisiin kuvioihin asti.

Monimutkaisten piirteiden oppiminen edellyttää kuitenkin runsaasti koulutusdataa ja laskentatehoa. Itse koulutusprosessi noudattaa samoja peruseriaatteita kuin yksinkertaisempien neuroverkkojen koulutus. Onnistuneen koulutuksen jälkeen konvoluutioverkot pystyvät soveltamaan opittuja piirteitä aiemmin näkemättömiin kuvajoukkoihin, mikä on olennainen vaatimus luotettavalle liikennemerkkien tunnistukselle.

[6]



Kuva 2. Yksinkertainen konvoluutioverkko. Konvoluutioverkot ovat yleensä huomattavasti laajempia kuin yksinkertaiset neuroverkot, joten niiden rakennetta tarkastellaan usein kerros kerrallaan. Konvoluutiokerroksissa kuvasta tunnistetaan paikallisia piirteitä (reunoja, kulmia, tekstuureja) liu'uttamalla konvoluutiomatriisia kuvan yli. Poolauskerrokset tiivistävät nämä piirteet pienempiin kuvioihin. Lopuksi täysin kytketty kerros yhdistää opitut piirteet ja tuottaa todennäköisyysjakauman syötteen luokista.

Liikennemerkkien tunnistamisessa käytetään usein laajempia malleja, kuten YOLO- sekä R-CNN-malleja. Nämä mallit koostuvat useammasta eri osasta, jotka yleensä ovat konvoluutioverkkoja. Tämä mahdollistaa kokonaisuuden paremman optimoinnin, sillä yksi osa vastaa vain yhdestä tehtävästä. Tunnistaminen on usein jaettu kolmeen eri osaan: piirteiden etsimiseen, niiden yhdistelemiseen, sekä luokitteluun.

2.2 Siirto-oppimisen perusteet

Koneoppimisessa siirto-oppimisella sekä syvällä siirto-oppimisella tarkoitetaan neuroverkkojen koulutusmenetelmää, jossa neuroverkko koulutetaan kahdessa vaiheessa. Ensimmäisessä vaiheessa verkko esikoulutetaan suurella lähdeaineistolla ja toisessa vaiheessa siirretään siitä opitut säännönmukaisuudet eli piirteet kohdotehtävään kohdedatan avulla. Lähdedata tarkoittaa esikoulutukseen käytettyä dataa ja vastaavasti kohdedata lopulliseen tehtävään koulutettaessa käytettyä dataa. Samoin mallin alkuperäistä tehtävää kutsutaan lähde tehtäväksi ja uutta tehtävää kohdotehtäväksi.

Uuden mallin kouluttaminen tapahtuu edellä esitellyillä kahdella vaiheella. Kouluttaminen perustuu esikoulutuksessa opittujen piirteiden hyödyntämiseen kohdotehtävässä. Esikoulutuksessa malli oppii datasta yleisiä piirteitä, joita säädetään vastaamaan kohdotehtävässä olevia piirteitä. [7] Esikoulutuksen johdosta kohdedataa tarvitaan huomattavasti vähemmän. Piirteiden muokkaamisen ansiosta käytettävän lähdedatan ei myöskään tarvitse täysin vastata kohdotehtävän sisältämiä piirteitä [8]. Lähdedatana voidaan siis käyttää vapaasti saatavilla olevia suuria kuva-aineistoja. Yli miljoona kuvaa käsittävät aineistot, kuten ImageNet, toimivat monipuolisuutensa ansiosta erinomaisena lähdedatana. Lähdedata ei kuitenkaan voi olla mitä tahansa dataa, vaan sen piirteiden pitäisi sopia mahdollisimman hyvin kohdotehtävään. Näin ollen kuvantunnistukseen liittyvissä tehtävissä, kuten liikennemerkkien tunnistamisessa, pitäisi lähdedatana käyttää kuva-aineistoa, eikä esimerkiksi tekstiaineistoja. [7]

Huonosti valittu lähdedata voi kuitenkin heikentää mallin suoriutumista, jos lähde- ja kohdedatojen sisältämät piirteet eroavat paljon toisistaan. Tätä ilmiötä kutsutaan negatiiviseksi siirroksi. Tästä johtuen, vaikka lähdedata voi erota kohdedatasta jonkin verran, pitää sen valinnassa kuitenkin huomioida kohdotehtävän sisältämät piirteet. [7] Toisaalta kohdedatan pitää olla tarkkaan valittua dataa. Liikennemerkkien tunnistamisessa kohdedatan tulisi olla luokiteltuja kuvia liikennemerkeistä. Kohdedataa ei tarvita läheskään yhtä paljoa

kuin jos malli koulutettaisiin suoraan haluttuun tehtävään, sillä siirrossa hyödynnetään esikoulutetun neuroverkon osaamista. [9]

2.3 Siirto-oppimisen menetelmät

Erilaiset siirto-oppimisen lähestymistavat voidaan jakaa lähde- ja kohdedatojen sekä lähde- ja kohdetehtävien välisten suhteiden mukaan kolmeen eri luokkaan: ”induktiiviseen, transduktiiviseen sekä valvomattomaan siirto-oppimiseen (taulukko 1) ja tarkastellaan näiden soveltuvuutta liikennemerkkien tunnistukseen. [10] Lisäksi luvussa tarkastellaan kahta erilaista siirto-oppimisen koulutusmenetelmää: hienosäätöä ja piirteiden poimintaa.

Induktiivisessa siirto-oppimisessä lähde- ja kohdetehtävät eroavat toisistaan, mutta sisältävät kuitenkin samankaltaisia piirteitä. Lähdedata voi olla joko luokiteltua tai luokittelematonta, mutta kohdedata on aina luokiteltua. [10] Tämä lähestymistapa on hyödyllinen, sillä käytössä olevat kohdedatat ovat usein valmiiksi luokiteltuja, ja lähdedatalle ei ole tarkkoja kriteereitä. Lähdedatan löyhemmät vaatimukset mahdollistavat myös valmiiksi esikoulutettujen lähdemallien käyttämisen, mikä säästää käytössä olevia resursseja. Induktiivinen siirto-oppiminen onkin yleisin liikennemerkkien tunnistamiseen liittyvässä tutkimuksessa käytetty menetelmä.

Transduktiivisessa siirto-oppimisessä lähde- ja kohdetehtävät ovat samat, mutta niihin liittyvät datat poikkeavat ominaisuuksiltaan, kuten resoluutiolta, väreiltään sekä sisältämiltään luokilta. [10] Tätä lähestymistapaa voidaan mahdollisesti käyttää laajennettaessa liikennemerkkien tunnistusmallia toimimaan toisessa maassa. Tällöin lähde- ja kohdetehtävä on liikennemerkkien tunnistaminen, mutta lähde- ja kohdedata sisältää erilaisia piirteitä. Tämä lähestymistapa ei kuitenkaan ole yleisesti käytössä liikennemerkkien tunnistamisessa.

Valvomattomassa siirto-oppimisessä lähde- ja kohdetehtävät eroavat toisistaan, samoin kuin lähde- ja kohdedata. Suurin ero induktiiviseen siirto-oppimiseen on sekä lähde- että kohdedatojen luokittelemattomuus. Tästä johtuen tavoitteena on yleensä datan klusterointi tai rakenteen tunnistaminen ilman valmiita luokkia. [10] Valvomattoman siirto-oppimisen hyödyntäminen liikennemerkkien tunnistamisessa on harvinaista, sillä se ei tuota samanlaista ennustetta liikennemerkin luokasta kuin induktiivisella tai transduktiivisella siirto-oppimisella koulutettu malli. Kuitenkin jos käytettävissä on myös luokiteltua dataa, on mahdollista hyödyntää valvomatonta siirto-oppimista osana mallin koulutusta.

Taulukko 1. Siirto-oppimisen kategoriat

Kategoria	Toiminta Periaate	Lähde- ja kohdealueiden erot	Kohdedata	Käyttökohde
Induktiivinen siirto-oppiminen	Siirretään tiedot uuteen tehtävään	Eri data ja eri tehtävä	Merkittyä	Kuvantunnistus-malli siirretään tunnistamaan liikennemerkkejä
Transduktiivinen siirto-oppiminen	Hyödynnetään osaamista samassa tehtävässä	Eri data ja sama tehtävä	Merkittyä, osa datasta voi olla merkitsemätöntä	Laajennetaan liikennemerkkien tunnistamista maasta toiseen
Valvomaton siirto-oppiminen	Oppii ryhmittelemään samanlaisia kohteita	Eri data ja samankaltainen tehtävä	Merkitsemätöntä	Klusterointi

Siirto-oppimisen koulutusmenetelmät voidaan jakaa kahteen pääluokkaan sen mukaan, kuinka paljon esikoulutettua mallia säädetään kohdedatalla: hienosäätöön ja piirteiden poimintaan (engl. fine-tuning ja feature extraction; Taulukko 2).

Hienosäädössä koko mallin arkkitehtuuri tai suurin osa siitä koulutetaan uudelleen kohdedatalla. Oppimisnopeus on kuitenkin huomattavasti pienempi kuin esikoulutuksessa, jolloin parametreihin tehdään vain pieniä muutoksia, mikä mahdollistaa mallissa valmiina olevien parametrien tehokkaan hyödyntämisen. Suuremmat mallit kuitenkin tarvitsevat kohtalaisen määrän kohdedataa parametrien optimoimiseksi. Kohdedatan tarvetta voidaan kuitenkin vähentää kouluttamalla vain osa mallista uudelleen. Tällöin kerrokset, joita ei haluta uudelleen kouluttaa, jäädytetään eli niiden parametrit asetetaan kiinteiksi koulutuksen ajaksi. Tulokset voivat kuitenkin heikentyä, sillä koko mallia ei optimoida uuteen tehtävään. [9]

Piirteiden poiminnassa vain luokittelevat kerrokset koulutetaan uudelleen kohdedatalla ja kaikki muut kerrokset jäädytetään. Luokittelevat kerrokset yleensä koulutetaan alusta asti, eli niiden painot asetetaan satunnaisiksi ennen uudelleen kouluttamista. Jäädytyksen takia piirteitä tunnistavat kerrokset säilyvät ennallaan, jolloin lähdemallin soveltuvuus nousee huomattavasti tärkeämpään rooliin kuin hienosäätöä käytettäessä. Lopulliset tulokset myös yleensä heikkenevät, sillä luokittelu perustuu lähdedatasta opittuihin piirteisiin. Piirteiden poiminnan merkittävä etu on kuitenkin pienempi datan tarve kuin hienosäädössä. [9]

Taulukko 2. Hienosäädön ja piirteiden poiminnan erot

Menetelmä	Mitä tehdään	hyödyt	haitat
Hienosäätö	Optimoidaan mallin parametreja kohdedatalla	Koko malli mukautuu uuteen tehtävään	Tarvitaan enemmän dataa ja laskentatehoa
Piirteiden poiminta	Luokittelija koulutetaan uudelleen kohdedatalla	Koulutus vaatii vähemmän laskentatehoa ja dataa	Ei opi uusia piirteitä, luokittelee aikaisemmin opittujen piirteiden mukaan

2.4 Datan laatu

Vaikka sopiva arkkitehtuuri ja siirto-oppimisen eri menetelmät ovatkin tärkeitä, mallin kyky yleistää ja tunnistaa liikennemerkkejä määräytyy lopulta koulutusdatan laadun perusteella. Etenkin huonolaatuinen data rajoittaa mallin suorituskykyä sekä heikentää yleistämiskykyä. Tässä aliluvussa määritellään, mitä laadukas data on liikennemerkkien tunnistuksessa sekä esitetään menetelmiä datan laadun parantamiseksi.

Siirto-oppimisessa kohdedatan laatu on ratkaisevassa roolissa, koska juuri sen perusteella malli oppii tunnistamaan liikennemerkit. Laadukas kohdedata kattaa jokaisesta liikennemerkestä riittävän määrän kuvia, joiden pitää heijastaa todellista käyttöympäristöä. Tämän vuoksi laadukkaassa aineistossa on edustettuna erilaisia sää- ja valaistusolosuhteita, vaihtelevia kuvakulmia, varjoja sekä mahdollisia näköesteitä, jotka vaikuttavat liikennemerkkien tunnistettavuuteen. [11]

Datan käyttöä edeltää yleensä esikäsittely, jonka tarkoituksena on varmistaa kuvien yhdenmukaisuus. Yleensä kuvat skaalataan samaan resoluutioon, pikseliarvot normalisoidaan valitun mallin mukaisesti ja tiedostomuoto yhdenmukaistetaan koko aineiston osalta. Lisäksi induktiivisessa ja transduktiivisessa siirto-oppimisessa jokaisella kuvalla tulee olla luokkatunniste. Vaikka suurin osa julkisesti saatavilla olevista aineistoista on jo valmiiksi luokiteltuja, omien aineistojen kohdalla luokittelutyö täytyy suorittaa erikseen. [12]

Liikennemerkkiaineistojen yleisimmät ongelmat ovat yksipuolisuus ja vinoutunut luokkajakauma, jolloin kuvia yleisimmistä liikennemerkeistä on runsaasti ja harvinaisemmista on vain vähän kuvia. Tätä ongelmaa voidaan lieventää käyttämällä data-augmentaatiota, jolla tarkoitetaan alkuperäisten kuvien muokkaamista uusien kuvien luomiseksi. Kuvien

augmentoinnissa voidaan hyödyntää useita erilaisia tekniikoita, kuten kiertoa, peilausta, skaalausta, kontrastin ja kirkkauden säätöä, väritasapainon muokkaamista sekä kohinan tai muiden häiriöiden lisäämistä. [12]

Liikennemerkkien tunnistuksessa data-augmentaation hyödyt korostuvat erityisesti merkkien yksinkertaisen geometrian vuoksi. Harvinaisempien merkkien kuvamäärää voidaan augmentaation avulla kasvattaa, jolloin luokkien välinen jakauma tasapainottuu ja mallin kyky tunnistaa harvinaisempia merkkejä paranee. On kuitenkin huomiotava, että data-augmentaatio toimii parhaiten rajatuissa kuvissa, joissa liikennemerkki on jo eroteltu taustastaan. Mikäli aineisto sisältää kokonaisia katunäkymiä, kuvien augmentointi muuttuu merkittävästi haastavammaksi, koska taustan muuttuminen saattaa haitata tunnistuksen tarkkuutta. [13]

3 Siirto-oppimisen hyödyntäminen liikennemerkkien tunnistuksessa

Kuten edellisessä luvussa todettiin, siirto-oppimisessa on useita eri lähestymistapoja. Tässä luvussa keskitytään vertailemaan näitä eri siirto-oppimisen menetelmiä sekä niiden käytännön suorituskykyä aiempien tutkimustulosten perusteella. Luvussa käsitellään ensin tulosten arvioinnin menetelmiä, minkä jälkeen vertaillaan ja analysoidaan eri tutkimusten esittämiä tuloksia.

3.1 Tulosten arviointi

Luotettavien johtopäätösten tekeminen edellyttää eri menetelmillä saavutettujen tulosten huolellista vertailua. Liikennemerkkien tunnistuksen tapauksessa vertailua kuitenkin vaikeuttavat monet tekijät, jotka on huomioitava tuloksia analysoitaessa. Hyvän kuvan muuttujien määrästä ja vaikutuksesta antaa mallien koulutuksen alussa käytetyt satunnaiset painoarvot, joilla voi olla jopa 1,3 %-yksikön vaikutus mallin saamaan luokittelutarkkuuteen [14]. Näiden syiden takia tuloksia pitää arvioida suurempana kokonaisuutena.

Merkittävin haaste vertailussa on standardoidun testiaineiston puute, minkä vuoksi tutkimuksissa mallit testataan ja koulutetaan erilaisilla aineistoilla [2]. Yleisimmin käytettävät liikennemerkkiaineistot löytyvät Euroopasta, vaikka myös useista muista maista on saatavilla aineistoja. Aineistojen välillä olevat erot ovat kuitenkin huomattavia. Ne eroavat huomattavasti kooltaan, laadultaan sekä teknisiltä ominaisuuksiltaan kuten kuvien resoluutiolta. Hyvä esimerkki teknisistä eroista on Kiinan ja Saksan liikennemerkkiaineistojen erot. Kiinasta saatavassa aineistossa joka kolmannessa kuvassa on liikennemerkki ja kuvien resoluutio on 2048x2048, kun Saksasta saatavassa aineistossa jokaisessa kuvassa on liikennemerkki ja resoluutiot ovat enimmillään 360x800. [15] Pelkästään nämä erot voivat tuottaa merkittäviä eroja mallien suoriutumisessa. Lisäksi itse kerätyissä aineistoissa datan laatu ja yhtenäisyys voivat vaihdella vielä huomattavasti enemmän, mikä edelleen vaikeuttaa tulosten keskinäistä vertailua.

Koska aineistojen sisältämät liikennemerkkit vaihtelevat, vaikuttaa tunnistamisen haastavuuteen myös näiden visuaalinen vaihtelu. Pienen vaihtelun liikennemerkkeissä, kuten nopeusrajoitus- sekä kieltomerkeissä, koko ja ulkonäkö pysyvät suhteellisen muuttumattomina, mikä helpottaa niiden tunnistamista. Sen sijaan suuren vaihtelun liikennemerkkeissä, kuten digitaalisissa nopeusmerkeissä sekä kaupunkien alkamisen ja

päättymisen näyttäviissä merkeissä, koko ja ulkonäkö voivat vaihdella huomattavasti, jolloin tunnistaminen on hankalampaa. [2] Nämä erot korostuvat erityisesti, jos yritetään tunnistaa vain muutamia pienen vaihtelun liikennemerkkejä. Tällöin eroa useampia merkkejä tunnistaviin malleihin tulee lisäksi myös pienemmästä luokkien määrästä, jolloin tulokset voivat antaa liian hyvän kuvan mallin todellisesta suoriutumuksesta.

Datassa olevien erojen lisäksi tuloksiin vaikuttavat huomattavasti liikennemerkkien tunnistamiseen käytettävä malli. Vaikka mallien toimintaperiaatteet olisivat samankaltaisia voi niiden suorituskyvyissä olla huomattavia eroja. Myös samojen mallien tuloksissa voi olla merkittäviä eroja käytetyn aktivaatiofunktion takia. [16] Mallin valinnassa pitää huomioida myös koulutusdatan määrä, sillä suuremmat mallit tarvitsevat enemmän koulutusdataa, jolloin datan riittämättömyys voi johtaa heikompiin tuloksiin.

Tutkimusten tavoitteet eroavat myös tunnistusympäristön osalta. Liikennemerkkejä voidaan yrittää tunnistaa joko oikean maailman kuvista, joissa liikennemerkit ovat osa ympäristöä, tai valmiiksi rajatuista kuvista. Rajattujen liikennemerkkien tunnistaminen on huomattavasti helpompaa, sillä siinä ei tarvitse etsiä liikennemerkkiä kuvasta.

Näiden erojen vaikutuksia voidaan rajata helpoiten vertailemalla samankaltaisia tutkimuksia. Kuitenkin vaikka tutkimukset olisivat samankaltaisia, eivät ne ole toistensa kopioita. Tällöin erojen vaikutus pitää aina huomioida. Helpoin tapa vertailuun on käydä tuloksia läpi isompana kokonaisuutena, jolloin saa laajemman kuvan eri tekniikoiden hyvistä ja huonoista puolista.

Tulosten vertailtavuutta voidaan kuitenkin parantaa käyttämällä standardoituja metriikoita. Yksi yleisesti käytetty metriikka on keskimääräinen tarkkuus (mean average precision, mAP). Tästä käytetään kahta eri versiota: mAP50 ja mAP50-95. Näissä molemmissa metriikoissa arvioidaan mallin kykyä sekä havaita että luokitella kohteet oikein. Vähemmän vaativa mAP50 määrittelee tuloksen oikeaksi, kun havaitun ja oikean kappaleen pinta-alat ovat vähintään 50 % päällekkäin (intersection over union, IoU). Vastaavasti vaativampi mAP50-95 sisältää useita kynnyksiarvoja, joilla tulos luokitellaan oikeaksi, yhden sijasta. Kynnyksiarvoja on 50 %:sta ylöspäin viiden prosentin välein aina 95 %:iin asti. [2]

Näiden mAP-metriikoiden tulokset lasketaan mallien tarkkuuden ja herkkyyden avulla. Tarkkuus kuvaa kuinka tarkkoja mallin antamat ennustukset ovat, ja se määritellään:

$$Tarkkuus = \frac{TP}{TP+FP}, \quad (1)$$

missä TP on oikeiden tunnistusten määrä ja FP on värien tunnistusten määrä. Herkkyys puolestaan kuvaa kuinka hyvin kaikki kohteet löydetään, ja se määritellään:

$$Herkkyys = \frac{TP}{TP+FN}, \quad (2)$$

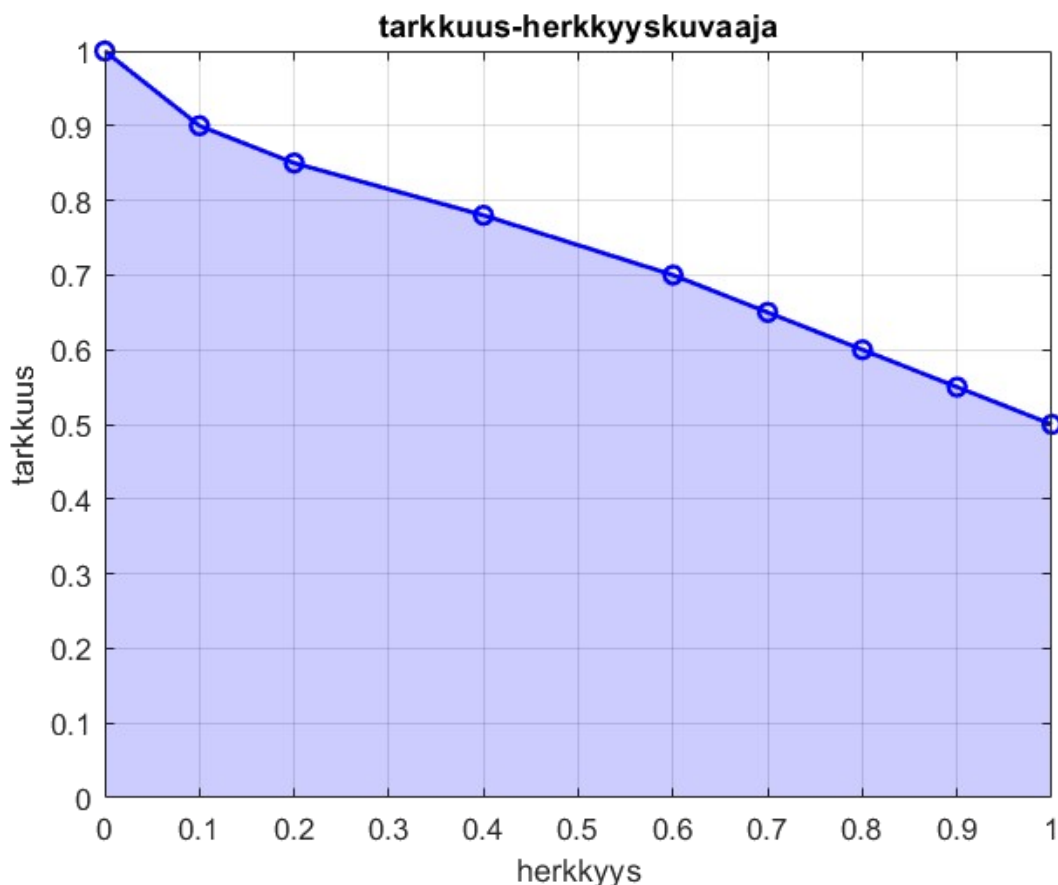
Missä TP on oikeiden tunnistusten määrä ja FN on väärin havaittujen määrä. Näistä saaduista arvoista tehdään tarkkuus-herkkyyskuvaaja erikseen jokaiselle tunnistettavalle luokalle.

Tarkkuus-herkkyyskuvaaja sekä siitä saatu keskimääräinen tarkkuus on esitetty kuvassa 3.

Tämän kuvaajan alle jäävää pinta-alaa kutsutaan luokan keskimääräiseksi tarkkuudeksi (average precision, AP). mAP50-95-metriikassa keskimääräinen tarkkuus saadaan tekemällä tarkkuus-herkkyyskuvaaja jokaiselle kynnyksarvolle ja laskemalla näiden tulosten keskiarvo.

Molemmissa metriikoissa lopullinen tulos saadaan laskemalla luokkien keskimääräisistä tarkkuuksista keskiarvo. [2]

Näistä kahdesta metriikasta mAP50 on huomattavasti suositumpi. Molemmat metriikat kuitenkin antavat laajan kuvan mallin kokonaissuorituksesta, mikä helpottaa tulosten vertailua. On kuitenkin huomattava, ettei mAP-metriikkaa voida käyttää, jos tutkimuksen tavoitteena on pelkkä liikennemerkkien luokittelu ilman niiden paikantamista kuvasta.



Kuva 3. Yhden tunnistettavan luokan tarkkuus-herkkyyskuvaaja, missä kuvaajan alle jäävä pinta-ala on kyseisen luokan keskimääräinen tarkkuus. Kuvan esimerkin kuvaajan alle jäävä pinta-ala eli keskimääräinen tarkkuus (AP) on noin 0.701 eli 70.1 %.

3.2 Tutkimustuloksia siirto-oppimisesta

Erilaisia tutkimuksia siirto-oppimisen hyödyntämisestä liikennemerkkien tunnistamisessa on runsaasti saatavilla. Näiden tulokset kuitenkin vaihtelevat merkittävästi. Tässä luvussa esitellään tarkemmin joitain keskeisiä tutkimuksia, joiden vertailun kautta pyritään selvittämään, miten eri tekijät vaikuttavat siirto-oppimisen tehokkuuteen liikennemerkkien tunnistuksessa.

Tarkemmin tutkittaviksi valikoitui kuusi erilaista tutkimusta (taulukko 3). Tutkimukset valittiin niin, että saadaan mahdollisimman laajasti erilaisia tulokseen vaikuttavia tekijöitä. Näin eri menetelmistä pystytään saamaan yleiskuva niiden soveltuvuudesta liikennemerkkien tunnistukseen. Kuten luvussa 3.1 todettiin tuloksiin vaikuttaa todella moni asia, joten vertailua ei pystytä tekemään pelkästään vertailemalla yksittäisiä numeroita. Lisäksi vertailussa pitää myös huomioida tulosten erojen merkitys suuremmilla tarkkuuksilla. Esimerkiksi tarkkuuden

noustaessa 94 %:sta 97 %:iin on näiden tulosten välinen ero vain kolme prosenttiyksikköä, mutta mallin tekemien virheiden määrä puolittuu. Vastaavasti pienemmillä arvoilla tuloksen noustaessa 50 %:sta 53 %:iin virheiden määrä pienenee 6 prosenttia.

Taulukko 3. Tutkimukset liikennemerkkien tunnistamisesta siirto-oppimalla ja niiden keskeiset tiedot

Tutkimus	Malli	Kohdedata	Tulokset	Muita huomioita
Tabernik ym. [2]	Faster R-CNN, Mask R-CNN sekä itse paranneltu Mask R-CNN	5254 kuvaa, 200 luokkaa, (Slovenia)	Faster R-CNN: 92,4 %, Mask R-CNN: 95,2 %, Muokattu Mask R-CNN: 95,5 % (mAP50)	mAP50-95 tulokset: 80,4–84,4 %
Nafaa ym. [17]	YOLOv5 ja YOLOv8	39 209 + 900 kuvaa, 9 luokkaa (Saksa)	YOLOv5: 96,9 %, YOLOv8: 94,8 % (mAP50)	16 ja 64 kuvan eräkoolla ei merkittävää vaikutusta tulokseen.
Nacir ym. [18]	YOLOv5	Saksa: 39 209 + 900 kuvaa, 4 luokkaa	YOLOv5: 90,5 % (mAP50), Pelkkä luokittelu rajatuista kuvista: 94,5 %	YOLOv5 esikoulutettiin 39 209 kuvan liikennemerkki-aineistolla ja hienosäädettiin 900 kuvalla liikenteestä.
Sarku ym. [4]	ResNet18, ResNet50 ja ResNet152	672 kuvaa, 3 luokkaa (Yhdysvallat)	ResNet18: 60 %, ResNet50: 93 %, ResNet152: 33 % (luokittelu-tarkkuus)	Data oli itse kerättyä. Eikä tutkimuksessa tehty data-augmentaatiota
Doherty ym. [16]	YOLOv5 ja BiFPN-YOLO useilla eri aktivaatio-funktiolla	määriä ei kerrottu, kyseessä kuitenkin sama aineisto kuin tutkimuksissa [17] ja [18] (Saksa)	YOLOv5: 95,6–98,0 % BiFPN-YOLO: 97,2 %–98,2 % (mAP50)	Hienosäädössä säädettiin vain 15:sta kerroksen painoja.
Amruth ym. [13]	ResNet-18, ResNet-34, VGG-19	6164 kuvaa, 58 luokkaa (Kiina)	ResNet-18: 60,65 % ResNet-34: 58,16 % VGG-19: 3,98 % (mAP50)	Vaikka tulokset ovat mAP50-tuloksia olivat kuvat kohtalaisen rajattuja.

Kuten taulukosta 3 nähdään, ylivoimaisesti suosituin kohdedata on Saksasta löytyvä aineisto, jonka suosiota selittää sen suuri koko ja kohtalaisen hyvä laatu. Aineisto on kuitenkin luokkajakaumaltaan epätasapainoinen, sillä yleisistä merkeistä on jopa yli 2000 kuvaa, kun taas harvinaisista merkeistä kuvia on vain noin 250. [17] Tätä eroa on kuitenkin mahdollista pienentää tai jopa kokonaan poistaa data-augmentaation avulla. Sen hyödyntäminen olikin yleistä kaikilla data-aineistoilla, sillä vain tutkimuksessa [4] sitä ei käytetty.

Tutkimuksissa saadut tulokset osoittavat selkeästi käytetyn mallin merkityksen suorituskykyyn, sillä jopa saman tutkimuksen sisällä eri mallien välillä voi olla huomattavia eroja. Tämä näkyy hyvin tutkimuksessa [2], missä Tabernik ym. saivat Faster R-CNN-mallille tuloksen 92,4 % kun heidän parantelemansa Mask R-CNN sai tulokseksi 95,5 %. Ero on huomattavan suuri, sillä Mask R-CNN tekee noin 40 % vähemmän virheitä. Sama voidaan huomata Sarku ym. [4] tekemästä tutkimuksesta, jossa ResNet-verkot saivat huomattavasti toisistaan eroavia tuloksia 33 %:sta 93 %:iin.

Kohdedatasta aiheutuvia eroja on selkeästi vaikeampi hahmottaa näiden erojen ollessa yleensä pieniä. Kuitenkin suurimmat erot ovat mahdollisia huomata helpommin, sillä ne johtuvat usein datan määrästä. Etenkin tutkimuksessa [4] käytetty hyvin pieni datamäärä, ilman data-augmentaatiota, heikentää tuloksia selvästi. Vaikka ResNet18:n saama 60 % luokittelutarkkuus on linjassa Amruth ym. [13] saaman tuloksen 60,65 % kanssa, ovat jälkimmäisen tutkimuksen tulokset kuitenkin vaativampia mAP50-tuloksia. Datan puute korostuu etenkin suuremmissa verkoissa, sillä verkoista suurin ResNet152 sai selvästi heikoimman tuloksen 33 %.

Kohdedataa ei kuitenkaan aina tarvita kovinkaan suuria määriä, sillä kuvia voidaan luoda lisää data-augmentaatiolla. Tästä hyvä esimerkki on tutkimus [2], jossa lähdedataa ei ollut kuin 5254 kuvaa 200 luokasta. Ilman data-augmentaatiota kuvia siis on keskimäärin vain noin 26 kappaletta yhdestä luokasta. Määrä on niin pieni, että se ei todennäköisesti riittäisi kuin korkeintaan kohtalaisiin tuloksiin.

Esikoulutusstrategiat vaihtelevat tutkimuksittain ja ne voidaan jakaa kolmeen ryhmään: valmiiksi esikoulutettujen mallien hyödyntäminen, mallien esikouluttaminen itse yleisellä aineistolla, sekä mallien esikoulutus liikennemerkkidatalla. Kahden ensimmäisen lähestymistavan välisiä eroja on vaikea vertailla, eikä niissä todennäköisesti ole suuria eroja. Nämä kaksi tapaa olivatkin ylivoimaisesti suosituimmat, sillä kaikissa muissa paitsi tutkimuksessa [18] käytettiin jompaakumpaa näistä tavoista. Esikouluttaminen liikennemerkeillä eroaa näistä kahdesta menetelmästä sen verran, että vertailu on mahdollista ja järkevää.

Nacir ym. [18] käyttivät Saksan liikennemerkkiaineistoa esikoulutukseen ja hienosäätivät mallia 900 liikenteestä otetun kuvan avulla. Lopullinen tulos YOLOv5-mallille 90,5 % ei ole kovinkaan hyvä. Hyvä vertailukohta on Nafaa ym. [17] saama 96,9 % tulos samalle YOLOv5-mallille. Heidän mallinsa oli esikoulutettu ImageNetin aineistolla ja sitä

hienosäädettiin samalla Saksasta löytyvällä aineistolla kuin mitä Nacir ym. käyttivät. Liikennemerkkiaineistolla esikoulutettu malli teki siis yli 3 kertaa enemmän virheitä.

Nacir ym. mainitsivat myös mallin tarkkuuden 98,4 % ja herkkyyden 89,3 %. Malli siis huomasi vain noin yhdeksän kymmenestä liikennemerkestä, mutta luokitteli melkein kaikki huomatuksi liikennemerkit oikein. Luokittelu siis toimi hyvin, mikä viittaisi liikennemerkkidatan toimivuuteen esikoulutuksessa. Luokittelua tehtiin kuitenkin vain neljään luokkaan, mikä helpottaa sitä huomattavasti. Huono herkkyys taas viittaa vahvasti riittämättömään koulutusdataan, jolloin malli ei osaa erottaa liikennemerkkejä ympäristöstä tehokkaasti. Koulutukseen tarvitaan kuitenkin runsaasti dataa, sillä malli sisältää 224 kerrosta ja 7062001 parametria. Suuremmalla data-aineistolla tämä voisi olla toimiva lähestymistapa, mutta näin pienillä määrillä tämä ei ole järkevää.

Hienosäädön ja piirteiden poiminnan eroja tutkittiin tutkimuksissa [4] ja [16]. Sarku ym. [4] raportoivat jokaisen mallin saaneen testauksessa täysin identtiset tulokset sekä hienosäädöllä että piirteiden poiminnalla. Tämä vaikuttaa epätodennäköiseltä, sillä sekä koulutus- että validointivaiheissa raportoitiin muutaman prosenttiyksikön parempia tuloksia hienosäädölle. Lisäksi ResNet18- ja ResNet152-mallien huonojen tulosten identtisyys hienosäädöllä sekä piirteiden poiminnalla on erittäin epätodennäköistä.

Doherty ym. [16] saamat tulokset ovatkin täysin erilaisia. Heidän ilmoittamansa mAP50-tulokset hienosäädölle olivat YOLOv5-mallilla 36,1–65,5 prosenttiyksikköä suuremmat riippuen käytetystä aktivaatiofunktioista. BiFPN-YOLO-mallilla erot olivat hieman pienemmät: 38,4–53,4 prosenttiyksikköä hienosäädön eduksi. Nämä tulokset eroavat huomattavasti Sarku ym. [4] saamista tuloksista, mikä osaltaan vahvistaa arviota tuon tuloksen virheellisyydestä.

Koulutuksen parametreista ei anneta tutkimuksissa kovinkaan paljoa tietoa. Yleisin mainittu parametri on koulutuskertojen määrä, mikä on noin sata jokaisessa tutkimuksessa, missä määrä mainitaan. Edes eräkokoja ei mainittu suurimmassa osassa tutkimuksia. Kuitenkin tutkimuksessa [17] verrattiin 16 ja 64 kuvan eräkokoja. Näillä ei kuitenkaan ollut merkittäviä vaikutuksia tuloksiin, sillä YOLOv5 sai 64 kuvan eräkoolla 0,8 prosenttiyksikköä paremman tuloksen, mutta YOLOv8 sai 0,2 prosenttiyksikköä huonomman tuloksen.

Koulutuksessa ei myöskään aina onnistu halutulla tavalla. Tutkimuksessa [13] Amruth ym. saivat käyttämälleen VGG-19-mallille mAP50-tulokseksi vain 3,98 %. Samoin

koulutusvaiheen aikana saavutettu 6,5 %:n tarkkuus on todella huono, mikä kertoo mallin oppivan liikennemerkkien piirteitä todella huonosti. He antavat huonolle tulokselle syyksi VGG-19-mallin sopimattomuuden liikennemerkkien tunnistamiseen. Tämä selitys ei kuitenkaan vaikuta kovinkaan uskottavalta, sillä samalla mallilla on saavutettu 95% luokittelutarkkuuksia samalla ennustettavien luokkien määrällä [19]. Tutkimuksessa ei mainita tarkemmin esikoulutuksessa käytettyä aineistoa, mutta erityisesti koulutusvaiheen heikko tarkkuus viittaa negatiiviseen siirtoon. Samassa tutkimuksessa ResNet-18 ja ResNet-34 saavat kuitenkin huomattavasti paremmat tulokset 60,65 % ja 58,16 %. Nämäkin tulokset eivät kuitenkaan ole suuria, joten kohdedatan vähyys tai muut ominaisuudet todennäköisesti vaikuttivat heikentävästi tulokseen.

On myös syytä huomata, että mallien todellinen suorituskyky voi olla heikompi kuin pelkästä mAP50-tuloksesta voisi päätellä. Tämä käy ilmi tutkimuksessa [2] esitetyistä mAP50-95-tuloksista. Vaikka Faster R-CNN saavutti mAP50-arvon 92,4 %, oli mAP50-95-tulos vain 80,4 %. Mask R-CNN -mallilla vastaavat luvut olivat 95,5 % ja 84,4 %. Tämä korostaa, että vaikka mallit näyttävät erittäin tehokkailta helpomman metriikan perusteella, suorituskyky vaativammassa olosuhteissa on selvästi matalampi. Toisaalta, käytännön liikennemerkkien tunnistuksessa mAP50-tarkkuus on usein riittävän hyvä, koska pieni sijainnin epätarkkuus ei yleensä haittaa lopputulosta merkittävästi.

4 Siirto-oppimisen ja suoraan kouluttamisen vertailu

Liikennemerkkien tunnistukseen käytettävät neuroverkkojen koulutusmenetelmät voidaan jakaa karkeasti kahteen eri kategoriaan: siirto-oppimiseen ja suoraan kouluttamiseen. Tässä luvussa verrataan näitä kahta lähestymistapaa ja arvioidaan niiden suorituskykyeroja tutkimustulosten avulla.

Jo pelkästään siirto-oppimismenetelmien keskinäinen vertailu on haasteellista, mutta vertailu suoraan koulutettujen mallien kanssa lisää haastavuutta entisestään. Yksi keskeinen vaikeus on se, että suoraan koulutukseen perustuvia tutkimuksia on huomattavasti vähemmän kuin siirto-oppimista hyödyntäviä tutkimuksia. Tämän takia tutkimuksia, joissa tehtiin suoraan kouluttamista, valikoitui vain kolme. Nämä tutkimukset on esitelty taulukossa 4. Tästä huolimatta voidaan olemassa olevien tutkimusten tulosten avulla tehdä johtopäätöksiä näiden menetelmien tehokkuudesta.

Taulukko 4. Tutkimukset liikennemerkkien tunnistuksesta suoraan kouluttamalla ja niiden keskeiset tiedot

Tutkimus	Malli	Kohdedata	Tulokset	Muita huomioita
Sreeja ym. [6]	Konvoluutioverkko sekä paikallisten binäärikuvioita hyödyntävä konvoluutioverkko	Intia: 4170, 57 luokkaa	Suoraan kouluttamalla: 95 pelkkä konvoluutio % ja 96 % binäärikuvioita hyödyntämällä. Siirto-oppimisella 98 % (pelkkä luokittelu)	Tutkimuksessa tavoite oli vain luokitella liikennemerkkejä, ei löytää niitä.
Doherty ym. [16]	YOLOv5 ja BiFPN-YOLO useilla eri aktivaatio-funktiolla	Saksa: määriä ei kerrottu, kyseessä kuitenkin sama aineisto kuin tutkimuksissa [17] ja [18]	YOLOv5: 87,8–97,5 % BiFPN-YOLO: 90,6 %–97,7 % (mAP50)	Tutkimuksessa saadut tulokset siirto-oppimiselle näkyvät taulukossa 3.
Wang ym. [20]	Paranneltu YOLOv5-S, YOLOv5-M, Faster R-CNN ja YOLOv8-M,	Kiina: 8941 kuvaa, 45 luokkaa	Paranneltu YOLOv5-S: 85,2 % YOLOv5-M: 82,8 % Faster R-CNN: 64,3 % YOLOv8-M: 87,1 %	Tutkimuksessa on annettu myös muiden YOLO-mallien tuloksia.

Näiden menetelmien vertailua helpottaa tutkimuksissa [6] ja [16] olevat tulokset sekä suoraan kouluttamalla että siirto-oppimisella. Näiden tulosten vertaaminen pienentää muiden tekijöiden vaikutusta ja näin helpottaa vertailua.

Sreeja ym. [6] vertailivat siirto-oppimista kahteen alusta asti koulutettuun konvoluutioverkkoon. Näistä toinen oli tavanomainen konvoluutioverkko, kun taas toinen käytti paikallisia binäärikuvioita (Local Binary Pattern, LBP). Siirto-oppimisella saavutettu 98 % luokittelutarkkuus oli selvästi parempi kuin suorilla koulutuksilla saavutetut tulokset 95 % ja 96 %. On kuitenkin huomioitava, että tutkimuksessa arvioitiin ainoastaan liikennemerkkien luokittelua valmiiksi rajatuista kuvista, mikä on huomattavasti helpompi tehtävä kuin kokonaisvaltainen tunnistus. Vaikka datan tarve yksinkertaisessa luokittelussa on pienempi, osoittautui siirto-oppiminen silti tehokkaammaksi.

Jo luvussa 3.2 käsitellyssä tutkimuksessa [16] annettiin myös suoraan kouluttamalla saatuja tuloksia YOLOv5:lle sekä BiFPN-YOLOlle. Erot mAP50 tuloksissa suoraan koulutetulla sekä hienosäädetyllä mallilla olivat YOLOv5 mallilla 0,5–4,5 prosenttiyksikköä parempia riippuen käytetystä aktivaatiofunktioista, parhaiden tulosten ollessa 97,2 % suoraan kouluttamisella ja 98,0 % siirto-oppimisella. Vastaavasti BiFPN-YOLO-mallilla erot olivat hieman suuremmat 0,1–6,6 prosenttiyksikköä siirto-oppimisen eduksi, parhaiden tulosten ollessa 97,7 % ja 98,2 %. Siirto-oppimalla saatiin siis toistuvasti parempia tuloksia, vaikka Saksan liikennemerkkiaineisto on kooltaan suuri verrattuna moniin muihin liikennemerkkiaineistoihin.

Samansuuntaisia päätelmiä voidaan myös johtaa Wang ym. [20] tekemästä tutkimuksesta, missä he kouluttivat parantelemaansa YOLOv5-S mallia. Tutkimuksessa saavutettu mAP50-tulos 85,2 % on huomattavasti pienempi kuin mitä siirto-oppimisella saatiin tutkimuksissa [17] ja [18]. Tutkimuksessa on myös useiden muiden mallien tuloksia, kuten Faster R-CNN saama tulos 64,3 %, mikä on myös huomattavasti pienempi kuin tutkimuksessa [2] saatu tulos.

Käytännössä myös kaikki muut tutkimukset antavat samansuuntaisia tuloksia, joten voidaan sanoa siirto-oppimisen olevan parempi lähestymistapa kuin suora kouluttaminen liikennemerkkien tunnistamisessa. Suurin syy tähän on rajallisesti saatavilla oleva data, mikä rajoittaa suoraan kouluttamista huomattavasti. Datamäärän kasvaessa erot todennäköisesti ainakin kaventuvat ja suoraan kouluttamalla voidaan mahdollisesti saada jopa parempia tuloksia.

5 Pohdinta

Siirto-oppiminen on osoittautunut erityisen suosituksi menetelmäksi liikennemerkkien tunnistamisessa. Siirto-oppiminen soveltuukin erinomaisesti liikennemerkkien tunnistukseen saatavilla olevan datan rajallisuuden takia ja etenkin hienosäätömenetelmää käyttämällä saavutetaan merkittävästi parempia tuloksia kuin mallien suoralla kouluttamisella. Siirto-oppimisen avulla saadut tulokset kuitenkin vaihtelevat huomattavasti, riippuen käytetystä mallista, aineistosta ja menetelmän toteutustavasta. Tämä osoittaa, ettei siirto-oppiminen yksinään takaa hyviä tuloksia, vaan onnistunut lopputulos edellyttää myös huolellisesti valittuja mallirakenteita, datan esikäsittelyä.

Tutkimusten rakenteet myös heijastavat tätä näkökulmaa. Siirto-oppimista käsitellään usein vain pintapuolisesti tai se voidaan jopa ohittaa kokonaan. Joissain tutkimuksissa ei edes mainittu siirto-oppimista sanallakaan, vaikka sitä käytettiin tutkimuksessa [2]. Siirto-oppimisen sijaan painotus oli tutkimuksessa käytettävässä datassa ja sen esikäsittelyssä sekä käytetyissä malleissa ja niiden toimintaperiaatteissa. Tuloksetkin kerrotaan vain tiiviisti tutkimusten lopussa usein ilman syvällisempää analyysiä tai johtopäätöksiä. Tutkimukset siis selvästi painottuvat datan ja mallien ympärille, mikä viittaa niiden suureen vaikutukseen tuloksissa, kuten luvussa 3.2 huomattiin. Rakennetta kuitenkin osittain selittää julkaisujen tyyppi, sillä valtaosa tutkimuksista on konferenssijulkaisuja. Tällöin kaikkea ei ehditä käsitellä tutkimuksessa kovinkaan laajasti. Konferenssijulkaisujen yleisyys myös kertoo alan nopeasta kehitymisestä, jolloin tutkimukset pitää saada nopeasti ulos ilman laajempia kuvauksia ja analyysejä.

Tutkimusten tavoitteet keskittyivät usein pelkästään liikennemerkkien luokitteluun rajatuista kuvista. Tämä ei kuitenkaan riitä autonomisessa ajamisessa, sillä liikennemerkit pitäisi myös löytää liikenteessä liikkeessa. Tarkka luokittelu luo kuitenkin hyvän pohjan laajemman järjestelmän kehittämiseen.

Yksi syy pelkän luokittelun yleisyyteen voi olla siitä saatavat paremmat tulokset, sillä tehtävä on huomattavasti yksinkertaisempi kuin liikennemerkkien havaitseminen ja tunnistaminen. Pelkässä luokittelussa saadaan myös huomattavasti parempia tuloksia. Yli 99,5 % prosentin tarkkuuksia on saatu useammassa tutkimuksessa [15]. Sama ilmiö luokittelun helppoudesta nähdään myös tutkimuksissa, joissa liikennemerkit pitää havaita. Esimerkiksi Nacir ym. [18]

saivat tutkimuksessaan mallin tarkkuudeksi 98,4 %, mutta herkkyys oli vain 89,3 %. Eli havaitut liikennemerkit saatiin oikein, mutta niiden havaitseminen oli haastavaa.

Siirto-oppimista sovellettiin tutkimuksissa suurin piirtein samalla tavalla, eikä erilaisia kokeiluja oikeastaan tehty. Tämä näkyy hyvin, jos tutkimuksissa käytetyt siirto-oppimiset luokitellaan luvussa 2.3 esiteltyihin kategorioihin. Tällöin kaikki läpikäydyt tutkimukset voidaan luokitella induktiiviseksi siirto-oppimiseksi. Tämä oli kuitenkin odotettu tulos, sillä näistä luokista se soveltuu parhaiten liikennemerkkien tunnistukseen. Toinen syy induktiivisen siirto-oppimisen yleisyyteen on tutkimusten aiheet. Tutkimuksissa yritettiin aina kehittää uusi toimiva malli, eikä esimerkiksi käytetty jo valmiiksi liikennemerkkejä tunnistavia malleja, joita olisi voinut kehittää eteenpäin. Tällöin transduktiivista siirto-oppimista ei kannata hyödyntää. Myöskään valvomatonta siirto-oppimista ei käytetty. Syy tähän voi olla sen soveltumattomuus, mutta myös yleisten data-aineistojen valmis luokittelu poistaa tarpeen hyödyntää sitä. Tämän takia valvomatonta siirto-oppimista olisi voinut hyödyntää lähinnä tutkimuksissa, joissa data kerättiin itse. Tällaisia tutkimuksia ei kuitenkaan ollut kovinkaan montaa, eikä näissä muutamissa tutkimuksissa kuitenkaan hyödynnetty valvomatonta siirto-oppimista, vaikka se olisi poistanut datan luokittelun tarvetta ainakin osittain. Tämä viittaisi sen soveltumattomuuteen liikennemerkkien tunnistuksessa.

Tutkimusten samankaltaisuus ei edistä alan tutkimusta läheskään yhtä paljoa kuin vaihtelevammat tutkimukset. Tällä hetkellä tutkimuksissa ei ole oikeastaan mitään uutta, mitä joku toinen ei olisi jo tehnyt. Kuitenkin uudet ideat ja keksinnöt voisivat viedä alan tilanteeseen, jossa oikeasti toimivia ja luotettavia liikennemerkkien tunnistusjärjestelmää pystyttäisiin kehittämään.

Suurimmat vaikutukset tutkimustuloksiin aiheuttivat käytetty koulutusmenetelmä, malli, kohdedata ja sen määrä, laatu ja mahdollinen data-augmentaatio sekä ennustettavien luokkien määrä. Näiden lisäksi useat muut tekijät vaikuttavat tuloksiin, mutta näiden arvioiminen tarvitsisi huomattavasti suuremman otannan tutkimuksia. Tällaisia tekijöitä ovat esimerkiksi kuvien resoluutiot, koulutuskertojen määrä, lähdedata, satunnaisuus sekä koulutuksen tai lopputuloksen mahdollinen optimointi.

Kahdesta eri siirto-oppimisen koulutustavasta hienosäätö osoittautui läpikäydyissä tutkimuksissa piirteiden poimintaa tehokkaammaksi siirto-oppimisen menetelmäksi. Tämä oli odotettu lopputulos, sillä siinä suurta osaa tai kaikkia mallin parametreja optimoidaan liikennemerkkien tunnistamiseen. Hienosäädön huonona puolena on kuitenkin sen suurempi

datan tarve, verrattuna piirteiden poimintaan. Tulosten perusteella vapaasti saatavilla olevat liikennemerkkiaineistot ovat kuitenkin tarpeeksi suuria hienosäädön käyttämiseen.

Suuremmilla data-aineistoilla saavutettiin kuitenkin hieman parempia tuloksia, mikä viittaa tulosten mahdolliseen paranemiseen vielä suuremmilla data-aineistoilla.

Vaikka tulokset vaihtelevat tutkimusten välillä, on siirto-oppimista hyödyntämällä saavutettu toistuvasti parempia mAP50-tuloksia kuin suoraan kouluttamalla. Suurin syy tähän on yksinkertaisesti saatavilla olevan datan rajallisuus. Jos koulutuksessa käytettävää dataa olisi saatavilla huomattavasti enemmän ei näiden menetelmien välillä todennäköisesti olisi kovinkaan suurta eroa [21]. Tutkimuksia liikennemerkkien tunnistamisesta alusta asti koulutetulla mallilla on huomattavasti vähemmän saatavilla, eikä kirjallisuuskatsausta tehtäessä löytynyt yhtään missä olisi käytetty menetelmän vaatimaa huomattavasti suurempaa data-aineistoa. Tämän takia ei pystytä sanomaan varmuudella saako siirto-oppimista hyödyntämällä parempia tuloksia liikennemerkkien tunnistamisessa kuin alusta alkaen kouluttamisella, kun datan määrä kasvaa todella suureksi. Kuitenkin muiden alojen tulokset viittaavat erojen kaventumiseen datan lisääntyessä [21].

Parhaan tuloksen läpikäydyissä tutkimuksissa siirto-oppimista hyödyntämällä sai Doherty ym. [16]. Heidän mAP50-tuloksensa 98,2 % BiFPN-YOLO-mallille ja 98,0 % YOLOv5-mallille ovat jo todella hyviä. Tämä tulos on kuitenkin yllättävä, sillä kyseessä ei ollut pelkästään liikennemerkkien tunnistamiseen keskittynyt tutkimus. He saivat kuitenkin eri aktivaatiofunktioilla myös hieman heikompia tuloksia, joista heikoin 95,6 % on jo heikompi kuin Nafaa ym. [17] saama tulos 96,9 %. Oikealla aktivaatiofunktioilla voi siis saada merkittäviä hyötyjä. Parhaat aktivaatiofunktiot kuitenkin vaihtuivat mallien ja koulutusmenetelmien vaihtuessa, mikä vaikeuttaa niiden vaikutusten arviointia. Aktivaatiofunktioiden vaikutusta ei kuitenkaan otettu huomioon yhdessäkään toisessa tutkimuksessa. Yksi mahdollinen syy tähän voi olla tavoite saada tutkimus ulos mahdollisimman nopeasti, jolloin koulutusta ja testausta ei ehditä tekemään usealla eri aktivaatiofunktioilla. Toinen mahdollinen syy on koko asian ohittaminen tarkoituksella tai tietämättömyyttään.

Myös useissa muissa tutkimuksissa päästiin yli 95 % mAP50-tuloksiin useilla eri malleilla. Toisaalta joukossa oli myös huomattavasti heikompia tuloksia kuten Sarkun ym. [4] saama 33 % tulos liikennemerkkien luokittelussa. Tulokset siis vaihtelevat paljon, vaikka tutkimukset ovat keskenään suhteellisen samankaltaisia. Tämä vahvistaa päätelmää siitä, että siirto-

oppiminen on hyödyllinen osa laajempaa kokonaisuutta, eikä mikään yksittäinen tekniikka, millä saisi automaattisesti hyviä tuloksia.

Parhaat tulokset tämän kirjallisuuskatsauksen perusteella saa, kun hyödyntää mahdollisimman kykeneviä malleja. Nämä mallit ovat kuitenkin suuria ja tarvitsevat paljon dataa. Data-aineistoksi kannattaa siksi valita mahdollisimman laaja aineisto, kuten useassa tutkimuksessa käytetty Saksan liikennemerkkiaineisto. Tämäkään aineisto ei itsestään ole tarpeeksi suuri, joten data-augmentaatiolla pitää luoda mahdollisimman paljon uusia kuvia. Mallin esikoulutus kannattaa tehdä isoimmalla kuva-aineistolla mitä on käytettävissä, huomioiden kuitenkin negatiivisen siirron mahdollisuuden. Lisäksi aktivaatiofunktiolla voidaan parantaa tai huonontaa tulosta merkittävästi. Näistä ei kuitenkaan ole kovinkaan paljoa tutkimustietoa liikennemerkkien tunnistamisessa, mikä on suuri puute.

Vaikka siirto-oppiminen näyttäytyy tämän kirjallisuuskatsauksen perusteella lupaavalta lähestymistavalta liikennemerkkien tunnistukseen, on kuitenkin huomioitava, että tutkimukset ovat todennäköisesti tämän hetken parhaita liikennemerkkien tunnistusjärjestelmiä jäljessä, sillä monet suuret teknologiayritykset kehittävät omia liikennemerkkien tunnistusjärjestelmiään, mutta näiden yksityiskohdat eivät ole julkisesti saatavilla.

Suurista teknologiayrityksistä Waymo on jo aloittanut robottitaksitoiminnan ja Tesla on ilmoittanut aloittavansa oman palvelunsa kuluvan vuoden aikana, mikä osoittaa tunnistusjärjestelmien olevan erittäin korkealla tasolla [22][23]. Robottitaksit eivät olisi mahdollisia, jos ne eivät tunnistaisi liikennemerkkejä todella tarkasti. Lisäksi autonomisten ajoneuvojen järjestelmät ovat todennäköisesti myös paljon laajempia, kuin mitä tutkimuksissa käytetyt mallit ovat. Autonomisessa ajamisessa ei riitä pelkästään liikennemerkkien tunnistaminen kuvista, sillä mallin on toimittava todella luotettavasti osana isompaa kokonaisjärjestelmää, johon kuuluu muun muassa kuvien kerääminen, niiden käsittely sekä päätöksenteko tunnistusten perusteella. Tällaiset laajemmat vaatimukset, kuten järjestelmän nopea toimivuus ja sen integroiminen suurempaan kokonaisuuteen, luovat uusia haasteita ja kriteerejä mallien kehittämiseksi. Nämä kriteerit voivat muuttaa mallien koulutusmenetelmiä, jolloin siirto-oppimisen käyttäminen ei välttämättä ole optimaalista. Lisäksi ei ole tiedossa onko siirto-oppimisella edes mahdollista tuottaa tarpeeksi tarkkoja malleja, jotka voitaisiin liittää osaksi autonomista autoa.

Yksi siirto-oppimisen keskeisistä eduista on sen kyky vähentää vaadittavia resursseja. Kuitenkin resurssien lisääntyessä voi siirto-oppimisesta saatavan hyödyn osuus pienentyä

todella pieneksi tai jopa kadota. Lisäksi resurssien kasvu mahdollistaa entistä suurempien ja monimutkaisempien mallien käytön, mikä voi osaltaan parantaa tuloksia – vaikkakin suuremmilla kustannuksilla. Tällöin parhaat menetelmät voivat erota menetelmistä, jotka toimivat pienemmillä resursseilla.

Toisaalta suuremmat konvoluutioverkot suoriutuivat liikennemerkkien tunnistamisesta keskimäärin paremmin kuin pienemmät konvoluutioverkot, mutta ne tarvitsevat kuitenkin enemmän koulutusdataa saavuttaakseen hyviä tuloksia [2]. Mallien koon kasvaessa datan tarve siis kasvaa koko ajan. Tällöin siirto-oppiminen tarjoaa vielä merkittävämpää etua verrattuna suoraan kouluttamiseen. Lähdedatan määrää on helppo kasvattaa, sillä vapaasti käytössä olevia luokiteltuja kuvia on saatavilla todella paljon. Kohdedataa tarvitaan kuitenkin myös enemmän, mutta sen tarve on huomattavasti pienempi kuin suoraan kouluttamalla.

Näitä huomioita tarkasteltaessa siirto-oppimisen paremmuudesta ei voida tehdä yleistettäviä johtopäätöksiä kaikkiin tilanteisiin. Kuitenkin siirto-oppimisella säästetään huomattavasti resursseja sekä mahdollistetaan monimutkaisempien mallien käyttäminen. Sen avulla on myös saatu järjestelmällisesti parempia tuloksia kuin mallien suoraan kouluttamisella, joten se todennäköisesti on paras menetelmä liikennemerkkien tunnistuksessa käytettyjen mallien koulutukseen tällä hetkellä.

6 Yhteenveto

Tässä kirjallisuuskatsauksessa tarkasteltiin siirto-oppimisen soveltamista liikennemerkkien tunnistukseen ja verrattiin sen suorituskykyä perinteiseen mallin suoraan kouluttamiseen. Tutkimuksessa analysoitiin eri lähestymistapoja ja selvitettiin, mitä tekijöitä on tärkeää huomioida sovellettaessa siirto-oppimista liikennemerkkien tunnistukseen.

Tutkimuksessa huomattiin siirto-oppimisen mahdollistavan olemassa olevien, laajoilla kuva-aineistoilla esikoulutettujen mallien sovittamisen liikennemerkkien tunnistukseen. Siirto-oppimisen koulutustavoista hienosäätö oli suosituimpi ja parempi kuin piirteiden poiminta. Siirto-oppimista kannattaa siis hyödyntää liikennemerkkien tunnistamisessa esikouluttamalla malli suurella data-aineistolla, minkä jälkeen hienosäädetään parametrien arvoja liikennemerkkien kuvilla. Siirto-oppimisessa pitää kuitenkin ottaa myös monia muita asioita huomioon, kuten käytettävä malli sekä data. Tämä vastaa tutkimuskysymykseen 1: Millä tavoin siirto-oppimista kannattaa hyödyntää liikennemerkkien tunnistamiseen?

Siirto-oppiminen osoittautui myös selvästi suoraan kouluttamista paremmaksi koulutusmenetelmäksi, sillä siirto-oppimisen avulla saadut tulokset oli huomattavasti parempia kuin suoraan kouluttamalla [16]. Tämä vastaa tutkimuskysymykseen 2: Parantaako siirto-oppiminen liikennemerkkien tunnistamisen tarkkuutta?

Suurin haaste katsauksessa oli vaihtelevat tutkimustulokset. Hyvin samalta vaikuttavien tutkimusten tuloksissa saattoi olla useiden prosenttiyksiköiden eroja. Tutkimuksissa esiintyi myös usein jonkinlaista tulosten parantelua, kuten liikennemerkkien määrän rajaamista vain muutamaaan. Tällöin tunnistettavat liikennemerkit olivat usein myös valittu niin, että niiden piirteet eroaisivat mahdollisimman paljon toisistaan. Tämä helpottaa tunnistusta huomattavasti ja näin parantaa tulosta. Lisäksi vaikka tutkimuksessa etsittiin liikennemerkkejä kuvista, saattoivat kuvat olla hyvinkin rajattuja, mikä taas helpottaa tehtävää huomattavasti.

Siirto-oppimisen tulevaisuus liikennemerkkien tunnistamisessa näyttää lupaavalta, ja menetelmän suosio tulee todennäköisesti edelleen kasvamaan mallien vaatimusten ja datantarpeen lisääntyessä. Erityisesti koulutusparametreilla ja aktivaatiofunktioilla vaikuttaa tutkimuksen perusteella olevan suuri vaikutus tuloksiin. Näitä ei kuitenkaan ole tutkittu liikennemerkkien tunnistamisessa, joten näiden parametrien systemaattinen tutkimus voisi merkittävästi edistää liikennemerkkien tunnistamisen suorituskykyä ja vähentää tutkimuksia, joissa siirto-oppimista käytetään epäoptimaalisilla asetuksilla.

Lähteet

- [1] B. Hofflinger, G. Conte, D. Esteve, ja P. Weisglas, *Integrated Electronics for Automotive Applications in the EUREKA Program PROMETHEUS. ESSCIRC '90: Sixteenth European Solid-State Circuits Conference*, Grenoble, Ranska, 1990, pp. 13-17.
- [2] D. Tabernik ja D. Skocaj, *Deep Learning for Large-Scale Traffic-Sign Detection and Recognition*, *IEEE Trans. Intell. Transp. Syst.*, vsk. 21, nro 4, ss. 1427–1440, huhti 2020, doi: 10.1109/TITS.2019.2913588.
- [3] E. M. Roumaissae, E. H. Outman, E. M. B. Eddine, M. A. Achhab, S. Adnan, ja A. Zbakh, *Review of a Comparative Survey on the Detection and Classification of Traffic Signs*, teoksessa *2023 7th IEEE Congress on Information Science and Technology (CiSt)*, Agadir - Essaouira, Morokko: IEEE, joulu 2023, ss. 559–565. doi: 10.1109/CiSt56084.2023.10409987.
- [4] E. Sarku, J. Steele, T. Ruffin, B. Gokaraju, ja A. Karimodini, *Reducing Data Costs-Transfer Learning Based Traffic Sign Classification Approach*, teoksessa *SoutheastCon 2021*, Atlanta, GA, USA: IEEE, maaliskuu 2021, ss. 1–5. doi: 10.1109/SoutheastCon45413.2021.9401900.
- [5] M. M. Hammad, *Artificial Neural Network and Deep Learning: Fundamentals and Theory*, Damanhour, Egypti: Damanhour University, 2024.
- [6] B. Sreeja, S. Bokka, G. Shravya, ja K. S. Vidya Vardini, *Traffic Sign Detection using Transfer learning and a Comparison Between Different Techniques*, teoksessa *2022 2nd Asian Conference on Innovation in Technology (ASIANCON)*, Ravet, Intia: IEEE, elokuu 2022, ss. 1–4. doi: 10.1109/ASIANCON55314.2022.9909281.
- [7] A. Hosna, E. Merry, J. Gyalmo, Z. Alom, Z. Aung, ja M. A. Azim, *Transfer learning: a friendly introduction*, *J. Big Data*, vsk. 9, nro 1, s. 102, loka 2022, doi: 10.1186/s40537-022-00652-w.
- [8] M. Iman, H. R. Arabnia, ja K. Rasheed, *A Review of Deep Transfer Learning and Recent Advancements*, *Technologies*, vsk. 11, nro 2, s. 40, maaliskuu 2023, doi: 10.3390/technologies11020040.
- [9] R. Kaur, R. Kumar, ja M. Gupta, *Review on Transfer Learning for Convolutional Neural Network*, teoksessa *2021 3rd International Conference on Advances in Computing*,

- Communication Control and Networking (ICAC3N)*, Greater Noida, India: IEEE, joulu 2021, ss. 922–926. doi: 10.1109/ICAC3N53548.2021.9725474.
- [10] S. J. Pan ja Q. Yang, *A Survey on Transfer Learning*, *IEEE Trans. Knowl. Data Eng.*, vsk. 22, nro 10, ss. 1345–1359, loka 2010, doi: 10.1109/TKDE.2009.191.
- [11] C. Gamez Serna ja Y. Ruichek, *Classification of Traffic Signs: The European Dataset*, *IEEE Access*, vsk. 6, ss. 78136–78148, 2018, doi: 10.1109/ACCESS.2018.2884826.
- [12] B. A. Kumar, M. Majji, H. J. Marni, M. Ateeq, S. Koduru, ja S. M. Maddi, *A Deep Transfer Learning Approach for Enhanced Traffic Sign Recognition in Autonomous Vehicles with NVIDIA Jetson Nano*, teoksessa *2023 International Conference on Sustainable Emerging Innovations in Engineering and Technology (ICSEIET)*, Ghaziabad, India: IEEE, syys 2023, ss. 692–698. doi: 10.1109/ICSEIET58677.2023.10303554.
- [13] A. Amruth, R. Ramanan, C. Vimal, ja B. M. Beena, *Deep Learning Solutions for Real-World Traffic Sign Recognition: A Transfer Learning Approach*, teoksessa *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kamand, India: IEEE, kesä 2024, ss. 1–10. doi: 10.1109/ICCCNT61001.2024.10723999.
- [14] K. Jordan, *On the Variance of Neural Network Training with respect to Test Sets and Distributions*, 10. kesäkuuta 2024, *arXiv*: arXiv:2304.01910. doi: 10.48550/arXiv.2304.01910.
- [15] Mohd Faizaanuddin, Kadiyala Ramana, ja Head, *A Comprehensive Survey of Traffic Sign Detection and Recognition*, 2023, doi: 10.13140/RG.2.2.19809.07525.
- [16] J. Doherty, B. Gardiner, E. Kerr, ja N. Siddique, *BiFPN-YOLO: One-stage object detection integrating Bi-Directional Feature Pyramid Networks*, *Pattern Recognit.*, vsk. 160, s. 111209, huhti 2025, doi: 10.1016/j.patcog.2024.111209.
- [17] S. Nafaa ym., *Advancing Roadway Sign Detection with YOLO Models and Transfer Learning*, teoksessa *2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)*, Mt Pleasant, MI, USA: IEEE, huhti 2024, ss. 1–4. doi: 10.1109/ICMI60790.2024.10586105.
- [18] O. Nacir, M. Amna, W. Imen, ja B. Hamdi, *Yolo V5 for Traffic Sign Recognition and Detection Using Transfer Learning*, teoksessa *2022 IEEE International Conference on*

- Electrical Sciences and Technologies in Maghreb (CISTEM)*, Tunis, Tunisia: IEEE, loka 2022, ss. 1–4. doi: 10.1109/CISTEM55808.2022.10044022.
- [19] T. Mahmud, T. Akter, D. Islam, M. T. Aziz, M. S. Hossain, ja K. Andersson, *Enhanced Traffic Sign Recognition Using Deep Learning Techniques*, teoksessa *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kamand, Intia: IEEE, kesä 2024, ss. 1–6. doi: 10.1109/ICCCNT61001.2024.10725273.
- [20] Z. Wang, W. Luo, X. Li, ja W. Hao, *Traffic Sign Detection Based on Improved YOLOv5-S*, teoksessa *2024 China Automation Congress (CAC)*, Qingdao, China: IEEE, marras 2024, ss. 740–745. doi: 10.1109/CAC63892.2024.10865409.
- [21] K. He, R. Girshick, ja P. Dollár, *Rethinking ImageNet Pre-training*, 21. marraskuuta 2018, *arXiv*: arXiv:1811.08883. doi: 10.48550/arXiv.1811.08883.
- [22] Tesla, Inc., *2025 Q1 Quarterly Update Deck*, Tesla, Palo Alto, CA, USA, 2025. [Verkossa]. Haettu: 5. toukokuuta 2025. Saatavilla: <https://digitalassets.tesla.com/tesla-contents/image/upload/IR/IR/TSLA-Q1-2025-Update.pdf>
- [23] Alphabet Inc., *Annual Report on Form 10-K, Fiscal Year Ended December 31, 2024*, Alphabet Parkway Mountain View, CA, USA, 2024. [Verkossa]. Haettu: 5. toukokuuta 2025. Saatavilla: <https://abc.xyz/assets/77/51/9841ad5c4fbe85b4440c47a4df8d/goog-10-k-2024.pdf>