



Koneoppimistekniikoiden soveltaminen radiografisten kuvien luokitteluun NDT- menetelmissä

Oulun yliopisto
Tietojenkäsittelytiede
LuK-tutkielma
Tomi Heinonen
2023

Tiivistelmä

Tämän tutkielman tarkoituksena oli tutkia tekoälyn ja koneoppimisen tekniikoita teollisuuden NDT-menetelmien parissa. Tutkielman motiivina toimi NDT-tarkastajan tehtävässä hankkimani työkokemus ja sitä kautta syntynyt mielenkiinto alan uusimpia tekniikoita ja virtauksia kohtaan. NDT-menetelmistä keskityttiin erityisesti radiografiseen tarkastukseen ja radiografisten kuvien luokitteluun käytettävien koneoppivien algoritmien käyttöön. Tavoitteena oli tiedon lisääminen oppivien algoritmien mahdollisuuksista radiografisten kuvien tulkinnassa erityisesti pienillä opetusaineistoilla. Tutkielma toteutettiin kirjallisten lähteiden avulla, vertaamalla keskenään aiheesta toteutettuja tutkimuksia ja niistä saatuja tuloksia.

Tutkielman tuloksena saatiin tietoa kolmen erilaisen algoritmin suorituskyvystä radiografisten kuvien luokittelussa ja vikojen segmentoinnissa. Tuloksista selvisi, että kahdella keskenään verratulla algoritmilla, tukivektorikoneella ja monikerrospereptronilla, päästään keskenään liki samanlaisiin luokittelutuloksiin, tukivektorikoneen ollessa tuloksissa näistä kahdesta keskimäärin parempi algoritmi. Kolmantena mukana olleen syväoppivan konvolutiivisen neuroverkon tutkimustuloksissa keskityttiin pienimmän mahdollisen vikakoon löytämiseen kyseisen algoritmin avulla ja tutkimuksen mukaan menetelmä täyttää vaativimmatkin NDT-menetelmän herkkyydelle teollisuudessa asetetut vaatimukset. Tutkimusaineiston mukaan, koneoppivilla algoritmeilla on täydet valmiudet toimia tarkastajan apuna mm. vika-alueiden paikantamisessa, segmentoimisessa ja vikojen tilastoinnissa jo tällä hetkellä. Alan tutkimus on viime aikoina vahvasti painottunut konvolutiivisten neuroverkkojen suuntaan ja niiden merkitys teollisuuden NDT-menetelmien automatisoinnissa tulee epäilemättä olemaan näistä kolmesta koneoppivasta tekniikasta suurin.

Avainsanat

Tekoäly, koneoppiminen, ohjattu oppiminen, ohjaamaton oppiminen, perseptroni, monikerrospereptroni, tukivektorikone, konvolutiivinen neuroverkko, rikkomaton aineenkoetus, NDT, radiografinen tarkastus.

Valvoja

Väitöskirjatutkija Leevi Rantala

Alkusanat

Tutkimusaihe on saanut innoituksensa Iikka Virkkusen Hitsaustekniikka-lehden numeroihin 3/2020 ja 3/2022 kirjoittamista koneoppimista ja NDT-menetelmiä käsittelevistä artikkeleista.

Haluan kiittää puolisoani ja perhettäni ymmärtäväisestä suhtautumisesta opiskeluuni, sekä työnantajaani, Nondest Oy:tä, joka on tehnyt mahdolliseksi työn ja opiskelun sujuvan yhteensovittamisen. Lisäksi haluan osoittaa kiitokseni työni valvojalle, Leevi Rantalalle, häneltä saamastani opastuksesta tieteellisen tutkielman kirjoittamiseen.

Sisältö

Tiivistelmä.....	2
Alkusanat.....	3
Sisältö.....	4
1. Johdanto.....	5
2. Tutkimusmenetelmät.....	6
3. Määritelmät ja tekniikat.....	7
3.1. Tekoäly ja koneoppiminen.....	7
3.2. Ohjaamaton oppiminen.....	7
3.2.1 Klusterointi.....	8
3.2.2 Assosiaatioanalyysi.....	8
3.3. Ohjattu oppiminen.....	8
3.3.1 Tukivektorikone.....	9
3.3.2 K-lähimmän naapurin luokitin.....	9
3.4. Neuroverkot ja syväoppiminen.....	9
3.5. Neuroverkot.....	10
3.6. Konvolutiivinen neuroverkko.....	11
3.7. Datan esikäsittely.....	13
4. Koneoppimistekniikat ja NDT.....	13
4.1. Radio grafinen tarkastus.....	14
4.2. Radio gra fisten kuvien auto maattinen luokittelu.....	14
4.3. Vian segmentointi.....	15
4.4. Piirteiden erottelu.....	16
4.5. Tukivektorikone luokittelijana.....	17
4.6. Monikerroperseptroni luokittelijana.....	18
4.7. Konvolutiivinen neuroverkko segmentoijana ja luokittelijana.....	18
5. Tulokset ja johtopäätökset.....	19
6. Yhteenveto.....	21
Lähteet.....	23

1. Johdanto

Teollinen vallankumous 1700- ja 1800-lukujen taitteessa sai alkusysäyksenä höyrykoneen keksimisestä. Sata vuotta myöhemmin alkaneen teollisen mullistuksen toisen vaiheen mahdollistajina toimivat sähkö- ja polttomoottorit. 1900-luvun puolivälissä mikropiirin keksimisestä käynnistynyt kehitys johti vuosisadan loppupuolella tietoteknisten laitteiden hintojen romahtamiseen, niiden yleistymiseen, sekä kolmanteen teolliseen vallankumoukseen. Nyt elämme neljännen teollisen vallankumouksen keskellä, jonka moottoreina tällä kertaa toimivat kaiken digitalisaatio, big data ja tekoäly. Niiden mukanaan tuoman muutoksen arvioidaan olevan jopa aiempien mullistuksien suuruinen (Roy, 2020). Muutos perustuu asioiden ja tuotteiden verkottuneisuuteen, niistä saatavan datan analytiikkaan ja tekoälyn ja automatiikan avulla toteutettuun tehtävien suorittamiseen, itsenäisesti, kokonaan tai osittain ilman ihmisen ohjausta.

Suurin osa tekoälyn käytännön sovelluksista pohjautuu koneoppimiseen. Koneoppimisessa tietokoneohjelma oppii sille syötetystä datasta tunnistamaan datassa esiintyviä yhdenmukaisuuksia ja käyttämään oppimaansa hyväksi sitä varten suunnitellussa sovelluksessa. Koneoppimiseen perustuvan tekoälyn suorituskyky on riippuvainen sille tarjoillun opetusdatan määrästä ja laadusta (Lim et al., 2007). Tekoälyn ja koneoppimisen käytännön sovellukset kattavat kaiken mahdollisen roskapostin suodatusohjelmista ja kuvien tunnistamisesta aina itseohjautuviin autoihin (Bironneau & Coleman, 2019).

NDT-menettelmien parissa tekoälyä käytetään apuna esimerkiksi radiografisten kuvien tulkinnassa. NDT on lyhenne sanoista nondestructive testing ja se käsittää joukon menetelmiä, joilla voidaan tutkia materiaalien ominaisuuksia ainetta rikkomatta. Menetelmiä käytetään yleisesti teollisuudessa, mm. hitsauksen laadun todentamiseen. Radiografinen tarkastus on eräs yleisimmin käytetyistä NDT-menettelmistä (L. Yang & Jiang, 2021).

Tämän tutkielman motiivina toimii oma työkokemukseni NDT-tarkastajan tehtävässä, useiden eri NDT-menettelmien parissa, ja sitä kautta syntynyt mielenkiinto alan uusimpia tuulia ja tulevaisuuden mahdollisuuksia kohtaan.

Tutkielman teoriaosassa käydään läpi olemaista teoriaa ja käsitteitä tekoälyn ja koneoppimisen aihepiiristä. NDT-osiossa pyritään selvittämään mitä NDT on, mitä menetelmiä siihen kuuluu ja mitä niillä tehdään. Tämän jälkeen käydään läpi mahdollinen prosessi radiografisen kuvan luokittelumiseksi, alkaen kuvan esikäsittelystä ja vikojen segmentoinnista, aina luokittelussa käytettävien vian piirteiden erotteluun asti. Lopuksi vertaillaan kolmea tutkimusta, joista kahdessa kuvien luokittelu suoritetaan sekä tukivektorikoneella että monikerrosperseptronilla, käyttäen niiden opetukseen pientä kuva-aineistoa. Kolmannessa tutkimuksessa mukana olleen konvolutiivisen neuroverkon opetukseen käytetään pientä kuva-aineistoa, jota laajennetaan kolmen erilaisen aineiston laajennusmenettelmän avulla ja tulokset raportoidaan pienimmän löydettävän vikakoon mukaan.

Tutkielman tuloksissa todetaan tukivektorikoneen ja monikerrosperseptronilla päästävän lähes samanlaisiin luokittelutuloksiin, tukivektorikoneen soveltuessa erityisesti pienellä opetusaineistolla suoritettavaan luokitteluun. Konvolutiivinen neuroverkko täyttää

vaativammatkin NDT-menetelmän herkkyydelle asetetut vaatimukset pienimmän löydettävissä olevan vikakoon osalta ja on siltä osin valmis otettavaksi käyttöön erilaisissa käyttötarkoituksissa.

2. Tutkimusmenetelmät

Tutkimus toteutettiin vertailevana tutkimuksena, kirjallisiin lähteisiin nojaten, eikä varsinaista omaa tutkimusta tehty. Tutkimusmenetelmä koostui viidestä askeleesta, Arksey & O'Malley (2005), esittämää mallia mukailien.

Askel 1, *Tutkimuskysymyksen tunnistaminen*. Tämän tutkielman pohjana on seuraava tutkimuskysymys: Miten koneoppivat algoritmit soveltuvat radiografisten NDT-menetelmien tulosten analysointiin määrältään hyvin rajatulla opetusdataalla. Tutkimuskysymys muotoutui havainnon pohjalta, että muihin NDT-menetelmiin verrattuna, radiografia kykenee parhaiten hyödyntämään muun automatisoidun kuvantunnistuksen parissa tapahtuvaa kehityksestä, ja että käytössä olevan opetusdatajoukon koko vaikuttaa oleellisesti koneoppivan algoritmin suorituskykyyn.

Askel 2, *Oleellisten tutkimusten tunnistaminen*. Tiedonhakuja lähdettiin toteuttamaan tutustumalla internetin hakukoneiden avulla löytyneisiin, aihepiiriä käsitteleviin artikkeleihin ja poimimalla aihepiiriin kuuluvaa oleellista sanastoa löytyneistä artikkeleista. Löytyneitä avainsanoja yhdisteltiin tieteelliseen tiedonhakuun tarkoitettujen hakukoneiden hakukentässä siten, että tuloksena oli mahdollisimman suppea ja aiheeseen oleellisesti liittyvä vastausjoukko. Käytettyjä hakusanoja ja lauseita olivat mm. "4th industrial revolution", "artificial intelligence", "machine learning", "neural network", "deep learning", "supervised learning", "image recognition", "weld defect" ja "automatic classification of weld defect", joita käytettiin yksinään, tai yhdessä "NDT" tai "NDE" tai "nondestructive testing" tai "radiography" hakusanojen kanssa, boolean operaattoreiden AND ja OR avulla hakulauseita muodostaen.

Käytettyjä hakukoneita olivat Google, Scopus ja Ebsco. Suurin osa hauista toteutettiin Ebscossa ja aihealueen perustietoutta haettiin rajaamalla hakua valinnoilla: ebook ja full text.

Askel 3, *Tutkimusten valinta*. Aiheen perustietouden lähteiksi valikoitui 6 e-kirjaa, jotka käsittelevät tekoälyn, koneoppimisen ja NDT-menetelmien perusteita tutkimusaiheen kannalta olennaisella tavalla. Varsinaista tutkimusaihetta käsittelevien hakutulosten joukosta karsittiin pois yli 20 vuotta vanhat, sekä muut kuin hitsausvirheiden automaattista luokittelua radiografisen menetelmän avulla käsittelevät tutkimukset, joista tarkasteltavaksi päätyi 4 tutkimuskysymykseen oleellisesti vastaavaa tutkimusta. Loput siteeratut tutkimukset ovat näitä täydentäviä lähteitä.

Askel 4, *Tutkimusdatan kartoittaminen*. Varsinaista tutkimusaihetta käsittelevistä lähteistä kartoitettiin tietoa radiografisten kuvien luokittelussa käytetyistä koneoppivista algoritmeista, sekä niillä saavutetuista tuloksista. Aiheen perusteoksista kartoitettiin tietoa kyseisten algoritmien toimintaperiaatteista.

Askel 5, *Tutkimustulosten koostaminen, yhteenveto ja raportointi*. Tutkimustulosten raportoinnissa kutakin tutkimusta ja niissä käytetyillä algoritmeilla saavutettuja tuloksia käsiteltiin erikseen, sekä verrattiin niitä lopuksi toisiinsa. Vertailututkimuksen tulokset on esitetty tutkimuksen Tulokset ja johtopäätökset-osiossa.

3. Määritelmät ja tekniikat

Tässä luvussa käydään läpi tekoälyn ja koneoppimisen määritelmät sekä niihin sisältyvät keskeiset tekniikat.

3.1. Tekoäly ja koneoppiminen

Tekoälyllä määritelmän mukaan tarkoitetaan tietokonepohjaista järjestelmää, joka kykenee matkimaan ihmisen aivojen ominaisuuksia, suorittaakseen toimintoja, joita muuten vain ihmiset kykenevät suorittamaan (Rahman, 2020). Tekoäly kykenee tähän kuitenkin vielä hyvin kapea-alaisesti, vain yksittäisten, niille erikseen opettujen tehtävien osalta. Koneoppimisella tarkoitetaan tekoälyn osa-alueita, jonka piiriin kuuluvat ohjelmat, jotka oppivat tunnistamaan datassa esiintyviä yhteneväisyyksiä ja toistuvuuksia kokemuseräisesti, vanhojen mallien ja esimerkkien pohjalta, määrätyn tehtävän suorittamista varten (Lee, 2019). Tätä ominaisuutta käytetään hyväksi esimerkiksi tietokonepohjaisessa puheen, tekstin ja kuvan tunnistuksessa. Koneoppivan ohjelman luomisessa ominaista on välttää algoritmien ja ohjelmakoodin kirjoittamista erikseen jokaista ohjelman mahdollisesti kohtaamaa tilannetta varten.

Koneoppiminen voidaan jakaa neljään osa-alueeseen, jotka ovat ohjattu oppiminen, ohjaamaton oppiminen, osittain ohjattu oppiminen ja vahvistus oppiminen. Aiheen kannalta oleellisia ovat näistä kaksi ensiksi mainittua.

3.2. Ohjaamaton oppiminen

Ohjaamattomalla oppimisella tarkoitetaan prosessia, jossa koneoppivalle algoritmille syötetään dataa, jota ei ole etukäteen luokiteltu eikä siihen ole luotu tunnisteita, vaan ohjelman tehtävänä on yrittää itse tunnistaa annetussa datassa toistuvia yhdenmukaisuuksia ja rakenteita, sekä lajitella aineistoa eri ryhmiin niiden perusteella (Bironneau & Coleman, 2019). Ohjaamattomaan oppimiseen perustuvaa algoritmia ei voi käyttää luokittimena, koska sillä ei ole etukäteen määrättyä tehtävää mitä sen tulee etsiä. Kyseinen algoritmi on hyödyllinen, kun analysoidaan isoja datajoukkoja, jossa voi olla lukematon määrä erilaisia muuttujia, ja halutaan näkemys datassa esiintyvistä

toistuvuuksista. Ohjaamaton oppiminen voidaan jakaa kahteen alaluokkaan: klusterointiin ja assosiointiin.

3.2.1 Klusterointi

Klusteroinnin tehtävänä on jakaa datajoukko sisältönsä perusteella erilaisiin ryhmiin tai klustereihin. Menetelmä kasaa yhteen datajoukot, jotka ovat kaikkein lähimpänä toisiaan. Yhteneväisyys perustuu datasta löytyviin piirteisiin ja toistuvuuksiin, jotka ovat merkityksellisiä klusterin kannalta. Erilaisia algoritmeja klusterointianalyysin suorittamiseksi ovat mm. tiheyteen perustuva klusterointi (density based), hierarkkinen klusterointi, k :n keskiarvon klusterointi (k -means clustering) ja spektriklusterointi (spectral clustering) (Taheri et al., 2022).

Eräs yleisimmin käytetyistä klusterointimenetelmistä on k :n keskiarvon klusterointi. Käytettäessä luokittelematonta datajoukkoa, k :n keskiarvon algoritmi jaottelee datajoukon pisteet ennalta määritellyyn määrään klustereita, sijoittaen pisteet klustereihin etäisyyden perusteella klusterin keskipisteeseen nähden. Jos jollain datajoukon pisteellä on sama etäisyys kahteen eri keskipisteeseen, klustereille lasketaan uudet keskipisteet ja sijoittelu toistetaan. Klusteroinnin ollessa valmis, datajoukko on siis jaettu osajoukkoihin (klustereihin), joista jokaisella on tietyt ominaispiirteet. k :n keskiarvon klusterointia käytetään menestyksellä monissa kohteissa, esimerkiksi teollisten materiaalien vian paikannuksessa lämpökamerakuvauksen avulla (Taheri et al., 2022).

3.2.2 Assosiaatioanalyysi

Assosiaatioanalyysi on ohjaamattoman oppimisen menetelmä, joka pyrkii löytämään datajoukosta siinä toistuvia aiheita ja niiden välisiä suhteita, datajoukon sisällön selittämiseksi. Assosiaatioanalyysin hyödyntää perinteisiä tilastotieteen menetelmiä ja se on hyödyllinen menetelmä suurissa datajoukoissa piilevien asioiden välisten yhteyksien löytämiseksi, sekä piirteiden erottelemiseksi (Taheri et al., 2022). Assosiaatioanalyysia on hyödynnetty esimerkiksi tautien välisten yhteyksien löytämisessä potilastiedostoja tutkimalla (Kitanishi et al., 2021).

3.3. Ohjattu oppiminen

Ohjatussa oppimisessa koneoppivalle algoritmille syötetään valmiiksi luokiteltua ja tunnisteilla varustettua opetusdataa. Käymällä läpi opetusdataa ohjelma oppii löytämään yhteyden datan sisällön ja niissä olevien tunnisteiden välillä ja tunnistamaan vastaavanlaista sisältöä sille syötettävästä uudesta materiaalista (Lee, 2019). Roskapostin suodatukseen käytettävät ohjelmat, jotka osaavat luokitella saapuvan viestin tärkeäksi tai vähemmän tärkeäksi, on opetettu toimimaan tällä menetelmällä. Esimerkki monimutkaisemmasta sovelluksesta on kuvantunnistusohjelma, joka on opetettu suuren etukäteen luokitellun kuvadatajoukon avulla tunnistamaan vastaavaa sisältöä täysin uudesta kuvamateriaalista (Bironneau & Coleman, 2019). Ohjattu oppiminen on jaettu kahteen eri kategoriaan algoritmilta toivotun lopputuloksen perusteella. Ensimmäinen kategoria käsittää algoritmit, jotka luokittelevat datajoukon sille etukäteen opetettuihin luokkiin. Tähän kategoriaan kuuluvat mm. tukivektorkone, k -lähimmän naapurin luokitin ja neuroverkot. Toinen kategoria käsittää algoritmit, jotka tuottavat portaattoman tulosteen. Esimerkkinä tästä on regressioanalyysi.

3.3.1 Tukivektorikone


Tukivektorikone (support vector machine) on luokittelualgoritmi, joka annetun opetusdatan perusteella piirtää kaksiulotteiseen koordinaatistoon tukivektorin, joka toimii rajapintana algoritmille syötettyjen datapisteiden jakamisessa kahteen lineaarisesti toisistaan eroteltuun luokkaan. Tukivektorikone toimii hyvin myös tilanteissa, joissa data tulee jakaa kahteen tai useampaan luokkaan, jolloin rajapintoja voi olla useita, sekä tilanteisiin, joissa luokkia erottava rajapinta ei ole lineaarinen, vaan esim. käyrä (Taheri et al., 2022). Tukivektorikoneetta on hyödynnetty hyvällä menestyksellä useissa eri sovelluksissa, mm. 2-tyyppin diabeteksen todentamisessa (Abbas et al., 2019).

3.3.2 K-lähimmän naapurin luokitin

K-Lähimmän naapurin luokitin (k-nearest neighbour), perustuu ajatukseen siitä, että samankaltaiset datapisteet datajoukossa asettuvat toistensa läheisyyteen koordinaatistolle ja edustavat näin ollen samaa luokkaa. Datapisteiden määrä, joka tarvitaan luokan sisällön tunnistamiseen, määritetään parametrilla k , jota ei kuitenkaan tule sekoittaa k -means klusterointitekniikkaan (Taheri et al., 2022). K-lähimmän naapurin luokittimen käyttömahdollisuudet ovat moninaiset, esimerkiksi kirjepostin lajittelu käsin kirjoitettujen postinumerotietojen perusteella (Wang et al., 2019).

3.4. Neuroverkot ja syväoppiminen

Syväoppiminen on eräs nopeimmin kasvavista koneoppimismenetelmistä. Menetelmä perustuu monikerroksisiin keinotekoisii neuroverkkoihin, jotka kykenevät ihmisen suorituskyvyn tasoisten tehtävien suorittamiseen. Idea neuroverkkojen taustalla ei ole uusi. Ensimmäinen esitys aiheesta julkaistiin jo vuonna 1943 (Bhardwaj et al., 2018). Neuroverkon ideana on matkia biologisen neuronin, eli hermosolun, toimintaa matemaattisen funktion avulla. Verkon rakenne muodostuu syöte- ja ulostulokerroksesta, sekä välissä mahdollisesti olevista piilokerroksista. Syväoppivasta verkosta puhutaan, kun piilokerroksia on enemmän kuin yksi. Parhaimmillaan piilokerroksia voi olla jopa satoja (Hemanth & Estrela, 2017). Kerrokset ovat yhteydessä toisiinsa neuroneiden välityksellä, jotka aktivoituessaan lähettävät niihin varastoitua informaatiota eteenpäin seuraavan kerroksen neuroneille. Neuroverkon toimintaa voidaan havainnollistaa parhaiten yksinkertaisen luokittimen, perseptronin, avulla (kuva 1).




Kuva 1. Yksikerrosperseptroni, Bhardwaj et al. (2018) mukaillen.

Yksikerrosperseptroni koostuu syöte- ja ulostulokerroksesta, pienestä määrästä neuroneja, ja niitä yhdistävistä painokertoimista. Perseptroni ottaa vastaan syötteitä ($x_1 \dots x_n$) numeerisina arvoina ja kertoo syötteen arvon sitä vastaavalla painokertoimella ($w_1 \dots w_n$). Syötteiden ja painokertoimien tulot lasketaan yhteen (Σ) ja tulos lähetään aktivointifunktiolle ($f(x)$), joka luokittelee perseptronille syötetyn informaation funktiolla asetetun kynnsarvon avulla. Mikäli kynnsarvo ylittyy, perseptronin antama ulostulosignaali on 1, muussa tapauksessa 0. Painokertoimen merkitys verkon toiminnalle on olennainen, koska se määrittelee minkä merkityksen kukin sisääntulosignaali verkossa saa.

3.5. Neuroverkot

Neuroverkko, eli monikerrosperseptroni, koostuu syöte- ja ulostulokerroksen lisäksi näiden välissä olevista piilokerroksista, joissa kerroksen jokainen neuroni ottaa vastaan signaaleja edellisen kerroksen neuroneilta, ja tuottaa eteenpäin seuraavan kerroksen jokaiselle neuronille vastaanottamiensa painotettujen syötteiden summan. Monikerrosperseptronia, jonka jokaisen kerroksen neuronit ottavat vastaan signaaleja edellisen kerroksen jokaiselta neuronilta, kutsutaan täysin kytketyksi eteenpäin syöttäväksi verkoksi. Kuvassa 2 monikerrosperseptronin rakenne havainnollistettuna.



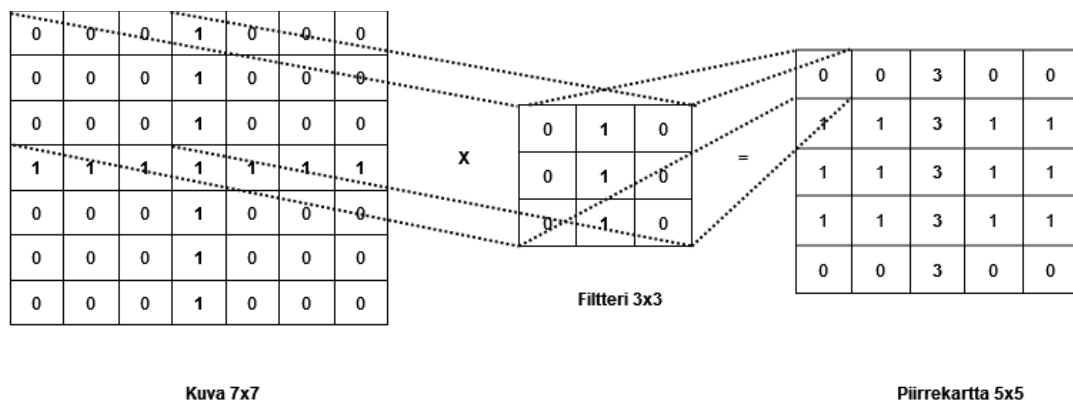
Kuva 2. Monikerrosperseptroni kahdella piilokerroksella, Bhardwaj et al. (2018) mukaillen.

Monikerrosperseptronia voidaan kouluttaa valmiiksi luokitellulla opetusdatalla, ns. vastavirta-algoritmin avulla. Vastavirta-algoritmin toimintaa voidaan kuvata tapana korjata neuroverkon tuottamat luokitteluvirheet sitä mukaa kun ne havaitaan, verkon painokertoimia korjaamalla. Kun neuroverkkoa ryhdytään opettamaan valmiiksi luokitellun opetusdatan avulla, painokertoimille on voitu aluksi asettaa satunnaiset arvot, jolloin verkon antamat tulokset annetuille syötteille ovat satunnaisia ja kaoottisia. Kun aktivointifunktiolta saatu tulos ei vastaa opetusdatan sisältöä, vastavirta-algoritmin avulla säädetään verkon painokertoimia asteittain siten, että useasti toistettuna syöte-tavoite-

parit vastaavat lopulta toisiaan. Painokertoimien korjaamisessa olennaista ei ole yksittäisen neuronin painokerroin, vaan jokaisen kerroksen tuottama painotettujen syötteiden kollektiivinen summa (Gulli & Pal, 2017).

3.6. Konvolutiivinen neuroverkko

Vaikka täysin kytkettyä eteenpäin syöttävää monikerrosperseptronia voidaan käyttää luokitteluun, sen kyky käsitellä suuria määriä syötteitä, esimerkiksi kokonaisia korkean resoluution kuvatiedostoja, ei ole paras mahdollinen. Jos mustavalkoisen kuvatiedoston jokainen pikseli muodostaa yhden syötteen, tuottaa esimerkiksi 32 x 32 pikselin kuvakoko 1024 syötettä. Isoilla kuvatiedostoilla seurauksena on erittäin suuri määrä laskutoimituksia jo matalilla kerrosarkkitehtuureilla. Toinen ongelma koskien kuvien luokittelua monikerrosperseptronin avulla liittyy sekin kuvapikseleihin ja niiden käyttämiseen verkon syötteinä. Jos kuvatiedoston pikselit asetetaan jonoon ja tarjoillaan verkolle syötteinä, tieto niiden sijainnista ja yhteydestä vieressä oleviin pikseleihin katoaa. Samalla katoaa arvokasta tietoa kuvan sisällöstä. Näitä ongelmia ratkaisemaan on kehitetty konvolutiivinen neuroverkko, joka kykenee käsittelemään kuvatiedostoa pienemmissä erissä, samalla muokaten kuvaa pienemmäksi, ilman että tieto pikseleiden sijainnista ja niiden muodostamista kokonaisuuksista katoaa (Zohuri, 2020).




Kuva 3. Konvolutiivinen operaatio. Bhardwaj et al. (2018) mukaillen.

Konvolutiivinen neuroverkko koostuu useista toisiaan seuraavista konvolutiivisista kerroksista, joiden tehtävänä on erottaa syötteistä piirteitä ja pakata kuvaa pienemmäksi, sekä lopussa olevasta monikerrosperseptronista, jonka tehtävänä on irrotettujen piirteiden luokittelu. Konvolutiivinen kerros ottaa vastaan syötteitä, erottaa niistä haluttuja piirteitä erilaisten filttereiden avulla, ja muodostaa tuloksena piirrekartan, jota voidaan käyttää syötteenä verkon seuraavalle kerrokselle. Kuvassa 3 havainnollistetaan konvolutiivisen operaation toimintaa yksinkertaistetun esimerkin avulla. Esimerkissä syötteenä annetaan 7x7 kokoa oleva mustavalkokuva, joka koostuu valkoisista (0) ja mustista (1) pikseleistä. Kuvan päälle, vasempaan ylänurkkaan, asetetaan kokoa 3x3 oleva filteri, jonka jokainen luku kerrotaan syötteessä sen alle jäävällä arvolla ja lasketaan luvut yhteen. Tulos siirretään piirrekartan vasempaan ylänurkkaan. Tämän jälkeen filteriä siirretään askel oikealle, toistetaan laskutoimitus, ja siirretään tulos piirrekartan viereiseen ruutuun. Filtterin luvut ovat konvolutiivisen operaation painokertoimia ja läpikäymällä koko kuva filteriä siirtämällä, tuloksena saadaan kokoa 5x5 oleva piirrekartta, johon on saatu

irrotettua syötteestä haluttuja ominaisuuksia. Esimerkin tapauksessa filterin tehtävänä on pystysuorien viivojen etsiminen ja irrottaminen kuvasta.

Kun syötteestä on saatu muodostettua piirrekartta (tai useita karttoja, käyttämällä erilaisia filttareita), siitä voidaan aktivointifunktion avulla poistaa epäoleellisia tekijöitä, kuten kohinaa, sopivaa kynmysarvoa käyttäen. Tämän jälkeen piirrekartta pakataan pienempään kokoon, ennen sen syöttämistä uudelle konvolutiiviselle kerrokselle, jossa siitä voidaan pyrkiä irrottamaa korkeamman tason piirteitä. Kuvassa 4 havainnollistetaan konvolutiivisen neuroverkon koko prosessi. Syötekuvasta irrotetaan konvolutiivisen operaation avulla piirteitä, muodostetaan niistä piirrekarttoja, jotka pakataan pienempää kokoon ja annetaan syötteinä seuraavalle konvolutiiviselle kerrokselle, jossa piirrekartoista voidaan erottaa lisää piirteitä. Lopuksi piirrekarttojen sisältämä data asetetaan jonoon ja syötetään monikerrosperseptronille, jonka ulostulofunktion tuottaman todennäköisyysluvun perusteella sisältö voidaan luokitella yhteen tai useampaan luokkaan (Bhardwaj et al., 2018).



Kuva 4. Havainnekuva konvolutiivisen neuroverkon rakenteesta. Bhardwaj et al. (2018) mukaillen.

Konvolutiivisen neuroverkon ensimmäisen kerroksen tehtävänä on tunnistaa datan yleisiä ominaisuuksia, kuvantunnistuksessa esimerkiksi kuvioiden reuna-alueita. Toinen kerros tunnistaa korkeamman tason ominaisuuksia, kuten kuvioiden nurkkia. Kolmas kerros tunnistaa kuvan tekstuuria ja muita pienempiä ominaisuuksia. Ensimmäiset kerrokset tunnistavat syötteestä kuvioita ohjaamattomasti ja lopuksi viimeiset kerrokset hoitavat tunnistamisen ohjatun oppimisen mukaisesti (Bhardwaj et al., 2018).

Menetelmän menestyksellä hyödyntäminen vaatii suuren määrän opetusdataa, sekä suoritustehoa tietokoneelta. Vuonna 2012 Toronton yliopiston tutkijaryhmä esitteli rakentamansa neuroverkon, joka koostui seitsemästä piilokerroksesta, viidestä konvolutiivisesta kerroksesta, sekä niiden perässä olevasta kolmesta täysin kytketystä kerroksesta, joka koostui 650 000 neuronista sekä 630 miljoonasta yhteydestä niiden välillä ja kykeni ottamaan 60 miljoonaa parametriä syötteinä. Käyttäen 10 miljoonan kuvan kuvapankkia verkon opetukseen ja 150 000 kuvan sarjaa sen testaamiseen, tutkijaryhmä onnistui pääsemään 85 % tunnistustarkkuuteen, eli 11 % parempaan virheprosenttiin kuin seuraavaksi paras ryhmä samalla kuvasarjalla (Bhardwaj et al., 2018). Tämän merkkipaalun jälkeen kehitys alalla on ollut nopeaa ja nykypäivänä voimme nähdä monia toimivia sovelluksia aiheesta, sekä kuvan tunnistamisen saralla, että myös tiedonhaun, liiketunnistuksen, liikemallinnuksen, robotiikan, puheentuottamisen, puheentunnistuksen, musiikin tuottamisen, taiteiden jne. saralla.

Vaikka useimmat neuroverkkoihin liittyvät teoreettiset keksinnöt tehtiinkin jo 1980 - 90-luvuilla, vasta tietokoneiden suoritusnopeuden 1000-kertaistuminen viimeisen vuosikymmenen aikana on tehnyt niiden käytännön sovelluksista mahdollisia (Bhardwaj et al., 2018).

3.7. Datan esikäsittely

Todellisesta elämästä poimittu raakadata on yleensä täynnä häiriöitä ja epä johdonmukaisuuksia, sekä jollain tasolla puutteellista. Datan esikäsittelyllä tarkoitetaan prosesseja, joiden avulla on mahdollista helpottaa oleellisen tiedon erottamista käytetystä aineistosta. Opetusdatan esikäsittely on välttämätön toimenpide koneoppivan algoritmin onnistuneeseen opettamiseen. Jopa 80 % tekoälyn parissa työskentelevän insinöörin ajasta kuluu laadukkaasti opetusdatan valmistamiseen ja loput 20 % itse ohjelman laatimiseen. Yksinkertainen ohjelma, joka saa käyttöönsä laadukasta opetusdataa päihittää aina monimutkaisemman mallin, joka hyödyntää heikkoa dataa (Das & Cakmak, 2018).

Suodattimia ja algoritmeja voidaan käyttää säätämään kuvan kohinaa, kirkkautta ja kontrastia. Algoritmien avulla on mahdollista korjata kuvan perspektiivin vääristymiä. Reunatunnistus on tekniikka, joka tunnistaa kuvapikselien jyrkkiä kirkkauden vaihteluja ja muodostaa reunalinjoja näitä kohtia yhdistämällä. Reunalinjojen avulla kuvadatasta on mahdollista muodostaa objekteja ja tunnistaa asioita. Segmentointi on toinen kuvanrajaustekniikka, jonka avulla kuvasta voidaan erottaa olennaisia tietoja, kuten muotoja, tekstiä ja kuvioita. Segmentoinnin tavoitteena on rajata kuvapikselit yhtenäisiin alueisiin, joita yhdistää kirkkaus, väri tai tekstuuri. Segmentointi on reunatunnistusta epätarkempaa, mutta silti toimiva menetelmä helpommissa kuvantunnistustehtävissä. Tekniikoiden toimivuuteen vaikuttaa oleellisesti myös kuvan laatu, valaistus, varjot ja kuvan kohina (Puurtinen, 2021).

4. Koneoppimistekniikat ja NDT

Rikkomaton aineenkoetus (Nondestructive testing, eli NDT) pitää sisällään useita eri menetelmiä, joilla voidaan tutkia materiaalien ominaisuuksia tuotteen valmistuksen tai sen käytön aikana, etsimällä niistä vikoja ja epäjatkuvuuksia, aiheuttamatta samalla vahinkoa itse tarkastettavalle kappaleelle. NDT-menetelmiä käytetään useilla eri teollisuuden aloilla estämään vahinkoja ja taloudellisia tappioita, joita vikoja sisältävän kappaleen mahdollinen tuleva käyttö voisi aiheuttaa. Erilaisten NDT-menetelmien kirjo on laaja ja kukin menetelmä voi pitää sisällään useita erilaisia tarkastustekniikoita. NDT-menetelmät voidaan jakaa pintatarkastus ja volumetrisiin tarkastusmenetelmien. Yleisimpiin pintatarkastusmenetelmiin kuuluvat mm. magneettijauhe-, tunkeumaneste- ja pyörrevirtatarkastus, ja niiden avulla voidaan havaita kappaleen pintaan aukeavia vikoja. Volumetrisiin tarkastusmenetelmiin kuuluvat mm. radiografisen- ja ultraäänitarkastus, joiden avulla on mahdollista havaita myös kappaleen sisällä olevia vikoja. Kaikilla NDT-menetelmillä on omat vahvuutensa ja puutteensa,


josta syystä niitä usein käytetään rinnakkain, toisiaan täydentävinä menetelminä (Cartz, 1995).

Tekoälyn ja koneoppimisen tekniikat ovat jo pitkään olleet tutkimuksen kohteena myös NDT-alan toimijoiden parissa. Tavoitteena on saavuttaa niiden avulla edistystä mm. NDT-menetelmien tarkkuudessa, tarkastuksen suorituksessa, tarkastusdatan analysoinnissa sekä luotettavuudessa, kuitenkin aiempaa pienemmillä kustannuksilla.

4.1. Radiografinen tarkastus

Radiografinen tarkastus (röntgentarkastus) on eräs tunnetuimmista ja tärkeimmistä NDT-menetelmistä, joka näyttelee tärkeää roolia paineastioiden ja teollisuusputkistojen hitsauksen laadunvalvonnassa, mm. öljy- ja voimalaitosteollisuuksien parissa. Radiografisessa tarkastuksessa säteilylähde lähettää röntgen- tai gammasäteilyä tarkastettavan kohteen läpi ja läpi menneet säteily valottaa kuvan kohteen sisällöstä sen taakse asetetulle tallentimelle, joka voi edustaa joko perinteistä filmitekniikkaa tai uudempaa digipaneelitekniikkaa. Suurin osa radiografisten valotusten käytännön toteutuksesta ja kuvien luokittelusta toteutetaan edelleen manuaalisesti, joka tekee työstä vahvasti tarkastajan kokemuksesta ja osaamisesta riippuvaista toimintaa (Cartz, 1995; Lim et al., 2007).

Radiografisen luokittelun kannalta oleelliset hitsauksen laatuvirheet voidaan jakaa viiteen eri virhetyyppiin, jotka ovat huokoisuus, sulkeumat, vajaa hitsautumissyvyys, liitosvirheet sekä halkeamat, eikä näiden vikatyypien erottaminen toisistaan ole aina täysin yksiselitteistä. Kuvassa 5 esitetään tyypillisiä hitsausvirheitä.



Kuva 5. Hitsausvirheet. a) sulkeuma, b) huokoisuus, c) liitosvika, d) vajaa hitsautumissyvyys, Yang & Jiang (2021) mukaillen.


Edistykset digitaalisen radiografian sekä koneoppivien menetelmien parissa ovat tehneet teoriassa mahdolliseksi vikojen automaattisen paikannuksen sekä luokittelun, jonka myötä radiografinen tarkastus on mahdollista tehdä aiempaa luotettavammin ja nopeammin.

4.2. Radiografisten kuvien automaattinen luokittelu

Automaattinen kuvien luokittelu voidaan erottaa neljään eri vaiheeseen, jotka ovat digitaalisen kuvan esikäsittely, vika-alueen segmentointi, vian piirteiden erottelu ja vian

luokittelu. Digitaalinen radiografinen kuva on yleensä heikkolaatuinen, johtuen epäyhtenäisistä mustuma-alueista, kohinasta ja huonosta kontrastista. Tästä johtuen kuvan esikäsittely on yleensä välttämätön ensivaihe prosessissa kuvan luokittelunsa. Esikäsittely pitää sisällään kuvan kohinatason vaimennuksen ja kontrastin säädön. Kuvan esikäsittelyn automaattiseen suorittamiseen voidaan toteuttaa useilla eri tekniikoilla, mm. oppivan neuroverkon avulla (Lim et al., 2007).

Vika-alueen segmentoinnin ensimmäinen vaihe on potentiaalisen vika-alueen paikantaminen, joka voidaan toteuttaa mustavalkoisen kuvan harmaansävyjä analysoimalla (Shen et al., 2009).




Kuva 6. a) huokonen, b) huokosen topografinen kartta rivillä A, c) taustan topografinen kartta rivillä B, Shen et al. (2009) mukailten.

Radiografisessa kuvassa kappaleen sisäiset hitsausvirheet esiintyvät yleensä ympäristöään tummempina alueina, jolloin kuvasta laaditussa topografisessa kartassa, jossa kuvan harmaasävyjen vaihtelut esitetään y-akselilla, hitsausvirheet näkyvät kuoppina ja ehyet kohdat tasaisina alueina. Kuvassa 6 huokosen ja sen taustan harmaasävyjen vaihtelut topografisen kartan avulla esitettyinä.

4.3. Vian segmentointi

Vika-alueen segmentointi voidaan suorittaa neuroverkon tai esimerkiksi jonkun klusterointialgoritmin avulla, jolloin topografisen kartan kuopat valitaan vian klusterointikeskipisteiksi, jonka ympärille klusterointialgoritmi muodostaa samaa harmaan sävyä edustavista kuvapikseleistä segmentoidun vika-alueen. Algoritmilta annettava kynnyksarvo kuvapikselien välillä olevista harmaansävyjen sallitusta erotuksesta määrittää mitkä sävyt kuuluvat klusteriin ja missä kulkee vian reuna-alue. Kuvassa 7 huokosen segmentoitu vika-alue punaisella merkattuna.



Kuva 7. Segmentoitu vika-alue (punaisella) ja vian tausta (vihreällä), Yang & Jiang (2021) mukaillen.

Näin muodostuneen segmentoidun vika-alueen etäisyys lähimmästä viereisestä vikasegmentistä tulisi olla suurempi kuin kummankaan alueen sisämittojen, jotta segmentointia voidaan pitää onnistuneena (Dang et al., 2019).

4.4. Piirteiden erottelu

Segmentoitua vika-aluetta, yhdessä sitä ympäröivän tausta-alueen kanssa, käytetään vian luokittelussa tarvittavien parametrien määrittelyyn. Parametrien määrittelyssä oleellisia tekijöitä ovat vika-alueen ja sitä ympäröivän taustan geometriaan, väri-intensiteettiin ja kontrastiin liittyvät ominaisuudet. Segmentoidun vika-alueen koko, muoto ja reunan piirteet ovat sen oleellisia geometrisia ominaisuuksia, kun taas vika-alueen ja sitä ympäröivän taustan harmaansävyn erot ovat oleellisia väri-intensiteetin ja kontrastin ominaisuuksia. Piirteiden erottelussa tavoitteena on saavuttaa riittävä määrä vikaa kuvaavia parametrejä, joiden avulla vian luokittelu on mahdollista suorittaa luotettavasti. Taulukossa 1 esitetään 12 erilaista parametriä, joiden avulla on mahdollista laskea segmentoidusta vika-alueesta ja sitä ympäröivästä taustasta geometrian, väri-intensiteetin ja kontrastin ominaisuuksia, Shen et al (2010) ja Yang & Jiang (2021) mukaan.

Tunnus	Piirre	Piirretyyppi	Määritelmä
$W^{1,2}$	Pituus	Geometrinen	Maksimietäisyys vian kahden pisteen välillä
P_r^1	Sijainti	Geometrinen	Vian sijainti suhteessa hitsin keskilinjaan
$A_r^{1,2}$	Muotosuhde	Geometrinen	Vian pituuden ja leveyden välinen suhde
$S_p^{1,2}$	Terävyys	Geometrinen	Vian terävyys vian pääakselin molemmissa päissä
$R_e^{1,2}$	E Rosoisuus	Geometrinen	Vikaprofilin (reunan) väripikselien vaihteluväli

$R_r^{1,2}$	R Rosoisuus	Intensiteetti	Vika-alueen sisäisten väripikselien vaihteluväli
$S_k^{1,2}$	Symmetria	Intensiteetti	Vika-alueen topografisen kartan symmetrisyys
$K_u^{1,2}$	Huipukkuus	Intensiteetti	Vika-alueen topografisen kartan jyrkkyysaste
H_c^2	H Kontrasti	Kontrasti	Harmaatason histogrammien Chi-neliöetäisyys vika-alueen ja sen taustan välillä
R_c^2	R Kontrasti	Kontrasti	Vika-alueen rosoisuussuhde taustaan
S_c^2	S Kontrasti	Kontrasti	Vika-alueen symmetrisyysasteen suhde taustaan
K_c^2	K Kontrasti	Kontrasti	Vika-alueen huipukkuusasteen suhde taustaan

¹ Shen et al. (2010), ² Yang & Jiang (2021)

Taulukko 1. Luokitteluparametreja

Shen et al. tutkimuksessa vuodelta 2010, hitsausvirheitä edustavasta aineistosta eroteltiin kustakin viasta kahdeksan vikaa kuvaavaa piirrettä, joita käytettiin parametreinä kuvien luokittelussa. Piirteet olivat: vian pituus (W), sijainti (Pr), muotosuhde (Ar), terävyys (Sp), symmetria (Sk), huipukkuus (Ku), vika-alueen sisäinen rosoisuus (Rr) ja vian reuna-alueen rosoisuus (Re).

Yang & Jiang tutkimuksessa vuodelta 2021, joka toteutettiin Shen et al. (2010) tutkimuksen suuntaviittoja mukaillen, hitsausvirheitä edustavasta aineistosta oli kustakin viasta eroteltu yksitoista piirrettä, joita oli käytetty parametreinä kuvien luokittelussa. Neljä piirrettä, jotka oli otettu mukaan, mutta joita ei käytetty Shen et al. tutkimuksessa, olivat kuvan kontrastiin liittyviä (Hc, Rc, Sc ja Kc). Lisäksi yksi piirre, vian sijainti (Pr), puuttui kokonaan tutkimukseen valittujen piirteiden listalta.

Kun kuvadatasta on saatu erotettua kaikki tarvittavat parametrit, kuvat on mahdollista luokitella niitä edustaviin luokkiin.

4.5. Tukivektorikone luokittelijana

Shen et al. (2010) tutkimuksessa aineistona oli 172 kuvan joukko, jossa edustettuina oli viisi eri vikatyyppeä: huokoisuus (65 kpl), kuonasulkeuma (42), vajaa hitsautumissyvyys (26), liitosvirhe (31) ja halkeama (17). Tutkimuksessa keskityttiin statistiseen oppimiseen perustuvaan tukivektorikoneeseen, joka sopii erityisesti pienten datajoukkojen lajitteluun. Tukivektorikone luokittelee aineiston yleensä kahteen (tai useampaan) eri luokkaan, piirtämällä kaksiulotteiseen koordinaatistoon tukivektorin, joka toimii rajapintana algoritmille tarjoiltujen syötteiden jakamisessa toisistaan eroteltuihin luokkiin. Ennen

luokittelua, jokainen parametri muutettiin vektorimuotoon, sekä normalisoitiin arvojen vaihteluväli välille $[-1, 1]$.

Kuva-aineisto jaettiin kahteen osaan, joista 115 kuvaa käytettiin opetukseen, eli luokkia jakavan tukivektorin luomiseen, ja 57 kuvaa käytettiin tukivektorikoneen testaukseen. Luokittimina käytettiin kolmea eri periaatteella rakennettua tukivektorikonetta, joiden tuloksia verrattiin kolmikerroksisella monikerrosperseptronilla saavutettuihin luokittelutuloksiin.

Tutkimuksessa huonoin luokitteluprosentti, 93,17 %, saavutettiin monikerrosperseptronilla, ja paras luokitteluprosentti, 94,25 %, tukivektorikoneella, joka jakoi aineiston suoraan yhtä moneen luokkaan kuin oli vikaluokkien määrä.

4.6. Monikerrosperseptroni luokittelijana

Yang & Jiang (2021) tutkimuksessa, aineistona oli 220 kuvan joukko, jossa edustettuna oli viisi eri vikatyyppeä, huokoisuus (50 kpl), kuonasulkeuma (50), vajaa hitsautumissyvyys (50), liitosvirhe (35) ja halkeama (35). Tutkimuksessa keskityttiin kahteen erilaiseen monikerrosperseptroniin, jotka molemmat koostuivat sisään- ja ulostulokerroksesta, sekä neljästä piilokerroksesta, joista toisen kaikki kolme ensimmäistä piilokerrosta oli yhdistetty suoraan neljänteen piilokerrokseen, parempien luokittelutulosten aikaansaamiseksi. Monikerrosperseptroneilla saatuja luokittelutuloksia verrattiin lisäksi tukivektorikoneella saatuihin tuloksiin. Ennen luokittelua parametrit normalisoitiin järkevälle vaihteluvälille ja muutettiin vektorimuotoon (tukivektorikoneelle). Kuva-aineisto oli jaettu kahteen osaa, joista 176 kuvaa käytettiin opetukseen, eli verkon painokertoimien arvojen säätämiseen, ja 44 kuvaa käytettiin testaukseen.

Tutkimuksessa huonoin luokitteluprosentti, 87,03 %, saavutettiin perinteisellä monikerrosperseptronilla, jonka jokainen kerros oli yhdistetty suoraan seuraavaan kerrokseen. Toiseksi paras prosentti, 88,18 %, saavutettiin tukivektorikoneella, joka jakoi aineiston suoraan viiteen luokkaan. Paras luokitteluprosentti, 91,36 %, saavutettiin monikerrosperseptronilla, jonka piilokerrokset oli yhdistetty suoraan viimeiseen piilokerrokseen.

4.7. Konvolutiivinen neuroverkko segmentoijana ja luokittelijana

Tyystjärvi et al. (2022) tutkimuksessa, materiaalina oli ilmailuteollisuuden parista kerätty 223 kuvan aineisto, jossa huokoisuus oli kuvissa pääasiallisesti edustettuna ollut hitsausvirhe. Aineistoa laajennettiin viidellä termisen väsymisen avulla tuotetulla keinotekoisella halkeamalla, jotka oli tuotettu samoihin materiaaleihin ja kuvattiin käyttäen samoja kuvauslaitteita ja arvoja kuin muukin kuva-aineisto. Viat merkattiin kuviin käsin, jolloin lopputuloksena oli 3500 erillistä vikamerkintää, joista viisi oli keinotekoisesti tuotettuja, ja neljä jo alkuperäisessä kuva-aineistossa esiintynyttä halkeamaa. Näin aikaan saatua kuva-aineistoa laajennettiin vielä kolmella eri menetelmällä, joista ensimmäisessä standardimallissa, kuva-aineistoa muokattiin erilaisilla kirkkauden, kohinan, kontrastin, terävyyden, kuvan koon, etc. muutoksilla, saaden aikaan moninkertainen datajoukko alkuperäiseen verrattuna. Toisessa menetelmässä, virtuaalimallissa, aineisto koostui yksinomaan virtuaalisesti tuotetuista

vioista. Kolmannessa menetelmässä aineisto oli yhdistelmä sekä standardi- että virtuaalimenetelmällä laajennetusta kuva-aineistosta. Kaikki kolme kuva-aineistoa jaettiin lopuksi kolmeen satunnaisesti valittuun osaan, joista suurinta, 60 % aineistosta käytettiin neuroverkon opetukseen, 20 % tulosten validoimiseen ja loppuja 20 % neuroverkon testaukseen.

Tutkimuksessa käytettiin täysin kytkettyä konvolutiivista neuroverkkoa sekä vikakohtien tunnistamiseen, että niiden segmentoimiseen. Tutkimustulokset raportoitiin käyttäen NDT-menetelmien herkkyyttä kuvaavaa, pienintä vikakokoa $a_{90/95}$. Eli pienintä vikakokoa millimetreissä, joka löytyy 90 % todennäköisyydellä ja voidaan todeta 95 % varmuudella. Kolmesta eri aineiston laajentamismenetelmästä parhaat tulokset saavutettiin yhdistetyllä menetelmällä, jolla päästiin 0,60 mm herkkyyteen, joka täyttää vaativammatkin ilmailuteollisuuden NDT-menetelmän herkkyydelle asettamat vaatimukset. Standardimenetelmällä laajennetulla kuva-aineistolla päästiin tätä huonompaan herkkyyteen, johtuen alkuperäisen kuva-aineiston yksipuolisesta vikamateriaalista. Täysin virtuaalisesti tuotetulla kuva-aineistolla saavutettu huonompi herkkyys johtui hienovaraisten vikapiirteiden epätäydellisestä mallintamisesta virtuaalivioissa.

5. Tulokset ja johtopäätökset

Tarkasteluun oli valittu kolme tutkimusta, joissa kaikissa oli käytetty ohjattua oppimista hyödyntäviä koneoppimisalgoritmeja. Kaikissa tutkimuksissa algoritmien opetukseen oli käytettävissä suhteellisen pieni määrä, eri hitsausvirhetyyppejä edustavia kuvia. Algoritmeilla saavutetut tulokset erillisistä testikuva-aineistoista poikkesivat toisistaan jossain määrin, ja syitä tähän voidaan epäillä löytyvän tutkimusten välillä havaituista erilaisista tulosten raportointitavoista, tutkimuksissa käytetyistä erilaisista opetus- ja testiaineistoista, valituista segmentointimenetelmistä, kuin luokitteluun valituista parametreista. Jiang et al. (2016) mukaan vian segmentointi ja piirteenerottelu ovat tärkeimpiä ja oleellisimpia vaiheita kuvan automaattisessa luokittelussa. Vian pituus ja muotosuhde ovat oleellisia piirteitä, jolla voimme erottaa huokoisuuden, joka on muodoltaan pyöreä, esimerkiksi vajaasta hitsautumissyvyydestä, joka on muodoltaan yleensä pitkänomainen. Sen sijaan huokoisuus ja kuonasulkeuma, jotka voivat molemmat olla muodoltaan pyöreitä, ei voida erottaa toisistaan näiden piirteiden avulla, vaan tarvitaan tietoa vian reuna-alueeseen liittyvistä ominaisuuksista. Kuonasulkeuman reunaviiva on huokosen reunaa rosoisempi, jolloin vikaprofiilin reuna-alueen pikseleiden vaihteluväli ja vian segmentoinnin merkitys nousee olennaiseksi vikatyyppeiden erottamiseksi toisistaan. Tyystjärvi et al. (2022) tutkimuksessa oli käytössä ainoastaan huokosista ja halkeamista koostunut opetusaineisto, jolloin menetelmän luotettavuudesta esim. huokosen ja kuonasulkeuman erottelussa ei saatu näyttöä. Lisäksi tutkimuksessa oli raportoitu ainoastaan segmentointivaiheen tulokset, pienimmän löydetyn vikakoon osalta ($a_{90/95}$) ja tulokset varsinaisen luokittelun osalta puuttuivat kokonaan, mahdollisesti tutkimuksessa käytetyn yksipuolisen vikamateriaalin johdosta.

Tutkimusten välillä on perinteisesti ollut erilaisia painotuksia luokitteluun käytettyjen piirteiden valinnassa ja tulosten raportoinnissa, eivätkä ne näin ollen ole keskenään täysin vertailukelpoisia.

Tutkimusten välisistä yhtäläisyyksistä huomio kiinnittyy Shen et al. (2010) ja Yang & Jiang (2021) tutkimuksissa lähes identtisiin tukivektorikoneella ja perinteisellä monikerrosperseptronilla saavutettuihin tuloksiin (94,25 % vs. 93,17 % Shen et al. (2010) tutkimuksessa ja 88,18 % vs. 87,03 % Yang & Jiang (2021) tutkimuksessa). Molemmissa tutkimuksissa tukivektorikoneella saadut paremmat luokittelutulokset perinteiseen monikerrosperseptroniin verrattuna kielivät siitä, että tukivektorikone on toimiva valinta erityisesti tilanteisiin, jossa opetusaineiston koko on suhteellisen pieni. Yang & Jiang (2021) tutkimuksessa parhaat tulokset, 91,36 %, saavutettiin tarkoitukseen räätälöidyllä monikerrosperseptronilla, jonka kolmesta ensimmäisestä piilokerroksesta oli suorat kytkennät neljanteen piilokerrokseen. Tämä antaa viitteitä siitä, että vaikka monikerrosperseptroni yleisesti ottaen toimii paremmin isolla opetusdatalla, sen suorituskyky on mahdollista virittää tukivektorikonetta paremmaksi myös pienemmällä aineistolla. Tyystjärvi et al. (2022) tutkimuksessa käytössä oli konvolutiivinen neuroverkko, joka yleensä vaatii käyttöönsä laajan opetusdatajoukon toimiakseen luotettavasti (D. Yang et al., 2021). Pienen opetusjoukon ongelmaa lähdettiin tutkimuksessa kiertämään kasvattamalla datajoukkoa keinotekoisesti, mm. luomalla termisen väsymisen avulla halkeamia todellisiin kappaleisiin ja käyttämällä niistä otettuja kuvia osana opetusdataa. Näin saatua kuvajoukkoa lisäksi laajennettiin standardimenetelmällä, muokkaamalla alkuperäisiä kuvia erilaisilla kirkkauden, kohinan, kontrastin, terävyyden etc. muutoksilla ja saatiin näin moninkertainen datajoukko alkuperäiseen verrattuna. Lisäksi luotiin puhtaasti virtuaalivioista koostuva datajoukko, jota käytettiin algoritmin opetusaineistona sellaisenaan, että yhdessä standardimenetelmällä luotujen kuvien kanssa. Parhaat tulokset pienimmän löydetyn vikakoon (a90/95) osalta saavutettiin yhdistetyllä menetelmällä (0,60 mm), joka täyttää NDT-menetelmän herkkyydelle asetetut vaatimukset mm. ilmailuteollisuuden parissa.

Radiografisessa tarkastuksessa dataa on periaatteessa runsaasti saatavilla, johtuen siitä, että jokaisesta tarkastuksesta jää kuvatalenne, jota voidaan haluttaessa käyttää myöhemmin algoritmin opetukseen. Ongelmaksi muodostuu kuvissa olevien vikojen merkkäminen – joita esiintyy lähes jokaisessa hitsatussa saumassa - joka on käsityönä tehtävää toimintaa ja näin ollen erittäin aikaa vievää. Tavoiteltaessa mahdollisimman isoa ja laadukasta opetusdatajoukkoa, avuksi on mahdollista ottaa erilaisia keinotekoisia datan laajentamismenetelmiä, joiden avulla algoritmin suorituskykyä on todistetusti mahdollista parantaa.

Vuosien saatossa monia erilaisia koneoppimismalleja ja tilastollisia menetelmiä on tutkittu ja kehitetty, pyrittäessä aikaansaamaan edistystä teollisuuden NDT-menetelmien tarkkuudessa, tarkastuksen suorituksessa, tarkastusdatan analysoinnissa sekä niiden luotettavuudessa. Konvolutiivinen neuroverkko on osoittautunut näistä malleista lupaavimmaksi myös radiografisen tarkastuksen käyttötarkoituksissa, johtuen verkon kyvystä ottaa vastaan ja omaksua isojenkin datajoukkojen sisältämä informaatio.

6. Yhteenveto

Radiografinen tarkastus on teollisuudessa yleisesti käytössä oleva NDT-menetelmä, mm. paineastioiden, putkistojen ja teräsrakenteiden hitsausaumojen tarkastuksessa. Vaikka radiografinen kuvaus esimerkiksi lääketieteen parissa on jo pitkälti digitalisoitua, teollisuudessa merkittävä osa radiografisesta tarkastuksesta tehdään vielä perinteisellä filmiteknologialla, kuvien valotuksen ja luokittelun tapahtuessa manuaalisesti. Manuaalinen kuvien luokittelu on tarkastajan henkilökohtaisesta kokemuksesta ja osaamisesta riippuvaista, ja näin ollen virheille altista toimintaa.

Digitaalisen radiografian tehdessä hidasta läpimurtoaan myös NDT-alalla, on kuvien automatisoitu luokittelu tullut periaatteessa mahdolliseksi, mahdollistaen aiempaa luotettavamman ja nopeamman kuvien luokittelun, ilman inhimillisen tekijän vaikutusta. Automatisoitu kuvan luokittelu koostuu neljästä vaiheesta, jotka ovat kuvan esikäsittely, vian segmentointi, vian piirteiden erottelu, sekä vian luokittelu jonkin tarkoitukseen opetetun luokittelualgoritmin avulla.

Luokittelualgoritmin suorituskyky on riippuvainen sen opetukseen käytetystä kuvadatasta, käytetyistä vian segmentointimenetelmistä, sekä luokitteluun valituista vikaa kuvaavista piirteistä. Johtuen tutkimusten välillä käytetyistä erilaisista tulosten raportointitavoista, opetusaineistosta, segmentointimenetelmistä ja vikaa kuvaavista piirteistä, algoritmeja koskevien tutkimusten tulokset eivät ole keskenään suoraan vertailukelpoisia. Tämä rajoittaa tekemästä liian pitkälle meneviä johtopäätöksiä parhaasta radiografisten kuvien luokittelualgoritmista, yksittäisten tutkimusten perusteella. Tästä huolimatta, voidaan käsiteltyjen tutkimusten valossa sanoa tukivektorikoneen olevan kilpailukykyinen luokittelualgoritmi, algoritmin opetukseen käytettävän datajoukon ollessa kooltaan pieni.

Konvolutiivinen neuroverkko, sekä monikerroksinen neuroverkko, ovat kirjallisten lähteiden mukaan sitä tehokkaampia luokittelijoita, mitä suurempi on niiden opetukseen käytettävän datajoukon koko. Näistä menetelmistä erityisesti konvolutiivinen neuroverkko sopii suurten datamäärien käsittelyyn, johtuen sen kyvystä käsitellä dataa pienemmissä erissä, muokata dataa pienemmäksi ja erotella siitä piirteitä, kuitenkin menettämättä käsitystä datan sisältämästä kokonaisuudesta. Ongelmana menetelmän soveltamisessa käytäntöön radiografisen tarkastuksen parissa on ollut riittävän suuren ja tarkoitukseen soveltuvan opetusdatan tuottaminen ja löytäminen, mutta ongelmaa on onnistuneesti kierretty laajentamalla opetusdatajoukkoa erilaisilla kuvan kirkkauden, kohinan, kontrastin etc. muutoksilla, sekä luomalla keinotekoisia vikoja todellisiin kappaleisiin, että puhtaasti virtuaalisesti luotujen vikojen avulla. Laajennetun aineiston avulla opetetulla konvolutiivisella neuroverkolla on mahdollista tavoittaa mm. ilmailuteollisuuden NDT-menetelmän herkkyydeltä edellytetyt vaatimukset ja näin ollen saavuttaa taso, jonka myötä tekoälyä on mahdollista hyödyntää osana teollisuuden tarkastustyötä.

Koskinen et al. (2022) tutkimuksessa esitetään kolme menettelytapaa, joita soveltamalla tekoäly ja koneoppivat algoritmit olisivat kypsiä otettavaksi osaksi NDT:n ja radiografian kenttätyötä jo nyt. Nämä menettelytavat ovat algoritmien käyttäminen apuna vikojen skannauksessa, indikaatioiden listauksessa sekä tilastollisen tiedon tarjoilemisessa. Vikojen skannausapu tarkoittaisi algoritmien käyttämistä avuksi oletettujen vika-alueiden merkkauksessa, jolloin vian tarkempi paikantaminen, luokittelutyö ja vakavuusasteen arviointi jäisi tarkastajan vastuulle. Indikaatioiden listauksessa algoritmi segmentoisi löydetyn vikaindikaation, ja tuottaisi numeerista tietoa löydöksestä listamuodossa, jonka tehtävänä olisi helpottaa tarkastajan tekemän varsinaisen arviointitehtävän suorittamista. Tilastollisen tiedon tarjoilemisessa keskiössä eivät olisi yksittäiset virheet, vaan tuotteen tai tuotannon yleinen laatutaso, esimerkiksi huokoisuusprosentin osalta.

Hitsatut tuotteet, hitsausmenetelmästä riippumatta, pitävät yleisesti ottaen sisällään epäjatkuvuuksia, jotka eivät aiheuta merkittävää vaaraa rakenteen kestävyydelle, kuten esimerkiksi pienet huokokset. Resurssien puutteesta johtuen, nämä epäjatkuvuudet jäävät yleensä tarkastushenkilökunnalta merkkäämättä ja raportoimatta. Hyväksyttävien epäjatkuvuuksien määrä, koko ja sijaintitiedot voivat kuitenkin tarjota tärkeää tietoa epäoptimaalisista hitsausparametreista tai laitteiden toimintahäiriöistä. Ottamalla tekoäly osaksi tuotannon laadunvalvontaa ja radiografisten kuvien analysointia, tietoa valmistuksen epäkohdista voidaan välittää tuotantohenkilökunnalle muodossa, joka on ymmärrettävissä myös niille, joilla ei ole aiempaa kokemusta radiografisten kuvien tulkitsemisesta. Ilman tekoälyn apua, kyseisen tiedon kerääminen, tilastoiminen ja raportointi on tehtävän vaatimista resursseista johtuen tällä hetkellä käytännössä katsoen mahdotonta.

Lähteet

- Abbas, H. T., Alic, L., Erraguntla, M., Ji, J. X., Abdul-Ghani, M., Abbasi, Q. H., & Qaraqe, M. K. (2019). Predicting long-term type 2 diabetes with support vector machine using oral glucose tolerance test. *PloS One*, *14*(12), e0219636.
- Arksey, H., & O'Malley, L. (2005). Scoping Studies: Towards a Methodological Framework. *International Journal of Social Research Methodology*, *8*(1), 19–32.
- Bhardwaj, A., Di, W., & Wei, J. (2018). *Deep Learning Essentials : Your Hands-on Guide to the Fundamentals of Deep Learning and Neural Network Modeling*. Packt Publishing.
- Bironneau, M., & Coleman, T. (2019). *Machine Learning with Go Quick Start Guide : Hands-on Techniques for Building Supervised and Unsupervised Machine Learning Workflows*. Packt Publishing.
- Cartz, L. (1995). *Nondestructive Testing*. ASM International.
- Dang, C., Li, J., Du, W., Zeng, Z., & Wang, R. (2019). A novel extraction method for weld defect segmentation seeds using ANDM and clustering. *Insight: Non-Destructive Testing & Condition Monitoring*, *61*(12), 706–713.
- Gulli, A., & Pal, S. (2017). *Deep Learning with Keras : Get to Grips with the Basics of Keras to Implement Fast and Efficient Deep-learning Models*. Packt Publishing.
- Hemanth, D. J., & Estrela, V. V. (2017). *Deep Learning for Image Processing Applications* (Issue volume 31). IOS Press.
- Kitanishi, Y., Fujiwara, M., & Binkowitz, B. (2021). Patient journey through cases of depression from claims database using machine learning algorithms. *PLoS ONE*, *16*(2), 1–11.
- Koskinen, T., Tyystjärvi, T., Siljama, O., & Virkkunen, I. (2022). The Advantage of Machine Learning to the Inspector. *59th Annual Conference of the British Institute of Non-Destructive Testing, NDT 2022*, 183–194.
- Lee, Y.-C. (2019). Stronger assurance through machine learning: By inferring from past examples, artificial intelligence tools can generate useful, real-world audit insights. *Internal Auditor*, *76*(4), 27–31.
- Lim, T. Y., Ratnam, M. M., & Khalid, M. A. (2007). Automatic classification of weld defects using simulated data and an MLP neural network. *Insight: Non-Destructive Testing & Condition Monitoring*, *49*(3), 154–159.

- Rahman, W. (2020). *AI and Machine Learning*. Sage Publications Pvt. Ltd.
- Roy, A. (2020). The Fourth Industrial Revolution: Klaus Schwab, New York, Currency Books, 2017, 192 pp., \$15.50 (Softcover), ISBN 978-1-5247-5886-8. *Journal of International Consumer Marketing*, 32(3), 268–270.
- Shen, Q. M., Gao, J. M., & Li, C. (2009). Adaptive segmentation of weld defects based on flooding. *Insight: Non-Destructive Testing & Condition Monitoring*, 51(10), 541–547.
- Taheri, H., Gonzalez Bocanegra, M., & Taheri, M. (2022). Artificial Intelligence, Machine Learning and Smart Technologies for Nondestructive Evaluation. *Sensors (14248220)*, 22(11), 4055.
- Tyystjärvi, T., Virkkunen, I., Fridolf, P., Rosell, A., & Barsoum, Z. (2022). Automated defect detection in digital radiography of aerospace welds using deep learning. *Welding in the World*, 66(4), 643–671.
- Wang, Y., Wang, R., Li, D., Adu-Gyamfi, D., Tian, K., & Zhu, Y. (2019). Improved Handwritten Digit Recognition using Quantum K-Nearest Neighbor Algorithm. *International Journal of Theoretical Physics*, 58(7), 2331–2340.
- Yang, D., Cui, Y., Yu, Z., & Yuan, H. (2021). Deep Learning Based Steel Pipe Weld Defect Detection. *Applied Artificial Intelligence*, 35(15), 1237–1249.
- Yang, L., & Jiang, H. (2021). Weld defect classification in radiographic images using unified deep neural network with multi-level features. *Journal of Intelligent Manufacturing*, 32(2), 459–469.
- Zohuri, B. . (2020). *Artificial Intelligence Driven By Machine Learning And Deep Learning*. Nova.