



Vaasan yliopisto
UNIVERSITY OF VAASA

Kaarle Nieminen

Konenäkö laadunvalvonnassa

Konenäön hyödyntäminen piirilevyjen valmistuksen laadunvalvonnassa

Tekniikan ja
innovaatiojohtamisen yksikkö
Kandidaatintutkielma
Automaatio ja tietotekniikka

Vaasa 2026

VAASAN YLIOPISTO**Tekniikan ja innovaatiojohtamisen yksikkö**

Tekijä:	Kaarle Nieminen		
Tutkielman nimi:	Konenäkö laadunvalvonnassa: Konenäön hyödyntäminen piirilevyjen valmistuksen laadunvalvonnassa		
Tutkinto:	Tekniikan kandidaatti		
Oppiaine:	Automaatio ja Tietotekniikka		
Työn ohjaaja:	Timo Mantere		
Valmistumisvuosi:	2026	Sivumäärä:	36

TIIVISTELMÄ:

Tässä kandidaatintutkielmassa tarkastellaan konenäön hyödyntämistä piirilevyvalmistuksen laadunvalvonnassa. Tavoitteena on selvittää, miten konenäköä voidaan käyttää tehokkaasti laadunvalvontaprosessissa. Tarkastelun kohteena ovat myös konenäön tuomat mahdolliset edut ja haasteet. Tämä tutkielma on kirjallisuuskatsaus, jossa esitellään ensin piirilevyjen valmistusprosessi ja nykyisiä laadunvalvontamenetelmiä. Tämän jälkeen käydään läpi konenäön ja syväoppimisen periaatteita sekä sovelluksia teollisuudessa.

Case-esimerkkinä tarkastellaan syväoppimiseen perustuvaa, YOLOv5-arkkitehtuuriin pohjalta kehitettyä mallia, joka on kehitetty pintavikojen tunnistamiseen piirilevyistä. Esimerkin perusteella syväoppiminen kykenee parantamaan vikojen tunnistustarkkuutta ja vähentämään väärin hälytysten määrää. Tutkielman johtopäätöksenä todetaan, että tekoäly ja konenäkö tarjoavat merkittäviä mahdollisuuksia laadunvalvonnan tehostamiseen, mutta käyttöönottoon kuitenkin vielä liittyy haasteita alkuinvestointien suuruudesta laadukkaan opetusdatan keräämiseen. Pitkällä aikavälillä kehityksen voidaan kuitenkin odottaa etenevän kohti integroidumpia sekä itseoppivia järjestelmiä.

AVAINSANAT: Konenäkö, laadunvalvonta, piirilevyn valmistus, tekoäly, syväoppiminen

Sisältö

1	Johdanto	6
2	Laadunvalvonnan nykytila	8
3	Konenäön perusteet	10
3.1	Sovellukset valmistavassa teollisuudessa	10
3.2	Tekoälyn käyttö teollisuudessa ja muilla sektoreilla	11
4	PCB-valmistusprosessi	13
4.1	Suunnittelu	13
4.2	Materiaalin valinta ja valmistus	13
4.3	Kerrostaminen ja poraukset	13
4.4	Komponenttien asettelu	14
4.5	Juottaminen	14
4.6	Testaus ja laadunvalvonta	14
4.7	Lopputäydennys ja -tarkastus	14
4.8	Yhteenveto piirilevyjen valmistusprosessista	15
5	Konenäön hyödyntäminen PCB-laadunvalvonnassa	16
5.1	PCB-laadunvalvonnan vaatimukset	16
5.2	Esimerkkejä käytetyistä konenäköratkaisuista	17
5.3	Konenäön hyödyt ja haasteet laadunvalvonnassa	17
5.4	Yhteenveto nyky menetelmistä	19
6	Case-esimerkki	20
7	Menetelmien vertailu	22
7.1	Kustannukset	22
7.1.1	AOI- ja AXI-järjestelmät	22
7.1.2	Case-esimerkin järjestelmä	26
7.2	Laadunvalvonnan suorituskyky	27
7.3	Nyky aikaisten konenäköratkaisuiden kustannukset	28
8	Johtopäätökset	30

9	Lähteet	32
---	---------	----

Kuvat

Kuva 1. Tilastokeskuksen kuvio tekoälyn käytöstä toimialasektoreittain (Tilastokeskus, 2024).	12
Kuva 2. Kuvassa vertailu kahden eri AOI-koneen värimaailman välillä (Chen ja muut, 2023, s. 3).	18
Kuva 3. Artikkelin käyttämää pohjadataa (EPP Europe, 2007).	22
Kuva 4. Kustannukset pelkällä ICT-testauksella (EPP Europe, 2007).	23
Kuva 5. Kustannukset ICT ja AOI testauksella (EPP Europe, 2007).	24
Kuva 6. Kustannukset ICT ja AXI testauksella (EPP Europe, 2007).	25

Termit ja Lyhenteet

Termit

Konenäkö on teknologia, joka mahdollistaa koneiden kyvyn hankkia, analysoida ja tulkita visuaalista dataa automaattisesti ilman ihmisen väliintuloa. Sen keskeisiä sovelluksia ovat teollinen laadunvalvonta, robotiikka ja prosessiautomaatio (Yasar, n.d).

Piirilevy on elektronisten komponenttien asennusalusta. Piirilevyyn kiinnitetään kaikki eri osat laitteen toimintavaatimuksen mukaan, esimerkiksi antennit, mikrofonit, kaiuttimet ja prosessorit.

Automaattinen optinen tarkastus on kuvantamiseen perustuva laadunvalvontamenetelmä, joka tunnistaa PCB:n virheet tehokkaasti ilman ihmisen väliintuloa (Emery ja muut, 2014, s. 1095–1096).

Automatisoitu röntgentarkastus (AXI) havaitsee virheitä ja vikoja piilossa olevissa komponenteissa, juotoksissa, sisäisissä johdinradoissa ja läpivienneissä röntgenkuvauksen avulla (Sierra Circuits Inc., 2022, s. 26).

Stereomallintaminen on useiden eri kulmista, mutta samasta esineestä tai asiasta otettujen pikselien vertaamista ja yhdistelyä kolmiulotteisen mallin luomiseksi. (Szeliski, 2010, s. 535).

Syväoppiminen (englanniksi deep learning) on koneoppimisen ja tekoälyn osa-alue, jossa hyödynnetään useista peräkkäisistä kerroksista koostuvia keinotekoisia neuroverkkoja monimutkaisten piirteiden ja riippuvuuksien oppimiseen suurista tietomassoista (Goodfellow, Bengio & Courville, 2016).

Lyhenteet

AOI:	Automatic Optical Inspection (Automaattinen optinen tarkastus)
AXI:	Automated X-ray Inspection (Automatisoitu röntgentarkastus)
ICT:	In-circuit test (Piirilevyn sisäinen testaus)
PCB:	Printed circuit board (Piirilevy)
AI:	Artificial intelligence (Tekoäly)

1 Johdanto

Piirilevyjen (PCB) valmistus on keskeinen osa elektroniikkateollisuutta. Laadukkaiden piirilevyjen valmistus on erittäin keskeisessä roolissa elektroniikkatuotteiden toimivuuden ja luotettavuuden kannalta. Huonosti valmistettu piirilevy saattaa, johtaa piirin sisäiseen oikosulkuun, joka pahimmillaan saattaa jopa saada aikaiseksi pienen elektroniikkapalon.

Modernit piirilevyt ovatkin jo niin pieniä ja monimutkaisia, etteivät perinteiset laadunvalvontamenetelmät, kuten manuaalinen tarkastus riitä takaamaan valmistusprosessin korkeaa laatua ja tehokkuutta (Taha ja muut, 2014, s.1). Tästä seurauksena on konenäön mahdollisuudet kasvaneet piirilevyjen valmistuksen laadunvalvonnassa, mahdollistaen nopean, tarkan ja automaattisen virheiden tunnistamisen (Wang ja muut, 2016).

Konenäkö yhdistää tekoälyn, koneoppimisen ja kuvantamisteknologiat, joiden avulla voidaan tunnistaa piirilevyjen ja muidenkin valmistusprosessien mahdollisia laatuvirheitä (Hornberg, 2017, s. 27).

Tässä tutkielmassa tarkastellaan, miten konenäköä voidaan käyttää piirilevyjen valmistuksen laadunvalvonnassa, ja mitkä ovat sen hyödyt perinteisiin tarkastusmenetelmiin verrattuna. Päätaivitteena on selvittää, miten konenäköä voidaan hyödyntää tehokkaasti laadunvalvontaprosesseissa PCB-valmistuksessa.

Tässä tutkielmassa alkuun käsitellään piirilevyjen valmistusprosessia ja sen laadunvalvontaa. Sitten syvennyttään konenäköön ja sen mahdollisuuksiin laadunvalvonnassa. Lopuksi analysoidaan konenäön hyötyjä ja haasteita perinteisiin laadunvalvontamenetelmiin verrattuna, sekä pohditaan mahdollisia tulevaisuuden kehityssuuntia.

Aiheeseen päädyttiin osittain sattumalta. Kandidaatin tutkielman aiheeksi oli pitkään harkittu jotakin konenäköön liittyvää teemaa. Tekoälyn avulla kartoitettiin erilaisia konenäön osa-alueita, joita olisi mahdollista tarkastella tutkimuksen näkökulmasta. Lopulta huomio kohdistui laadunvalvontaan, erityisesti sen mahdollisiin sovellusmahdollisuuksiin sähkömoottoritehtaan komponenttivalmistuksessa. Työnantajalta saadun vastauksen viivästyttyä päätettiin kuitenkin siirtyä toiseen aiheeseen, joka liittyi konenäön hyödyntämiseen laadunvalvonnassa laajemmin. Eri teollisuudenalojen laadunvalvontasovelluksia tarkasteltaessa löytyi useita kiinnostavia artikkeleita ja käsikirjoja, jotka käsittelevät konenäön käyttöä piirilevyjen valmistuksessa.

Tämä tutkielma onkin suunnattu opiskelijoille ja muille lukijoille, joilla on kiinnostusta konenäköön, mutta ei vielä välttämättä ole laajempaa käsitystä kaikkeen sitä voidaan hyödyntää. Tämä tutkielma on myös kirjallisuuskatsaus konenäön hyödyntämiseen piirilevyvalmistuksen laadunvalvonnassa, jossa hyödynnetään artikkeleita ja kirjoja eri konenäön sovelluksista piirilevyjen laadunvalvonnassa. Kirjallisuuskatsaus on tieteellinen teksti, jossa kootaan, jäsennetään ja arvioidaan aiempaa tutkimusta rajatusta aiheesta tai tutkimuskysymyksestä, ja jonka tavoitteena on muodostaa kokonaiskuva olemassa olevasta tiedosta, keskeisistä käsitteistä, käytetyistä menetelmistä ja tutkimusaukoista (Salminen, 2011).

Tämän tutkielman tarkoituksena on selvittää konenäön roolia piirilevyjen valmistuksen laadunvalvonnassa. Tutkimuksessa haetaan vastausta seuraaviin pääkysymyksiin. Miten syväoppimiseen perustuvaa konenäköä voidaan hyödyntää piirilevyjen valmistuksen laadunvalvonnassa. Jotta tätä aihetta voidaan käsitellä kattavasti, tulee uutta teknologiaa verrata myös nyky menetelmiin, vastaamalla kysymykseen miten syväoppimismenetelmien suorituskyky ja kustannukset vertautuvat perinteisiin laadunvalvontamenetelmiin. Lisäksi selvitetään myös, mitä etuja ja haasteita tekoälypohjaisen laadunvalvonnan käyttöönottoon liittyy nykyisessä tuotantoympäristössä.

2 Laadunvalvonnan nykytila

Ghelanin (2024, s. 1550–1551) mukaan lopputuotteen nykyinen laadunvalvonta piirilevyjen valmistuksessa koostuu kolmesta eri päätävästä, jotka ovat visuaalinen tarkistus, AOI-tarkistus ja röntgentarkistus. Visuaalisessa tarkistuksessa koulutetut henkilöt silmämääräisesti tarkistavat piirilevyt suurennuslaseilla ja muilla suurennustyökaluilla. AOI-tarkistuksessa käytetäänkin jo konenäköä. Siinä tarkistetaan korkean resoluution kameroilla ja kirkkailla LED-valoilla löytyykö piiristä mitään selkeitä virheitä, esimerkiksi puuttuvia komponentteja tai väärin aseteltuja komponentteja. Röntgentarkistuksessa taas tarkastetaan monimutkaisempien piirilevyjen sisäistä rakennetta, jolla varmistetaan, että juotokset ovat laadukkaita ja oikeanlaisia.

Ghelani (2024, s. 1551) kertoo myös, että yleisimmät ongelmat näissä perinteisissä laadunvalvontametoodeissa ovat inhimilliset erehdykset, korkeat kustannukset, epä johdonmukainen vian havaitseminen ja tuotannon kasvaessa skaalautuvuusongelmat.

Perinteiset laadunvalvontamenetelmät ovat reaktiivisia ja tunnistavat viat vasta valmistuksen jälkeen, mikä lisää tuotantokustannuksia ja jätettä (Ghelani, 2024, s. 1552). Tekoälyn avulla laadunvalvonnasta voidaan tehdä ennakoivaa. Tämä alentaisi kustannuksia ja vähentäisi jätettä, sillä virheet tunnistettaisiin jo valmistusvaiheessa, jolloin niihin voitaisiin reagoida ennen tuotteen valmistumista.

Seuraavaksi käydään läpi esimerkki laadunvalvontaprosessista. Tässä käytetään esimerkkinä PCBASIC JS YouTube-kanavan julkaisemaa videota piirilevyjen valmistusprosessista. Videossa käydään erityisesti läpi laadunvarmistusprosessia piirilevyjen tuotannossa.

Laadunvalvontaprosessi videolla alkaa materiaalien tarkastuksella, jossa jo ennen ensimmäisenkään piirilevyjen valmistusta tarkastetaan materiaalit, joita tuotannossa tullaan käyttämään. Näitä materiaaleja ovat levyjen alusta materiaali ja levyyn liitettävät

komponentit. Seuraavaksi materiaalitarkastuksen jälkeen juotepasta levitetään piirilevylle kaaviotulostimella. Juotepasta tarkastetaan solder paste inspection (SPI)-laitteella, joka käyttää 3D-rasterikameroita piirilevyn kuvaamiseen.

Tämän jälkeen laadunvalvontaprosessissa seuraa AOI-tarkastus, jossa otetaan kuvia piirilevystä ja kuvia verrataan pohjatietoihin ja tarkastetaan muun muassa komponenttien paikat ja piirilevyn koko. AOI-tarkastuksella myös varmistetaan, että juotteet ovat laadullisesti vaaditulla tasolla.

AOI- testauksen jälkeen tehdään tarkempi ensimmäisen kappaleen tarkastus, jossa varmistetaan perinpohjaisesti tuotetun piirilevyn laatu ennen massatuotannon aloittamista. Tällä pyritään vähentämään työkuormaa massatuotannon aikana varmistamalla, että kaikki osat piirilevystä varmasti ovat vaaditulla tasolla laadullisesti. Tätä vaihetta ei tehdä itse massatuotantovaiheen aikana vaan ainoastaan ennen massatuotannon aloitusta.

Viimeinen osa laadun tarkastusta tässä esimerkissä on in-process quality control (IPQC), jolla mitataan useita muuttujia tasaisen laadun varmistamiseksi. Mitattavia muuttujia ovat komponenttien vastus ja jännite, näiden lisäksi tarkastetaan piirilevyn koko, komponenttien sijoittelu, napaisuus ja kulmasuunta. Lisäksi asennettujen komponenttien määrä ja tekniset tiedot tarkastetaan materiaaliluetteloon ja asiakasasiakirjoihin verraten. IPQC:n avulla varmistetaan, että laatu säilyy koko tuotantoprosessin ajan.

Tämä esimerkki tosiaan on otettu PCBasic JS YouTube-kanavan videosta Quality Inspection Process for PCB Assembly Manufacturer.

3 Konenäön perusteet

Konenäkö perusidealtaan pyrkii mallintamaan kolmiulotteisen maailman visuaalisten havaintojen perusteelta esimerkkinä kuvien pohjalta. (Szeliski, 2010, s. 3). Konenäön perusteiden ymmärtämistä helpottaa, kun vertaa sitä siihen, miten ihmisten silmät ja aivot toimivat. Esimerkiksi kukkamaljakkoa tarkastellessa kykenemme erottamaan kukan yksittäiset terälehdet ja muun muassa arvioimaan kyseisen terälehdän läpinäkyvyyttä (Szeliski, 2010, s. 3). Konenäkö pyrkii samaan kuvia tarkastelemalla esimerkiksi algoritmeilla, kolmiulotteisilla mallinuksilla ja stereomallintamisella.

Näköhavainnot kuitenkin tuottavat omat ongelmansa, sillä kuva sisältää vain osan informaatiosta ja paljon tuntemattomia suureita jää pääteltäväksi (Szeliski, 2010, s. 3). Tästä syystä joudutaankin usein turvautumaan fysiikka- ja todennäköisyyspohjaisiin malleihin, joilla pyritään löytämään todennäköisimmät ratkaisut näihin tuntemattomiin suureisiin. Tästä syystä visuaalisen maailman monimuotoisuutta on selkeästi hankalampi mallintaa, kuin esimerkiksi äänielimistön, joka tuottaa puhuttuja ääniä (Szeliski, 2010, s. 3).

Konenäköä pystytään vertaamaan käänteisesti animointiin. Animoinnissa tarkoituksena on luoda muotoja ja liikettä, sekä sovittaa ne ympäristöönsä, miten valo heijastuu kappaleesta ja niin edelleen. Konenäkö taas pyrkii juuri päinvastaiseen eli kuvaamaan maailman yhden tai useamman kuvan pohjalta (Szeliski, 2010, s. 5). Se pyrkii rekonstruoimaan ja ymmärtämään kuvan tai kuvien sisältöä, kuten muotoja, valotusta ja värejä (Szeliski, 2010, s. 5).

3.1 Sovellukset valmistavassa teollisuudessa


Konenäköä käytetään useisiin erilaisiin tehtäviin nykyään valmistavassa teollisuudessa. Eri tehtäviä ovat muun muassa tarkastustehtävät, kokoonpanotehtävät, mittaustehtävät, ohjaustehtävät ja kappalelaskentatehtävät (Savon Automaatio). Näistä eri valmistavan teollisuuden tehtävistä tarkastustehtävät, sekä mittaustehtävät ovat juuri

laadunvalvonnallista puolta tuotantoprosessissa. Tarkastustehtävät ovat esimerkiksi pakkausten ulkonäön tarkastaminen tai oikeiden pakkausmerkintöjen tarkistaminen (Savon Automaatio). Mittaustehtävät ovat taas esimerkiksi kappaleiden mittausta reunantunnistusalgoritmeilla, jossa mitataan kuvan pikselit, jotka kerrotaan ennalta parametroiduilla kertoimilla (Savon Automaatio). Näin saadaan konenäön avulla tarkastettua valmistuttujen kappaleiden mittoja ja, että ne täyttävät niille asetetut vaatimukset.

3.2 Tekoälyn käyttö teollisuudessa ja muilla sektoreilla

Konenäön ja tekoälyn käyttö teollisuudessa ja muillakin sektoreilla kasvaa vuosi vuodelta. Vuonna 2024 teollisuusalan yrityksistä 22 % käytti jotakin tekoälyteknologiaa, johon konenäkö lukeutuu (Tilastokeskus, 2024). Kaikilla sektoreilla tekoälyteknologiaa käyttävien yritysten määrä kasvoi 9 % vuodesta 2023 (Tilastokeskus, 2024). Teollisuussektorilla tekoälyn ja konenäön käyttö ei ole vielä niin yleistä, kuin muilla sektoreilla. Kuitenkin muiden alojen tavoin on tekoäly lisääntymässä myös teollisuussektorilla. Kuvassa 1 näemme teollisuussektorin tekoälyn käytön muihin toimialasektoreihin verrattuna.

Yrityksellä käytössä tekoälyteknologioita, % yrityksistä 2024 toimialoittain



Lähde: Tilastokeskus, tietotekniikan käyttö yrityksissä

Kuva 1. Tilastokeskuksen kuvio tekoälyn käytöstä toimialasektoreittain (Tilastokeskus, 2024).

4 PCB-valmistusprosessi

4.1 Suunnittelu

Suunnitteluvaiheessa luodaan piirikaaviot, piiritoimintoja, komponenttien järjestys ja määritellään johtojen reitit. Tässä käytetään useimmiten automaattista suunnittelujärjestelmää, joka asetettujen vaatimusten mukaisesti osaa suunnitella toimivan piirilevyn (PCBAndAssembly, 2023). Suunnitteluvaiheessa valitaan myös piirilevyn alustan materiaali. Levy voi olla tehty esimerkiksi paperilevystä, joka kovetetaan epoksilla, lasikankaasta, joka kovetetaan epoksilla, metallista tai ne voivat olla myös keraamisia (NeoDen, 2019). Yleisimmin käytetyt levyt ovat valmistettu epoksista ja lasikankaasta, josta käytetään FR4 lyhennettä (NeoDen, 2019). FR4 tarkoittaa palonestokäsittelyä, joka tehdään lasikuituepoksille (Yogendrappa, 2021).

4.2 Materiaalin valinta ja valmistus

Suunnitteluvaiheessa päätetystä materiaalista valmistetaan piirilevyn pohja ja valmistellaan kuparifolio, josta piiri johtimet valmistetaan (PCBAndAssembly, 2023). Lisäksi tässä vaiheessa pinnoitetaan piirilevyn kohdat joihin juotoksia ei tule, sekä tulostetaan levyyn tulevat tekstit ja merkinnät (PCBAndAssembly, 2023).

4.3 Kerrostaminen ja poraukset

Tässä vaiheessa piirilevyn eri kerrokset laminoidaan yhteen (ICAPE, n.d.). Piirilevyt ei kuitenkaan välttämättä ole monikerroksisia, jolloin laminointia ei tarvitse tehdä. Tässä vaiheessa myös porataan levyyn tarvittavat reiät johtimille ja monikerroksisissa piirilevyissä myös läpivienneille (ICAPE, n.d.).

4.4 Komponenttien asettelu

Komponentit asetetaan piirrettyjen suunnitelmien mukaisille paikoille. Komponentteja löytyy pääosin kahta eri tyyppiä, jotka hyödyntävät joko pintaliitostekniikkaa tai rei'itettävyystekniikkaa (ICAPE, n.d.).

4.5 Juottaminen

Pintaliitoskomponentit asetellaan paikoilleen ja juotetaan nimensä mukaisesti piirilevyn pintaan. rei'itettävyystekniikkaa käyttävät komponentit asetetaan poraamisvaiheessa tehtyjen reikien kohdalle, jotta ne saadaan juotettua oikealle tasolle monikerroksisessa piirilevyssä.

4.6 Testaus ja laadunvalvonta

Testausvaiheessa lähes valmiiden piirilevyjen juotokset ja yleiset toiminnallisuudet testataan (ICAPE, n.d.). Laadunvalvontavaiheessa tarkistetaan piirilevyt käyttäen eri automatisoituja ja manuaalisia tarkistusmenetelmiä, piirilevyn monimutkaisuudesta ja valmistajasta riippuen. Lopputarkastuksessa suurin osa testeistä toistetaan vielä laadunvarmistamiseksi.

4.7 Lopputäydennys ja -tarkastus

Lopputäydennyksessä lisätään viimeiset liittimet, lisäkomponentit sekä muut tarvittavat suojakotelot ja kuljetussuojat (ICAPE, n.d.).

Lopputarkastukset ovat (ICAPE, n.d.) mukaan olennainen osa piirilevyjen (PCB) valmistusta, ja niiden avulla varmistetaan sekä sähköinen toimivuus että luotettavuus. Visuaalinen tarkastus ja automaattinen optinen tarkastus (AOI) tunnistavat pintapuoliset viat, kun taas sähköiset testit, kuten in-circuit-testaus (ICT) ja toiminnallinen testaus, varmistavat liitännät ja komponenttien moitteettoman toiminnan. Lentävien anturien testaus (flying probe) tarjoaa joustavan tarkastusvaihtoehdon prototyypeille ja pienille

tuotantoerille ilman erillisiä testikalusteita. Röntgentarkastus paljastaa piilevät viat, ja lämpörasitustestit mittaavat piirilevyn kestävyyttä erilaisissa lämpötiloissa. Laadunvalvontadokumentaatio puolestaan varmistaa jäljitettävyyden ja standardien mukaisuuden, jotta valmistusvirheet voidaan havaita ja korjata jo varhaisessa vaiheessa.

4.8 Yhteenveto piirilevyjen valmistusprosessista

Edellisistä kappaleista voi huomata, piirilevyjen valmistus on monivaiheinen sekä monimutkainen valmistusprosessi varsinkin nykyaikaisten piirilevyjen erittäin pienen koon takia. Valmistusprosessi itsessään on jo niin laaja, kun kaikki eri materiaalivaihtoehdot, juotostavat, useat kerrokset ja komponentit ottaisi huomioon kykenisi siitä pelkästään kirjoittamaan jo useamman kandidaatintutkielman. Mahdollisuuksia erilaisiin valmistusvirheisiin on runsaasti, aina inhimillisistä virheistä valmistuslaitteiden tekemiin virheisiin. Kaikkien näiden valmistusvaiheiden aikana väistämättä tapahtuu virheitä ja siksi juuri konenäön ja tekoälyn laajempi käyttöön otto valmistusprosessin laadunvalvontaan voisi, jopa merkittävästi parantaa valmistusprosessin tehokkuutta. Jo pelkästään virheiden havaitsemisen lisääminen tuotantoprosessiin tulisi lisäämään tehokkuutta, kun ei tarvitsisi odotella tuotantoprosessia loppuun, jotta voisi tarkastaa piirilevyyn tulleet mahdolliset valmistusvirheet.

5 Konenäön hyödyntäminen PCB-laadunvalvonnassa

5.1 PCB-laadunvalvonnan vaatimukset

Piirilevyjen valmistuksen laadunvalvonnassa kuten muittenkin tuotteiden laadunvalvonnassa on useita päävaatimuksia. PCB valmistuksen laadunvalvonnan päävaatimuksia ovat tarkkuus, toistettavuus, nopeus ja automaatio (Sierra Circuits Inc., 2022, s. 8–12).

Tarkkuus on erittäin tärkeää erityisesti pienten vikojen havaitsemiseen, esimerkkinä näistä juotosvirheet, oikosulut ja väärin sijoitellut komponentit. Tarkastustekniikkoja, jotka jo hyödyntävät konenäkö, joilla saadaan hyvä tarkkuus ovat AOI ja AXI eli automaattinen optinen tarkastus ja automatisoitu röntgentarkastus. AXI testauksessa piirilevy asetetaan röntgentarkastus laitteen sisälle, jossa se kuvataan ja kuvat tarkastutetaan ihmisen toimesta. (Sierra Circuits Inc., 2022, s. 26). Kuvista tarkastetaan juotosten laatu, joka nähdään röntgenkuvassa juotosten värin perusteella, jossa tumma väri juotoksessa merkitsee korkeaa laatua (Sierra Circuits Inc., 2022, s. 26).

Laadunvalvonnassa tärkeää myös toistettavuus. Tarkastusprosessin on pystyttävä tuottamaan luotettavia ja johdonmukaisia tuloksia jokaisessa tuotantoerässä. Tässä yleisesti käytetty menetelmä on ICT testaus. ICT testauksessa tuotantolinjaan esiasennetut sähköanturit testaavat ennalta määritellyistä kohdista mitataan piirilevyn johtavuus (Sierra Circuits Inc., 2022, s. 16). Tämän tyyppinen testaus ei käytä konenäköä ja toistaiseksi sen korvaaminen konenäöllä on hyödytöntä, sillä piirin johtavuutta ei kameran avulla pysty testaamaan. ICT testaus on kuitenkin keskeinen osa laadunvalvontaprosessia.

Nopeus on tuotantoprosessin kannalta keskeinen vaatimus laadunvalvonnankin osalta. ICT ja AOI testaukset pystytään integroimaan suoraan tuotantolinjaan, joka mahdollistaa reaaliaikaisen tarkastuksen ilman manuaalisia välikäsitteilyjä. Tämä nopeuttaa koko

tuotantoprosessia, kun osa testauksista pystytään suorittamaan suoraa tuotantolinjalla eikä esimerkiksi erillisellä testikentällä.

5.2 Esimerkkejä käytetyistä konenäköratkaisuista


Piirilevyn valmistuksessa käytetään jo useita eri konenäköratkaisuja. Yleisimpiä ratkaisuja ovat jo aikaisemmin mainitut AOI ja AXI tarkastus. Näiden lisäksi yleisesti käytettyjä tekniikoita ovat algoritmit pintavirheiden tarkastamiseen ja kuviontunnitus, joka yleisesti on osa AOI tarkastusta. Toistaiseksi vielä vähäisemmässä käytössä oleva tekoälyyn perustuva konenäkö, jonka käyttö ja yleisyys kuitenkin kasvaa jatkuvasti.

Nämä tekoälypohjaiset konenäkö ratkaisut poikkeavat nykyisistä sääntöpohjaisista tarkistus menetelmistä, kuten AOI ja AXI tarkistuksesta siten, että ne pystyvät oppimaan saamastaan tiedosta oppia parantamaan tarkkuutta ja tehokkuutta (Ghelani, 2024, s. 1549–1554). Eräs merkittävä sovellus näistä tekoälypohjaisista tarkastustavoista hyödyntää neuroverkkoja, jotka ovat koulutettu laajalla kuvadatasarjoilla. Nämä datasarjat sisältävät viallisia ja viattomia piirilevyjä, jotta tekoäly kykenisi mahdollisimman tarkasti tunnistamaan pienimmätkin virheet eri ympäristöissä ja valo olosuhteissa (Ghelani, 2024, p. 1553). Kappaleessa 6 Case-esimerkit ja tulevaisuuden kehityssuunnat palaan vielä tarkemmin asiaan käsittelemällä tarkemmin tutkimusta tekoälypohjaisista konenäköratkaisuista piirilevyvalmistuksen laadunvalvonnassa.

5.3 Konenäön hyödyt ja haasteet laadunvalvonnassa

Mitä hyötyjä ja haasteita konenäön käyttämisestä piirilevyjen valmistusprosessin laadunvalvonnassa sitten on. Hyötyjä on jo tekstissä aikaisemmin mainittu jo muutamaan kertaan. Niitä ovat muun muassa tehokkuus, toistettavuus ja tarkkuus. Näiden lisäksi jopa suurin hyöty eli reaaliaikainen palaute. Lisäksi hyöty, jota ei vielä juurikaan ole käsitelty on pitkäaikaiset kustannussäästöt. Tekoälypohjaiset järjestelmät vähentävät työvoimakustannuksia, joka pitkällä aikavälillä kerryttää suuria säästöjä (Ghelani, 2024, s. 1552).

Monien hyötyjen lisäksi konenäköjärjestelmät tuovat esiin omat haasteensa. Valon ja kontrastin vaihtelu on yksi iso haaste konenäköjärjestelmille. Esimerkiksi AOI-tarkastuskoneet ovat herkkiä valaistuksen muutoksille, joka vaikuttaa kuvan laatuun ja sitä kautta konenäön kykyyn havaita virheitä kuvista (Chen ja muut, 2023, s. 3). Eri AOI-koneilla otetut kuvat tuottavat useimmiten erilaisen kuvan valotukselta, kontrastilta ja tarkkuudelta, joka tuottaa haasteita toisille AOI-koneille tulkitta oikein näitä kuvia (Chen ja muut, 2023, s. 6). Kuvassa 2 nähdään kahden eri AOI-koneen ottamat kuvat samasta kohteesta ja näemme, kuinka erilaiset värimaailmat kahden eri koneen välillä on. Nämä erot kuvissa tekevät virheiden havaitsemisesta vaikeampaa, kun niitä on otettu useilla eri koneilla.



Kuva 2. Kuvassa vertailu kahden eri AOI-koneen värimaailman välillä (Chen ja muut, 2023, s. 3).

5.4 Yhteenveto nyky menetelmistä

Konenäön merkitys piirilevyvalmistuksen laadunvalvonnassa on kasvanut merkittäväksi osaksi tuotantoprosessia. Edeltävässä luvussa kävimme läpi piirilevyvalmistuksen laadunvalvonnan keskeisiä vaatimuksia, yleisimpiä käytössä olevia konenäköjärjestelmiä ja niiden tuomia haasteita ja höytyjä.

Keskeisinä vaatimuksina laadunvalvonnassa on toistettavuus, tarkkuus, nopeus ja automaatio. Automaattinen optinen tarkastus (AOI) esimerkiksi mahdollistaa edellisten vaatimusten täytön integroimalla laadunvalvonnan suoraa tuotantolinjalle.

Konenäköjärjestemien käyttöönottoon kuitenkin liittyy edelleen teknisiä haasteita. Yhtenä niistä on vaihtelevat valaistusympäristöt ja olosuhteet ja eri laitteiden tuottamien kuvien yhteensopivuus keskenään. Nämä tekijät voivat vaikuttaa mahdollisten tuotantovirheiden tunnistamisen tarkkuuteen ja luotettavuuteen. Näytä mahdollisia virheitä tekoälypohjaisilla algoritmeilla pystyisikin korjaamaan.

Tästä kappaleesta huomataankin, että konenäköpohjaisia laadunvalvontajärjestelmiä on jo ollut käytössä pidemmän aikaa ja minkälaisia etuja ne tuovat tasaamaan tuotannon laatua. Seuraavassa kappaleessa käydään läpi esimerkki, miten tekoälyä hyödyntämällä kyetään parantamaan jo olemassa olevia järjestelmiä.

6 Case-esimerkki

Tässä case-esimerkissä käyn läpi A. Bhattachryan ja S. G. Cloutierin kirjoittaman tutkimusraportin *End-to-end deep learning framework for printed circuit board manufacturing defect classification*. Tutkimuksen tarkoituksena on kehittää yksivaiheinen syväoppimiseen perustuva kehys, jolla pystytään reaaliaikaiseen vikojen tunnistamiseen ja luokitteluun piirilevyistä käyttäen matalaresoluutioisia kuvia. Tämä tutkimus osuu juuri täydellisesti oman tutkielmani aiheeseen siitä, miten nykyisiä konenäköjärjestelmiä pystyttäisiin parantamaan implementoimalla tekoälyä perinteisen konenäön tueksi vikojen havaitsemiseen. Tutkimuksessa yritetään ratkaista perinteisen laaduntarkastuksen ongelmia muun muassa manuaalisen työn määrä, tarkastuksen hitaus ja kuinka nykyiset menetelmät eivät välttämättä pysty skaalautumaan tuleviin entistä vaativampiin piirilevyihin.

Tutkimuksessa hyödynnetään syväoppimiseen perustuvaa *You Only Look Once* (YOLOv5) arkkitehtuuria objektintunnistukseen. YOLOv5 (Ultralytics, 2025) on Ultralytics-yrityksen kehittämä erittäin tehokas syväoppimiseen perustuva objektintunnistusalgoritmi. YOLOv5-algoritmi pystyy reaaliaikaisesti tunnistamaan ja luokittelemaan useita eri kohteita yksittäisestä kuvasta yhdellä laskentakierroksella. Ultralytics (2025) kertoo julkaisussaan YOLOv5-algoritmin koostuvan kolmesta pääosasta: backbone, neck ja head. Backbone-osa vastaa poimittujen piirteiden tunnistamista kuvasta (Ultralytics, 2025). Neck-osa taas yhdistää eri mittakaavoissa tunnistetut piirteet, jota kautta se mahdollistaa erikokoisten objektien havaitsemisen (Ultralytics, 2025). Head-osa taas antaa havaitulle objektille lopullisen luokituksen sekä ennustaa kohteiden sijainnit kuvasta (Ultralytics, 2025).

Tutkimuksessa jatkokehitettiin olemassa olevaa YOLOv5 arkkitehtuuria lisäämällä siihen Transformer-moduuli parantamaan mallin kykyä ymmärtää laajoja kuvallisia riippuvuuksia. Malli siis yhdistää paikallisten piirteiden tunnistamisen, transformerien kyvyn mallintaa kuvien kokonaisrakennetta ja konvoluutioverkkojen vahvuuksia. Konvoluutioverkot (convolutional neural networks) ovat syväoppimisen

neuroverkkomalleja, jotka ovat suunniteltu käsittelemään ruudukkomuotoista dataa, esimerkiksi digitaalisia kuvia (Goodfellow, Bengio, & Courville, 2016). Konvoluutioverkot pyrkivät ihmisen silmän tyyliseen objektin tunnistukseen.

Tutkimuksessa käytetty data pohjautuu julkiseen HRIPCB-datasarjaan (Huang, Li, Zhang, & Chen, 2020). Tämä datasarja sisältää yli tuhat merkittyä kuvaa erityyppisistä piirilevyistä, näitä ovat esimerkiksi avoimet piirilevyt, ylimääräistä kuparia sisältävät piirilevyt ja oikosulkuja sisältävät piirilevyt. Tämän aineiston avulla mallia tunnistamaan kuusi eri vikaluokkaa, jotka ovat puuttuva reikä eli johdinreikä puuttuu levystä, avoin piiri eli johtorata on katkennut, oikosulku eli ei toivottu yhteys johtimien välillä, piikkimäinen ylimääräinen kuparijäännös ja ylimääräinen alue kuparia. Erityistä mallin opettamisessa oli se, että sen tuli kyetä tunnistamaan virheet matalan resoluution kuvista. Matalan resoluution kuvia käytettiin, siksi että se tuo todellista taloudellista hyötyä teollisuuteen, sillä tuotantoon ei tarvitse ostaa korkeanresoluution kalliita kameroita.

Malli saavutti testauksessa 98,1 % tunnistustarkkuuden. Tuloksia verrattiin perinteiseen YOLOv5 malliin, joka saavutti 94,9 % tunnistustarkkuuden, sekä konvoluutioverkkomalliin Faster R-CNN, joka saavutti 96,7 % prosentin tunnistustarkkuuden. Kuten huomataan, erot eivät ole valtavat, mutta huomioon tulee ottaa se, että kehitetty malli vaatii huomattavasti pienemmän määrän esimääritettyjä parametrejä, joka nopeuttaa mallin käyttöä ja tekee siitä kevyemmän ajettavaksi tuotantoympäristössä.

7 Menetelmien vertailu

Tässä luvussa vertaillaan case-esimerkissä esiteltyä konenäköön perustuvaa ratkaisua piirilevyjen nykyisiin laadunvalvontamenetelmiin, kuten manuaaliseen tarkastukseen, AOI- ja AXI-järjestelmiin. Vertailussa tarkastellaan erityisesti menetelmien kustannuksia, sekä laadunvalvonnan suorituskykyä.

7.1 Kustannukset

7.1.1 AOI- ja AXI-järjestelmät

Vertailussani käyttämät kustannusarviot perustuvat EPP Europe lehdessä julkaistuun artikkeliin, jossa vertaillaan järjestelmien tuomia säästöjä vuodessa verrattuna niin sanottuun "do nothing" tilanteeseen, jossa käytettäisiin ainoastaan ICT-testausta.

Board Assumptions						
Number of solder joints	4.000					
Number of components	400					
Annual production volume	50,000 boards					
Value of board if/when scrapped	\$ 600					
Total opportunities for error	4.400					
Repair Assumptions						
Repair yield	90 %					
Number of repair cycles permitted	3					
PCB scrap rate	0,10 %					
Component scrap value per repair	\$ 5					
Defect Rate Assumptions (Process Capability)						
Electrical DPMO (ppmC)	160					
Structural DPMO (ppmJ)	250					
Board DPMO	242					
Qty of structural defects per board	1					
Qty of electrical defects per board	0,064					
Debug Diagnostics and Repair Costs						
	AXI	AOI	ICT	FT	System	
Hourly labor costs of verification/diagnostics	\$ 30,00	\$ 30,00	\$ 30,00	\$ 30,00	\$ 30,00	
Hourly labor cost to repair	\$ 35,00	\$ 35,00	\$ 35,00	\$ 35,00	\$ 35,00	
Time to verify/diagnose one defect (minutes)	0,08	0,08	5	10	60	
Time to repair one defect	10	10	25	50	50	
Cost to debug/diagnose one defect	\$ 0,04	\$ 0,04	\$ 2,50	\$ 5,00	\$ 30,00	
Cost to repair one defect	\$ 5,83	\$ 5,83	\$ 14,58	\$ 29,17	\$ 29,17	
Re-Test Cost						
Cost of Field Failures>Returns	\$ 2.500					
Current Field Return Rate without AXI	0,10 %					
Annual Equipment Costs						
	AXI	AOI				
System + Operation + Maintenance Amortized of 5-years	110.000	30.000				

Kuva 3. Artikkelin käyttämää pohjadataa (EPP Europe, 2007).

Artikkelissa tehdään numeerinen vertailu, jossa verrataan kolmen eri testausjärjestelmän käytön tuomia kustannuksia ja säästöjä tuotantoon. Kuvassa 3 näemme testauksen pohjatietoja. Testissä käytetään siis 50000 piirilevyä, joissa jokaisessa 4000 juotosta ja 400 komponenttia, eli 4400 virheen mahdollisuutta. Kuvan 3 alaosassa näemme myös AXI- ja AOI-laitteiden lasketut vuotuiset kustannukset. Kuvasta 3 voimmekin todeta kuten myös Edelstein artikkelissa toteaa, että AOI-järjestelmät ovat selvästi halvempia.

	ICT	FT	System	Costs
Structural defects before test (per board)	1,00	0,36	0,25	
Structural defects after test (per board)	0,36	0,25	0,21	
Electrical defects before test (per board)	0,06	0,02	0,01	
Electrical defects after test (per board)	0,02	0,01	0,01	
Structural defects found (per board)	0,64	0,11	0,04	
Electrical defects found (per board)	0,05	0,01	0,00	
Total defects found (per board)	0,69	0,12	0,04	
First pass yield	50,4 %	89,1 %	96,0 %	
Overall test effectiveness	64,0 %	31,0 %	15,0 %	
DPMO remaining on board after test	86	59,7	50,5	
Annual cost of verification	\$ 85.696	\$ 28.958	\$ 60.635	\$ 175.289
Annual cost of repair	\$ 499.893	\$ 168.924	\$ 58.950	\$ 727.768
Annual cost of component scrap	\$ 171.392	\$ 28.958	\$ 10.106	\$ 210.456
Annual cost of PCB scrap	\$ 27.167	\$ 4.795	\$ 1.477	\$ 34.099
Annual cost of retest	\$ 24.810	\$ 8.203	\$ 5.943	\$ 38.956
Annual cost of field failures and returns				\$ 125.000
Total	\$ 784.148	\$ 231.636	\$ 131.167	\$ 1.311.567

Kuva 4. Kustannukset pelkällä ICT-testauksella (EPP Europe, 2007).

Kuvassa 4 voimme nähdä miten viankorjauksista johtuvat kustannukset jakautuvat. Kuvan 4 oikeassa alareunassa näemme huomattavan 1,31 miljoonan dollarin kokonaishinnan tämän esimerkin virhekorjauksille. Kuvasta 4 näemme myös, kuinka ICT-testaus pystyy havaitsemaan ainoastaan 64 prosenttia virheistä, joten ei ihme, että kustannukset ovat kovat.

	AOI	ICT	FT	System	Costs	AOI Savings
Structural defects before test (per board)	1,000	0,382	0,137	0,096		
Structural defects after test (per board)	0,382	0,137	0,096	0,082		
Electrical defects before test (per board)	0,064	0,064	0,018	0,011		
Electrical defects after test (per board)	0,064	0,018	0,011	0,008		
Structural defects found (per board)	0,618	0,244	0,041	0,014		
Electrical defects found (per board)	0,000	0,046	0,008	0,003		
Total defects found (per board)	0,618	0,290	0,049	0,017		
First pass yield	53,9 %	74,8 %	95,2 %	98,3 %		
Overall test effectiveness	58,0 %	65,0 %	31,0 %	16,0 %		
DPMO remaining on board after test	101,3	35,4	24,3	20,4		
Annual cost of false call at verification	\$ 10.417				\$ 10.417	(\$ -10.417)
Annual cost of false repairs	\$ 43.750				\$ 43.750	(\$ -43.750)
Annual cost of AOI system	\$ 30.000				\$ 30.000	(\$ -30.000)
Programming cost, 2 hrs at \$ 160/hr	\$ 3.840	(3 days per program)			\$ 3.840	(\$ -3.840)
Annual cost of verification	\$ 1.516	\$ 36.226	\$ 5.383	\$ 25.573	\$ 68.697	\$ 106.592
Annual cost of repair	\$ 180.359	\$ 211.318	\$ 71.530	\$ 24.862	\$ 488.070	\$ 239.698
Annual cost of component scrap	\$ 192.094	\$ 72.452	\$ 12.262	\$ 4.262	\$ 281.070	(\$ -70.614)
Annual cost of PCB scrap		\$ 15.294	\$ 2.791	\$ 775	\$ 19.521	\$ 14.578
Annual cost of retest		\$ 5.952	\$ 1.598	\$ 1.108	\$ 8.657	\$ 30.298
Annual cost of field failures and returns					\$ 50.478	\$ 74.522
Total	\$ 461.976	\$ 335.290	\$ 91.966	\$ 55.472	\$ 1.004.500	\$ 307.067

Kuva 5. Kustannukset ICT ja AOI testauksella (EPP Europe, 2007).

Kuvassa 5 näemme kuvan 4 kaltaisen taulukon virheiden kuluista. Kuvan 5 taulukko on laskettu käyttäen ICT ja AOI testausta ja voimmekin huomata, että AOI testauksen lisääminen vähentää kuluja tässä mallissa noin 300 000 dollaria. Tästä voidaan todeta, että, 30 000 dollarin investointi AOI laitteeseen on kannattava investointi tämän laskennan perusteella. Seuraavaksi näemme vielä millaisia mahdollisia säästöjä AXI järjestelmä toisi ICT-testauksen rinnalle.

	AXI	ICT	FT	System	Costs	AXI Savings
Structural defects before test (per board)	1,000	0,127	0,046	0,032		
Structural defects after test (per board)	0,127	0,046	0,032	0,027		
Electrical defects before test (per board)	0,064	0,064	0,018	0,011		
Electrical defects after test (per board)	0,064	0,018	0,011	0,008		
Structural defects found (per board)	0,873	0,081	0,014	0,005		
Electrical defects found (per board)	0,000	0,046	0,008	0,003		
Total defects found (per board)	0,873	0,127	0,022	0,007		
First pass yield	41,8 %	88,1 %	97,9 %	99,3 %		
Overall test effectiveness	82,0 %	66,0 %	34,0 %	17,0 %		
DPMO remaining on board after test	43,4	14,6	9,7	8		
Annual cost of false call at verification	\$ 4.167				\$ 4.167	(\$ -4.167)
Annual cost of false repairs	\$ 11.667				\$ 11.667	(\$ -11.667)
Annual cost of AOI system	\$ 110.000				\$ 110.000	(\$ -110.000)
Programming cost, 2 hrs at \$ 160/hr	\$ 12.800				\$ 12.800	(\$ -12.800)
Annual cost of verification	\$ 2.021	\$ 15.842	\$ 5.383	\$ 11.125	\$ 34.371	\$ 140.918
Annual cost of repair	\$ 254.678	\$ 92.409	\$ 31.398	\$ 10.816	\$ 389.301	\$ 338.466
Annual cost of component scrap	\$ 228.295	\$ 31.683	\$ 5.383	\$ 1.854	\$ 267.215	(\$ -56.759)
Annual cost of PCB scrap		\$ 10.402	\$ 1.966	\$ 487	\$ 13.514	\$ 20.584
Annual cost of retest		\$ 5.952	\$ 1.598	\$ 1.108	\$ 8.657	\$ 30.298
Annual cost of field failures and returns					\$ 19.771	\$ 105.229
Total	\$ 623.628	\$ 150.336	\$ 44.130	\$ 24.282	\$ 871.463	\$ 440.102

Kuva 6. Kustannukset ICT ja AXI testauksella (EPP Europe, 2007).

Kuvassa 6 esitetään kuvien 5 ja 4 kaltainen taulukko virheiden tuottamista kustannuksista ja niiden tarkastuksesta. Kuvassa 6 näkyvät kustannukset koostuvat ICT ja AXI-testauksen tuottamista kustannuksista. Kuten kuvasta 3 huomataan, on AXI-järjestelmä itsessään kalliimpi kuin AOI-järjestelmä, melkein neljä kertaa kalliimpi jopa. Vaikka hinta itse järjestelmälle onkin kalliimpi tuottaa se myös enemmän säästöjä, kun kuvia 6 ja 5 verrataan. AXI-järjestelmä tuottaa laskennassa vuoden aikana, jopa noin 440 000 dollaria säästöä, joka on hiukan yli 130 000 dollaria säästöä enemmän kuin AOI-järjestelmä.

Näistä laskennallisista testeistä voidaankin siis todeta, että pelkästään jo AOI- ja AXI-järjestelmät tuovat suuria säästöjä virheiden havaitsemisessa pelkkään ICT-testaukseen verrattuna. Artikkelista ei valitettavasti löytynyt laskelmaa tilanteelle, jossa olisi käytössä kaikki kolme eri laadunvalvonta järjestelmää käytössä samaan aikaan, mutta itse katsoisin tarkkuuden kasvavan entisestään ja sitä kautta myös säästöjen. En kuitenkaan usko, että säästöissä päästäisiin sellaisiin lukemiin, jos vain yhdistettäisiin AOI- ja AXI-järjestelmän tuomat säästöt. Katsoisin säästön olevan jossain noin 0,6 miljoonan dollarin paikkeilla.

7.1.2 Case-esimerkin järjestelmä

Tällaisen järjestelmän kustannuksia on hankala tarkastella, sillä case-esimerkissäni ei ollut käytännön testausta vaan ainoastaan syväoppimisjärjestelmän opettamista ja sen toimivuuden testaamista.

Kustannukset tällaisessa järjestelmässä riippuvat useista toisiinsa kytkeytyvistä tekijöistä. Näitä ovat esimerkiksi laitevalinnat, integraatiotyön laajuus, ylläpitomallien lisenssit ja itse tuotantoympäristön mahdolliset erikoispiirteet. Automaattisten tarkastus- ja konenäköjärjestelmien hinnoittelu onkin todettu vaihtelevan huomattavasti edeltävien tekijöiden vaihtelevuuden takia, minkä takia kokonaisbudjetin ja elinkaarikustannusten tarkka ennustaminen on erittäin vaikeaa ilman tarkempaa tapauskohtaista tarkastelua (Softarex, 2025). Pelkästään datan käsittelyyn ja tekoälyyn liittyvät kustannukset voivat olla noin 110 000–200 000 dollarin välillä (Softarex, 2025).

Yllä mainittujen kustannusten lisäksi tulisi vielä AOI-järjestelmän tuomat kustannukset päälle. Eli kustannusten kannalta case-esimerkin tyyppisen järjestelmän kustannukset voivat olla hyvinkin suuret vielä toistaiseksi. Mutta nämäkin kustannukset varmasti tulevat vielä laskemaan tulevien vuosien aikana, jollain tällaisista järjestelmistä tulee kannattavampia.

7.2 Laadunvalvonnan suorituskyky

Laadunvalvonnan suorituskykyä voidaan tarkastella vikojen havaitsemisasteen, tarkastusnopeuden, väärin hälytysten sekä toistettavuuden näkökulmista. Painotukset näiden tekijöiden välillä vaihtelee menetelmittäin, jonka vuoksi niitä usein yhdistetään käytännössä täydentämään toisiaan (Ghelani, 2024; Sierra Circuits Inc., 2022). AOI, AXI, ICT ja manuaalinen tarkastaminen, eli niin sanotut perinteiset menetelmät muodostavat siis käytännössä toisiaan täydentäviä kokonaisuuksia.

AOI-järjestelmät tarjoavat hyvän tarkkuuden ja toistettavuuden pintapuolisten vikojen havaitsemiseen. AOI-järjestelmät voidaan integroida suoraan tuotantolinjaan ilman pullonkauloja ja mahdollistaen 100 % tarkistettavuuden tuotannosta (Emary ja muut, 2014; PCBX, 2024). AXI-järjestelmät taas täydentävät AOI-järjestelmiä havaitsemalla piilossa olevia rakenteellisia- ja juotosvikoja monikerroksissa levyissä. AXI-järjestelmien tarkastusajat ovat tosin hitaampia ja myös kalliimpia. Näistä syistä niitä käytetään kohdennetusti kriittisimmissä kohdissa (Cortex Robotics, 2021; Sierra Circuits Inc., 2022).

Syväoppimiseen perustuvat konenäköjärjestelmät piirilevyjen laadunvalvonnassa tyypillisesti rakentuvat olemassa olevan AOI-järjestelmän päälle ja parantavat erityisesti juuri vikojen tunnistustarkkuutta sekä sopeutuvuutta eri valaistusympäristöihin, komponenttien ja piirilevyversioiden vaihteluun (Adibhatla ja muut, 2021; Bhattacharya & Cloutier, 2022). Case-esimerkissä läpikäydyssä tutkimuksessa raportoidaankin syväoppimismallien saavuttavan perinteistä AOI-järjestelmää korkeamman tarkkuuden sekä pienentävän väärin hälytysten määrää, mikä vähentää turhaa uudelleentarkastusta ja parantaa laadunvalvontaketjun tehokkuutta.

Voidaankin todeta siis, että mikään menetelmä ei yksinään kykene vielä kattamaan kaikkia vikatyyppejä ja laadunvarmistuksen vaatimuksia, minkä vuoksi paras suorituskyky saadaankin yhdistämällä eri menetelmiä. Syväoppimiseen perustuvat järjestelmät eivät toistaiseksi ainakaan pysty korvaamaan täysin jo olemassa olevia järjestelmiä, mutta ovat hyvä lisä parantamaan nykyisten järjestelmien tarkkuutta.

7.3 Nykyaikaisten konenäköratkaisuiden kustannukset

EPP Europe -lehden vuonna 2007 julkaisema artikkeli antaa kohtuullisen pohjakäsityksen AOI-, AXI- ja ICT- menetelmien suhteellisista kustannuseroista. Artikkelin esittämät dollarimääräiset arvot eivät kuitenkaan välttämättä enää kovin hyvin vastaa nykypäivän hintatasoa. Tuoreemmissa selvityksissä konenäköratkaisujen kustannuksia tyypillisesti tarkastellaan laajempina kokonaisuutena. Näissä tyypillisesti erotellaan erikseen laitteiston hankintahinta, mahdolliset integraatiokustannukset, käyttöönottokustannukset sekä ohjelmisto ja ylläpitokulut (Photoneo, 2025; Averroes.ai, 2025).

Photoneon katsauksessa konenäköratkaisut jaettiin kolmen tasoiseen järjestelmiin, perusluokan 2D-järjestelmät kustantavat tyypillisesti 200–3000 dollaria, kun taas korkeamman tason järjestelmät kustantavat 10 000–25 000 dollaria tai enemmän (Photoneo, 2025). Nämä luvut kuvaavat kamerapohjaisia perusratkaisuja eikä ota huomioon muita mahdollisia erikoistarkastuskoneita tai tuotantolinjaan vaadittavia muutostöitä. Piirilevyvalmistuksessa tällainen perusjärjestelmän kokonaisinvestoinnit määräytyvät suuresti integrointi- ja ohjelmistokuluista, sillä AOI-järjestelmät sisältävät jo useimmiten vaadittavat kamerat ja muut tarkastuslaitteet. Photoneon järjestelmät eivät siis ole suunniteltu erityisesti piirilevyvalmistusta varten vaan ovat yleiskäyttöisempiä järjestelmiä, jota voidaan integroida esimerkiksi autojen valmistuksen tuotantolinjoihin.

Averroes.ai:n mukaan nykyaikaisen AIO-järjestelmän hankintahinnat sijoittuvat yllä mainittujen peruskonenäköjärjestelmiä selvästi korkeammalle. Averroes.ai:n esittämä haarukka 2D-AOI-järjestelmille olisi noin 30 000–50 000 dollaria, kun taas huipputason 3D-AOI-järjestelmät olisivat jopa 100 000–200 000 dollaria (Averroes.ai, 2025). Näiden lisäksi tulisi hintalappuun vielä päälle integraatio- sekä käyttöönottokustannukset, jotka ovat arvioitu vaativuuden mukaan 5 000–15 000 dollarin välille (Averroes.ai, 2025). Lisäksi vielä laitteiden kalibrointi käyttöönoton yhteydessä lisää kustannuksia jopa 30 000 dollariin asti (Averroes.ai, 2025).

Elinkaarikustannuksia kun tarkastellaan, tulee ottaa huomioon ylläpito- sekä lisenssikulut. Näistä lisenssikulut ovat yleisesti huomattavasti suuremmat ylläpitokustannuksiin verrattuna. Averroes.ai arvio ylläpitokustannusten olevan sadoissa tai maksimissaan muutamissa tuhansissa vuotuisella tasolla, kun taas lisenssikustannukset yleisesti ovat alkaen muutamissa tuhansissa. Tästä voidaankin EPP Europe -artikkelin laiteinvestointien hinnan pysyneen jokseenkin samana nykyisiin laitteisiin verrattuina, kun pelkkää laitteen hintaa vertaillaan. Nykyaikaisten järjestelmien kokonaiskustannukset ovat kuitenkin jonkin verran korkeampia, kun lasketaan mukaan käyttöönottoon liittyvät kustannukset, ylläpidon kustannukset sekä järjestelmälisenssien kustannukset.

8 Johtopäätökset

Tässä tutkielmassa tarkasteltiin konenäön nykyistä hyödyntämistä piirilevyjen valmistuksen laadunvalvonnassa, sekä siitä mihin suuntaan sen käyttöä olisi mahdollista kehittää case-esimerkkiä hyödyntäen. Tavoitteena tutkielmassa oli selvittää, miten konenäköä voidaan käyttää tehokkaasti laadunvalvontaprosessissa ja millaisia hyötyjä ja haasteita se tuo perinteisiin laadunvalvontamenetelmiin verrattuna.

Konenäön käyttöönotto piirilevyteollisuudessa on jo tapahtunut ja osoittautunut merkittäväksi askeleeksi kohti tehokkaampaa tuotantoa. AOI- ja AXI-tarkastus mahdollistavat nopean ja tarkan virheiden havaitsemisen ilman laajaa manuaalista valvontaa. Pelkästään jo näillä kahdella menetelmällä voidaan havaita, juotosvirheitä, komponenttien asetteluvirheitä, sekä useita muita vikoja, jotka helposti jäävät manuaalisessa tarkastuksessa huomaamatta pelkästään pienen kokoluokan takia. Nämä menetelmät parantavat tuotannon laatua ja laskevat kustannuksia vähentämällä väärien hälytysten määrää. Nämä menetelmät myös tehostavat tuotantoprosessia, sillä ne ovat integroitavissa suoraan tuotantolinjan osaksi.

Case-esimerkissä tarkasteltiin syväoppimiseen perustuvaa, YOLOv5-algoritmista johdettua mallia, jonka tarkoituksena on viedä nykyiset konenäköpohjaiset järjestelmät uudelle tasolle tarkkuuden ja adaptiivisuuden osalta. Mallilla saavutettu 98,1 prosentin tunnistustarkkuus osoittaa, että yhdistämällä tällainen malli jo olemassa olevien AOI- ja AXI-järjestelmien kanssa pystyttäisiin tunnistusta tehostamaan merkittävästi. Malli on opetettu tunnistamaan matalan resoluution kuvista, joten integrointi vanhempien järjestelmien kanssa olisi mahdollista, eikä olisi tarvetta kalliilla korkean resoluution kameroilla. Mallilla parametrien määrä ja laskennallinen kuorma ovat myös verrattain pieniä, joka helpottaa käyttöönottoa teollisessa ympäristössä, jossa ei välttämättä ole resursseja tehokkaille tietokoneille mallin suorittamiseen.

Samalla kuitenkin huomattiin, että nykyisissä konenäköjärjestelmissä on edelleen useita haasteita. Vaihtelevat valaistusolosuhteet, laitteiden yhteensopivuus, kuvamuotojen ja

rajapintojen standardointi sekä riittävän laadukkaan opetusdatan kerääminen vaikuttavat järjestelmän toimivuuteen tositilanteessa. Alkuinvestoinnit voivat myös olla huomattavia, kun otetaan huomioon laskentayksiköt, ohjelmistokehitys, integraatio tuotantolinjaan ja tarvittaessa uudet kamerat. Pitkällä aikavälillä nämä kustannukset kuitenkin usein kompensoituvat laadun ja tehokkuuden parantumisen, romutuskustannusten ja manuaalisen tarkastustyön kautta.

Yhteenvetona voidaan siis todeta, että tekoäly ja konenäkö muodostavat yhdessä luonnollisen suunnan piirilevyvalmistuksen laadunvalvonnan tulevaisuudelle. Piirilevyvalmistuksessa niiden yhdistelmä tarjoaa nopeuden ja paremman tarkkuuden lisäksi myös mahdollisuuden tehokkaampaan ennakoivaan laadunhallintaan, jossa virheet kyetään paremmin havaita ja korjata jo tuotannon aikana. Tulevaisuuden kehityksen voidaan nähdä etenevän kohti enemmän ja enemmän integroidumpia ja itseoppivampia järjestelmiä, jotka kykenisivät hyödyntämään dataa koko tuotannon ajan, säätämään itseään sekä mukautumaan automaattisesti muuttuviin olosuhteisiin. Tässä tutkielmassa käytyjen asioiden pohjalta vaikuttavat syväoppimiseen pohjautuvat konenäköjärjestelmät todennäköiseltä tulevaisuuden suunnalta piirilevyvalmistuksen laadunvalvonnassa.

9 Lähteet

- Adibhatla, V. A., Chih, H.-C., Hsu, C.-C., Cheng, J., Abbod, M. F., & Shieh, J.-S. (2021). Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once. <https://doi.org/10.3934/mbe.2021223>
- Averroes. (28.03.2025). Low cost vision inspection system: Cost breakdown & ROI. <https://averroes.ai/blog/low-cost-vision-inspection-system>
- Bhattacharya, A., & Cloutier, S. G. (2022). End-to-end deep learning framework for printed circuit board manufacturing defect classification. Scientific Reports, 12(1), 12559. <https://doi.org/10.1038/s41598-022-16302-3>
- Boyle, R., Hlavac, V. & Sonka, M. (2013). Image processing, analysis, and machine vision 4th edition <https://www.cl72.org/090imagePLib/books/sonka,hlavac,boyle-imageProc.pdf>
- Chen, I.-C., Hwang, R.-C., & Huang, H.-C. (2023). PCB Defect Detection Based on Deep Learning Algorithm. Processes, 11(3), 775. <https://www.mdpi.com/2227-9717/11/3/775>
- Cortex Robotics. (2021, maaliskuuta 29). AOI vs ICT vs AXI & PCB SMT Assembly Inspection. <https://cortexrobotics.my/aoi-ict-axi-pcb-smt-assembly-inspection/>
- Duric, D. & Matic, V. (2019). Computer vision in industry. <https://doi.org/10.15308/Sinteza-2019-439-444>
- Edelstein, P. (2007). Comparing costs and ROI of AOI and AXI. EPP Europe. <https://smtnet.com/library/files/upload/EPPEuropeArticle.pdf>

Emary, E., Moustafa, K., & Taha, E. (7.2014). Automatic Optical Inspection for PCB Manufacturing: a Survey.

[https://d1wqtxts1xzle7.cloudfront.net/34408517/researchpaper_Automatic-Optical-Inspection-for-PCB-Manufacturing-a-Survey-libre.pdf?1407758110=&response-content-disposition=inline%3B+filename%3DAutomatic O ptical Inspection f or PCB M.pdf&Expires=1741782846&Signature=Pc1wOzfjTPw3rAEIFRhFZlghMSRU5NHMxGqth1RJCmrsu7NRwahT2K6zDTXJ4oSwp71on0dMH6Lhz4WiyuOmkhc9ukoBz-5uLlxdxIU7jgHWESPmjKFbiAoj-tlC3Dh~zGkHX-e-XK1jB-fOM2k5OD-6EsYzDSUPeV2FxeYXXCKr2hWz~Oh4LpB6QU~AceXUtMJijqjnY5NfjImeG9VljcHltgdne87iXPJnIO7letaclkZOl~qE7Ddo9sCqslEyyNsXiQdQEUM-AWB-49X5b7-C3fCmp5Kwels0Hc056ha7ojmYBHehRjMVdMISUttrapQudFLpQaaAktOJVCUvg&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA](https://d1wqtxts1xzle7.cloudfront.net/34408517/researchpaper_Automatic-Optical-Inspection-for-PCB-Manufacturing-a-Survey-libre.pdf?1407758110=&response-content-disposition=inline%3B+filename%3DAutomatic+Optical+Inspection+for+PCB+M.pdf&Expires=1741782846&Signature=Pc1wOzfjTPw3rAEIFRhFZlghMSRU5NHMxGqth1RJCmrsu7NRwahT2K6zDTXJ4oSwp71on0dMH6Lhz4WiyuOmkhc9ukoBz-5uLlxdxIU7jgHWESPmjKFbiAoj-tlC3Dh~zGkHX-e-XK1jB-fOM2k5OD-6EsYzDSUPeV2FxeYXXCKr2hWz~Oh4LpB6QU~AceXUtMJijqjnY5NfjImeG9VljcHltgdne87iXPJnIO7letaclkZOl~qE7Ddo9sCqslEyyNsXiQdQEUM-AWB-49X5b7-C3fCmp5Kwels0Hc056ha7ojmYBHehRjMVdMISUttrapQudFLpQaaAktOJVCUvg&Key-Pair-Id=APKAJLOHF5GGSLRBV4ZA)

Ghelani, H. (2019). Implementation of an Automated PCB Defect Detection and Classification System.

https://www.researchgate.net/publication/384888028_Implementation_of_an_Automated_PCB_Defect_Detection_and_Classification_System

Ghelani, H. (2024). AI-Driven Quality Control in PCB Manufacturing: Enhancing Production Efficiency and Precision.

https://www.researchgate.net/publication/384992034_AI-Driven_Quality_Control_in_PCB_Manufacturing_Enhancing_Production_Efficiency_and_Precision

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.

<https://www.deeplearningbook.org/contents/convnets.html>

Hornber, A. (4.3.2017). Handbook of Machine and Computer Vision.

<https://unidel.edu.ng/focelibrary/books/handbook-of-machine-and-computer-vision-the-guide-for-developers-and-users.9783527413393.78111.pdf>

Huang, S., Li, Y., Zhang, X., & Chen, H. (2020). A high-resolution PCB dataset for defect detection and classification. *IEEE Access*, 8, 185392–185402.

<https://doi.org/10.1109/ACCESS.2020.3030113>

ICAPE Group. (n.d.). PCB Manufacturing: Comprehensive guide. ICAPE Group.

<https://www.icape-group.com/pcb-manufacturing-comprehensive-guide/>

Kuinka tehdä PCB? Yksityiskohtainen piirilevyn tuotantoprosessi!. (2023).

<https://pcbassembly.com/fi/blogi/kuinka-tehd%C3%A4-PCB-yksityiskohtaiset-PCB-tuotantoprosessit/>

NeoDen. (17.4.2019). PCB-materiaalit painetun piirilevyn pohjaan.

<https://fi.pnpsmachine.com/news/pcb-materials-for-base-of-printed-circuit-board-24978564.html>

PCBasic JS. (2022, October 18). Quality inspection process for PCB assembly manufacturer [Video]. YouTube.

<https://www.youtube.com/watch?v=0cGsQ5gVnfw>

PCBX. (2024). Comparison of AOI, ICT, and AXI. Comparison of AOI, ICT, and AXI.

<https://www.pcbx.com/article/Comparison-of-AOI-ICT-and-AXI>

Salminen, A. (2011). Mikä kirjallisuuskatsaus? Vaasan yliopisto.

https://www.uwasa.fi/materiaali/pdf/isbn_978-952-476-349-3.pdf

Savon Automaatio. (n.d.). Konenäkö teollisuudessa.

<https://www.savonautomaatio.fi/palvelut/konenako/>

Sierra Circuits Inc. (2022). *Design for testing handbook*.

<https://www.protoexpress.com/pcb-design-guides/design-for-testing-handbook/>

Softarex. (2025). How much does an automated inspection system cost? Softarex.

<https://softarex.com/insights/article/how-much-does-an-automated-inspection-system-cost/>

Soral, P. (31.01.2025). Machine vision systems: From industry applications to cost

implications. <https://www.photoneo.com/machine-vision-systems-industry-applications-cost-implications/>

Szeliski, R. (18.8.2010). *Computer Vision: Algorithms and Applications*.

<https://vim.ustc.edu.cn/upload/article/files/d4/87/71e9467745a5a7b8e80e94007d1b/4cd69b21-85d3-43ba-9935-fd9ae33da82b.pdf>

Tilastokeskus. (17.12.2024) Tekoälyteknologioita käytti 24 % yrityksistä.

<https://stat.fi/julkaisu/cln3odelx9f5x0bvziegurum4>

Ultralytics. (2025). Ultralytics YOLOv5 architecture. Ultralytics Docs.

https://docs.ultralytics.com/yolov5/tutorials/architecture_description/

Wang, W.-C., Chen, S.-L., Chen, L.-B., & Chang, W.-J. (24.9.2016). A machine vision

based automatic optical inspection system for measuring drilling quality of printed circuit boards. <https://doi.org/10.1109/ACCESS.2016.2631658>

Yasar, K. (n.d.). What is machine vision?

<https://www.techtarget.com/searchenterpriseai/definition/machine-vision-computer-vision>