



**Kauno technologijos universitetas**  
Panevėžio technologijų ir verslo fakultetas

**Paviršinio montavimo elektronikos komponentų atpažinimo  
spausdintinėse plokštėse sistemos kūrimas ir tyrimas**

Baigiamasis magistro projektas

---

**Edvinas Blažys**  
Projekto autorius

**Dėstytojas-praktikas dr. Donatas Pelenis**  
Vadovas

---

**Panevėžys, 2026**



**Kauno technologijos universitetas**

Panevėžio technologijų ir verslo fakultetas

# **Paviršinio montavimo elektronikos komponentų atpažinimo spausdintinėse plokštėse sistemos kūrimas ir tyrimas**

Baigiamasis magistro projektas

Valdymo technologijos (6211EX014)

---

**Edvinas Blažys**

Projekto autorius

**Dėstytojas-praktikas dr. Donatas  
Pelenis**

Vadovas

Recenzentas (-ė)

---

**Panevėžys, 2026**



**Kauno technologijos universitetas**

Panevėžio technologijų ir verslo fakultetas

Edvinas Blažys

## **Paviršinio montavimo elektronikos komponentų atpažinimo spausdintinėse plokštėse sistemos kūrimas ir tyrimas**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdamas kitų asmenų autoriaus ar kitų teisių, laikydamasis Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs;
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalintas iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Edvinas Blažys

*Patvirtinta elektroniniu būdu*



**Kauno technologijos universitetas**  
Panevėžio technologijų ir verslo fakultetas

**TVIRTINU**  
TVKC vadovė  
Doc. dr. Nida Kvedaraitė

### **Baigiamojo magistro projekto užduotis**

Diplomantui **Edvinui Blažiui**

---

Baigiamojo projekto tema (lietuvių kalba)	Paviršinio montavimo elektronikos komponentų atpažinimo spausdintinėse plokštėse sistemos kūrimas ir tyrimas
----------------------------------------------	-----------------------------------------------------------------------------------------------------------------

---

Baigiamojo projekto tema (anglų kalba)	Development and Research of a System for Recognizing Surface- Mounted Electronic Components on Printed Circuit Boards
-------------------------------------------	--------------------------------------------------------------------------------------------------------------------------

---

Patvirtinta 2026 m. balandžio 7 d. dekanu potvarkiu Nr. V25-13-9

Parengto baigiamojo projekto įkėlimo į Moodle aplinką terminas iki 2026 m. gegužės 29 d.

Duomenys, reikalavimai ir sąlygos baigiamajam projektui – nėra.

---

Baigiamojo projekto užduotys / uždaviniai, kurie turi būti atskleisti projekte:

1. Išanalizuoti mokslinę literatūrą, nagrinėjančią paviršinio montavimo elektronikos komponentų atpažinimo ir defektų aptikimo spausdintinėse plokštėse metodus. 2. Suprojektuoti eksperimentinę elektronikos plokščių optinės kontrolės sistemą, skirtą komponentams aptikti. 3. Sukurti ir iširti paviršinio montavimo elektronikos komponentų kokybės vertinimo algoritmą. 4. Eksperimentiškai patvirtinti paviršinio montavimo elektronikos komponentų kokybės vertinimo algoritmo veikimą realiomis elektronikos gaminių testavimo sąlygomis.

---

Vadovas	lektorius praktikas dr. Donatas Pelenis
---------	-----------------------------------------

*(vadovo pareigos, vardas, pavardė, parašas)*

Užduotį gavau	Edvinas Blažys
---------------	----------------

*(studento vardas, pavardė, parašas)*

2026 m. balandžio 16 d.

Blažys Edvinas. Paviršinio montavimo elektronikos komponentų atpažinimo spausdintinėse plokštėse sistemos kūrimas ir tyrimas. Magistro baigiamasis projektas / vadovas lektorius praktikas dr. Donatas Pelenis; Kauno technologijos universitetas, Panevėžio technologijų ir verslo fakultetas.

Studijų kryptis ir sritis: elektronikos inžinerija, technologijos mokslai.

Reikšminiai žodžiai: paviršinio montavimo komponentai, spausdintinės plokštės, automatinė optinė patikra, YOLO neuroniniai tinklai, gilusis mokymasis, kompiuterinė rega, „Raspberry Pi AI HAT+“, RGBW apšvietimas.

Panevėžys, 2026. 93 p.

## Santrauka

Baigiamajame magistro projekte nagrinėjamas paviršinio montavimo elektronikos komponentų aptikimas spausdintinėse plokštėse, taikant automatizuotą optinę kontrolę ir „YOLO“ šeimos neuroninius tinklus. Darbo tikslas – sukurti ir iširti AOI sistemą, skirtą PCB komponentų aptikimui, įvertinant RGBW apšvietimo ir PCB orientacijos įtaką aptikimo kokybei. Literatūros analizėje aptarti klasikiniai vaizdo apdorojimo, mašininio mokymosi, giliojo mokymosi, AOI ir „YOLO“ metodai, o AXI, ICT ir kiti testavimo metodai nagrinėti kaip platesnis elektronikos kokybės kontrolės kontekstas. Eksperimentinė AOI sistema realizuota naudojant „Raspberry Pi 5“, „Raspberry Pi AI HAT+ 26 TOPS“ modulį, „Raspberry Pi AI Camera“ su „Sony IMX500“ jutikliu, RGBW apšvietimą ir „Shelly RGBW“ valdiklį. Sistema skirta PCB vaizdams fiksuoti, apšvietimo režimams valdyti, „YOLO“ modelių inferencijai vykdyti „HAILORT / HAILO8“ aplinkoje ir aptikimo rezultatams registruoti CSV faile. Modelių apmokymui naudota duomenų bazė, sudaryta iš 54 534 anotuotų vaizdų ir 475 067 anotacijų, suskirstytų į mokymo, validacijos ir testavimo rinkinius 80 / 10 / 10 proc.

Tyrime apmokyti ir palyginti keturi „YOLO“ šeimos modeliai: „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“. Geriausius mokymo rezultatus pasiekė „YOLOv11M“ modelis: mAP<sub>0.5</sub> = 94,8 proc., mAP<sub>0.5:0.95</sub> = 80,8 proc., tikslumas – 89,7 proc., o atgavimo rodiklis – 90,2 proc. AOI stende atlikti bandymai su 4 „YOLO“ modeliais, 9 PCB plokštėmis, 4 PCB orientacijomis ir 4 RGBW apšvietimo režimais. Iš viso gauti 576 eksperimentiniai PCB vaizdai.

AOI stendo sąlygomis daugiausia komponentų aptiko „YOLOv8m“ modelis – 949 vnt., iš kurių 146 turėjo ne mažesnę kaip 50 proc. pasitikėjimo reikšmę. „YOLOv5m“ aptiko 888 komponentus ir veikė greičiausiai – vidutinė inferencijos trukmė siekė 210,15 ms vienam vaizdai, tačiau šis modelis turėjo 88 klaidingus žymėjimus. „YOLOv8m“ inferencijos trukmė buvo 233,77 ms, o klaidingų žymėjimų skaičius – 58. Apšvietimo tyrimas parodė, kad efektyviausias buvo baltas RGBW apšvietimas – 1 353 aptikimai. Žalias apšvietimas 579 aptikimai, raudonas – 234, o mėlynas – 45. PCB orientacijos poveikis buvo mažesnis: skirtumas tarp didžiausio ir mažiausio aptikimų skaičiaus sudarė 24 aptikimus, apie 4,3 proc.

Tyrimo rezultatai parodė, kad geriausi mokymo metrikų rezultatai ne visada sutampa su geriausiais realaus AOI stendo rezultatais. Nors mokymo metu geriausius mAP rodiklius pasiekė „YOLOv11M“, realiomis optinės kontrolės sąlygomis geriausią komponentų aptikimo ir praktinio taikymo balansą parodė „YOLOv8M“. Praktiniam sukurtos AOI sistemos taikymui rekomenduojama naudoti „YOLOv8M“ modelį, baltą RGBW apšvietimą ir 1 280 × 1 280 pikselių įvesties vaizdą.

Blažys Edvinas. Development and Research of a System for Recognizing Surface-Mounted Electronic Components on Printed Circuit Boards. Master's Degree Project / supervisor practitioner dr. Donatas Pelenis; Panevėžys Faculty of Technologies and Business, Kaunas University of Technology.

Study field and area: Electronics Engineering, Technology Sciences.

Keywords: surface-mounted components, printed circuit boards, automated optical inspection, YOLO neural networks, deep learning, computer vision, "Raspberry Pi AI HAT+", RGBW lighting.

Panevėžys, 2026. 93 pages.

### Summary

In this master's final project, the detection of surface-mounted electronic components on printed circuit boards is investigated using automated optical inspection and YOLO-family neural networks. The aim of the work is to develop and investigate an AOI system for PCB component detection by evaluating the influence of RGBW lighting and PCB orientation on detection quality. The literature analysis discusses classical image processing, machine learning, deep learning, AOI, and YOLO-based methods, while AXI, ICT, and other testing methods are considered as part of the broader context of electronics quality control.

The experimental AOI system was implemented using a Raspberry Pi 5, a Raspberry Pi AI HAT+ 26 TOPS module, a Raspberry Pi AI Camera with a Sony IMX500 sensor, RGBW lighting, and a Shelly RGBW controller. The system is designed to capture PCB images, control lighting modes, perform YOLO model inference in the HAILORT / HAILO8 environment, and record detection results in a CSV file. For model training, a dataset consisting of 54,534 annotated images and 475,067 annotations was used. The dataset was divided into training, validation, and testing subsets in an 80 / 10 / 10 % ratio.

Four YOLO-family models were trained and compared in the study: YOLOv5mu, YOLOv8m, YOLOv11m, and YOLOv26m. The best training results were achieved by the YOLOv11M model: mAP0.5 = 94.8 %, mAP0.5:0.95 = 80.8 %, precision = 89.7 %, and recall = 90.2 %. Tests in the AOI stand were performed using 4 YOLO models, 9 PCB boards, 4 PCB orientations, and 4 RGBW lighting modes. In total, 576 experimental PCB images were obtained.

Under the AOI stand conditions, the highest number of components was detected by the YOLOv8m model – 949 detections, of which 146 had a confidence value of at least 50 %. The YOLOv5mu model detected 888 components and operated the fastest, with an average inference time of 210.15 ms per image; however, this model produced 88 false markings. The inference time of YOLOv8m was 233.77 ms, and the number of false markings was 58. The lighting study showed that white RGBW lighting was the most effective, producing 1,353 detections. Green lighting produced 579 detections, red lighting 234, and blue lighting 45. The effect of PCB orientation was smaller: the difference between the highest and lowest number of detections was 24 detections, or about 4.3 %.

The results showed that the best training metrics do not always correspond to the best results in the real AOI stand. Although YOLOv11M achieved the best mAP values during training, YOLOv8M demonstrated the best balance between component detection and practical applicability under real optical inspection conditions. For practical application of the developed AOI system, the YOLOv8M model, white RGBW lighting, and a 1,280 × 1,280 pixel input image are recommended.

## Turinys

<b>Lentelių sąrašas .....</b>	<b>8</b>
<b>Paveikslų sąrašas .....</b>	<b>9</b>
<b>Santrumpų ir terminų sąrašas .....</b>	<b>10</b>
<b>Įvadas.....</b>	<b>13</b>
<b>1. PCB optinės kontrolės ir dirbtinio intelekto metodų analizė .....</b>	<b>15</b>
1.1. PCB ir PCBA kokybės kontrolės problema .....	15
1.2. Automatinės optinės patikros AOI metodai .....	15
1.3. Klasikiniai vaizdo apdorojimo ir ML metodai .....	16
1.4. CNN ir kiti giliojo mokymosi metodai.....	20
1.5. „YOLO“ šeimos modeliai PCB komponentų ir defektų aptikimui .....	32
1.6. Apšvietimo įtaka optiniam atpažinimui.....	42
1.7. Alternatyvūs elektronikos testavimo metodai: AXI, ICT, talpiniai jutikliai, FPICT .....	44
1.8. Skyriaus apibendrinimas ir tyrimo krypties pagrindimas.....	53
<b>2. Eksperimentinės AOI sistemos projektavimas ir tyrimo metodika.....</b>	<b>54</b>
2.1. Eksperimentinės sistemos funkcinė struktūra .....	54
2.2. Techninė įranga: kamera, Raspberry Pi, AI HAT+, RGBW apšvietimas .....	55
2.3. Apšvietimo režimai .....	57
2.4. Programinė įranga ir duomenų srautai .....	60
2.5. Duomenų rinkinio sudarymas ir anotavimas .....	61
2.6. YOLO modelių paruošimas ir apmokymas .....	65
2.7. Kokybės vertinimo algoritmo struktūra.....	67
2.7.1. Realus laiko AOI vykdymo režimas su RGBW apšvietimo valdymu.....	67
2.7.2. Stacionaraus kadro AOI analizės režimas su RGBW apšvietimo seka .....	70
2.8. Eksperimento planas ir vertinimo kriterijai .....	73
2.9. Skyriaus išvados .....	75
<b>3. YOLOvX šeimos neuroninių tinklų tyrimas.....</b>	<b>76</b>
3.1. YOLO modelių mokymo rezultatų palyginimas .....	76
3.2. YOLO modelių veikimas realiame AOI stende .....	79
3.3. RGBW apšvietimo įtaka komponentų aptikimui .....	81
3.4. PCB orientacijos įtaka komponentų aptikimui.....	82
3.5. Inferencijos trukmės ir praktinio taikymo analizė.....	83
3.6. Mokymo rezultatų ir realaus stendo rezultatų neatitikimo aptarimas .....	84
3.7. Skyriaus išvados .....	85
<b>Išvados .....</b>	<b>87</b>
<b>Rekomendacijos tolimesniam darbui .....</b>	<b>88</b>
<b>Literatūros ir informacijos šaltinių sąrašas .....</b>	<b>89</b>

## Lentelių sąrašas

<b>1 lentelė.</b> Mašininio mokymosi metodų apžvalga [1] .....	17
<b>2 lentelė.</b> Algoritmo įvertinimas [5].....	19
<b>3 lentelė.</b> Mašininio mokymosi modelių testavimas [6] .....	19
<b>4 lentelė.</b> Giliojo mokymosi parametrų palyginimas [1] .....	21
<b>5 lentelė.</b> Parametrų palyginimas [2] .....	21
<b>6 lentelė.</b> Duomenų rinkinių paruošimas kiekviename poklasyje [7] .....	22
<b>7 lentelė.</b> Bendri klasifikatorių rezultatai [7] .....	23
<b>8 lentelė.</b> Architektūrų įvertinimas [8].....	23
<b>9 lentelė.</b> Pasiūlyto modelio ir CNN pagrįstų modelių klasifikacijos rezultatų palyginimas [12]....	24
<b>10 lentelė.</b> Klasifikacijos tikslumai atskiriems PCB SPI vaizdų duomenų rinkiniams [13].....	25
<b>11 lentelė.</b> Modelių veikimo rezultatai [14].....	26
<b>12 lentelė.</b> Palyginimas tarp „Xception“, „Inception“, „ResNet“, „YOLO“ ir AOI metodų [9] .....	27
<b>13 lentelė.</b> IOU rodiklio priklausomybė vertinant epochas [15].....	28
<b>14 lentelė.</b> Modelių veikimo palyginimas [17] .....	30
<b>15 lentelė.</b> Suliejimo šalinimo modelio veikimo rezultatai [18] .....	31
<b>16 lentelė.</b> Modelio veikimo rezultatai esant šilumos pokyčiams ir skirtingiems kampiniams duomenims [19].....	32
<b>17 lentelė.</b> Rezultatų tarp modelių palyginimas [20] .....	33
<b>18 lentelė.</b> Skirtingų modelių generuojamų rezultatų palyginimas [21].....	35
<b>19 lentelė.</b> Palyginimas su baziniu modeliu naudojant „PCB_dataset“ ir „DeepPCB“ duomenų rinkinius [22] .....	36
<b>20 lentelė.</b> Algoritmų palyginimas kiekvienoje kategorijoje [23] .....	37
<b>21 lentelė.</b> Komponentų aptikimo palyginimas naudojant PCBWACV duomenų rinkinį [11].....	37
<b>22 lentelė.</b> Komponentų aptikimo palyginimas naudojant EAPCB duomenų rinkinį [11] .....	38
<b>23 lentelė.</b> Modelių palyginimas [10] .....	38
<b>24 lentelė.</b> Modelių palyginimas [24] .....	39
<b>25 lentelė.</b> Eksperimentinių rezultatų palyginimas [25] .....	39
<b>26 lentelė.</b> „AE-YOLO“ ir pagrindinių algoritmų našumo palyginimas [26].....	41
<b>27 lentelė.</b> AE-YOLO ir pagrindinių algoritmų našumo palyginimas [27] .....	42
<b>28 lentelė.</b> Modelio veikimo rezultatai esant šilumos pokyčiams ir skirtingiems kampiniams duomenims [19].....	46
<b>29 lentelė.</b> Duomenų rinkinio charakteristikos [34].....	49
<b>30 lentelė.</b> Apšvietimo režimai .....	68
<b>31 lentelė.</b> CVS duomenys.....	70
<b>32 lentelė.</b> Pirmojo modelių apmokymo etapo rezultatai.....	76
<b>33 lentelė.</b> Antrojo modelių apmokymo etapo rezultatai .....	77
<b>34 lentelė.</b> Trečiojo modelių apmokymo etapo rezultatai.....	78
<b>35 lentelė.</b> Ketvirtojo modelių apmokymo etapo rezultatai .....	78
<b>36 lentelė.</b> Eksperimento struktūrą.....	79
<b>37 lentelė.</b> Bendras YOLO modelių palyginimas eksperimentiniame AOI stende .....	80
<b>38 lentelė.</b> RGBW apšvietimo įtaka aptikimų skaičiui .....	81
<b>39 lentelė.</b> PCB orientacijos įtaka aptikimui.....	82
<b>40 lentelė.</b> YOLO modelių inferencijos trukmės palyginimas eksperimentiniame AOI stende.....	83

## Paveikslų sąrašas

<b>1 pav.</b> „Grubios“ padėties nustatymo pavyzdžiai, naudojant NCC schemą [5].....	18
<b>2 pav.</b> Savybių, požymių taškų sujungimo rezultatai tarp dviejų PCB vaizdų [6].....	18
<b>3 pav.</b> Hierarchinis klasifikatorius [7].....	22
<b>4 pav.</b> „D3PointNet“ tinklas [12].....	24
<b>5 pav.</b> „MarsNet“ tinklo struktūra [13] .....	25
<b>6 pav.</b> Modelyje naudota lygiagrečių filtrų architektūra [14].....	26
<b>7 pav.</b> Modelio treniruotė „A“ [16].....	28
<b>8 pav.</b> Autorių siūloma tikrinimo proceso procedūra naudojant dirbtinį intelektą [17].....	29
<b>9 pav.</b> Autoenkoderio architektūra [18] .....	30
<b>10 pav.</b> Aptikimo rezultatai: a) analizuotas modelis; b) „YOLOv8-Nano“ modelis [20] .....	34
<b>11 pav.</b> Šeši pagrindiniai PCB plokščių defektų tipai [21] .....	35
<b>12 pav.</b> Jutiklio veikimo principas pagrįstas talpiniu matavimu [29] .....	44
<b>13 pav.</b> Hibridinis slenksčių nustatymo metodas, užtikrinantis testavimo tikslumą [29].....	45
<b>14 pav.</b> Jutiklio generuojami rezultatai be testuojamo objekto DUT [30].....	47
<b>15 pav.</b> „fr“ pasiskirstymas tiriamojo objekto DUT atviro ir trumpo jungimo defektų atvejais [30].....	47
<b>16 pav.</b> Išgaunamo tikslumo priklausomybė nuo parametro $R_{guard}$ [32].....	48
<b>17 pav.</b> Šaltinio įtampos priklausomybė nuo krūvio, esant skirtingoms išėjimo elektrodo įtampoms. [40] .....	51
<b>18 pav.</b> Elektros jungimo schema .....	56
<b>19 pav.</b> Įranga.....	57
<b>20 pav.</b> Baltas apšvietimas .....	58
<b>21 pav.</b> Raudonas apšvietimas .....	58
<b>22 pav.</b> Žalias apšvietimas .....	59
<b>23 pav.</b> Mėlynas apšvietimas .....	59
<b>24 pav.</b> „Hailo-8“ formato paruošimo kelias .....	61
<b>25 pav.</b> „IMX500“ formato paruošimo kelias .....	61
<b>26 pav.</b> Komponentų klasių kiekis „1“ .....	63
<b>27 pav.</b> Komponentų klasių kiekis „2“ .....	64
<b>27 pav.</b> Komponentų klasių kiekis „2“ .....	64
<b>28 pav.</b> Režimu algoritmas.....	72
<b>29 pav.</b> RGBW apšvietimo seka .....	74

## Santrumpų ir terminų sąrašas

### Santrumpos:

- AI – dirbtinis intelektas (angl. *artificial intelligence*);
- ADC – analoginis-skaitmeninis keitiklis (angl. *analog-to-digital converter*);
- AOI – automatinė optinė patikra (angl. *automated optical inspection*);
- ASIC – specialios paskirties integrinis lustas (angl. *application-specific integrated circuit*);
- AXI – automatinė rentgeno patikra (angl. *automated X-ray inspection*);
- BGA – rutulinė kontaktų matrica (angl. *ball grid array*);
- CNN – konvoliuciniai neuroniniai tinklai (angl. *convolutional neural networks*);
- DL – giluminis mokymasis (angl. *deep learning*);
- DUT – testuojamas įrenginys (angl. *device under test*);
- EVB – vertinimo plokštė (angl. *evaluation board*);
- FCOS – vienos pakopos konvoliucinis objektų aptikimas (angl. *fully convolutional one-stage object detection*);
- FPS – kadrai per sekundę (angl. *frames per second*);
- FHE – lanksti hibridinė elektronika (angl. *flexible hybrid electronics*);
- FPN – požymių piramidės tinklas (angl. *feature pyramid network*);
- FPGA – programuojama loginė matrica (angl. *field-programmable gate array*);
- FPR – klaidingai teigiamų atvejų rodiklis (angl. *false positive rate*);
- HDL – aparatinės įrangos aprašymo kalba (angl. *hardware description language*);
- IC – integruotas lustas (angl. *integrated circuit*);
- ICD – grandinės derinimo įrankis (angl. *in-circuit debugger*);
- ICT – vidinis grandinių testavimas (angl. *in-circuit test*);
- IoU – persidengimo koeficientas (angl. *intersection over union*);
- KS – Kolmogorovo-Smirnovo statistika, naudojama pasiskirstymo skirtumui įvertinti;
- LSTM – ilgos trukmės trumpalaikė atmintis (angl. *long short-term memory*);
- mAP – vidutinis tikslumo įvertinimas (angl. *mean average precision*);
- ML – mašininis mokymasis (angl. *machine learning*);
- MLP – daugiapakopis perceptronas (angl. *multi-layer perceptron*);

PANet – kelio agregavimo tinklas (angl. *path aggregation network*);

PCB – spausdintinė plokštė (angl. *printed circuit board*);

PCBA – surinkta spausdintinė plokštė (angl. *printed circuit board assembly*);

PEM – emisijos mikroskopija (angl. *photon emission microscopy*);

R-CNN – regionais pagrįstas CNN (angl. *region-based convolutional neural network*);

RFID – radijo dažnio identifikacija (angl. *radio-frequency identification*);

RPCA – patikimoji pagrindinių komponentų analizė (angl. *robust principal component analysis*);

SGD – stochastinis gradientinis nusileidimas (angl. *stochastic gradient descent*);

SPI – nuosekli periferinė sąsaja (angl. *serial peripheral interface*);

SSIM – struktūrinio panašumo indeksas (angl. *structural similarity index*);

SVM – atraminių vektorių mašina (angl. *support vector machine*);

UART – universalus asinchroninis siųstuvas-imtuvėjas (angl. *universal asynchronous receiver-transmitter*);

VLSI – labai didelio masto integracija (angl. *very-large-scale integration*);

YOLO – vienkartinis objektų aptikimas (angl. *you only look once*);

HTTP – hiperteksto perdavimo protokolas (angl. *hypertext transfer protocol*)

GPU – grafinis procesorius (angl. *graphics processing unit*)

API – programavimo sąsaja (angl. *application programming interface*)

LED – šviesos diodas (angl. *light-emitting diode*)

RGBW – raudonos, žalios, mėlynos ir baltos spalvos apšvietimas (angl. *red, green, blue, white*)

TOPS – trilijonai operacijų per sekundę (angl. *tera operations per second*)

### **Terminai:**

**„Atgavimo“ rodiklis** (angl. *recall*) – metrika, parodanti kiek iš visų tikrųjų defektų modelis sugebėjo aptikti [1].

**F1 balas** – sudėtinis rodiklis, kuris subalansuoja tikslumą (angl. *precision*) ir „atgavimo“ rodiklį (angl. *recall*), naudingas vertinant klasifikatorių [1].

**Tikslumas** (angl. *precision*) – rodiklis, parodantis, kiek iš modelio aptiktų defektų buvo tikrai teisingi [1].

**Defektų lokalizacija** – defekto vietos nurodymas vaizde ar fiziniėje erdvėje [1].

**Giluminis mokymasis** – mašininio mokymosi dalis, kuri remiasi sudėtingomis neuroninių tinklų struktūromis [1].

**Konvoliucija** – matematinis veiksmas, naudojamas CNN tinkluose, skirtas aptikti vaizdo bruožus (pvz., kraštus, kampus, tekstūras) [1].

**Realus laikas** (angl. *real-time*) – sistemos gebėjimas reaguoti arba apdoroti duomenis nedelsiant, dažnai <30 milisekundžių [1].

**Neuroninis tinklas** – algoritmų sistema, modeliuojanti žmogaus smegenų veikimą, naudojama atpažinimui, prognozavimui, klasifikacijai [2].

**Patikimumas** (angl. *testability*) – galimybė testuoti konkrečius signalus ar blokus, naudojant ATPG ar kitus metodus [5].

**Anotavimas** (angl. *annotation*) – objektų pažymėjimo procesas vaizduose, naudojamas neuroninių tinklų mokymui. [15]

**Apribojantis rėmelis** (angl. *bounding box*) – stačiakampė sritis vaizde, naudojama objekto vietai nurodyti. [19]

**Inferencija** (angl. *inference*) – apmokyto neuroninio tinklo vykdymo procesas, kurio metu atliekamas objektų aptikimas arba klasifikavimas naujiems duomenims. [25]

**Autoenkoderis** – neuroninio tinklo struktūra, skirta duomenims suspausti, atkurti arba anomalijoms (defektams) aptikti [36].

**Testavimo padengimas** (angl. *test coverage*) – rodiklis, apibrėžiantis, kiek komponentų ar signalų tikrinama atliekant testus [40].

**Pasitikėjimo balas** (angl. *confidence score*) – neuroninio tinklo apskaičiuota tikimybė, rodanti aptikto objekto teisingumą.

**Perkėlimo mokymasis** (angl. *transfer learning*) – metodas, kai modelis mokomas naudojant iš anksto apmokytus svorius. [50]

## Įvadas

**Problematika.** Sudėtingėjant PCB bei PCBA plokščių gamybos technologijoms bei didėjant jų gamybos mastams, išauga ir kokybės tikrinimo svarba. Naudojami testavimo metodai reikalauja didelių laiko ir darbo sąnaudų, o jų tikslumas priklauso nuo žmogaus patirties ar specializuotos įrangos. Dėl to kyla šios problemos:

1. Ribotos galimybės adaptuoti gamybą prie naujų PCB variantų.
2. Trūksta lanksčių, automatizuotų ir savarankiškai prisitaikančių testavimo sprendimų.
3. Sunkumai užtikrinant kokybę didelės apimties gamyboje.

**Aktualumas.** Didėjant elektronikos gaminių įvairovei ir sudėtingėjant jų konstrukcijoms, automatizuotų tikrinimo bei kokybės kontrolės sistemų diegimas tampa neišvengimas. Elektronikos testavimo iššūkiai kyla dėl šių priežasčių:

1. Sudėtingos technologijos: PCB plokštėse integruoti lustai, ryšių protokolai, įvairios elektronikos grandinės ir smulkūs komponentai daro testavimo procesą sudėtingesnę.
2. Neefektyvūs rankiniai testavimo metodai: žmogiškosios klaidos ir laiko sąnaudos riboja rankinio testavimo efektyvumą.
3. Gamybos kaštų mažinimas: automatizuota testavimo įranga leidžia sumažinti rankinio darbo poreikį, greitai aptikti gedimus ir padidinti gamybos efektyvumą.
4. Kokybės užtikrinimas: aukštos kokybės standartai tampa būtinybe, siekiant užtikrinti gaminių patikimumą ir konkurencingumą rinkoje.

**Tyrimo objektas** – SMD komponentų optinio atpažinimo PCB plokštėse, naudojant YOLO modelius eksperimentinėje AOI sistemoje.

**Tikslas** – sukurti ir iširti automatizuotą optinės kontrolės sistemą, skirtą paviršinio montavimo elektronikos komponentų aptikimui spausdintinėse plokštėse, taikant YOLO šeimos neuroninius tinklus ir analizuojant RGBW apšvietimo bei PCB orientacijos įtaką aptikimo kokybei.

### Uždaviniai:

1. Išanalizuoti mokslinę literatūrą, nagrinėjančią paviršinio montavimo elektronikos komponentų atpažinimo ir defektų aptikimo metodus spausdintinėse plokštėse;
2. Suprojektuoti eksperimentinę automatizuotos optinės kontrolės sistemą, skirtą PCB komponentų aptikimui ir tyrimams realiomis testavimo sąlygomis;
3. Sukurti ir iširti YOLO šeimos neuroniniais tinklais pagrįstą PCB komponentų aptikimo algoritmą, įvertinant RGBW apšvietimo ir PCB orientacijos įtaką aptikimo kokybei;
4. Eksperimentiškai patvirtinti sukurtos AOI sistemos ir komponentų aptikimo algoritmo veikimą realiomis AOI sistemos veikimo sąlygomis.

**Tyrimo metodai:** literatūros analizė, eksperimentinio AOI stendo projektavimas, YOLO modelių apmokymas, inferencijos bandymai, RGBW apšvietimo ir PCB orientacijos įtakos analizė, rezultatų statistinis vertinimas.

### Konferencijoje(-jose) skaityti pranešimai:

Blažys, Edvinas; vaizdo atpažinimo algoritmų taikymas elektronikos komponentų optinei kontrolei. 25-oji studentų mokslinė konferencija „Technologijų ir verslo aktualijos“. Panevėžys: Kauno technologijos universiteto Panevėžio technologijų ir verslo fakultetas, 2025 m. lapkričio 21 d.

**Autoriaus publikuotų straipsnių bibliografinis sąrašas:**

Blažys, Edvinas; Strikulienė, Olga; Pelenis, Donatas. Vaizdo atpažinimo algoritmų taikymas elektronikos komponentų optinei kontrolei // Technologijų ir verslo aktualijos – 2025: studentų mokslinės konferencijos pranešimų medžiaga, Lietuva, Panevėžys, 2025 m. lapkričio 21 d., 434–444 psl. / Kauno technologijos universiteto Panevėžio technologijų ir verslo fakultetas. Kaunas: Kauno technologijos universitetas. ISSN 2538-8045. 2025.

## **1. PCB optinės kontrolės ir dirbtinio intelekto metodų analizė**

Šiame skyriuje analizuojami PCB ir PCBA kokybės kontrolės metodai, taikomi elektronikos gamyboje. Pirmiausia aptariama PCB ir PCBA defektų aptikimo problema, automatinės optinės patikros AOI taikymas ir klasikiniai vaizdo apdorojimo bei mašininio mokymosi metodai. Toliau nagrinėjami giliojo mokymosi modeliai, ypatingą dėmesį skiriant „YOLO“ šeimos algoritmams, kurie leidžia tiesiogiai nustatyti komponentų arba defektų klasę, koordinates ir aptikimo pasitikėjimo reikšmę. Taip pat aptariama apšvietimo įtaka optiniam atpažinimui ir alternatyvūs elektronikos testavimo metodai, tokie kaip AXI, ICT, FPICT, JTAG ir talpiniai jutikliai.

### **1.1. PCB ir PCBA kokybės kontrolės problema**

Elektronikos gamyboje [1, 2] spausdintinės plokštės PCB ir surinktos spausdintinės plokštės PCBA tampa vis sudėtingesnės dėl didėjančio komponentų tankio, mažėjančių paviršinio montavimo komponentų matmenų, didesnio integrinių grandynų kiekio ir augančių gamybos apimčių. PCB plokštėse montuojami skirtingų tipų komponentai – rezistoriai, kondensatoriai, diodai, tranzistoriai, jungtys ir integriniai grandynai, todėl net nedideli litavimo, komponentų padėties ar montavimo neatitikimai gali turėti įtakos viso elektronikos gaminio veikimui. Dėl šios priežasties kokybės kontrolės sistema turi ne tik aptikti vizualiai matomus defektus, bet ir užtikrinti pakankamą tikrinimo spartą, pakartojamumą ir galimybę prisitaikyti prie skirtingų PCB konstrukcijų.

Rankinė PCB ir PCBA patikra tampa nepakankamai efektyvi, kai gamyboje didėja tikrinamų plokščių ir komponentų kiekis. Tokia patikra priklauso nuo operatoriaus patirties, nuovargio, apšvietimo sąlygų ir subjektyvaus vertinimo, todėl didėja klaidingų sprendimų rizika. Literatūroje [1, 2, 3]. pažymima, kad automatizuotos tikrinimo sistemos reikalingos siekiant sumažinti rankinio darbo poreikį, greičiau aptikti defektus ir pagerinti elektronikos gaminių kokybę. Tai ypač aktualu tada, kai gaminamos skirtingos PCB versijos, nes kiekvienam naujam plokštės variantui rankinis tikrinimas arba griežtai šablonais paremtos sistemos reikalauja papildomo derinimo.

PCB ir PCBA kokybės kontrolei [4] taikomi skirtingi metodai: automatinė optinė patikra AOI, vidinis grandinių testavimas ICT, rentgeno patikra AXI ir dirbtinio intelekto pagrindu veikiančys vaizdo analizės algoritmai. AOI sistemos leidžia kameromis fiksuoti plokštės vaizdus ir aptikti vizualius komponentų, litavimo ar išdėstymo neatitikimus, o ICT metodai naudojami elektriniams parametrų, tokiems kaip varža, talpa, atviros arba trumpos grandinės, tikrinti. Tačiau optinės patikros tikslumas priklauso nuo PCB struktūros, komponentų tankio, apšvietimo sąlygų ir vaizdo apdorojimo algoritmo gebėjimo atskirti tikrus defektus nuo fono ar nereikšmingų vaizdo pokyčių. Mokslininkų [3] taip pat akcentuojama, kad tradiciniai optinės patikros metodai yra jautrūs apšvietimo pokyčiams ir sudėtingoms PCB struktūroms, todėl vis dažniau taikomi giluminio mokymosi modeliai.

### **1.2. Automatinės optinės patikros AOI metodai**

Automatinė optinė patikra AOI yra elektronikos gaminių kokybės kontrolės metodas, kai PCB arba PCBA plokštės vertinamos naudojant kameromis užfiksuotus vaizdus. Tokiose sistemose analizuojamas komponentų buvimas, jų padėtis, orientacija, litavimo taškų kokybė, paviršiaus pažeidimai ir kiti vizualiai matomi neatitikimai. AOI metodas ypač svarbus elektronikos gamyboje, nes leidžia automatizuoti vizualinę patikrą, sumažinti rankinio tikrinimo įtaką ir užtikrinti pakartojamą kokybės vertinimą.

AOI sistemos veikimą galima suskirstyti į kelis pagrindinius etapus: PCB vaizdo fiksavimą, plokštės padėties nustatymą, vaizdo paruošimą analizei, komponentų arba defektų lokalizavimą ir gautų rezultatų klasifikavimą. Pirmiausia kamera užfiksuoja tikrinamos plokštės vaizdą, tada nustatoma plokštės padėtis ir įvertinama, ar vaizdas tinkamas tolesnei analizei. Vėliau sistemoje ieškoma komponentų, litavimo sričių arba galimų defektų, o gauti rezultatai naudojami kokybės sprendimui priimti. Tradicinėse AOI sistemose dažnai taikomas etaloninio ir tikrinamo PCB vaizdo palyginimas. Tokiu atveju tikrinamas vaizdas lyginamas su iš anksto paruoštu geros kokybės plokštės vaizdu, o skirtumai tarp jų gali būti laikomi galimais defektais arba komponentų padėties neatitikimais. Šiai krypčiai priskiriami vaizdų registracijos ir lygiavimo metodai, kai naudojami NCC, ORB, RANSAC arba homografijos metodai [5, 6]. Tokie metodai naudingi tada, kai reikia tiksliai sulygtinti PCB vaizdą su etalonu, tačiau jie priklauso nuo etaloninio vaizdo, apšvietimo stabilumo ir plokštės pozicionavimo tikslumo.

Naujesnėse AOI sistemose vis dažniau taikomi dirbtinio intelekto ir giluminio mokymosi metodai. CNN architektūros naudojamos komponentų buvimui, padėčiai, litavimo kokybei ir defektų požymiams vertinti [7, 8, 9, 10]. Tokie modeliai leidžia sistemai ne tik lygti vaizdą su etalonu, bet ir išmokti būdingus komponentų ar defektų požymius iš duomenų. Tai padidina sistemos lankstumą, nes ji gali būti pritaikoma skirtingoms PCB plokštėms ir įvairesnėms patikros sąlygoms.

AOI sistemose taip pat taikomi „YOLO“ tipo objektų aptikimo modeliai, kurie leidžia vienu metu nustatyti komponento arba defekto klasę ir jo vietą vaizde [8, 9, 10, 11]. Tokie modeliai ypač naudingi tada, kai reikia aptikti daug skirtingų komponentų viename PCB vaizde. „YOLO“ modelių taikymas AOI sistemose leidžia atlikti komponentų lokalizavimą tiesiogiai iš kameros vaizdo, todėl sumažėja poreikis naudoti griežtai apibrėžtus šablonus ar rankiniu būdu parinktus požymius.

Šablonų atsisakymas yra svarbi šiuolaikinių AOI sistemų kryptis. Tradicinės sistemos, kurios remiasi „geros“ plokštės etalonu, gali būti jautrios naujiems PCB variantams, apšvietimo pokyčiams arba mažiems geometriniams poslinkiams. DI pagrindu veikiančios AOI sistemos gali mokytis iš didesnio vaizdų kiekio ir atpažinti komponentus arba defektus pagal jų požymius. Dėl to tokios sistemos gali būti lankstesnės ir geriau pritaikomos kintančioms gamybos sąlygoms.

Apibendrinant galima teigti, kad AOI yra kameromis pagrįstas PCB ir PCBA kokybės kontrolės metodas, skirtas komponentų buvimui, padėčiai, litavimo kokybei ir vizualiems defektams vertinti. Tradiciniai AOI metodai dažniausiai remiasi etaloninių vaizdų palyginimu ir vaizdų lygiavimu, o šiuolaikinės AOI sistemos vis dažniau papildomos CNN, „YOLO“ ir kitais dirbtinio intelekto metodais. Šiame darbe aktualiausia yra AOI kryptis, kurioje kameromis užfiksuotuose PCB vaizduose paviršinio montavimo komponentai aptinkami naudojant „YOLO“ šeimos modelius.

### **1.3. Klasikiniai vaizdo apdorojimo ir ML metodai**

Klasikiniai vaizdo apdorojimo ir mašininio mokymosi ML metodai PCB kokybės kontrolėje naudojami tada, kai reikia išskirti vaizdo požymius, palygti tikrinamą plokštę su etalonu, įvertinti tekstūrą, spalvą, kontūrus arba geometrinius neatitikimus. Šiai metodų grupei priskiriami SVM, MLP, RPCA, „Random Forest“, NCC, ORB, RANSAC ir statistiniai metodai. Jie gali būti taikomi litavimo defektams, komponentų padėties nuokrypiams, paviršiaus pažeidimams arba testavimo duomenų pokyčiams nustatyti.

Mokslininkai [1] išanalizavo 128 mokslinius straipsnius, siekdami įvertinti PCB defektų aptikimui taikomų metodų efektyvumą, trūkumus, greitaveiką ir pritaikymą pramonėje. Apžvalgoje nurodoma, kad klasikiniai mašininio mokymosi metodai gali pasiekti aukštus defektų aptikimo rezultatus, kai defektų požymiai yra aiškiai apibrėžti ir iš anksto parinkti.

**1 lentelė.** Mašininio mokymosi metodų apžvalga [1]


Metodas	Aptikimo kriterijai	Tikslumas, %
SVM ir pakopinė žiedinė apšvietimo sistema su RGB	Klasifikacijos dažnumas	>96
LVQ ir neraiškioji „fuzzy“ logika	Klasifikacijos dažnumas	95,83
MLP ir „GW Gaboro“ bangelės	Klasifikacijos dažnumas	98,8
„Bayers“ klasifikatorius ir SVM atraminių vektorių mašina	Klasifikacijos dažnumas	100
RPCA kartu su RGB	Tikslumas, <i>F</i> -balas*	95,65
Atsitiktinio „miško“ klasifikatorius	Aptikimo tikslumas	98,96

\* čia *F*-balas (angl. *F-score*) – statistinis rodiklis, naudojamas klasifikavimo algoritmo tikslumu įvertinti, kuris subalansuoja du rodiklius: tikslumą (angl. *precision*) ir „atgavimo“ rodiklį (angl. *recall*).

Mašininio mokymosi metodų apžvalgos rezultatai [1] rodo, kad klasikiniai algoritmai gali pasiekti aukštus PCB defektų aptikimo tikslumo rodiklius (žr. 1 lentelę). Atraminių vektorių mašina SVM (angl. *support vector machine*) su RGB apšvietimu naudojama litavimo defektams aptikti ir pasiekia daugiau kaip 96 proc. tikslumą. LVQ su neraiškiaja logika (angl. *learning vector quantization with fuzzy logic*) defektus pagal apšvietimo sąlygas klasifikuoja 95,83 proc. tikslumu. Daugiapakopis perceptronas su „Gaboro“ bangelėmis MLP + GW (angl. *multi-layer perceptron with Gabor wavelets*) naudojamas tekstūrų analizei ir pasiekia 98,8 proc. tikslumą. Patikimoji pagrindinių komponentų analizė RPCA (angl. *robust principal component analysis*) kartu su RGB vaizdais naudojama mažiems litavimo defektams aptikti ir pasiekia 95,65 proc. tikslumą, o atsitiktinio miško klasifikatorius (angl. *random forest*) 3D vaizdų analizei pasiekia 98,96 proc. tikslumą.


Nors klasikiniai ML metodai gali pasiekti aukštus tikslumo rodiklius, autoriai [1] nurodo ir jų ribojimus. Šiems metodams dažnai reikia iš anksto išskirti požymius ir rankiniu būdu parinkti vaizdo bruožus, pavyzdžiui, tekstūras, kraštus ar spalvų intensyvumą. Be to, jie dažnai remiasi šablonais arba etaloniniais vaizdais, todėl jų gebėjimas prisitaikyti prie naujų PCB plokščių, nestandartinių defektų ar kintančių apšvietimo sąlygų yra ribotas. Dėl to tokie metodai ne visada leidžia tiksliai lokalizuoti defektą – dažnai nustatoma tik jo klasė, bet ne tiksli vieta vaizde.

Kita klasikinių metodų kryptis yra PCB vaizdų registracija ir lygiavimas. Moksliniame šaltinyje [5] analizuotas dviejų etapų vaizdų lygiavimo metodas, skirtas PCB plokščių optinei patikrai gamybinėje linijoje. Tyrime giluminio mokymosi CNN metodai nebuvo taikyti. Vietoje jų naudotas skaitmeninio signalo apdorojimo DSP metodas, pagrįstas vaizdų registracija ir atitikmenų paieška tarp tikrinamo PCB vaizdo ir etaloninio vaizdo. Tokia metodika leidžia nustatyti PCB padėties nuokrypius ir paruošti vaizdą tolesnei optinei analizei. Pirmajame metodo etape naudota normalizuota kryžminė koreliacija NCC, skirta grubiam PCB padėties nustatymui pagal etaloninį vaizdą (žr. 1 pav.).



**1 pav.** „Grubios“ padėties nustatymo pavyzdžiai, naudojant NCC schemą [5]

Antrajame etape taikytas ORB požymių taškų išskyrimas ir RANSAC algoritmas, leidžiantis at mesti klaidingus atitikmenis bei tiksliau sulygtinti PCB vaizdus (žr. 1 pav.).



**2 pav.** Savybių, požymių taškų sujungimo rezultatai tarp dviejų PCB vaizdų [5]

Tam buvo taikyta normalizuota kryžminė koreliacija NCC grubiam padėties nustatymui (žr. 1 pav.), ORB požymių taškams išskirti ir RANSAC algoritmas klaidingiems atitikmenims at mesti.

**2 lentelė.** Algoritmo įvertinimas [5]

Vaizdas	Atitikimas, vnt.	Rasta taškų, vnt.	Teisingi atitikimai, vnt.	Pastovumas / Patikimumas, proc.	Tikslumas, proc.
Vaizdas 0	202	195	198	0,96	0,98
Vaizdas 1	240	189	199	0,78	0,82
Vaizdas 2	247	183	198	0,74	0,80
Vaizdas 3	258	201	215	0,77	0,83
Vaizdas 4	250	228	240	0,91	0,96
Vaizdas 5	245	186	197	0,75	0,80

Gauti rezultatai (žr. 2 lentelę) parodė, kad vidutinė lygiavimo paklaida sudarė 7 pikselius, kai vaizdo raiška buvo  $3200 \times 2400$  pikselių, o vieno vaizdo apdorojimo laikas siekė 118,6 ms. Šis metodas šiame darbe tiesiogiai netaikomas, tačiau jis įtraukiamas kaip klasikinės AOI vaizdų registracijos pavyzdys, parodantis, kad PCB pozicionavimas ir orientacija yra svarbūs optinės kontrolės rezultatų stabilumui. Šis metodas šiame darbe tiesiogiai netaikomas, tačiau jis įtraukiamas kaip klasikinės AOI vaizdų registracijos pavyzdys. Jis parodo, kad PCB pozicionavimas ir orientacija yra svarbūs optinės kontrolės rezultatų stabilumui. Šiame darbe ši problema vertinama kitu būdu – eksperimentiniame AOI stende tirama, kaip skirtingos PCB orientacijos daro įtaką „YOLO“ modelių komponentų aptikimo rezultatams.

Panaši AOI vaizdų derinimo kryptis nagrinėta šaltinyje [6]. Autoriai taikė vaizdų derinimo algoritmą, skirtą tikrinamo PCB vaizdo sulyginimui su etaloniniu vaizdu. Tyrime  $3200 \times 2400$  pikselių PCB vaizdams apdoroti naudoti klasikiniai vaizdo registracijos metodai: normalizuota kryžminė koreliacija NCC, ORB požymių taškų aptikimas, Hamming atstumo skaičiavimas, RANSAC algoritmas ir homografijos matrica. Tokia metodika leidžia tiksliau paruošti PCB vaizdą tolesnei defektų arba komponentų analizei, tačiau išlieka priklausoma nuo etaloninio vaizdo, požymių taškų kokybės ir geometrinio vaizdo stabilumo.

**3 lentelė.** Mašininio mokymosi modelių testavimas [6]

„ML“ modeliai	Duomenų rinkiniai				
	1	2	3	4	5
„Random Forest“	0,99	0,94	0,98	0,92	0,99
„SVM“	0,98	0,92	0,96	0,89	0,97
„KNN“	0,98	0,91	0,97	0,89	0,99
„Naive Bayes“	0,89	0,93	0,98	0,88	0,93
„Logistic Regression“	0,87	0,93	0,97	0,89	0,99
„Decision Tree“	0,98	0,91	0,97	0,90	0,99

Šaltinyje [6] taip pat analizuotas AOI ir AXI testavimo duomenų suderinamumas, naudojant mašininio mokymosi modelius (žr. 3 lentelę). Geriausi rezultatai gauti naudojant „Random Forest“ modelį, kai penktame duomenų rinkinyje pasiektas 0,99 mAP rodiklis. Tyrime nustatyta, kad AOI ir AXI testų sutapimas gali siekti 99 proc., tačiau apie 10 proc. BGA tipo komponentų gali būti pilnai įvertinti tik AXI metodu. Redundancijos sumažinimo nauda AXI testuose siekė iki 2,8 proc.

Šis tyrimas [6] parodo, kad tikslus PCB vaizdo sulyginimas su etalonu gali pagerinti optinės patikros stabilumą, tačiau kartu atskleidžia AOI ribojimą – optinė sistema negali patikimai įvertinti paslėptų komponentų ar kontaktų, kurie nėra matomi kameros vaizde. Šaltinyje [6] aprašyti mašininio mokymosi modeliai šiame darbe tiesiogiai netaikomi, nes tyrimas orientuojamas į matomų SMD komponentų aptikimą.

Apibendrinant galima teigti, kad klasikiniai vaizdo apdorojimo ir mašininio mokymosi metodai PCB kokybės kontrolėje gali pasiekti aukštus tikslumo rodiklius, tačiau jų taikymas dažnai priklauso nuo iš anksto parinktų požymių, etaloninių vaizdų ir stabilių vaizdo fiksavimo sąlygų. Šaltinyje [1] apžvelgti SVM, MLP, RPCA, „Random Forest“ ir kiti metodai pasiekė 95,65–100 proc. tikslumo reikšmes, tačiau šie metodai dažniausiai reikalauja rankinio požymių parinkimo ir ne visada leidžia tiksliai lokalizuoti defektą vaizde.

Klasikiniai vaizdų registracijos metodai, tokie kaip NCC, ORB, RANSAC ir homografijos matrica, yra naudingi PCB padėčiai ir orientacijai koreguoti. Tyrime [5] tokia metodika leido pasiekti 7 pikselių vidutinę lygiavimo paklaidą, kai vaizdo raiška buvo  $3200 \times 2400$  pikselių, o vieno vaizdo apdorojimo laikas siekė 118,6 ms. Panaši kryptis taikyta ir šaltinyje [6], kuriame vaizdų derinimas su etalonu buvo naudojamas AOI rezultatų stabilumui gerinti, o „Random Forest“ modelis viename duomenų rinkinyje pasiekė 0,99 mAP rodiklį. Vis dėlto tokie metodai išlieka priklausomi nuo etaloninio vaizdo, požymių taškų kokybės ir geometrinio vaizdo stabilumo.

Šiame darbe klasikiniai ML ir vaizdų registracijos metodai tiesiogiai netaikomi, nes tyrimo tikslas yra ne tik palyginti PCB vaizdą su etalonu ar klasifikuoti iš anksto apibrėžtus defektus, bet realiame AOI stende aptikti matomus paviršinio montavimo komponentus. Todėl tolesnėje darbo dalyje pagrindinis dėmesys skiriamas „YOLO“ tipo objektų aptikimo modeliams, kurie vieno apdorojimo metu leidžia nustatyti komponento klasę, koordinates ir aptikimo pasitikėjimo reikšmę.

#### 1.4. CNN ir kiti giliojo mokymosi metodai

Giliojo mokymosi metodai PCB ir PCBA kokybės kontrolėje taikomi tada, kai reikia automatiškai išmokti vaizdo požymius ir sumažinti rankinio požymių parinkimo poreikį. Skirtingai nei klasikiniai ML metodai, CNN architektūros gali pačios išskirti komponentų formą, kraštus, tekstūrą ir kitus vaizdo požymius, todėl jos plačiai taikomos komponentų atpažinimo, litavimo kokybės, SPI, AXI, termovizijos ir defektų aptikimo užduotyse. Giliojo mokymosi metodai naudojami [1] PCB plokščių paviršių defektams, komponentams aptikti:

- trys skirtingo dydžio YOLOv5 architektūros (maža, vidutinė, didelė) buvo taikytos defektams  $400 \times 400$  pikselių PCB vaizduose aptikti;
- „Faster R-CNN“ su FPN (angl. *feature pyramid network*) pritaikytas smulkiems defektams (pvz., smulkių įtrūkimų) lokalizuoti; FPN tinka skirtingų mastelių objektams;
- „YOLOv4“ algoritmas su „MobileNetV3“ architektūra naudotas išskaidytajai konvoliucijai (angl. *depth-wise separable convolution*) analizuoti, ji sumažino parametrų kiekį ~40 proc., išlaikydamas kokybę (žr. 4 lentelę); tai leido efektyviai taikyti modelį ribotų resursų įrenginiuose;
- „FCOS“ algoritmas su „MobileNetV2“ ir „PANet“ plėtiniais – tai vienos pakopos modelis (angl. *fully convolutional one-stage object detection*), gebantis greitai aptikti objektus tiesiai iš požymių žemėlapių; „PANet“ – tai kelio agregavimo tinklas (angl. *path aggregation*

network), kuris pagerina savybių perdavimą tarp sluoksnių, todėl modelis tinka skirtingų mastelių defektams analizuoti.

**4 lentelė.** Giliojo mokymosi parametrų palyginimas [1]

Metodas	Aptikimo kriterijai	Tikslumas, proc.
„YOLOv5“ algoritmas	Aptikimo tikslumas	>99
„Faster R-CNN“ su FPN	mAP*	94,2
„YOLOv4“ su „MobileNetV3“	mAP, $F_1$ -balas*	98,64; 97,83
„FCOS“ su „MobileNetV2“ ir „PANet“	mAP	44,3

\* čia  $F_1$  balas – metrika, subalansuojanti tikslumą (angl. *precision*) ir „atgavimo“ rodiklį (angl. *recall*), naudojama vertinant klasifikavimą, esant nesubalansuotiems duomenims; mAP reikšmė – vidutinis tikslumo rodiklis, parodantis, kaip tiksliai modelis aptinka ir lokalizuoja objektus visose klasėse; „atgavimo“ rodiklis – rodo, kiek objektų modelis sugebėjo aptikti.

Autoriai [1] nustatė, kad giluminio mokymosi algoritmai pagerina PCB defektų aptikimą, tačiau daugumos modelių kadru per sekundę FPS (angl. *frames per second*) duomenys nepateikti, todėl jų palyginimas ribotas. „YOLOv4“ algoritmas su „MobileNetV3“ plėtinium pasiekė 56,98 FPS spartą, t. y. užruko 17,5 ms vienam vaizdui apdoroti.

Moksliniame šaltinyje [2] spręsta elektroninių komponentų vaizdo atpažinimo problema elektronikos gamyboje. Autoriai pažymėjo, kad tradiciniai metodai, tokie kaip pagrindinių komponentų analizė PCA (angl. *principal component analysis*) ir atraminių vektorių mašina SVM (angl. *support vector machine*), pasižymi mažesniu tikslumu ir efektyvumu, todėl pasiūlė optimizuotą giluminio mokymosi tinklą „Faster SqueezeNet“. Šis modelis buvo pritaikytas PCB komponentams atpažinti, sumažinant modelio dydį ir išlaikant aukštą atpažinimo tikslumą.

Tyrime [2] naudotas kompiuteris su „Intel Core i5-7300H“ 2,5 GHz procesoriumi, „NVIDIA GTX 1050“ vaizdo plokšte su 2 GB vaizdo atmintimi ir 8 GB operatyviosios atminties. Siūloma „Faster SqueezeNet“ architektūra buvo papildyta „DenseNet“, normalizuotų duomenų paketo BN (angl. *batch normalization*), likutinių jungčių (angl. *residual connections*) ir „ResNet“ struktūros principais. Šie sprendimai pagerino informacijos perdavimą tarp tinklo sluoksnių, mokymo stabilumą ir sumažino persimokymo riziką.

**5 lentelė.** Parametrų palyginimas [2]

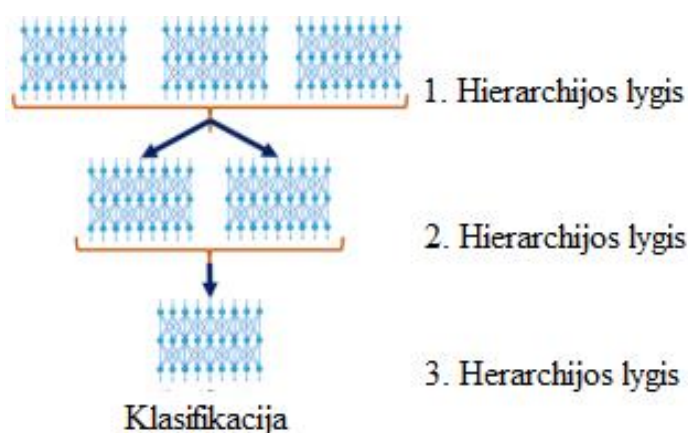
CNN modelis	Duomenų tipas (bitais)*	Modelio dydis (MB)	TPR* (FPR = 10e-6) (proc.)	Vidutinis apdorojimo laikas (AVG) ms	Vidutinis „Tensor“ apdorojimo laikas, ms
„PCA SVM“	32	0,875	93,29	0,29	-
„ResNetV2“	32	9,100	96,995	4,65	-
„MobileNetV2“	32	8,750	99,998	4,83	-
Standartinis „SqueezeNet“	32	0,470	96,391	3,53	-
Autorių modifikuotas „SqueezeNet“	32	0,255	99,999	2,67	0,65

\* čia 32 bitų formatas reiškia, kad kiekvienas skaičius, svoris neuroniniame tinkle yra saugomas kaip 32 bitų reikšmė su slankiuoju kableliu (angl. *float*); TPR (angl. *true positive rate*) – jautrumas – dalis teigiamų atvejų, kuriuos modelis

teisingai atpažįsta; FPR (angl. *false positive rate*) – dalis neigiamų atvejų, kuriuos modelis teisingai atpažįsta; „FPR =  $10e^{-6}$ “ – modelyje galimas tik 1 klaidingas atvejis iš 1 milijono.

Tyrimo [2] rezultatai parodė, kad autorių modifikuotas „SqueezeNet“ modelis pasiekė 99,999 proc. TPR rodiklį, kai FPR =  $10e^{-6}$ , o modelio dydis sumažintas iki 0,255 MB. Vidutinis komponentų atpažinimo laikas siekė 2,67 ms, o naudojant „TensorRT“ – 0,65 ms. Palyginimui, „PCA SVM“ metodas pasiekė 93,29 proc. TPR, „ResNetV2“ – 96,995 proc., „MobileNetV2“ – 99,998 proc., o standartinis „SqueezeNet“ – 96,391 proc. TPR. Tai rodo, kad optimizuotos CNN architektūros gali būti efektyvios elektroninių komponentų atpažinimo užduotyse, ypač kai svarbus mažas modelio dydis ir trumpas apdorojimo laikas.

Šaltinyje [7] buvo pasiūlytas hierarchinis CNN modelis (žr. 3 pav.), skirtas litavimo taškų ir komponentų kokybės vertinimui PCB gamyboje.



3 pav. Hierarchinis klasifikatorius [7]

Modelis sudarytas iš keturių lygių: komponento buvimo nustatymo, litavimo kokybės įvertinimo, komponentų kiekio nustatymo ir komponento padėties klasifikavimo. Tyrime [7] naudoti „Robert Bosch Elektronik GmbH“ gamybos linijos vaizdai (žr. 6 lentelę), kuriuose buvo analizuojami C0402–C1210 kondensatoriai ir R0402–R0603 rezistoriai.

6 lentelė. Duomenų rinkinių paruošimas kiekviename poklasyje [7]

Bendras modelis H1	Poklasiai	Komponentų tipai	Duomenų rinkinio dydis, vnt.
Komponentų aptikimas „N1“	Aptiktas, neaptiktas	C0402–C1210, R0402, R0603	140 000 (70 000 kiekvienai klasei, 10 000 kiekvienam komponentui)
Kokybės būseną „N2“	Geras, blogas	C0402–C1210, R0402, R0603	140 000 (70 000 kiekvienai klasei, 10 000 kiekvienam komponentui)
Komponentų skaičius „N3“	Nėra komponento, vienas komponentas, pašalinis objektas	C0402–C1210, R0402, R0603	262 500 (87 500 kiekvienai klasei, 12 500 kiekvienam komponentui)
Komponentų klasė „N4“	Geras, neteisinga padėtis, nepakankamas litavimas	C0402–C1210, R0402, R0603	262 500 (87 500 kiekvienai klasei, 12 500 kiekvienam komponentui)

7 lentelė. Bendri klasifikatorių rezultatai [7]

Duomenų rinkiniai	Vienas modelis su mokymų duomenų rinkiniu				Hierarchinis modelis H1			
	Tikslumas (proc.)	Logaritminė paklaida	Pseudo klaidos (proc.)	Neaptikti defektai (proc.)	Tikslumas (proc.)	Logaritminė paklaida	Pseudo klaidos (proc.)	Neaptikti defektai (proc.)
Testas „A“	96,4	0,1161	0,5	0,2	97,7	0,0802	0,4	0,1
Testas „B“	96,0	0,1419	0,1	0,5	98,0	0,0733	0,1	0,1
Testas „C1“	97,4	0,0991	0,2	0	97,6	0,0959	0,4	0
Testas „C2“	95,6	0,1930	0,8	0,4	97,5	0,0773	0,8	0

Šiuo atveju hierarchinis modelis geba aptikti nuo 96 iki 96,4 proc. („A“ ir „B“ testas) defektų, t. y. iš 1 000 bandymų praleistas tik 1 blogas komponentas, o atliktų „C1“ ir „C2“ testų rezultatai tokie, kad nepraleistas nei vienas blogas komponentas.

Šis tyrimas [7] svarbus tuo, kad parodo AOI sistemos kokybės vertinimo logiką: pirmiausia nustatomas komponento buvimas, vėliau vertinama jo padėtis, kiekis ir litavimo kokybė. Šiame darbe tokia hierarchinė kokybės klasifikacija netaikoma, nes tyrimas siaurinamas iki paviršinio montavimo komponentų aptikimo, jų klasės, koordinatų ir pasitikėjimo reikšmės nustatymo eksperimentiniame AOI stende.

Šaltinyje [8] nagrinėta AOI sistema, kuri nenaudojo etaloninių vaizdų ir veikė be vadinamųjų „auksinių“ šablonų. Tokia sistema yra lankstesnė, nes gali būti mažiau jautri aplinkos ir PCB vaizdo pokyčiams. Tyrime naudotas vienos pakopos CNN modelis, atliekantis komponentų klasifikavimą ir jų lokalizavimą. Eksperimentams naudota „NVIDIA GeForce GTX 1060“ vaizdo plokštė, „Anaconda Python“ aplinka, „Keras API“ ir „TensorFlow“ karkasas. Duomenų rinkinį sudarė 15000 sugeneruotų  $256 \times 256$  pikselių vaizdų.

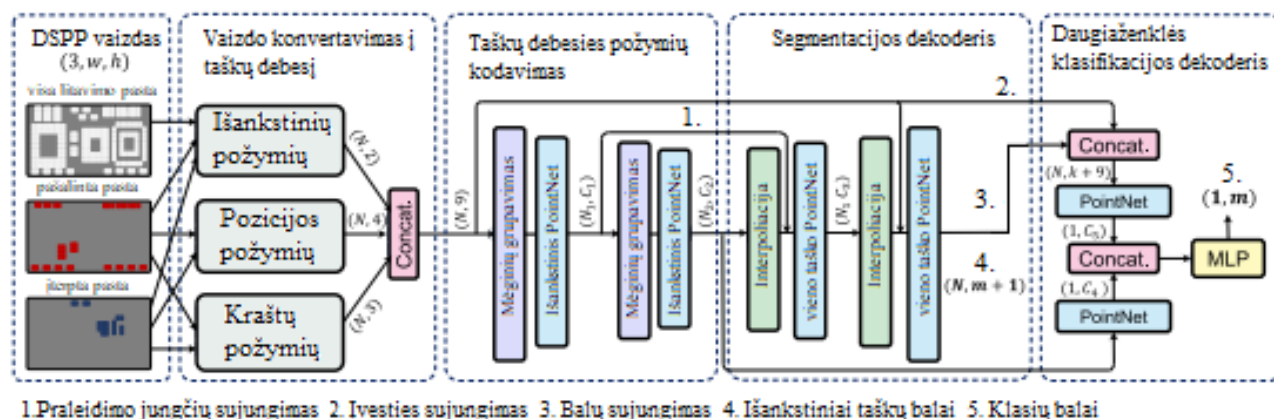
8 lentelė. Architektūrų įvertinimas [8]

Architektūra	mAP (proc.)		MAE (pikseliais)	
	Mokymas	Patvirtinimas	Mokymas	Patvirtinimas
Modifikuotas CNN	0,98	0,90	0,0038	0,0043
TL su papildomu parametru derinimu	0,99	0,89	0,0066	0,0101
TL be papildomo parametru derinimo	0,72	0,31	0,0136	0,0253

Gauti rezultatai [8] parodė, kad apsimokantys giliojo mokymosi algoritmai gali būti be šablonų pritaikyti veikiančioje AOI sistemoje. Matoma (žr. 8 lentele), kad mAP reikšmė viršija 90 proc., kai naudojamas individualiai kurtas modelis. Vidutinė lokalizavimo paklaida MAE (angl. *mean absolute error*) siekia  $\sim 1$  pikselį.

Dar viename tyrime [12] giliojo mokymosi metodai taikyti paviršinio montavimo technologijos SMT gamybos procesuose, konkrečiai litavimo pastos patikrai SPI. Autoriai [12] sukūrė dviejų lygių defektų aptikimo sistemą „D3PointNet“, kuri vienu metu atlieka defektų segmentaciją ir klasifikaciją.

Segmentacija leidžia nustatyti defekto vietą, o klasifikacija – priskirti defektą konkrečiam tipui. Tyrime analizuoti litavimo pastos defektai, tokie kaip pastos išsiliejimas, suvarvėjimas, pastos nebuvimas ir kiti neatitikimai, naudojant 3D taškų debesų duomenis, gautus iš SPI sistemų.



4 pav. „D3PointNet“ tinklas [12]

„D3PointNet“ sistemoje SPI vaizdai konvertuojami į 3D taškų debesį, iš kurio išskiriami kraštų ir struktūriniai požymiai. Modelio mokymui [12] naudota darbo stotis su „Intel Core i7-8700K“ procesoriumi, 64 GB RAM ir „NVIDIA GTX 2080Ti“ vaizdo plokšte. Duomenų kiekis buvo padidintas taikant pasukimą, mastelio keitimą ir taškų iškraipymą. Iš viso mokymui paruošta 33 600 vaizdų, o testavimui – 42 000 vaizdų.

Modelių palyginime naudoti keli vertinimo rodikliai ir defektų grupės: mAP – vidutinio tikslumo vertinimas (angl. *mean average precision*), SBD – litavimo sujungimų defektai (angl. *solder bridging defects*), SD – litavimo defektai (angl. *solder defects*), RA – registracijos tikslumas (angl. *registration accuracy*), SNK – litavimo susiaurėjimai (angl. *solder necking*), CD – komponentų defektai (angl. *component defects*).

9 lentelė. Pasiūlyto modelio ir CNN pagrįstų modelių klasifikacijos rezultatų palyginimas [12]


Modelis	SBD, proc.	SD, proc.	RA, proc.	SNK, proc.	CD, proc.	mAP, proc.
„ResNet50“ + SPP(3) + MLP	98,08	90,02	99,62	92,75	92,32	94,56
„ResNet50“ + SPPI(1,3) + MLP	98,98	88,27	99,64	91,38	94,35	94,52
„InceptionV4“ + SPP(3) + MLP	97,97	94,09	99,03	92,68	94,67	95,69
„InceptionV4“ + SPPI(1,3) + MLP	98,75	93,83	99,18	92,10	94,54	95,68
„MarsNet“	98,84	94,78	99,19	93,42	95,24	96,29
„D3PointNet“ (pilnas)	99,96	98,40	99,95	98,10	98,95	99,07

Kaip matyti iš (žr. 9 lentelę) „D3PointNet“ modelis pasiekė geriausią rezultatą tarp lygintų modelių – 99,07 proc. mAP. Palyginimui, „MarsNet“ pasiekė 96,29 proc., „InceptionV4“ pagrindu sudaryti

modeliai – apie 95,68–95,69 proc., o „ResNet50“ pagrindu sudaryti modeliai – apie 94,52–94,56 proc. Šis tyrimas rodo, kad 3D duomenimis ir giliuoju mokymusi pagrįsti modeliai gali tiksliai aptikti litavimo pastos defektus SPI patikroje.

Kitame tyrime [13] giluminio mokymosi modelis „MarsNet“ taikytas litavimo pastos patikrai SPI PCB gamybos linijose. Modelis skirtas daugiaženklei klasifikacijai, kai viename vaizde gali būti keli skirtingi defektų tipai. „MarsNet“ leidžia atpažinti litavimo pastos defektus skirtingos raiškos SPI vaizduose, nekeičiant jų dydžio, todėl modelis gali būti taikomas skirtingoms gamybinėms sąlygoms.

Tyrime [13] naudoti gamybos SPI duomenys. Buvo sudaryti devyni PCB duomenų rinkiniai, atspindintys skirtingų dydžių plokštes, o kiekvieną rinkinį sudarė 8400 SPI vaizdų. Modeliui apmokyti naudoti keturi duomenų rinkiniai, o likę penki skirti testavimui ir vertinimui. „MarsNet“ architektūroje naudotas modifikuotas išplėstinis liekamasis tinklas mDRN (angl. *modified dilated residual network*), horizontalusis-vertikalusis apjungimas HVP (angl. *horizontal-vertical pooling*), daugiaženklis vertinimo modulis ir automatinis slenksčio nustatymo modulis.



5 pav. „MarsNet“ tinklo struktūra [13]

10 lentelėje pateikiami „MarsNet“ ir lyginamojo CNN modelio rezultatai. Lentelėje SPI vaizdų skiriamoji geba parodo skirtingo dydžio įvesties vaizdus, o tikslumas nurodo defektų klasifikavimo rezultatą procentais.

10 lentelė. Klasifikacijos tikslumai atskiriems PCB SPI vaizdų duomenų rinkiniams [13]

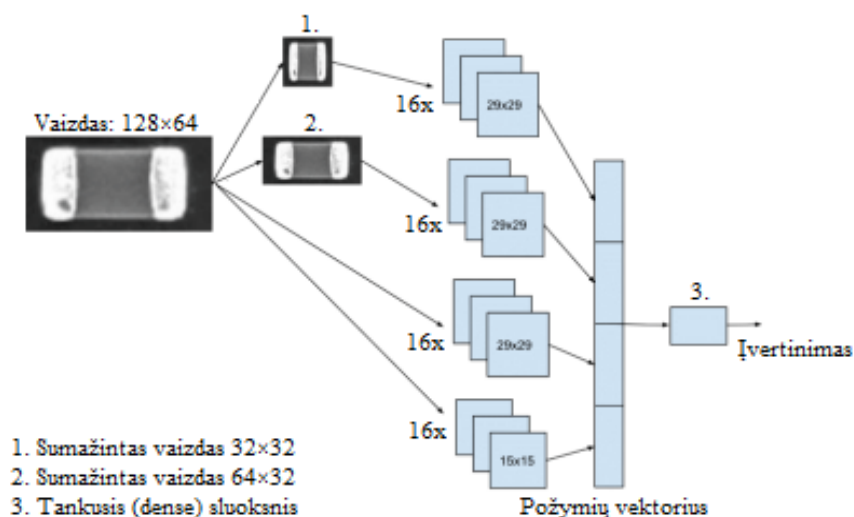
SPI skiriamosios gebos dydis	Tikslumas, proc.	
	Lyginamasis modelis	„MarsNet“
151 × 226	94,92	95,80
75 × 121	84,99	91,27
160 × 220	97,65	98,13
341 × 397	97,10	96,62
110 × 110	90,83	93,74

Kaip matyti iš 10 lentelės, „MarsNet“ daugumoje duomenų rinkinių pasiekė didesnę tikslumą nei lyginamasis CNN modelis. Geriausias rezultatas [13] pasiektas naudojant 160 × 220 pikselių SPI

vaizdus – 98,13 proc. tikslumas. Mažos raiškos  $75 \times 121$  pikselių vaizduose „MarsNet“ taip pat buvo pranašesnis: pasiekė 91,27 proc. tikslumą, kai lyginamasis modelis pasiekė 84,99 proc. Tai rodo, kad mDRN ir HVP struktūros pagerina erdvinės informacijos apjungimą ir leidžia stabiliau klasifikuoti defektus skirtingos raiškos vaizduose.

Šaltinyje [14] giluminio mokymosi metodas taikytas elektroninių komponentų litavimo paviršių korozijos pažeidimams aptikti gamybos proceso metu. Tyrime analizuoti komponentų vaizdai, gauti PNP paėmimo ir padėjimo įrenginiuose, o defektai nustatyti pagal šviesos atspindžio pokyčius nuo komponentų paviršiaus. Korozijos požymiai buvo siejami su paviršiaus šiurkštumu, spalvos ir atspindžio pokyčiais, kurie gali rodyti galimus litavimo ar kontaktų patikimumo sutrikimus.

Tyrime naudota „ASM Siplace SX“ paėmimo ir padėjimo sistema, „Cybord.ai“ dirbtinio intelekto algoritmas, taip pat papildomi tikrinimo metodai: SEM elektroninė mikroskopija, EDS energijos dispersinė spektroskopija ir pjūvio analizė. Šie metodai buvo naudojami DI modelio rezultatams patikrinti ir paviršiaus pažeidimų priežastims įvertinti [14].



6 pav. Modelyje naudota lygiagrečių filtrų architektūra [14]

Modelyje taikyta lygiagrečių konvoliucinių filtrų architektūra, kurioje skirtingo dydžio filtrai analizuoja įvairius paviršiaus pažeidimų požymius. Išskirti požymiai perduodami į tankųjį sluoksnį, kuriame atliekamas galutinis komponento paviršiaus būklės įvertinimas.

11 lentelė. Modelių veikimo rezultatai [14]

	CAP defektas 1	CAP defektas 2	CAP defektas 3	CAP defektas 4
Tikslumas (angl. <i>accuracy</i> )*, proc.	0,953	0,930	0,943	0,917
Tikslumas (angl. <i>precision</i> )*, proc.	0,945	0,945	0,945	0,867
„Atgavimo“ rodiklis, proc.	0,961	0,912	0,932	0,984
F1 balas, proc.	0,953	0,929	0,943	0,922

\* tikslumas (angl. *accuracy*) – parametras parodantis kiek bendrų prognozių buvo teisingos; tikslumas (angl. *precision*) – parametras parodantis kiek modelio „taip“ atsakymų buvo tikslūs.

Tyrimo [14] rezultatai parodė, kad DI modelis gali būti taikomas ankstyvam korozijos požymių aptikimui dar prieš litavimo procesą. Naudojant „NVIDIA Tesla T4 GPU“ vaizdo plokštę, pasiektas iki 3000 vaizdų per sekundę apdorojimo našumas, o sistema buvo pritaikyta daugiau kaip 3,5 mlrd. komponentų duomenų analizei. Bendras modelio tikslumas viršijo 99,5 proc.

Kitame moksliniame šaltinyje [9] nagrinėjama integruota AI-AOI sistema, skirta PCB metalizuotų kiaurymių PTH (angl. *plated through holes*) defektams aptikti. Sistema sujungia „YOLOv8“ objektų aptikimo algoritmą, „ResNet-50“ defektų klasifikavimui, „K-Means“ pusiau automatiniam duomenų žymėjimui ir „W-GAN“ duomenų rinkiniui išplėsti. Eksperimentuose naudoti pramoninės AOI sistemos vaizdai, fiksuoti „Smartek“ 500 W kamera, kurios raiška buvo  $2592 \times 1944$  pikseliai. Iš pradžių rankiniu būdu pažymėti 785 PTH pavyzdžiai, o vėliau naudojant „YOLO“ modelį sudarytas 5037 PTH vaizdų rinkinys.

**12 lentelė.** Palyginimas tarp „Xception“, „Inception“, „ResNet“, „YOLO“ ir AOI metodų [9]

Modelis	Teisingai aptikti defektai, proc.	Teisingai atpažinti normalūs objektai, proc.	Nepastebėtas defektas, proc.	Klaidingai aptiktas defektas, proc.	Tikslumas, proc.	F1 balas, proc.
„Xception“	96,85	98,62	3,15	1,38	97,74	97,71
„Inception v3“	97,49	98,24	2,51	1,76	97,87	97,86
„ResNet-50“	98,97	98,58	1,03	1,42	98,78	98,78
„YOLO“	50,89	85,80	49,56	14,70	68,36	61,74
AOI	80,23	99,96	19,74	0,04	90,11	89,03

Tyrimo [9] defektams klasifikuoti naudotas „ResNet-50“ modelis, kurio rezultatai lyginti su „Xception“, „Inception v3“, „YOLO“ ir tradicine AOI sistema (žr. 12 lentelė). Geriausius rezultatus pasiekė „ResNet-50“: teisingai aptiktų defektų rodiklis sudarė 98,97 proc., bendras tikslumas – 98,78 proc., o F1 balas – 98,78 proc. Taip pat nustatyta, kad tradicinė AOI sistema vieną PCB plokštę patikrina per maždaug 35 s, o siūloma AI-AOI sistema – per apie 3,5 s

Šaltinyje [15] giluminio mokymosi metodas taikytas litavimo ertmių aptikimui SSDC SiC vienpusio aušinimo moduluose, naudojamuose elektromobilių traukos inverteriuose. Tyrimo naudoti rentgeno „X-ray“ vaizdai, kurie buvo apkarpyti iki  $1750 \times 1250$  pikselių ir suskaidyti į  $256 \times 256$  pikselių fragmentus. Iš 101 rentgeno vaizdo sudaryti 3535 vaizdų fragmentai, o po duomenų papildymo mokymui naudota 2 651 000 vaizdų, testavimui – 884 000 vaizdų.

Tyrimo [15] analizuotas „U-Net“ CNN modelis su „ResNet34“ architektūra, skirtas semantiniam segmentavimui, t. y. vaizdo suskaidymui į klases pagal pikselių turinį. Naudotos dvejetainės kryžminės entropijos nuostolio funkcija (angl. *binary cross-entropy*) ir „Jaccard Loss“ funkcija. Modelio tikslumas vertintas naudojant persidengimo rodiklį IoU (angl. *intersection over union*). Duomenų anotavimas atliktas naudojant „Labkit“ papildinį (angl. *Labkit plugin*) vaizdo analizės platformoje „Fiji“ / „ImageJ“, skirtą interaktyviam vaizdų žymėjimui, anotacijoms ir segmentavimui. Litavimo ertmės (angl. *void*) buvo žymimos kaip binarinės kaukės, kai kiekvienas pikselis priskiriamas vienai iš dviejų klasių: ertmė arba fonas (angl. *background*).

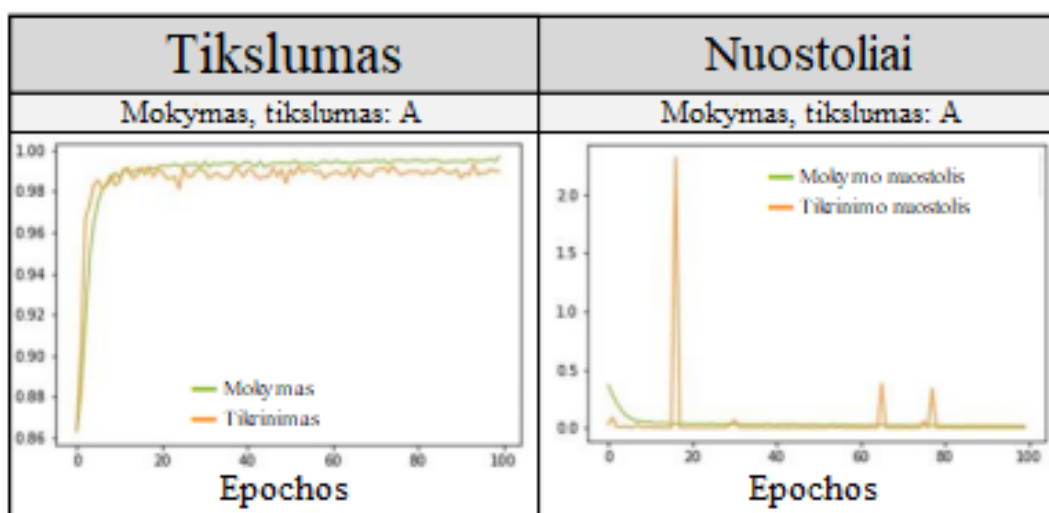
**13 lentelė.** IOU rodiklio priklausomybė vertinant epochas [15]

Epochos	IoU rodiklis	Laikas (sek. žingsnis)	Bendras laikas (val.)
200	64,00	115	6,39
400	69,96	118	13,11
600	72,35	120	20,00
800	75,83	125	27,78
1 000	78,31	128	35,56
1 500	81,91	128	53,33
2 000	84,09	128	71,11

Kaip matyti iš 13 lentelės, didinant mokymo epochų skaičių, IoU rodiklis didėjo nuo 64,00 proc. po 200 epochų iki 84,09 proc. po 2000 epochų. Modelis su 1000 epochų pasiekė 78,31 proc. IoU, o geriausias rezultatas [15] gautas po 2000 epochų – 84,09 proc. IoU. Tai rodo, kad „U-Net“ CNN modelis su „ResNet34“ architektūra gali pagerinti litavimo defektų aptikimą rentgeno vaizduose.

Dar viename tyrime [16] giluminio mokymosi metodai taikyti SMT litavimo jungčių kokybei tikrinti, naudojant rentgeno „X-ray“ vaizdus. Tyrime siekta sumažinti klaidingų aptikimų skaičių ir padidinti sistemos gebėjimą prisitaikyti prie naujų duomenų. Naudota „Omron VT-750 X-ray“ sistema ir CT kompiuterinė tomografija (angl. *computed tomography*), leidžianti sudaryti sluoksninius objekto vaizdus ir įvertinti litavimo jungčių vidinę struktūrą. Rentgeno vaizdų dydis buvo  $623 \times 483$  pikseliai, o vienam objektui sudaryti 65 sluoksniai, leidžiantys analizuoti defektus gylio kryptimi.

Duomenų rinkinį [16] sudarė 6387 vaizdai, iš kurių 70 proc. naudota modelio mokymui, 20 proc. – validacijai, o 10 proc. – testavimui. Duomenų papildymui naudotos rotacijos, reikšmingos srities ROI (angl. *region of interest*) poslinkiai ir triukšmo įterpimas. Tyrime taikyta modifikuota „Mask R-CNN“ architektūra, skirta objektų aptikimui, ir „ResNet-101“ tinklas, skirtas sudėtingiems rentgeno vaizdų požymiams išskirti. Modelio mokymui naudotas stochastinis gradientinis nusileidimas SGD (angl. *stochastic gradient descent*), kai mokymosi greitis  $\eta = 0,0001$ , ir kategorizuota kryžminė entropija (angl. *categorical cross-entropy*), skirta kelių klasių klasifikavimo užduočiai.



a)

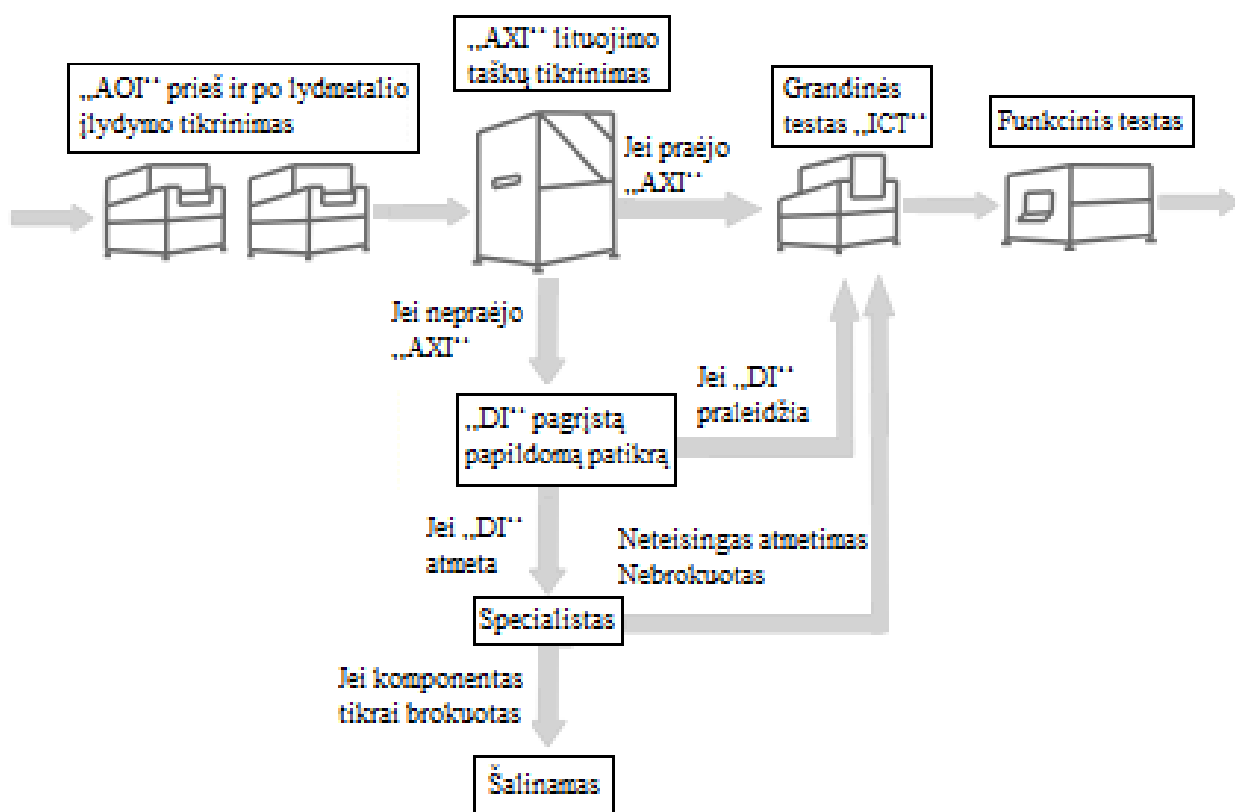
b)

**7 pav.** Modelio treniruotė „A“ [16]

Tyrimo [16] rezultatai parodė, kad CNN ir „Mask R-CNN“ pagrindu veikiantis modelis gali pagerinti litavimo jungčių defektų aptikimą rentgeno vaizduose. Viename iš mokymo variantų tikslumas po 4–5 epochų pakilo virš 98 proc., o mokymo ir validacijos tikslumo kreivės išliko panašios (žr. 7 pav.). Tai rodo, kad modelis mokėsi stabiliai ir nebuvo aiškių persimokymo požymių. Autoriai nurodo, kad toks sprendimas padeda sumažinti klaidingų signalų skaičių (angl. *false calls*) ir pagerinti BGA tipo komponentų (angl. *ball grid array*) litavimo jungčių patikros patikimumą.

Aurių [17] tyrime giluminio mokymosi metodai taikyti litavimo jungčių defektams aptikti automatizuotoje rentgeno patikroje AXI (angl. *automated X-ray inspection*). Tyrimo tikslas buvo sumažinti specialistų darbo krūvį, atsirandantį dėl rankinio litavimo jungčių defektų vertinimo, ir sumažinti klaidingų pranešimų skaičių (angl. *false calls*), kai geri litavimo taškai klaidingai pažymimi kaip defektiniai.

Tyrimo [17] naudota pramoninė 3D „X-ray“ AXI įranga, o duomenų rinkinį sudarė 518 292 litavimo jungčių pavyzdžiai iš realaus gamybos proceso. Analizuotos tos pačios litavimo jungties rentgeno vaizdų sekos, gautos skirtinguose gyliuose. Kad kintamo ilgio „X-ray“ pjūvių duomenys būtų tinkami neuroniniam tinklui, taikytas išankstinis kanalų lygio apdorojimas (angl. *channel-wise pre-processing*). Duomenų anotacijos buvo sudarytos specialistų, remiantis kontrolės peržiūromis.



8 pav. Aurių siūloma tikrinimo proceso procedūra naudojant dirbtinį intelektą [17]

Tyrimo [17] išbandyti du giluminio mokymosi modeliai: 3D CNN ir LSTM. 3D CNN modelis buvo skirtas apdoroti „X-ray“ sluoksnių sekas kaip trimačius vaizdo duomenis, leidžiančius vertinti litavimo jungties vidinę struktūrą. LSTM atminties modelis (angl. *long short-term memory*) buvo pritaikytas analizuoti skirtingo ilgio „X-ray“ sluoksnių sekas. Abu modeliai buvo mokomi atpažinti

litavimo defektus, tokius kaip trūkstamas litavimas, perteklinis litavimas, šaltas litavimas ir trumpieji jungimai (angl. *shorts*).

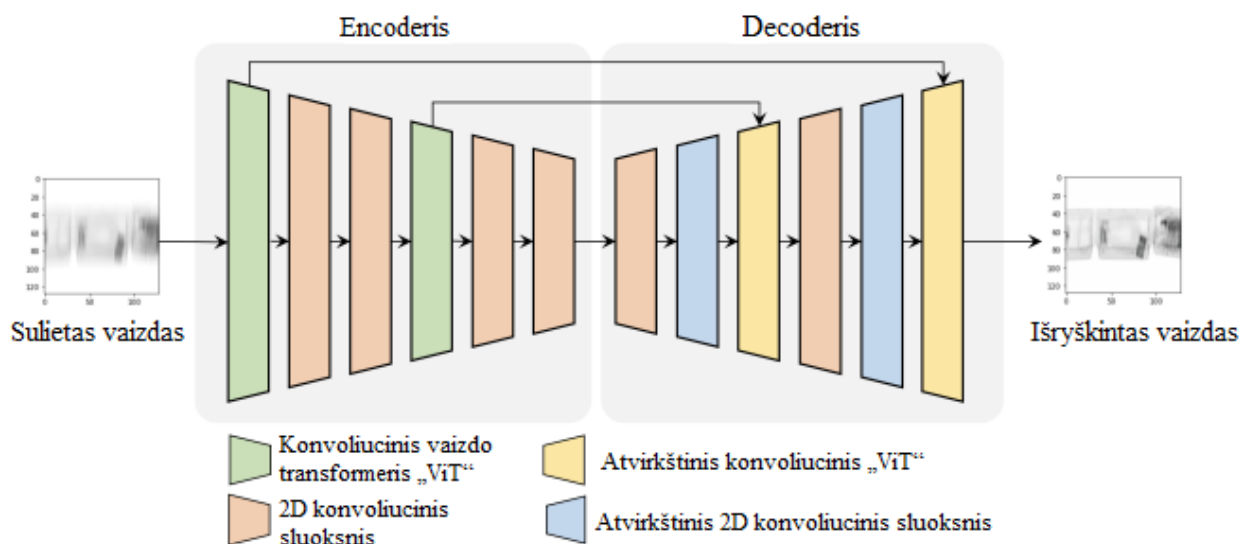
**14 lentelė.** Modelių veikimo palyginimas [17]

Modelis	AUROC*	FPR* prie 90 proc.	FPR prie 95 proc.
„3D CNN“	0,9005	0,3349	0,6040
„LSTM“	0,8916	0,3637	0,5872

\* čia AUROC (angl. *area under the ROC curve*) – tai plotas po ROC kreive, kuri vaizduoja klasifikatoriaus jautrumo (angl. *true positive rate*) ir klaidingai teigiamų atvejų dažnio (angl. *false positive rate*) santykį, keičiant klasifikavimo slenkstį. FPR (angl. *false positive rate*) – tai dalis neigiamų atvejų, kurie klaidingai klasifikuojami kaip teigiami.

Kaip matyti iš 14 lentelės, 3D CNN modelis pasiekė 0,9005 AUROC rodiklį, o LSTM modelis – 0,8916. Esant 90 proc. jautrumui, 3D CNN klaidingai teigiamų atvejų dažnis FPR (angl. *false positive rate*) buvo 0,3349, o LSTM – 0,3637. Tai rodo, kad 3D CNN šiame tyrime [17] veikė šiek tiek geriau nei LSTM. Autoriai nurodo, kad pritaikius giluminio mokymosi modelius dalis PCB plokščių galėjo būti perduota galutiniam testavimui, o kontrolės skyriaus darbo krūvis sumažintas iki 66,51 proc.

Mokslininkai [18] sukūrė ir išbandė automatinį „X-ray“ vaizdų išryškinimo modelį, skirtą neryškių rentgeno vaizdų kokybei pagerinti prieš defektų analizę. Tyrime naudotas konvoliucinis vaizdų transformatorius CvT (angl. *convolutional vision transformer*), kuris sujungia konvoliucinių neuroninių tinklų CNN savybes ir vaizdų transformatorių ViT (angl. *vision transformer*) gebėjimą analizuoti platesnį vaizdo kontekstą. Nors tyrimas orientuotas į vėjo turbinų vidinės struktūros analizę, metodas gali būti taikomas ir elektronikos testavimo srityje, kai reikia pagerinti rentgeno vaizdų kokybę prieš litavimo defektų vertinimą.



**9 pav.** Autoenkoderio architektūra [18]

Tyrime [18] naudotas viešas „X-ray“ vaizdų rinkinys, iš kurio sintetiniu būdu sugeneruoti sulieti vaizdai. Modelio autoenkoderio (angl. *autoencoder*) architektūra sudaryta iš kodavimo dalies (angl. *encoder*), dekodavimo dalies (angl. *decoder*) ir šuolio jungčių (angl. *skip connections*), kurios padeda išlaikyti smulkias vaizdo detales atkūrimo metu. Kodavimo dalyje naudoti CNN ir ViT blokai, o

dekodavimo dalyje – transponuoti CNN ir ViT sluoksniai, skirti sulietam vaizdui atkurti į išryškintą formą.

**15 lentelė.** Suliejimo šalinimo modelio veikimo rezultatai [18]

Filtravimo sąlygos, proc.		SSIM reikšmė, proc.		Atpažinimo padidėjimas, proc.		Atvejų kiekis, vnt.
Maža	Didelė	Sulietas vaizdas	Išryškintas vaizdas	Absoliutus	Santykinis	
0,97	1,0	0,994	0,982	-0,01	-1,26	193
0,94	0,97	0,952	0,964	0,013	1,338	115
0,91	0,94	0,924	0,955	0,031	3,363	144
0,88	0,91	0,896	0,948	0,052	5,804	136
0,85	0,88	0,867	0,938	0,070	8,118	127
0,82	0,85	0,835	0,924	0,089	10,652	87
0,79	0,82	0,805	0,911	0,106	13,121	76
0,76	0,79	0,775	0,904	0,129	16,586	63
0,73	0,76	0,746	0,895	0,148	19,882	33
0,70	0,73	0,716	0,885	0,169	23,631	14
0,67	0,70	0,687	0,876	0,189	27,559	9
0,64	0,67	0,663	0,842	0,179	27,009	3

Modelio veikimas vertintas naudojant struktūrinio panašumo rodiklį SSIM (angl. *structural similarity index*), kuris leidžia įvertinti dviejų vaizdų panašumą pagal ryškumą, kontrastą ir tekstūrą. Kaip matyti iš 15 lentelės, modelis pasiekė vidutinį 5,93 proc. SSIM pagerėjimą, o stipriai sulietuose vaizduose pagerėjimas siekė iki 27 proc. Tai rodo, kad CvT pagrindu sukurtas autoenkoderis gali pagerinti rentgeno vaizdų kokybę, kai pradiniai vaizdai yra stipriai sulieti.

Analizuotame tyrime [19] pristatytas bekontaktis PCBA defektų aptikimo metodas, pagrįstas giluminio mokymosi DL (angl. *deep learning*) algoritmais ir termovizinių, t. y. infraraudonųjų spindulių, vaizdų analize. Šis metodas buvo siūlomas kaip alternatyva kontaktiniam grandinės vidiniam testavimui ICT (angl. *in-circuit test*). Tyrime infraraudonųjų spindulių vaizdams fiksuoti naudota „FLIR T420“ termovizinė kamera, kuria vertinti temperatūriniai pokyčiai PCBA plokštėse. Defektas buvo imituojamas pakeičiant rezistorių iš 40 kΩ į 20 kΩ, taip sukeliant pakitusį šilumos pasiskirstymą.

Tyrime [19] taikyti keli giluminio mokymosi metodai. CNN konvoliucinis neuroninis tinklas (angl. *convolutional neural network*) naudotas termoviziniams vaizdams klasifikuoti į dvi klases: „gera“ ir „defektuota“ plokštė. „YOLOv5“ algoritmas (angl. *you only look once*) naudotas defektams vaizde aptikti ir lokalizuoti, aplink įtartinas zonas sudarant apibrėžimo dėžutes (angl. *bounding boxes*). Taip pat naudotas autoenkoderis AE (angl. *autoencoder*), kuris buvo mokomas atkurti normalius vaizdus. Jei atkūrimo paklaida padidėdavo, tokia sritis buvo laikoma galimu defektu. Vaizdų panašumui įvertinti naudotas struktūrinio panašumo indeksas SSIM (angl. *structural similarity index measure*).

Modelio mokymui naudotas autorių [19] sudarytas termovizinių vaizdų rinkinys: 840 vaizdų skirta mokymui, o 360 – testavimui. Duomenų papildymui taikytas vaizdų sukimas, apvertimas ir suliejimo įterpimas. Klasifikavimui naudota dvejetainė kryžminė entropija (angl. *binary cross-entropy*), nes vaizdai buvo skirstomi į dvi klases – gerus ir defektuotus atvejus.

**16 lentelė.** Modelio veikimo rezultatai esant šilumos pokyčiams ir skirtingiems kampiniams duomenims [19]

<b>Šildymas</b>				
Laikas, sek.	10	20	30	40
Tikslumas, proc.	45,0	70,5	96,6	99,2
Apdorojimo laikas, ms	7			
<b>Kampų matavimas</b>				
Kampas, laipsniai	Fiksuotas	+5	+10	+5, +10
Tikslumas, proc.	96,6	95,7	94,0	94,2
Apdorojimo laikas, ms	7			

Kaip matyti iš 16 lentelės, didinant PCBA šildymo laiką nuo 10 s iki 40 s, klasifikavimo tikslumas padidėjo nuo 45,0 proc. iki 99,2 proc. Geriausias rezultatas pasiektas po 40 s šildymo, o duomenų apdorojimo laikas siekė 7 ms. Keičiant kameros stebėjimo kampą, tikslumas išliko aukštas – nuo 94,0 proc. iki 96,6 proc. Autoriai taip pat nurodo, kad „YOLOv5“ modelio aptikimo tikslumas  $mAP@0,5$  siekė 96,1 proc., o aptikimo laikas buvo apie 20 ms vienam vaizdai. Autoenkoderis normalius vaizdus atkūrė su  $SSIM \geq 0,97$ , o defektinių vaizdų  $SSIM$  reikšmė sumažėjo iki  $< 0,90$ , todėl rekonstrukcijos skirtumas galėjo būti naudojamas defektams identifikuoti.

Apibendrinant galima teigti, kad klasikiniai ML ir giliojo mokymosi metodai PCB bei PCBA kokybės kontrolėje gali pasiekti aukštus tikslumo rezultatus, tačiau jų taikymas dažnai priklauso nuo konkrečios užduoties, duomenų tipo ir naudojamos testavimo įrangos. Klasikiniai ML metodai, tokie kaip SVM, MLP, RPCA ar „Random Forest“, gali būti naudingi defektams klasifikuoti, tačiau dažnai reikalauja rankinio požymių parinkimo, etaloninių vaizdų arba iš anksto apibrėžtų defektų požymių [1]. Giliojo mokymosi metodai šiuos ribojimus sumažina, nes CNN, „ResNet“, „U-Net“, „Mask R-CNN“, „3D CNN“, LSTM, autoenkoderiai ir modeliai geba automatiškai išmokti vaizdo požymius [2, 7, 8, 12, 13, 14, 9, 15, 16, 17, 18, 19].

Vis dėlto nagrinėti giliojo mokymosi sprendimai dažnai yra pritaikyti siauresnėms kokybės kontrolės užduotims: litavimo taškų kokybės vertinimui [7], litavimo pastos SPI patikrai [12, 13], komponentų paviršiaus korozijos požymiams [14], PTH defektų klasifikavimui [9], AXI / „X-ray“ litavimo jungčių ar ertmių analizei [15, 16, 17], rentgeno vaizdų kokybės gerinimui [18] arba termoviziniams PCBA defektams aptikti [19]. Šie metodai yra naudingi kaip elektronikos kokybės kontrolės kontekstas, tačiau ne visi tiesiogiai tinka šiame darbe kuriamam kameromis pagrįstam AOI stendui, kuriame tiriamas paviršinio montavimo komponentų aptikimas įprastuose PCB vaizduose.

Dėl šios priežasties šiame darbe pasirenkama ne klasikinė ML kryptis ir ne siaurai vienai defektų grupei pritaikytas DL metodas, o „YOLO“ tipo objektų aptikimas. „YOLO“ modeliai leidžia vieno apdorojimo metu nustatyti komponento klasę, koordinates ir pasitikėjimo reikšmę, todėl jie geriau atitinka eksperimentinio AOI stendo tikslą – aptikti paviršinio montavimo komponentus kameromis užfiksuotuose PCB vaizduose. Toks pasirinkimas leidžia vertinti ne tik komponentų atpažinimo tikslumą, bet ir lokalizavimo stabilumą, apdorojimo spartą bei modelių veikimą realiomis optinės kontrolės sąlygomis.

### 1.5. „YOLO“ šeimos modeliai PCB komponentų ir defektų aptikimui

„YOLO“ šeimos objektų aptikimo modeliai pastaraisiais metais plačiai taikomi PCB komponentų ir defektų aptikimui automatinės optinės patikros AOI sistemose. Šie modeliai leidžia vieno vaizdo

apdoravimo metu nustatyti objekto klasę, koordinates ir aptikimo pasitikėjimo reikšmę, todėl yra tinkami realaus laiko elektronikos kokybės kontrolės užduotims. Šiame poskyryje analizuojami skirtingi „YOLO“ šeimos modeliai ir jų patobulinimai, taikyti PCB defektams, smulkiems komponentams ir tankiai išdėstytiems objektams aptikti. Kadangi šiame darbe eksperimentinėje AOI sistemoje tiriami „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“ modeliai, šis poskyris sudaro pagrindinį literatūrinį pagrindimą pasirinktai objektų aptikimo kryptiai.

Kadangi analizuotuose „YOLO“ šeimos tyrimuose naudoti skirtingi duomenų rinkiniai, nevienodos PCB defektų ar komponentų klasės, skirtingos vaizdų raiškos, eksperimentinė įranga ir vertinimo metrikos, literatūros šaltinių rezultatai šiame darbe nėra naudojami tiesioginiam kiekybiniam palyginimui pagal mAP, tikslumą ar FPS. Jie vertinami kaip metodinis pagrindimas, parodantis, kad „YOLO“ šeimos modeliai yra tinkami PCB komponentų arba defektų lokalizavimui automatinės optinės patikros sistemose.


Šaltinyje [20] nagrinėtas modifikuotas „YOLOv8“ pagrindu sukurtas giluminio mokymosi modelis, skirtas tankiai išdėstytiems PCB komponentams aptikti ir lokalizuoti. Tyrimo tikslas buvo padidinti komponentų aptikimo tikslumą ir sumažinti modelio skaičiavimo apkrovą, kad algoritmas galėtų būti taikomas automatizuotose PCB gamybos ir optinės patikros sistemose realiuoju laiku. Eksperimentuose naudota „NVIDIA RTX A4000“ vaizdo plokštė, pramoninė kamera ir „Jetson AGX Xavier“ įterptinis kompiuteris. Modeliui apmokyti naudotas 11 330 vaizdų duomenų rinkinys, kurio vaizdų dydis buvo  $640 \times 640$  pikselių.

Autoriai [20] bazinę „YOLOv8“ architektūrą modifikavo keliais būdais. Pirmiausia buvo įdiegtas „C2Focal“ modulis, skirtas smulkioms vietinėms vaizdo savybėms, komponentų struktūrai ir jų išsidėstymui tiksliau išskirti. Taip pat naudotos „Ghost“ konvoliucijos, kurios sumažina skaičiavimo operacijų kiekį, išlaikant pakankamą aptikimo tikslumą. Komponentų lokalizavimo tikslumui pagerinti taikyta „Sig-IoU“ nuostolio funkcija, optimizuojanti objektus ribojančių stačiakampių, t. y. apibrėžimo dėžučių (angl. *bounding boxes*), padėtį. Šių dėžučių tikslumas vertintas pagal sankirtos su sąjunga rodiklį IoU (angl. *intersection over union*). Modelio mokymo patikimumui padidinti taip pat naudotas duomenų papildymas, įtraukiant padėties, atspindžių ir triukšmo pokyčius.

**17 lentelė.** Rezultatų tarp modelių palyginimas [20]

Modelis	Parametrai (M)*	mAP0.5 (%)*	mAP0.5:0.95 (%)*	FPS
„Faster RCNN“	41,15	64,90	49,71	12
„YOLOv5-Small“	7,10	78,6	63,7	104
„YOLOv7-Tiny“	6,02	52,7	38,1	130
„YOLOv8-Nano“	3,20	85,8	73,9	113
Analizuotas modelis	2,60	87,7	75,3	110

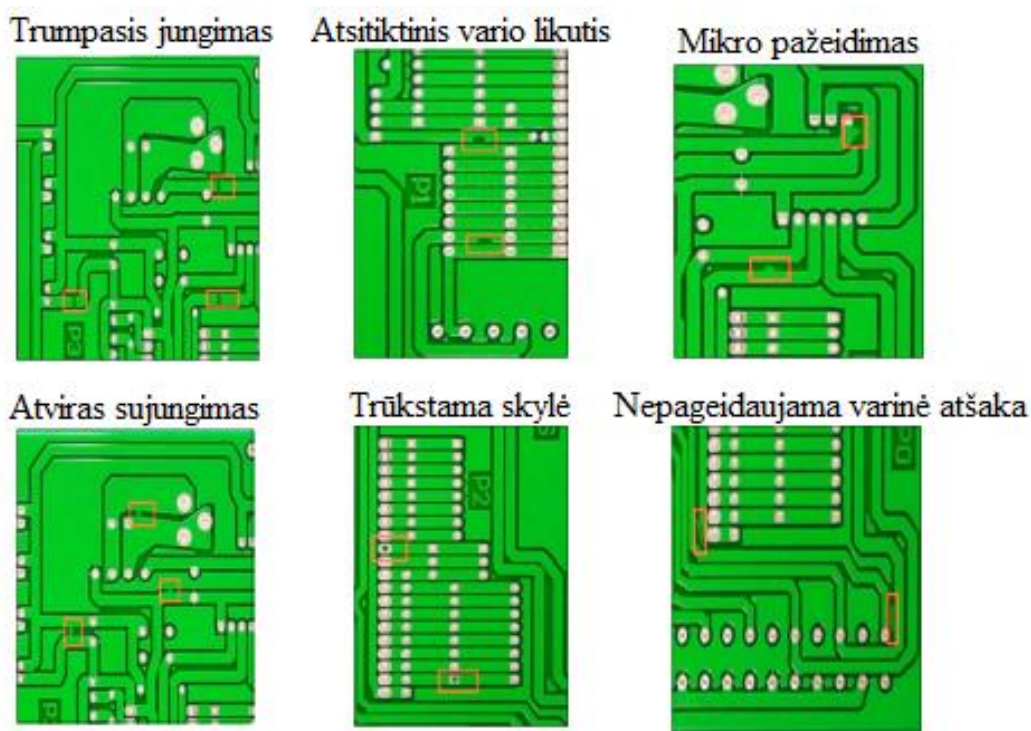
Kaip matyti iš 17 lentelės, analizuotas modelis pasiekė geriausią tikslumo ir skaičiavimo efektyvumo santykį tarp lygintų modelių. Jo mAP0,5 rodiklis siekė 87,7 proc., o mAP0,5:0,95 – 75,3 proc. Modelis turėjo tik 2,60 mln. parametrų ir pasiekė 110 kadru per sekundę spartą. Palyginimui, „YOLOv8-Nano“ pasiekė 85,8 proc. mAP0,5 ir 73,9 proc. mAP0,5:0,95, tačiau turėjo daugiau parametrų – 3,20 mln. „Faster R-CNN“ modelis turėjo 41,15 mln. parametrų ir veikė tik 12 kadru per sekundę sparta, todėl buvo mažiau tinkamas realaus laiko PCB patikrai.



**10 pav.** Aptikimo rezultatai: a) analizuotas modelis; b) „YOLOv8-Nano“ modelis [20]

Aptikimo rezultatų palyginimas [20] parodė, kad modifikuotas modelis tiksliau lokalizavo PCB komponentus nei bazinis „YOLOv8-Nano“ modelis. „YOLOv8-Nano“ atveju buvo nustatyti klaidingi aptikimai: nereikalinga aptikimo žymė, fono srities atpažinimas kaip jungties ir neatpažinta baterija. Tai rodo, kad smulkių ir tankiai išdėstytų komponentų aptikimui vien bazinė „YOLO“ architektūra gali būti nepakankama, todėl architektūriniai patobulinimai, tokie kaip „C2Focal“, „Ghost“ konvoliucijos ir „Sig-IoU“ nuostolio funkcija, gali pagerinti aptikimo stabilumą.

Dar viename tyrime [21] nagrinėtas „YOLOv7“ architektūra pagrįstas giluminio mokymosi modelis, skirtas PCB plokščių defektams aptikti ir kokybės kontrolei automatizuoti. Tyrime naudotas viešai prieinamas Pekino universiteto „Human-Robot Interaction“ laboratorijos duomenų rinkinys, sudarytas iš 1386 PCB vaizdų su anotuotomis defektų sritimis. Duomenų rinkinyje buvo pažymėti šeši pagrindiniai PCB defektų tipai: trūkstama skylė, pelės įkandimas, atvira grandinė, trumpasis jungimas, atšaka ir pašalinis varis.



11 pav. Šeši pagrindiniai PCB plokščių defektų tipai [21]

Siekiant padidinti modelio atsparumą vaizdo pokyčiams, tyrime [21] taikytas duomenų papildymas naudojant „Roboflow“ įrankį. Vaizdams buvo taikomas pasukimas, mastelio keitimas ir apšvietimo sąlygų keitimas. Duomenų anotavimas atliktas naudojant „LabelImg“ programinę įrangą, o objektai žymėti apibrėžimo dėžutėmis (angl. *bounding boxes*). Vėliau anotacijos buvo konvertuotos į „YOLO“ formato tekstinius failus. Modelyje naudota devynių inkaro dėžučių sistema (angl. *anchor boxes*), leidžianti aptikti skirtingo dydžio defektus, o mažų ir sunkiau aptinkamų defektų svarbai padidinti taikyta fokusavimo nuostolio funkcija (angl. *focal loss*).

Modeliui mokytį naudoti 554 vaizdai, kurių skiriamoji geba buvo  $608 \times 608$  pikselių, o likę 832 vaizdai skirti validacijos ir testavimo procesams. Modelis treniruotas 200 epochų, naudojant „Google Colaboratory“ aplinką. Gauti rezultatai [21] parodė, kad „YOLOv7“ pasiekė 98,2 proc. tikslumą, 97,4 proc. atgavimo rodiklį ir 98,0 proc. mAP reikšmę. Palyginimui, „YOLOv5“ modelio tikslumas siekė 97,7 proc., atgavimo rodiklis – 96,6 proc., o mAP – 97,8 proc.

18 lentelė. Skirtingų modelių generuojamų rezultatų palyginimas [21]

Modelio tipas	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.	mAP, proc.
„YOLOv5“	97,7	96,6	97,8
„YOLOv7“	98,2	97,4	98,0

Kaip matyti iš 18 lentelės, „YOLOv7“ rezultatai buvo šiek tiek geresni už „YOLOv5“: tikslumas padidėjo 0,5 proc., atgavimo rodiklis – 0,8 proc., o mAP – 0,2 proc. Nors skirtumai nėra dideli, tyrimas rodo, kad YOLO šeimos modeliai yra tinkami PCB defektų aptikimo užduotims, nes leidžia lokalizuoti defektus vaizde ir išlaikyti aukštą aptikimo tikslumą.

Kitame moksliniame šaltinyje [22] pristatytas patobulintas PCB defektų aptikimo metodas „YOLO-HB“, sukurtas „YOLOv8“ architektūros pagrindu. Tyrimo tikslas buvo padidinti smulkių ir tankiai išsidėsčiusių PCB paviršiaus defektų aptikimo tikslumą, kartu išlaikant modelio efektyvumą

automatinės optinės patikros sistemose. Į bazinį „YOLOv8“ tinklą integruotas hibridinis dėmesio transformatorius HAT (angl. *hybrid attention transformer*), skirtas svarbiausiems vaizdo požymiams išryškinti, ir dvipusis požymių piramidės tinklas BiFPN (angl. *bidirectional feature pyramid network*), leidžiantis sujungti skirtingų mastelių požymius. Toks sprendimas padeda tiksliau aptikti mažus ir skirtingo dydžio PCB defektus.

Eksperimentams [22] naudoti du vieši PCB defektų duomenų rinkiniai – „PCB\_DATASET“ ir „DeepPCB“. Modelis mokytas naudojant  $640 \times 640$  pikselių vaizdus, SGD optimizatorių ir 300 epochų mokymo procesą. Tyrimui naudotas kompiuteris su „Intel Core i9-13900K“ 3,00 GHz procesoriumi, „RTX 3090Ti“ vaizdo plokšte ir 32 GB RAM, o modelis realizuotas „PyTorch“ aplinkoje.

**19 lentelė.** Palyginimas su baziniu modeliu naudojant „PCB\_dataset“ ir „DeepPCB“ duomenų rinkinius [22]

Modelis	Duomenų rinkiniai	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.	mAP, proc.	mAP 50:95, proc.	GFLOPs
„YOLOv8“	„PCB_DATASET“	91,6	84,2	88,1	42,4	8,1
„YOLO-HB“		93,5	84,5	89,5	44,7	7,0
„YOLOv8“	„DeepPCB“	94,8	93,8	97,9	67,1	8,1
„YOLO-HB“		97,2	95,7	98,4	72,4	7,0

\* čia GFLOPs (angl. *giga floating point operations*) – milijardai slankaus kablelio operacijų. Tai rodiklis, parodantis kiek milijardų matematinių skaičiavimo operacijų modelis turi atlikti apdorodamas vieną duomenų įvestį, pavyzdžiui, vieną vaizdą.

Kaip matyti iš 19 lentelės, „YOLO-HB“ modelis abiejuose duomenų rinkiniuose pasiekė geresnius rezultatus nei bazinis „YOLOv8“ modelis. Naudojant „PCB\_DATASET“, mAP rodiklis padidėjo nuo 88,1 proc. iki 89,5 proc., o mAP50:95 – nuo 42,4 proc. iki 44,7 proc. Naudojant „DeepPCB“, mAP rodiklis padidėjo nuo 97,9 proc. iki 98,4 proc., o mAP50:95 – nuo 67,1 proc. iki 72,4 proc. Svarbu ir tai, kad skaičiavimo apkrova sumažėjo nuo 8,1 iki 7,0 GFLOPs. GFLOPs (angl. *giga floating point operations*) nurodo, kiek milijardų slankiojo kablelio operacijų modelis turi atlikti apdorodamas vieną įvestį.

Kitame moksliniame šaltinyje [23] pristatytas patobulintas PCB defektų aptikimo metodas, paremtas „YOLOv8n“ architektūra. Tyrimo tikslas buvo padidinti smulkių PCB defektų aptikimo tikslumą ir kartu sumažinti modelio skaičiavimo sudėtingumą, kad algoritmas galėtų būti taikomas ribotų išteklių įrenginiuose arba įterptinėse sistemose. Autoriai pažymi, kad dauguma PCB defektų yra labai maži, dažnai mažesni nei  $32 \times 32$  pikseliai, todėl standartiniams objektų aptikimo modeliams juos patikimai identifikuoti yra sudėtinga [23].

Tyrėjų [23] siūlomas metodas remiasi „YOLOv8n“ modelio modifikavimu, integruojant kelis architektūrinius patobulinimus. Į bazinį „YOLOv8“ C2f bloką, t. y. spartesnę dalinio tarpstadijinio apdorojimo su dviem konvoliucijomis bloką (angl. *cross stage partial with two convolutions-faster*, C2f), įterptas erdvinės ir kanalų rekonstrukcijos konvoliucijos modulis SCConv (angl. *spatial-channel reconstruction convolution*). Šis modulis sumažina konvoliucinių operacijų kiekį ir pagerina PCB paviršiaus defektų požymių išgavimą. Taip pat naudotas adaptacinės požymių atrankos modulis, padidinantis tinklo gebėjimą aptikti smulkius defektus skirtinguose masteliuose. Standartinis atskirtasis aptikimo sluoksnis (angl. *decoupled head*) pakeistas bendros lengvos konvoliucijos

aptikimo moduliu SLCD (angl. *shared lightweight convolutional detection*), kuris sumažina modelio skaičiavimo sudėtingumą. Papildomai įdiegta svertinė sankirtos su sąjunga nuostolio funkcija WIoU (angl. *weighted intersection over union*), skirta tiksliau optimizuoti ribojančių stačiakampių, t. y. apibrėžimo dėžučių, lokalizaciją.

**20 lentelė.** Algoritmų palyginimas kiekvienoje kategorijoje [23]

Modelis	Tikslumas, proc.	mAP, proc.	Modelio dydis $\times 10^6$	FLOPS $\times 10^9$	Kadrai per sek.
„YOLOv5s“	97,1	95,1	13,7	15,8	110,1
„YOLOv7-Tiny“	93,4	95,3	6,03	10,2	82,5
„YOLOv8n“	97,7	94,8	5,96	8,2	124,8
Siūlomas modelis	99,8	98,6	4,1	5,9	144,1

\* čia FLOPS  $\times 10^9$  – tai rodiklis, parodantis kiek milijardų slankiojo kablelio skaičiavimo operacijų (angl. *floating-point operations*) reikia atlikti modeliui apdorojant duomenis.

Kaip matyti iš 20 lentelės, siūlomas modelis [23] pasiekė geriausias rezultatus tarp lygintų „YOLOv5s“, „YOLOv7-Tiny“ ir „YOLOv8n“ modelių. Jo bendras tikslumas siekė 99,8 proc., o mAP reikšmė – 98,6 proc. Modelis taip pat pasižymėjo mažesniu dydžiu – 4,1 mln. parametru, mažesne skaičiavimo apkrova –  $5,9 \times 10^9$  FLOPS ir didžiausia apdoravimo sparta – 144,1 kadro per sekundę. FLOPS (angl. *floating-point operations*) nurodo, kiek slankiojo kablelio skaičiavimo operacijų reikia atlikti modeliui apdorojant duomenis.

AOI sistemose objektų aptikimui vis dažniau naudojami „YOLO“ šeimos modeliai. Šaltinyje [11] pristatytas „FC-YOLO“ metodas, skirtas PCB komponentų aptikimui automatinės optinės patikros sistemose. Tyrime nagrinėjama problema, kad tradiciniai objektų aptikimo modeliai dažnai pasižymi didesniu klaidingų aptikimų skaičiumi ir mažesniu tikslumu aptinkant labai smulkius bei tankiai išdėstytus komponentus. Todėl pasiūlyta modifikuota „YOLOv11“ pagrindu sukurta architektūra, kuri naudoja dvi analizės kryptis: koordinatinę vaizdo informaciją ir dažnių srities požymius.

**21 lentelė.** Komponentų aptikimo palyginimas naudojant PCBWACV duomenų rinkinį [11]

Modelis	Parametrai, mln.	mAP50, proc.	mAP50-95, proc.	mAPs*, proc.	mAPm*, proc.	mAPI*, proc.	Kadrai per sek.
„YOLOv12n“	2,54	85,2	76,2	78,7	86,8	90,1	199
„RT-DETR“	25,13	86,0	74,5	77,5	88,0	88,5	140
„RF-DETR“	30,52	87,5	73,8	79,1	90,5	88,0	135
„INO-DETR“	45,03	88,0	76,0	80,0	91,0	90,5	100
„FC-YOLO“	2,56	88,7	76,5	82,4	89,4	94,3	201

\* čia mAPs – vidutinis tikslumas mažiems objektams; mAPm – vidutinis tikslumas vidutinio dydžio objektams; mAPI – vidutinis tikslumas didelio dydžio objektams.

Naudojant „PCBWACV“ duomenų rinkinį (žr. 21 lentelę), „FC-YOLO“ modelis pasiekė geriausias bendrus rezultatus tarp lygintų modelių. Jo mAP50 rodiklis siekė 88,7 proc., mAP50-95 – 76,5 proc., o apdoravimo sparta – 201 kadras per sekundę. Lyginant su „YOLOv12n“, „FC-YOLO“ pasiekė 3,5 proc. didesnę mAP50 rodiklį ir 2 kadrais per sekundę didesnę spartą. Taip pat šis modelis turėjo tik 2,56 mln. parametru, todėl išlaikė mažą skaičiavimo apkrovą. Tai rodo, kad „FC-YOLO“ efektyviai suderina aptikimo tikslumą ir spartą.

Eksperimentiniai tyrimai [11] taip pat atlikti naudojant autorių sudarytą „EAPCB“ duomenų rinkinį, kurį sudarė 160 aukštos raiškos PCB vaizdų, gautų eksperimentinėje AOI sistemoje. Šis rinkinys svarbus tuo, kad labiau atspindi realias PCB komponentų aptikimo sąlygas.

**22 lentelė.** Komponentų aptikimo palyginimas naudojant EAPCB duomenų rinkinį [11]

Modelis	Parametrai, mln.	mAP50 proc.	mAP50-95 proc.	mAPs*, proc.	mAPm*, proc.	mAPI*, proc.	Kadrai per sek.
YOLOv12n	2,53	86,7	66,7	82,3	85,2	91,6	205
RT-DETR	24,52	87,2	67,5	81,2	86,6	91,9	145
RF-DETR	29,91	86,8	68,2	80,8	84,5	91,8	130
INO-DETR	42,87	88,6	69,3	82,7	87,3	92,3	108
FC-YOLO	2,52	89,2	69,9	87,1	87,9	93,5	206

Naudojant „EAPCB“ duomenų rinkinį (žr. 22 lentelę), „FC-YOLO“ taip pat pasiekė geriausius rezultatus. Modelio mAP50 rodiklis siekė 89,2 proc., mAP50-95 – 69,9 proc., o apdorojimo sparta – 206 kadrai per sekundę. Lyginant su „YOLOv12n“, „FC-YOLO“ mAP50 rodiklis buvo 2,5 proc. didesnis, o mAP50-95 – 3,2 proc. didesnis. Be to, „FC-YOLO“ buvo greitesnis už „RT-DETR“, „RF-DETR“ ir „INO-DETR“ modelius, kurių sparta atitinkamai siekė 145, 130 ir 108 kadrus per sekundę. Gauti rezultatai rodo, kad „FC-YOLO“ yra tinkamas realaus laiko PCB komponentų aptikimo užduotims AOI sistemose.

Tyrime [10] pristatytas giluminio mokymosi metodas, skirtas PCB defektų aptikimui AOI sistemose, naudojant „YOLOv8“ objektų aptikimo algoritmą kartu su CNN architektūra. Autoriai nagrinėjo gamybos sąlygomis pasitaikančius PCB defektus: trūkstamas skylės, atviras grandines, trumpuosius jungimus, atšakas, pašalinį varį ir kitus paviršiaus pažeidimus. Siūlomas metodas [10] remiasi hibridine architektūra, kurioje „YOLOv8“ modelis sujungiamas su „DenseNet“ tinklu, siekiant pagerinti defektų lokalizavimo ir klasifikavimo tikslumą. Modelio mokymui naudotas specializuotas PCB duomenų rinkinys, sudarytas naudojant „KiCad“ programinę įrangą, o duomenų įvairovei padidinti taikytas vaizdų pasukimas, atspindėjimas ir triukšmo įterpimas.

**23 lentelė.** Modelių palyginimas [10]

Modelis	Tikslumas, proc.
„YOLOv8“	91,3
„DenseNet“	86,1
„DenseNet“ +YOLO8	96,5

Kaip matyti iš modelių palyginimo (žr. 23 lentelę), hibridinis „DenseNet“ + „YOLOv8“ modelis pasiekė geriausią 96,5 proc. tikslumą. Atskirai taikytas „YOLOv8“ modelis pasiekė 91,3 proc., o „DenseNet“ – 86,1 proc. tikslumą. Tai rodo, kad objektų aptikimo ir klasifikavimo architektūrų sujungimas gali pagerinti PCB defektų aptikimo kokybę AOI sistemose.

Moksliniame šaltinyje [24] pristatytas patobulintas PCB defektų aptikimo metodas, paremtas „G-YOLOv8“ giliojo mokymosi architektūra, skirtas automatizuotoms optinės patikros AOI sistemoms elektronikos gamyboje. Tyrimo tikslas – sumažinti objekto aptikimo modelio skaičiavimo sudėtingumą ir kartu pagerinti PCB defektų aptikimo tikslumą, ypač dirbant su ribotų resursų įterptinėmis sistemomis. Modelio architektūra optimizuota integruojant vaiduoklio konvoliucijos

(angl. *ghost convolution*) operacijas, kurios leidžia sumažinti perteklinius skaičiavimus ir modelio parametrų skaičių neprarandant požymių informacijos.

Eksperimentams tyrime [24] naudotas „PKU PCB“ defektų duomenų rinkinys, apimantis šešias pagrindines defektų klases. Po duomenų papildymo metodų taikymo mokymo duomenų rinkinys buvo išplėstas iki 9 669 vaizdų, kurių raiška siekė  $640 \times 640$  pikselių, o modelio mokymas atliktas 150 epochų. Tokia duomenų paruošimo metodika padėjo pagerinti modelio gebėjimą atpažinti įvairius PCB defektus ir sumažinti duomenų disbalanso įtaką mokymo procesui.

**24 lentelė.** Modelių palyginimas [24]

Modelis	mAP <sub>0,5</sub> , proc.	Parametrai, mln.	GFLOPs 10 <sup>9</sup>
„SSD“	89,6	25,2	116,1
„YOLOv8“	93,1	3,0	8,1
„G-YOLOv8“	94,4	2,6	7,5

Eksperimentiniai [24] rezultatai (žr. 24 lentelę) parodė, kad siūlomas „G-YOLOv8“ modelis pasiekė  $mAP@0,5 = 94,4$  proc., kas yra geresnis rezultatas nei bazinio „YOLOv8“ modelio 93,1 proc. Tuo pačiu modelio dydis sumažintas iki 2,6 mln. parametrų, o skaičiavimo sudėtingumas sumažintas iki 7,5 GFLOPs, lyginant su baziniu „YOLOv8“ modeliu. Tai leidžia sumažinti skaičiavimo apkrovą ir padidinti modelio efektyvumą realaus laiko PCB defektų aptikimo sistemose.

Šaltinyje [25] analizuojamas naujos kartos „YOLOv12“ serijos objektų aptikimo modelių pritaikymas PCB defektų aptikimui elektronikos gamybos procesuose. Tyrimo tikslas įvertinti skirtingų „YOLOv12“ modelio versijų našumą automatizuotose optinės patikros AOI sistemose ir nustatyti, kuris modelis geriausiai tinka realaus laiko PCB defektų aptikimo užduotims. Straipsnyje nagrinėjamos kelios „YOLOv12“ architektūros modifikacijos (pvz., „YOLOv12n“, „YOLOv12s“ ir „YOLOv12m“), kurios skiriasi parametrų skaičiumi, skaičiavimo sudėtingumu ir aptikimo tikslumu.

Eksperimentams tyrime [25] naudotas PCB defektų duomenų rinkinys, kuriame pateikiamos šešios dažniausiai pasitaikančios defektų klasės: trūkstama skylė, pelės įkandimo defektas, atvira grandinė, trumpasis jungimas, varinė atšaka, pašalinis varis. Prieš modelio mokymą taikyti duomenų papildymo metodai, tokie kaip vaizdų pasukimas, mastelio keitimas ir triukšmo įterpimas, leidžiantys padidinti mokymo duomenų įvairovę ir pagerinti modelio gebėjimą apibendrinti skirtingas defektų formas.

**25 lentelė.** Eksperimentinių rezultatų palyginimas [25]

Modelis	Epochos, vnt.	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.	F <sub>1</sub> balas, proc.	mAP <sub>0,5</sub> , proc.	mAP <sub>0,5:0,95</sub> , proc.	Inferencija*
„YOLOv12l“	150	0,952	0,813	0,877	0,768	0,503	7,59
„YOLOv12m“	150	0,956	0,802	0,878	0,737	0,500	5,88
„YOLOv12n“	150	0,931	0,804	0,872	0,779	0,422	3,11
„YOLOv12s“	150	0,935	0,876	0,848	0,843	0,466	6,2
„YOLOv12x“	150	0,964	0,828	0,891	0,887	0,506	10,62

\* čia inferencija (ms) – vieno vaizdo apdorojimo laikas.

Eksperimentiniai rezultatai (žr. 25 lentelę) parodė, kad „YOLOv12“ modelių serija pasižymi aukštu PCB defektų aptikimo tikslumu, o geriausi rezultatai pasiekti naudojant „YOLOv12x“ modelį, kuris

pasiekė 96 proc. aptikimo tikslumą ir daugiau kaip 88 proc. mAP<sub>0,5</sub> rodiklį. Tačiau jo apdorojimo laikas yra didesnis 10,62 ms. Tuo tarpu „YOLOv12n“ modelis yra greičiausias 3,11 ms, bet jo aptikimo tikslumas yra mažesnis. Tai rodo kompromisą tarp modelio tikslumo ir veikimo greičio realaus laiko PCB defektų aptikimo sistemose.

Tyrėjų [3] darbe nagrinėtas giluminio mokymosi metodais paremtas PCB defektų aptikimo sprendimas, skirtas automatizuotoms elektronikos gamybos tikrinimo sistemoms. Tyrime analizuota, kaip skirtingos neuroninių tinklų architektūros gali būti pritaikytos PCB vaizdų analizei ir defektų identifikavimui, siekiant sumažinti rankinio tikrinimo poreikį ir padidinti kokybės kontrolės patikimumą. Autoriai pažymi, kad tradiciniai optinės patikros metodai dažnai yra jautrūs apšvietimo pokyčiams ir sudėtingoms PCB struktūroms, todėl vis dažniau taikomi giluminio mokymosi modeliai, gebantys automatiškai išmokti defektų požymius iš vaizdų duomenų.

Tyrime [3] buvo analizuojamos kelios giliojo mokymosi architektūros, tarp jų CNN, „ResNet“ ir „YOLO“ modeliai. Eksperimentams naudotas „PKU-Market-PCB“ duomenų rinkinys, sudarytas iš maždaug 1386 sintetinių PCB defektų vaizdų, kuriuose pateikiamos šešios dažniausios defektų kategorijos: trūkstama skylė, pelės įkandimo defektas, atvira grandinė, trumpasis jungimas, varinė atšaka ir pašalinis varis. Tyrimo rezultatai parodė, kad „YOLO“ architektūra pasižymi geru tikslumu ir skaičiavimo efektyvumu balansu, o PCB defektų aptikimo tikslumas gali siekti apie 98 proc. Todėl šis šaltinis pagrindžia „YOLO“ šeimos modelių pasirinkimą realaus laiko AOI sistemoms, kuriose svarbus ne tik aptikimo tikslumas, bet ir apdorojimo sparta bei santykinai nedideli skaičiavimo resursų reikalavimai.

Moksliniame šaltinyje [26] pristatytas patobulintas lengvas PCB defektų aptikimo algoritmas „AE-YOLO“, skirtas automatizuotoms optinės patikros AOI sistemoms elektronikos gamyboje. Tyrime spęstos dažnos PCB defektų aptikimo modelių problemos: didelis parametų skaičius, lėtesnis aptikimo greitis ir nepakankamas tikslumas sudėtingose vizualinėse sąlygose. Siūlomas metodas sukurtas „YOLO“ architektūros pagrindu, papildant ją pažangesniais požymių išgavimo ir dėmesio mechanizmais (angl. *attention mechanisms*).

Autorių [26] siūlomame modelyje integruoti keli architektūriniai patobulinimai. „CoTNet“ pagrindu veikiantis modulis naudojamas kontekstinei informacijai analizuoti ir ryšiams tarp skirtingų vaizdo sričių nustatyti. „CC3“ modulis pagerina kanalų dėmesio mechanizmą ir leidžia tiksliau išgauti daugialyę požymių informaciją iš PCB vaizdų. Taip pat taikomas „SimAM“ dėmesio mechanizmas, kuris sumažina nereikšmingos foninės informacijos įtaką ir padeda tiksliau identifikuoti defektų struktūrinius požymius.

Eksperimentai [26] atlikti naudojant PCB defektų duomenų rinkinį, kuriame analizuotos šešios pagrindinės defektų klasės: trūkstama skylė, atvira grandinė, trumpasis jungimas, varinė atšaka, pelės įkandimo defektas ir pašalinis varis. Gauti rezultatai parodė, kad „AE-YOLO“ pasiekė 97,0 proc. tikslumą (angl. *precision*), 93,5 proc. atgavimo rodiklį (angl. *recall*), 96,7 proc. mAP ir 1824 kadru per sekundę apdorojimo spartą (žr. 26 lentelę). Modelis turėjo 2,6 mln. parametų, todėl išliko lengvas ir tinkamas efektyviam PCB defektų aptikimui.

**26 lentelė.** „AE-YOLO“ ir pagrindinių algoritmų našumo palyginimas [26]

Modelis	Parametrai, mln.	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.	mAP, proc.	FPS
„YOLOv8“	3,2	94,1	90,2	94,2	1801
„YOLOv3“	12,1	91,83	81,5	90,2	1574
„YOLOv5“	2,5	95,40	93,3	96,3	1618
„YOLOv5-Lite“	1,5	87,7	77,4	83,5	526
„YOLOv6“	4,2	95,3	92,1	95,4	1744
„YOLOX-Tiny“	5,0	9,8	60,9	67,0	139
„YOLOv9“	2,6	96,7	96,6	97,7	417
„YOLOv10“	2,7	96,3	95,3	97,2	455
„AE-YOLO“	2,6	97,0	93,5	96,7	1824

Kaip matyti iš 26 lentelės, „AE-YOLO“ modelis pasiekė didesnę tikslumą nei bazinis „YOLOv8“ modelis, kurio tikslumas buvo 94,1 proc., atgavimo rodiklis – 90,2 proc., o mAP – 94,2 proc. Nors „YOLOv9“ ir „YOLOv10“ modeliai pasiekė šiek tiek didesnes mAP reikšmes, atitinkamai 97,7 proc. ir 97,2 proc., jų apdorojimo sparta buvo mažesnė – 417 ir 455 kadrai per sekundę. „AE-YOLO“ išsiskyrė labai didele sparta – 1824 kadrai per sekundę.

Kitame moksliniame šaltinyje [27] pristatytas patobulintas PCB mišrių defektų aptikimo metodas „TR-YOLO“, sukurtas remiantis „YOLOv5“ objektų aptikimo architektūra, siekiant padidinti defektų aptikimo tikslumą ir sumažinti skaičiavimo sudėtingumą automatizuotose optinės patikros AOI sistemose. Tyrime nagrinėjama problema, kad standartiniai „YOLO“ modeliai kartais sunkiai identifikuoja smulkius ar sudėtingos formos PCB defektus, todėl į modelio struktūrą integruotas transformerio (angl. *transformer*) modulis, leidžiantis efektyviau išgauti globalią vaizdo kontekstinę informaciją ir pagerinti požymių reprezentaciją.

Aurių [27] tiriamame modelyje transformerio blokas integruojamas į „C3“ sluoksnį „YOLOv5 Backbone“ struktūroje, taip pagerinant požymių išgavimą iš skirtingų PCB vaizdo regionų. Modelio mokymas atliktas naudojant „MDD\_PCB“ mišrių PCB defektų duomenų rinkinį, taikant perkeliamojo mokymosi metodą su iš anksto apmokytais svoriais. Mokymo procese naudotas stochastinis gradientinis nusileidimas SGD su 0,001 mokymosi sparta ir 0,9 inercijos koeficientu, o modelis treniruotas 300 epochų, siekiant užtikrinti stabilų mokymosi procesą ir aukštą defektų aptikimo tikslumą.

**27 lentelė.** AE-YOLO ir pagrindinių algoritmų našumo palyginimas [27]

Modelis	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.	mAP, proc.	F1 balas, proc.	Parametrai, mln.	FLOPs	FPS	Dydis, MB
„YOLOv5“	95,7	96	95,8	95,40	1,77	4,2	120,69	3,87
„YOLOv6“	95,1	96,0	95,1	86,2	4,7	11,4	118,69	39,3
„YOLOv7“	90,8	98,1	94,5	89,6	2,34	6,9	115,73	71,3
„YOLOv8“	85,9	94,2	93,6	92,4	3,0	8,1	112,13	6,23
„YOLOv9“	95,8	86,4	95,7	91	4,8	19,1	68,03	10,8
„YOLOv10“	97,9	89,7	95,8	93	2,6	8,2	126,58	5,8
„TR-YOLO“	96,4	97	96,4	96,68	1,80	4,1	129,87	4,0

Ekspimentinių tyrimų rezultatai parodė (žr. 27 lentelę), kad siūlomas „TR-YOLO“ modelis pasiekė 96,4 proc. tikslumo, 97 proc. „atgavimo“ rodiklio ir 96,4 proc. mAP rodiklį, o F1 rodiklis siekė 96,68 proc. Modelio architektūra pasižymi palyginti nedideliu skaičiavimo sudėtingumu 1,80 mln. parametrų ir 4,1 „GFLOPs“, o apdorojimo sparta siekia 129,87 kadrų per sekundę FPS. Tokie rezultatai rodo, kad siūlomas metodas gali užtikrinti aukštą PCB defektų aptikimo tikslumą kartu išlaikant realaus laiko veikimo galimybes. „TR-YOLO“ modelis, integruojantis transformerių architektūros elementus į „YOLOv5“ struktūrą, leidžia pagerinti mišrių PCB defektų aptikimo tikslumą ir sumažinti modelio skaičiavimo sudėtingumą.

Galima teigti, kad „YOLO“ šeimos modeliai yra viena tinkamiausių kryptių PCB komponentų ir defektų aptikimui automatinės optinės patikros sistemose. Analizuotuose šaltiniuose YOLOv7, „YOLOv8“, „YOLOv12“, „AE-YOLO“, „TR-YOLO“, „FC-YOLO“, „G-YOLOv8“ ir kiti patobulinti modeliai taikomi smulkiems PCB defektams, tankiai išdėstytiems komponentams ir mišriems defektams lokalizuoti [20, 21, 22, 23, 11, 10, 24, 25, 26, 27]. Šie modeliai pasižymi tuo, kad vieno apdorojimo metu leidžia nustatyti objekto klasę, koordinatas ir pasitikėjimo reikšmę, todėl jie yra tinkami realaus laiko optinės kontrolės užduotims.

Nagrinėti tyrimai rodo, kad „YOLO“ architektūros dažniausiai tobulinamos trimis kryptimis: didinant smulkių objektų aptikimo tikslumą, mažinant modelio parametrų ir skaičiavimo operacijų kiekį bei išlaikant didelę inferencijos spartą. Tai svarbu šiame darbe, nes eksperimentiniame AOI stende naudojama ribotų skaičiavimo išteklių įranga, o tyrimo tikslas yra ne tik aptikti PCB komponentus, bet ir įvertinti modelių veikimą realiomis optinės patikros sąlygomis. Dėl šios priežasties šiame darbe pasirenkama „YOLO“ tipo objektų aptikimo kryptis, o eksperimentinėje dalyje lyginami „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“ modeliai.

## 1.6. Apšvietimo įtaka optiniam atpažinimui

Optinėse PCB ir PCBA patikros sistemose apšvietimas yra vienas iš svarbiausių veiksnių, lemiančių vaizdo kokybę ir aptikimo rezultatų stabilumą. Kamera fiksuoja ne patį objektą, o nuo jo paviršiaus atsispindėjusią šviesą, todėl komponentų kontūrai, litavimo vietos, paviršiaus pažeidimai ir spalviniai skirtumai priklauso nuo apšvietimo krypties, intensyvumo ir spektro. Net ir naudojant tą patį objektų aptikimo algoritmą, skirtingas apšvietimas gali pakeisti komponentų matomumą, šešėlius, atspindžius ir kontrastą tarp komponento bei PCB pagrindo.

Šaltinyje [1] nurodoma, kad tradiciniai vaizdo apdorojimo ir mašininio mokymosi metodai dažnai jautrūs apšvietimo pokyčiams, nes jų veikimas priklauso nuo iš anksto išskirtų požymių, etaloninių vaizdų ir stabilios aplinkos. Apžvalgoje taip pat pateikiami pavyzdžiai, kai litavimo jungčių analizei naudotos trijų spalvų apšvietimo sistemos: raudona, žalia ir mėlyna šviesa. Tokiu būdu buvo siekiama išryškinti litavimo paviršiaus atspindžius ir pagal jų intensyvumą klasifikuoti litavimo kokybę. Tai rodo, kad skirtingos šviesos spalvos gali išryškinti nevienodus PCB arba litavimo paviršiaus požymius, todėl apšvietimas turi tiesioginę įtaką optinės patikros rezultatams.

Apšvietimo įtaka matoma ir giliojo mokymosi modelių taikyme. Šaltinyje [21] PCB defektų aptikimui naudojant „YOLOv7“ buvo taikytas duomenų papildymas, įtraukiant pasukimo, mastelio keitimo ir apšvietimo sąlygų variacijas. Tokia metodika leidžia padidinti modelio atsparumą skirtingoms vaizdo fiksavimo sąlygoms. Tai svarbu AOI sistemose, nes realioje gamyboje apšvietimas gali kisti dėl LED šaltinių padėties, PCB paviršiaus atspindžių, kameros kampo ar skirtingų komponentų medžiagų.

Kitas apšvietimo svarbos pavyzdys pateiktas šaltinyje [14], kuriame komponentų paviršiaus korozijos požymiai nustatomi pagal šviesos atspindžio pokyčius. Tyrime defektai siejami su paviršiaus šiurkštumu, spalvos ir atspindžio pasikeitimais. Tai rodo, kad net ir nedideli paviršiaus optinių savybių pokyčiai gali būti naudojami komponentų kokybei vertinti, tačiau tam būtinos stabilios ir tinkamai parinktos apšvietimo sąlygos.

Šaltinyje [28] nagrinėjamos skirtingos vaizdinės patikros technologijos: matomos šviesos vaizdai, artimojo infraraudonojo spektro NIR (angl. *near infrared*) vaizdai ir rentgeno „X-ray“ vaizdai. Matomos šviesos metodai labiausiai tinka paviršiuje esantiems komponentams, jų padėčiai ir vizualiems defektams vertinti, tačiau jų rezultatai priklauso nuo apšvietimo, paviršiaus atspindžių ir komponentų spalvos. NIR ir „X-ray“ metodai leidžia gauti kitokio tipo informaciją, tačiau reikalauja specialios įrangos ir nėra tiesiogiai analogiški paprastam kameromis pagrįstam AOI stendui.

Papildomą alternatyvų vaizdų gavimo būdą pateikia šaltinis [19], kuriame PCBA defektams aptikti naudoti termoviziniai, t. y. infraraudonųjų spindulių, vaizdai. Tyrime naudota „FLIR T420“ termovizinė kamera, o defektai buvo nustatomi pagal šilumos pasiskirstymo skirtumus. CNN modelis klasifikavo plokštes į geras ir defektuotas, „YOLOv5“ lokalizavo įtartinas zonas, o autoenkoderis AE (angl. *autoencoder*) vertino rekonstrukcijos nuokrypius pagal struktūrinio panašumo indeksą SSIM (angl. *structural similarity index measure*). Šis šaltinis rodo, kad defektų aptikimo kokybė priklauso ne tik nuo algoritmo, bet ir nuo pasirinkto vaizdo gavimo principo – matomos šviesos, infraraudonųjų spindulių ar rentgeno vaizdų.

Šiame darbe apšvietimo įtaka vertinama eksperimentiškai, naudojant RGBW apšvietimą. Tiriami baltas, raudonas, žalias ir mėlynas apšvietimo režimai, o jų poveikis vertinamas pagal YOLO modelių aptikimų skaičių. Eksperimento rezultatai parodė, kad baltas apšvietimas davė daugiausia aptikimų – 1353, žalias – 579, raudonas – 234, o mėlynas – tik 45 aptikimus. Tai patvirtina literatūroje aptariamą teiginį, kad apšvietimo spektras ir vaizdo kontrastas gali reikšmingai pakeisti komponentų matomumą ir objektų aptikimo rezultata.

Apibendrinant galima teigti, kad apšvietimas AOI sistemose yra ne pagalbinis, o vienas iš pagrindinių vaizdo kokybės ir aptikimo stabilumo veiksnių. Literatūroje RGB apšvietimas naudojamas litavimo paviršių požymiams išryškinti [1], apšvietimo variacijos taikomos „YOLO“ modelių atsparumui didinti [21], atspindžio pokyčiai naudojami komponentų paviršiaus kokybei vertinti [14], o NIR, „X-

ray“ ir termoviziniai metodai parodo, kad skirtingi vaizdo gavimo principai leidžia aptikti skirtingo pobūdžio defektus [19, 28]. Todėl šiame darbe RGBW apšvietimo režimų palyginimas yra būtina eksperimentinės AOI sistemos dalis, leidžianti nustatyti, kuris apšvietimas geriausiai tinka paviršinio montavimo komponentų aptikimui „YOLO“ šeimos modeliais.


### 1.7. Alternatyvūs elektronikos testavimo metodai: AXI, ICT, talpiniai jutikliai, FPICT

Be automatinės optinės patikros AOI, elektronikos gamyboje taikomi ir kiti PCB bei PCBA testavimo metodai, skirti vidinėms struktūroms, elektriniams parametrų, kontaktų būklei ar integruotų grandynų veikimui vertinti. Tokiems metodams priskiriama rentgeno patikra „X-ray“, artimųjų infraraudonųjų spindulių NIR analizė, talpiniai ir rezonansiniai jutikliai, grandinės vidinis testavimas ICT, FPICT, JTAG, ICST savitestavimas ir SoC gedimų lokalizavimo metodai. Šie metodai šiame darbe plačiau netaikomi, tačiau jie svarbūs kaip platesnis elektronikos testavimo sistemų kontekstas, leidžiantis palyginti, kuo kameromis pagrįsta AOI ir „YOLO“ kryptis skiriasi nuo elektrinių, rentgeno ar bekontaktų diagnostikos metodų.

Moksliniame tyrime [28] lyginti trys vaizdinės PCBA plokščių patikros metodai: matomos šviesos vaizdai, artimųjų infraraudonųjų spindulių NIR (angl. *near infrared*) vaizdai ir rentgeno „X-ray“ vaizdai. Tyrimo tikslas buvo nustatyti, kaip skirtingi bangos ilgiai padeda aptikti PCBA defektus ir ar NIR metodas gali būti taikomas kaip alternatyva kitoms patikros technologijoms.

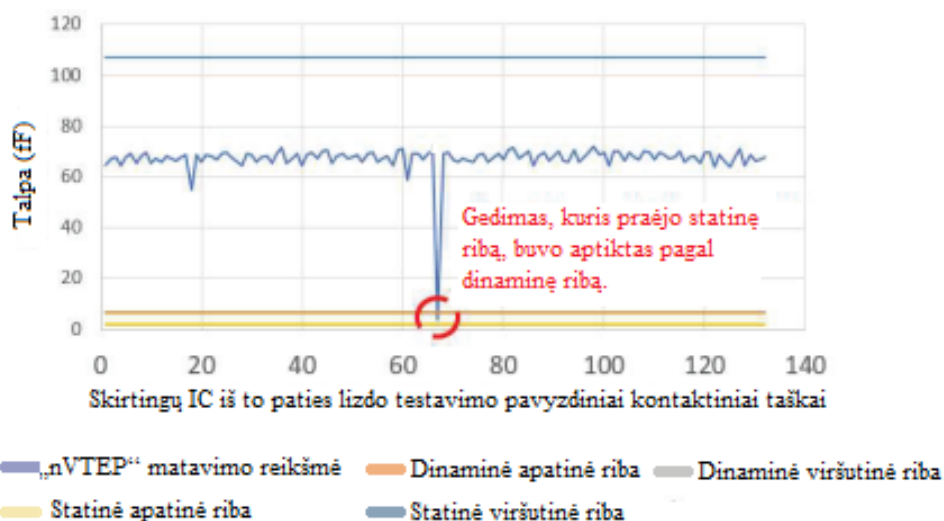
Tyrime naudota „Nikon D90 DSLR“ skaitmeninė veidrodinė kamera (angl. *digital single-lens reflex*), kurios skiriamoji geba buvo  $4288 \times 2848$  pikselių, rentgeno „X-ray“ sistema, kurios skiriamoji geba buvo  $3840 \times 3072$  pikselių, ir NIR hiperspektrinė kamera, veikusi 950–1700 nm spektro diapazone. Rezultatai parodė, kad matomos šviesos vaizdai tinkami paviršiuje esantiems komponentams ir vizualiems defektams vertinti, „X-ray“ metodas leidžia aptikti vidines struktūras, litavimo taškus, tuštumas ir paslėptus trumpuosius jungimus, o NIR analizė gali išryškinti medžiagų skirtumus, pavyzdžiui, vario takelius, lydmetali, plastikinius komponentų korpusus ir rašalo sluoksnį (angl. *silkscreen*). Spektriniais duomenimis analizuoti taikyta pagrindinių komponentų analizė PCA (angl. *principal component analysis*), leidžianti atskirti skirtingas medžiagas pagal jų spektrinius požymius.

Dar viename moksliniame šaltinyje [29] analizuota neinvazinė testavimo sistema, skirta laidų sujungimo defektams IC integruotų grandynų pakuotėse aptikti. Autorių pasiūlytas metodas pagrįstas talpiniu matavimo principu, kai defektai nustatomi pagal elektrinės talpos pokyčius tarp laidų sujungimų (angl. *wire bonding*). Tokia sistema leidžia aptikti elektrines anomalijas nepažeidžiant komponentų ir gali būti integruojama į gamybos liniją.



12 pav. Jutiklio veikimo principas pagrįstas talpiniu matavimu [29]

Eksperimentuose [29] naudoti įtampos testavimo elektriniai zondai VTEP (angl. *voltage terminal evaluation point*), skirti elektrinio lauko pokyčiams tarp laidų matuoti (žr. 12 pav.). Matavimo duomenys buvo fiksuojami laiko sekų pavidalu, todėl defektams nustatyti taikytas dvigubo slenksčio metodas. Jį sudarė statistinis globalus slenkstis, apskaičiuojamas pagal istorinių duomenų dispersiją, ir lokalus adaptacinis slenkstis, pritaikomas kiekvienam komponentui individualiai. Jei matavimo reikšmė viršydavo abu slenksčius, jungtis buvo laikoma defektine, jei viršydavo tik vieną – reikėdavo papildomos analizės, o jei neviršydavo nė vieno – jungtis laikyta gera.



**13 pav.** Hibridinis slenksčių nustatymo metodas, užtikrinantis testavimo tikslumą [29]

Tyrimo [29] rezultatai parodė, kad talpinio matavimu pagrįsta sistema pasiekė didesnę nei 95 proc. defektų aptikimo jautrumą (angl. *sensitivity*). Dėl statistinio ir adaptacinio slenksčio derinio sistema taip pat pasižymėjo mažu klaidingų signalų skaičiumi (angl. *false positives*), todėl galėjo tiksliai identifikuoti laidų sujungimo defektus be perteklinio gerų komponentų atmetimo.

Analizuotame tyrime [19] pristatytas bekontaktis PCBA defektų aptikimo metodas, pagrįstas giluminio mokymosi DL (angl. *deep learning*) algoritmais ir termoviziniais, t. y. infraraudonųjų spindulių, vaizdais. Šis metodas siūlomas kaip alternatyva kontaktiniam grandinės vidiniam testavimui ICT (angl. *in-circuit test*). Tyrime infraraudonųjų spindulių vaizdams fiksuoti naudota „FLIR T420“ termovizinė kamera. Defektas buvo imituojamas pakeičiant rezistorių iš 40 kΩ į 20 kΩ, kad būtų sukeltas pakitęs šilumos pasiskirstymas PCBA plokštėje.

Tyrimo [19] taikyti keli metodai: CNN konvoliucinis neuroninis tinklas (angl. *convolutional neural network*) naudotas termoviziniams vaizdams klasifikuoti į dvi klases – „gera“ ir „defektuota“ plokštė; „YOLOv5“ algoritmas (angl. *you only look once*) naudotas defektams lokalizuoti, sudarant apibrėžimo dėžutes (angl. *bounding boxes*); autoenkoderis AE (angl. *autoencoder*) taikytas kaip neprižiūrimo mokymosi modelis, kuris pagal vaizdo atkūrimo nuokrypius leidžia nustatyti galimus defektus. Vaizdų panašumui vertinti naudotas struktūrinio panašumo indeksas SSIM (angl. *structural similarity index measure*).

Modelio mokymui naudotas autorių surinktas termovizinių vaizdų rinkinys: 840 vaizdų skirta mokymui, o 360 – testavimui. Siekiant sumažinti persimokymo riziką, taikytas duomenų papildymas: vaizdų sukimas, apvertimas ir suliejimo įterpimas. CNN modelio mokymui naudota dvejetainė

kryžminė entropija (angl. *binary cross-entropy*), nes vaizdai buvo skirstomi į dvi klases – gerus ir defektuotus atvejus [19].

**28 lentelė.** Modelio veikimo rezultatai esant šilumos pokyčiams ir skirtingiems kampiniams duomenims [19]

<b>Šildymas</b>				
Laikas, sek.	10	20	30	40
Tikslumas, proc.	45,0	70,5	96,6	99,2
Apdorojimo laikas, ms	7			
<b>Kampų matavimas</b>				
Kampas, laipsniai	Fiksuotas	+5	+10	+5, +10
Tikslumas, proc.	96,6	95,7	94,0	94,2
Apdorojimo laikas, ms	7			

Gauti [19] rezultatai parodė, kad po 40 s PCBA plokštės šildymo klasifikavimo tikslumas pasiekė 99,2 proc., o duomenų apdorojimo laikas siekė 7 ms. Keičiant stebėjimo kampą, tikslumas išliko 94,0–96,6 proc. ribose. Autoriai taip pat nurodo, kad „YOLOv5“ defektų aptikimo tikslumas  $mAP@0,5$  siekė 96,1 proc., o aptikimo laikas buvo 20 ms vienam vaizdui. Autoenkoderis normalius vaizdus atkūrė su  $SSIM \geq 0,97$ , o defektnių vaizdų  $SSIM$  reikšmė buvo mažesnė nei 0,90, todėl atkūrimo skirtumas galėjo būti naudojamas defektams identifikuoti.

Tyrimė [4] nagrinėtas dirbtinio intelekto AI (angl. *artificial intelligence*) ir mašininio mokymosi ML (angl. *machine learning*) metodų taikymas AOI ir ICT testavimo duomenims analizuoti. Pagrindinis tikslas buvo ne tik aptikti defektus gamybos metu, bet ir prognozuoti galimus gaminių gedimus eksploatacijos metu. Šiam tikslui naudoti duomenys iš automatinės optinės patikros AOI (angl. *automated optical inspection*), grandinės vidinio testavimo ICT (angl. *in-circuit test*), litavimo pastos kokybės rodiklių, komponentų charakteristikų, gamybos sąlygų, elektrostatinio išlydžio ESD (angl. *electrostatic discharge*) ir gedimų statistikos .

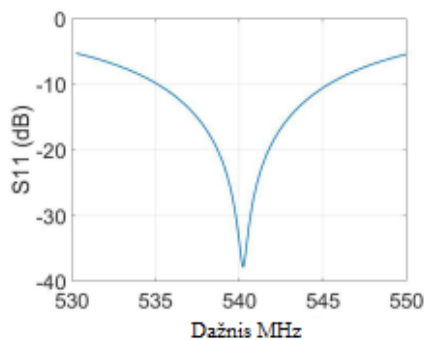
Tyrimė [4] AOI sistema naudota vizualiems komponentų, litavimo ir išdėstymo neatitikimams aptikti, o ICT sistema su adatiniu testavimo stalu (angl. *bed of nails*) – elektriniams parametrų matuoti, pavyzdžiui, varžai, talpai, atviroms grandinėms ir trumpiesiems jungimams. Surinkti duomenys buvo filtruojami, žymimi (angl. *labeling*), klasifikuojami ir naudojami klaidingoms pavojaus signalams (angl. *false calls*) mažinti. Autoriai taip pat akcentavo gamybos duomenų atsekamumą, kai kiekvienam gaminiui gali būti sudaromas produkto skaitmeninis pasas (angl. *product passport*), susiejamas su QR kodu (angl. *quick response code*) arba RFID žyma (angl. *radio-frequency identification*).

Šis tyrimas [4] rodo, kad AOI ir ICT duomenų sujungimas su AI / ML metodais gali būti naudingas defektų šaltiniams nustatyti, gedimų tendencijoms prognozuoti ir profilaktinės priežiūros (angl. *preventive maintenance*) planams optimizuoti. Tokia kryptis svarbi elektronikos testavimo sistemų kontekste, nes leidžia vertinti ne tik atskiro gaminio būklę, bet ir viso gamybos proceso stabilumą bei duomenų atsekamumą.

Mokslininkai [30] sukūrė ir išbandė kompaktišką aukštos raiškos talpinį rezonansinį jutiklį (angl. *capacitive resonance sensor*), skirtą atviroms (angl. *open*) ir trumposioms jungtims (angl. *short*) aptikti PCBA plokštėse. Tyrimo tikslas buvo pasiūlyti bekontaktį testavimo metodą, tinkamą

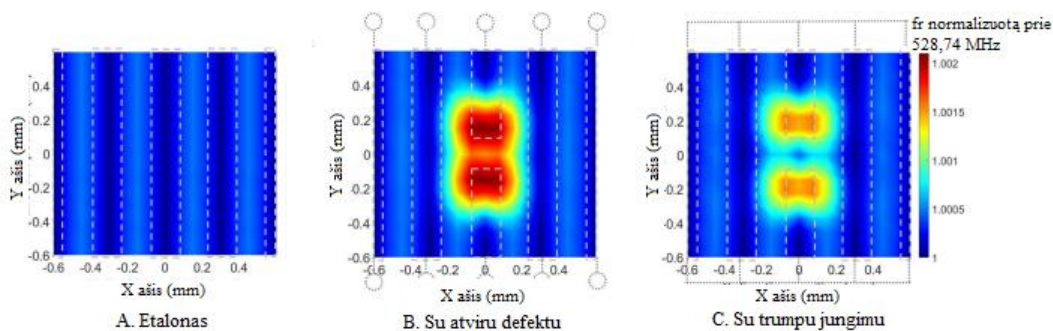
smulkiems ir tankiai komponentais užpildytiems PCB segmentams, kuriuose kontaktiniai metodai, tokie kaip ICT, tampa riboti dėl fizinės prieigos prie testavimo taškų.

Tyrime [30] naudotas talpinis rezonansinis jutiklis, integruotas į lanksčią PCB plokštę iš vario laminato FCCL (angl. *flexible copper clad laminate*), vektorinis tinklų analizatorius „Keysight N5249B“, skirtas rezonansiniam dažniui ir S11 parametrui matuoti 530–550 MHz dažnių ruože, bei VT-80 judėjimo platforma, leidžianti pozicionuoti jutiklį 1 μm žingsnio tikslumu. Jutiklio veikimas pagrįstas LC rezonansine grandine, kurios rezonansinis dažnis keičiasi priklausomai nuo šalia esančių PCB laidininkų ir jų defektų. Eksperimento metu jutiklis buvo judinamas 0,05 mm atstumu virš PCB paviršiaus, o dažnio pokyčiai naudoti defektų vietai nustatyti.



14 pav. Jutiklio generuojami rezultatai be testuojamo objekto DUT [30]

Defektams imituoti PCB struktūrose buvo suformuotos 0,2 mm ilgio atvirosios ir trumposios jungtys. Metodo [30] veikimui įvertinti naudota „EMPro“ elektromagnetinio modeliavimo programa (angl. *electromagnetic professional*), kuria sudarytas jutiklio LCR modelis, apimantis induktyvumą L, talpą C ir varžą R. Tyrimo rezultatai parodė, kad be testuojamo objekto DUT (angl. *device under test*) rezonansinis dažnis siekė apie 540,24 MHz, o S11 reikšmė buvo apie -38 dB. Esant defektams, rezonansinis dažnis pasislinkdavo, todėl buvo galima nustatyti atvirų ir trumpųjų jungimų vietas.



15 pav. „fr“ pasiskirstymas tiriamojo objekto DUT atviro ir trumpo jungimo defektų atvejais [30]

Tyrimas [30] parodė, kad jutiklis gali aptikti labai mažus, apie 0,15 mm × 0,2 mm dydžio defektus, atitinkančius IC kojelių tarpus. 2D rezonansinio dažnio žemėlapiai leido vizualiai lokalizuoti defektų vietas, todėl metodas tinkamas aukšto tankio PCB struktūrų bekontaktiam testavimui.

Dar kelių autorių [31] tyrime pristatyta automatizuota grandinių vidinio testavimo ICT (angl. *in-circuit test*) sistema, skirta PCB plokščių kokybės kontrolei gamybos linijoje. Tyrimo tikslas buvo

sumažinti rankinio darbo poreikį, sutrumpinti testavimo ciklą ir padidinti elektrinių bandymų patikimumą pramoninėje aplinkoje.

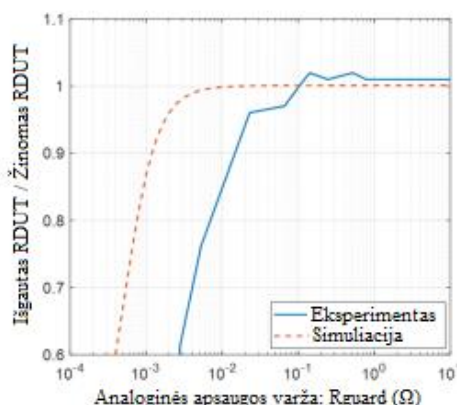
Tyrime [31] naudota „Epson“ G20-A04S roboto ranka su RC-180 valdikliu, „Agilent ICT“ testavimo įranga, „LabVIEW GUI“ programinė sąsaja, „Omron“ PLC programuojamasis loginis valdiklis (angl. *programmable logic controller*), „Datalogic“ brūkšninių kodų skaitytuvas, „Ethernet“ ryšys ir SFCS gamybos cecho valdymo sistema (angl. *shop floor control system*). ICT sistema buvo skirta elektriniams grandinių bandymams atlikti: atviriems sujungimams, trumpiesiems jungimams, varžos neatitikimams ir kitiems elektriniams defektams nustatyti.

Testavimo [31] metu roboto ranka automatiškai paimdavo PCB plokštę, nuskaitydavo brūkšninį kodą, įdėdavo ją į ICT testavimo lizdą, o pagal rezultatą plokštė buvo nukreipiama į „OK“ arba „NG“ (angl. *not good*) konvejerio liniją. Sistema buvo koordinuojama „LabVIEW“ aplinkoje, o duomenų mainams naudota TCP/IP sąsaja. Tyrimo rezultatai parodė, kad ICT testavimo ciklas buvo optimizuotas iki 10 s vienai PCB plokštei, todėl per 10 darbo valandų sistema galėjo apdoroti iki 3600 PCB vienetų.

Straipsnyje [32] analizuota ICT testavimo metodika, skirta IC sujungimų varžai matuoti lanksčiose hibridinėse elektroninėse FHE sistemose (angl. *flexible hybrid electronics*). Metodas leidžia aptikti parazitines varžas tarp IC ir PCB sujungimų net tada, kai bandymo taškai yra fiziškai sunkiai pasiekiami. Tam naudojama integruotų lustų IC vidinė elektrostatinė iškrovos ESD apsauga (angl. *electrostatic discharge*), kuri veikia kaip netiesioginis priėjimas prie IC kontaktų.

Tyrime [32] naudotas FHE prototipas ant „Kapton“ pagrindo, kuriame sumontuoti du „ATTINY85“ mikrovaldikliai. Matavimams naudotas „Keithley 2450“ DC srovės šaltinis, „Keysight E4980A LCR“ matuoklis ir analoginis sargas (angl. *analog guard*), realizuotas naudojant „OP37“ operacinį stiprintuvą. Analoginio sargo paskirtis – sumažinti parazitinių srovių įtaką ir padidinti matavimo tikslumą.

Matavimai atlikti tarp testavimo taškų T1–T3, taikant matricių lygčių sistemą, kuri leidžia apskaičiuoti kiekvienos IC kojelės varžą RDUT (angl. *resistance of device under test*). Kaip matyti iš 21 pav., didinant analoginės apsaugos varžą Rguard, išgautos ir žinomos RDUT varžos santykis artėja prie 1. Tai reiškia, kad matavimo rezultatas tampa artimesnis etaloninei varžos reikšmei. Eksperimentinė kreivė rodo, kad esant didesnei Rguard reikšmei matavimas stabilizuojasi, o metodo tikslumas pagerėja.



16 pav. Išgaunamo tikslumo priklausomybė nuo parametro  $R_{guard}$  [32]

Tyrimo [32] rezultatai parodė, kad sistema gali matuoti iki 300 mΩ varžos pokyčius su mažesne nei 5 proc. paklaida, kai naudojamas 10 kHz dažnio juostos plotis. Patvarumo bandymo metu atlikus 1200 lenkimo ciklų nustatyta, kad 4 iš 8 IC kojelių parodė ryškų jungties varžos padidėjimą, todėl metodas gali būti taikomas mechaninių sujungimų pažeidimams aptikti.

Tyrimo [33] analizuota „NTOU\_LF1826“ mikrovaldiklio MCU (angl. *microcontroller unit*) architektūra su PIC16LF1826 šerdimi ir integruotu vidiniu grandinės derintuvu ICD (angl. *in-circuit debugger*). Tokia sistema leidžia stebėti mikrovaldiklio veikimą, valdyti instrukcijų vykdymą ir nuskaityti vidinių registrų būsenas testavimo metu. Tai naudinga automatizuotose testavimo sistemose, kuriose reikia tikrinti ne tik išorinę PCB struktūrą, bet ir integruoto valdiklio veikimo būsenas.

Tyrimo [33] naudota „Altera DE10 FPGA“ platforma, „USB2UIS“ plokštė duomenų mainams per SPI nuoseklią periferinę sąsają (angl. *serial peripheral interface*), „TravelLogic36“ loginis analizatorius ir „TSMC 0,18 μm CMOS“ technologija galutiniam VLSI lustui realizuoti. Mikrovaldiklio architektūra aprašyta „Verilog“ HDL kalba, o funkcionalumas tikrintas „ModelSim“ modeliavimo aplinkoje. ICD valdymas įgyvendintas per „Visual Basic“ programą „Windows“ operacinėje sistemoje, naudojant tokias funkcijas kaip derinimas, atstatymas, žingsninis vykdymas, skaitymas, rašymas ir registrų stebėjimas.

Tyrimo [33] rezultatai parodė, kad pagamintas MCU lustas gali veikti iki 100 MHz taktiniu dažniu, o integruotas ICD leidžia realiuoju laiku stebėti ir valdyti mikrovaldiklio būsenas. Šis metodas aktualus elektronikos testavimo sistemų kontekste, nes leidžia atlikti integruotų grandynų derinimą ir savikontrolę, tačiau jis nėra skirtas optimaliam PCB komponentų aptikimui.

Dar viename moksliniame šaltinyje [34] atlikta vidinio grandinių testavimo ICT (angl. *in-circuit test*) kontaktinių adatų sistemos „bed of nails“ nusidėvėjimo analizė. Tyrimo tikslas buvo įvertinti, kaip kontaktinių adatų (angl. *probe pins*) dėvėjimasis veikia testavimo rezultatų patikimumą ilgalaikėje gamyboje. Tam taikyta duomenimis paremta analizės metodika (angl. *data-driven approach*), leidžianti pagal sukauptus ICT testų duomenis nustatyti nusidėvėjimo tendencijas ir planuoti prevencinę priežiūrą.

Tyrimo [34] naudoti ICT testavimo įrenginiai su kontaktiniais adapteriais ir įmonės vidinė testavimo duomenų bazė. Duomenų rinkinį sudarė 344 391 duomenų taškas, 84 požymiai viename taške, 13 priežiūros operacijų, o vertinimo laikotarpis siekė 11 mėnesių. Analizei taikyta testavimo rezultatų laiko eilučių analizė ir Kolmogorovo-Smirnovo KS statistinis testas, skirtas palyginti rezultatų pasiskirstymus tarp naujų ir nusidėvėjusių kontaktinių adapterių.

**29 lentelė.** Duomenų rinkinio charakteristikos [34]

Charakteristika	Kiekis
Duomenų taškai	344 391
Požymių kiekis viename taške	84
Priežiūros operacijos	13
Vertinimo laikotarpis (mėnesiais)	11

Tyrimo rezultatai parodė, kad po kiekvienos kontaktinių adatų sistemos priežiūros operacijos KS statistikos reikšmė D didėjo kartu su ištestuotų PCBA plokščių skaičiumi. Tai rodo, kad kontaktinių

adatų nusidėvėjimas keičia testavimo rezultatų pasiskirstymą ir gali būti naudojamas kaip nusidėvėjimo indikatorius prognozuojamos priežiūros (angl. *predictive maintenance*) algoritmuose.

Tyrimuose [35, 36, 37, 38] analizuoti FPICT tipo judančio zondo principu pagrįsti testavimo įrenginiai (angl. *flying probe-inspired in-circuit tester*), skirti PCB elektrinių jungčių diagnostikai. Šie prototipai buvo kuriami kaip lankstesnė alternatyva klasikiniam ICT testavimui, kai reikia tikrinti įtampą, srovę, jungčių vientisumą ar mikrovaldiklių būsenas be sudėtingo kontaktinių adatų adapterio. Kai kuriuose prototipuose naudoti papildomi jutikliai, pavyzdžiui, fotovoltinės celės arba mechaniniai ribiniai jungikliai, o kituose testavimas atliktas remiantis tik elektrinių parametru matavimu.

Tyrimuose [35, 36, 37, 38] naudotos įvairios valdymo platformos: „Arduino Uno“, „Arduino Mega“, STM32, „Raspberry Pi 5“, „Raspberry Pi 3B+“, ESP32, „ATmega328P“ ir „ATmega16U2“. Zondo pozicionavimui naudoti 28BYJ-48 žingsniniai varikliai su ULN2003A arba L298N valdymo moduliais. Elektriniams signalams nuskaityti naudotas mikrovaldikliuose integruotas analoginis-skaitmeninis keitiklis ADC (angl. *analog to digital converter*), o duomenų perdavimui taikyta UART nuosekioji sąsaja (angl. *universal asynchronous receiver transmitter*), nuosekiojo ryšio terminalas (angl. *serial monitor*) ir kai kuriais atvejais MQTT protokolas (angl. *message queuing telemetry transport*), skirtas nuotolinei stebėsenai.

Dalis tyrimų [35, 36, 37, 38] taip pat nagrinėjo hibridinį FPICT + JTAG metodą. FPICT buvo naudojamas fizinių PCB jungčių, įtampos ir srovės parametrų patikrai, o JTAG (angl. *joint test action group*) IEEE 1149.1 – mikrovaldiklių vidinių registru, valdymo logikos ir programinių klaidų diagnostikai. Toks metodas leido pasiekti iki 71,7 proc. struktūrinių defektų padengimą ir 100 proc. zondo pozicionavimo tikslumą. Realaus laiko duomenų fiksavimo intervalas buvo mažesnis nei 1 s, todėl matavimo reikšmės galėjo būti registruojamos iš karto po zondo prisilietimo prie testavimo taško.

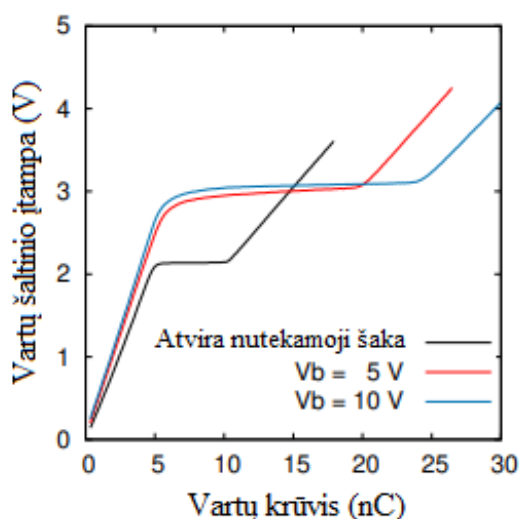
Moksliniame šaltinyje [39] pasiūlyta vidinė grandinės savitestavimo ICST metodika (angl. *in-circuit self-test*), skirta MOSFET tranzistoriaus įjungimo vartų krūviui  $Q_g$  (angl. *gate charge*) matuoti tiesiogiai grandinėje, neatjungiant išėjimo ir šaltinio terminalų (angl. *drain, source*). Šis metodas leidžia įvertinti MOSFET senėjimą ir vartų oksido pažeidimus (angl. *oxide stress*), kurie yra svarbūs komponento patikimumo rodikliai.

Tyrimo [39] naudotas „RFP50N06“ MOSFET tranzistorius kaip testuojamas elementas DUT (angl. *device under test*), „Arduino Uno R3“ valdiklis duomenims rinkti ir pusės tiltelio inverterio schema su dviem MOSFET tranzistoriais bei 2200  $\mu\text{F}$  elektrolitiniiais kondensatoriais. Visa schema buvo realizuota maketavimo plokštėje (angl. *breadboard*). ICST grandinėje jungikliai S1 ir S2 naudoti MOSFET vartams atjungti nuo valdiklio, varža  $R_a = 1,5 \text{ M}\Omega$  – krūviui į MOSFET vartus įvesti, o  $R_b = 10 \Omega$  – apkrovos sąlygoms imituoti.

Tyrimo [39] rezultatai parodė, kad vartų krūvis apskaičiuojamas taikant diskretinę integraciją pagal vartų įtampos kitimą laike. Izoliuoto MOSFET matavimai parodė, kad vartų ir šaltinio įtampa kanalo formavimosi metu išlieka apie 3,2 V, o įjungimo vartų krūvis siekia apie 20 nC esant 5 V įtampai ir apie 25 nC esant 10 V įtampai. Autoriai nurodo, kad tokia neinvazinė ICST metodika leidžia stebėti MOSFET degradacijos požymius, susijusius su vartų oksido sluoksnio pažeidimais.

Dar viename straipsnyje [40] pristatytas gedimų lokalizavimo metodas, skirtas elektronikos gaminių funkcinių klaidų ir testavimo padengimo problemoms nustatyti. Tyrime apjungti automatinio testavimo modelių generavimo ATPG (angl. *automatic test pattern generation*) metodai ir gedimų analizė, atliekama naudojant bandymo platformą EVB (angl. *evaluation board*). Šis metodas taikomas tada, kai standartinė automatizuota testavimo sistema ATE (angl. *automatic test equipment*) negali tiesiogiai nustatyti defekto vietos.

Tyrime [40] naudota EVB platforma, ATE sistema su ATPG loginio testavimo algoritmais, gedimų analizės įranga „PHEMOS-1000“ ir nanozondo sistema „nProbeII“ („ThermoFisher Scientific“). Gedimų lokalizavimui taikyta fotonų emisijos mikroskopija PEM (angl. *photon emission microscopy*), optiniu spinduliu sukulto varžos pokyčio metodas OBIRCH (angl. *optical beam induced resistance change*), EOP bangos formos matavimas ir fizinė defektų lokalizacija luste. Tokia metodika leidžia tirti sudėtingus funkcinius gedimus, pavyzdžiui, DDR sąsajos arba GPIO klaidas, kurios gali likti neaptiktos įprastuose ATE testuose.



17 pav. Šaltinio įtampos priklausomybė nuo krūvio, esant skirtingoms išėjimo elektrodo įtampoms. [40]

Tyrimo [40] rezultatai parodė, kad ATPG taikymas padėjo tiksliau nukreipti gedimų analizę į potencialias defekto vietas ir sutrumpinti analizės laiką iki apie 13,9  $\mu$ s. Tai rodo, kad kombinuotas ATPG, EVB ir fizinės gedimų analizės metodas yra naudingas lustų bei SoC tipo sistemų diagnostikai, kai reikia lokalizuoti vidinius funkcinius defektus.

Apibendrinant galima teigti, kad alternatyvūs elektronikos testavimo metodai papildo PCB ir PCBA kokybės kontrolę, tačiau jų paskirtis skiriasi nuo šiame darbe tiriamos AOI krypties. NIR ir „X-ray“ metodai leidžia gauti papildomą informaciją apie medžiagas, vidines struktūras, litavimo taškus ar paslėptus trumpuosius jungimus [21]. Talpiniai ir rezonansiniai jutikliai gali būti naudojami atviroms bei trumposioms jungtims aptikti pagal elektrinės talpos arba rezonansinio dažnio pokyčius [27], [30]. ICT, FPICT, JTAG ir panašūs metodai skirti elektrinių parametrų, kontaktų, mikrovaldiklių būsenų ar programinės logikos diagnostikai [31, 38]. ICST ir ATPG pagrindu veikiančios metodai taikomi komponentų, MOSFET tranzistorių arba SoC tipo sistemų vidiniams gedimams bei testavimo padengimui vertinti [39, 40].

Šie metodai yra naudingi elektronikos testavimo sistemų kontekste, nes leidžia aptikti tokius defektus, kurių įprasta kamera gali nematyti: paslėptas litavimo jungtis, vidinius takelius, kontaktų varžos

pokyčius, elektrinius nutrūkimus arba funkcinius integruotų grandynų gedimus. Vis dėlto dauguma šių metodų reikalauja specialios matavimo įrangos, kontaktinių zondų, rentgeno, hiperspektrinių kamerų, elektrinių testavimo adapterių arba tiesioginės prieigos prie grandinės signalų. Todėl jie nėra tiesiogiai tinkami šiame darbe atliekamam eksperimentui, kuriame tiriamas kameromis pagrįstas paviršinio montavimo komponentų aptikimas PCB vaizde.

Dėl šios priežasties šiame darbe pasirinkta AOI+ „YOLO“ kryptis. Ji leidžia be kontaktinio testavimo nustatyti matomų paviršinio montavimo komponentų klasę, koordinates ir aptikimo pasitikėjimo reikšmę. Nors alternatyvūs metodai gali būti pranašesni vertinant vidinius arba elektrinius defektus, šiame tyrime svarbiausia yra optinis komponentų atpažinimas realiame AOI stende, naudojant RGBW apšvietimą ir „YOLO“ šeimos modelius.

## 1.8. Skyriaus apibendrinimas ir tyrimo krypties pagrindimas

1. Literatūros analizė parodė, kad PCB ir PCBA kokybės kontrolei taikomi skirtingi metodai: AOI, AXI, ICT, FPICT, JTAG, talpiniai jutikliai, klasikiniai ML ir giliojo mokymosi algoritmai. Tačiau šių metodų paskirtis skiriasi: AXI ir ICT labiau tinka vidiniams arba elektriniams defektams nustatyti, o AOI – vizualiai matomiems komponentams, jų padėčiai ir paviršiaus neatitikimams vertinti.
2. Klasikiniai vaizdo apdorojimo ir ML metodai gali pasiekti aukštus tikslumo rodiklius – literatūroje SVM metodas su RGB apšvietimu pasiekė daugiau kaip 96 proc. tikslumą, LVQ su neraiškiaja logika – 95,83 proc. MLP su „Gaboro“ bangelėmis – 98,8 proc., RPCA kartu su RGB vaizdais – 95,65 proc., o „Random Forest“ klasifikatorius – 98,96 proc. Vis dėlto šie metodai dažnai priklauso nuo etaloninių vaizdų, rankiniu būdu parinktų požymių, stabilaus apšvietimo ir tikslaus PCB pozicionavimo, todėl nėra pakankamai lankstūs realiam AOI stendui, kuriame keičiasi apšvietimas, plokštės orientacija ir komponentų matomumas.
3. Giliojo mokymosi metodai, tokie kaip CNN, „ResNet“, „U-Net“, „3D CNN“, „LSTM“ ir autoenkoderiai, gerai veikia konkrečiose užduotyse, pavyzdžiui, SPI, AXI, termovizijos ar litavimo defektų analizėje. Vis dėlto dauguma jų pritaikyti specialiai įrangai arba siaurai defektų grupei, todėl ne visi tiesiogiai tinka kameromis pagrįstam paviršinio montavimo komponentų aptikimui.
4. „YOLO“ šeimos modeliai literatūroje išskiriami kaip tinkami realaus laiko AOI užduotims, nes vieno vaizdo apdorojimo metu leidžia nustatyti objekto klasę, koordinates ir pasitikėjimo reikšmę. Tai tiesiogiai atitinka šio darbo eksperimentinę kryptį, kurioje vertinamas „YOLO“ modelių gebėjimas aptikti SMD komponentus PCB vaizde.
5. Literatūroje daugiausia nagrinėjamas galutinis PCB defektų aptikimas, tačiau mažiau dėmesio skiriama pirminiam AOI etapui – komponento buvimo, klasės ir koordinatinių nustatymui realiame stende. Ši spraga aktuali šiam darbui, nes neaptikus komponento negalima patikimai vertinti jo padėties, orientacijos ar litavimo kokybės.
6. Apšvietimo analizė parodė, kad komponentų matomumas priklauso nuo šviesos spektro, atspindžių ir kontrasto. Kadangi daugelyje „YOLO“ tyrimų apšvietimas nėra vertinamas kaip atskiras veiksnys, šiame darbe papildomai tiriama RGBW apšvietimo įtaka komponentų aptikimo rezultatams.
7. Atsižvelgiant į literatūros analizę, šiame darbe pasirenkama „YOLO“ tipo objektų aptikimo kryptis, nes šie modeliai geriausiai atitinka eksperimentinio AOI stendo užduotį – aptikti matomus SMD komponentus PCB vaizde. Analizuotuose tyrimuose „YOLO“ modeliai pasižymėjo tinkamu tikslumo ir spartos santykiu: modifikuotas „YOLOv8“ modelis pasiekė 87,7 proc. mAP<sub>0,5</sub> ir 110 kadrų per sekundę spartą [3], „YOLOv7“ PCB defektų aptikime pasiekė 98,0 proc. mAP [9], patobulintas „YOLOv8n“ modelis – 98,6 proc. mAP ir 144,1 kadro per sekundę spartą [12], o „FC-YOLO“ komponentų aptikimo užduotyje pasiekė iki 89,2 proc. mAP<sub>50</sub> ir 206 kadrų per sekundę spartą [14]. Šie rezultatai rodo, kad „YOLO“ šeimos modeliai gali būti taikomi tiek PCB defektams, tiek komponentams lokalizuoti.

## 2. Eksperimentinės AOI sistemos projektavimas ir tyrimo metodika

Eksperimentinėje dalyje sudaroma tyrimui reikalinga elektronikos komponentų vaizdų duomenų bazė, paruošiami ir apmokomi „YOLO“ šeimos objektų aptikimo modeliai bei surenkamas automatinės optinės patikros AOI stendas. Duomenų bazė sudaroma iš PCB plokščių vaizdų, kuriuose pažymimi paviršinio montavimo komponentai. Šie duomenys naudojami neuroninių tinklų apmokymui, validavimui ir testavimui, siekiant įvertinti jų gebėjimą aptikti komponentus skirtingomis sąlygomis.

Eksperimentinė dalis vykdoma penkiais etapais. Pirmajame etape paruošiamas ir anotuojamas duomenų rinkinys, sudarytas iš PCB komponentų vaizdų. Antrajame etape apmokomi „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“ modeliai, keičiant mokymo parametrus, duomenų rinkinio apimtį ir įvesties vaizdų raišką. Trečiajame etape apmokyti modeliai paruošiami vykdymui įterptinėje sistemoje, konvertuojant juos į „HAILO8“ spartintuvui tinkamą formatą. Ketvirtajame etape sukonstruotame AOI stende atliekami bandymai su skirtingais RGBW apšvietimo režimais, PCB orientacijomis ir „YOLO“ modeliais. Penktajame etape įvertinami gauti rezultatai: aptikimų skaičius, patikimesni aptikimai, klaidingi žymėjimai, inferencijos trukmė ir praktinis modelių tinkamumas AOI sistemai.

### 2.1. Eksperimentinės sistemos funkcinė struktūra

Eksperimentinė AOI sistema suprojektuota kaip kameromis pagrįsta spausdintinių plokščių paviršinio montavimo komponentų atpažinimo sistema. Jos paskirtis – fiksuoti PCB vaizdus, valdyti RGBW apšvietimo režimus, atlikti „YOLO“ šeimos modelių inferenciją ir išsaugoti gautus komponentų aptikimo rezultatus. Sistemoje vertinami tokie aptikimo duomenys kaip komponento klasė, koordinatės vaizde, aptikimo pasitikėjimo reikšmė ir inferencijos trukmė.

Eksperimentinės dalies metu sudaroma PCB vaizdų duomenų bazė, paruošiamos anotacijos, apmokomi „YOLO“ šeimos modeliai ir surenkamas eksperimentinis AOI stendas, kuriame atliekami realūs komponentų aptikimo bandymai. Sukurta sistema leidžia tirti, kaip komponentų aptikimo rezultatus veikia skirtingi „YOLO“ modeliai, RGBW apšvietimo režimai ir PCB plokštės orientacija kameros atžvilgiu.

Funkciškai sistema sudaryta iš kelių pagrindinių dalių: vaizdo fiksavimo modulio, apšvietimo valdymo modulio, duomenų apdorojimo ir inferencijos modulio bei rezultatų saugojimo modulio. Vaizdo fiksavimo modulis pagrįstas „Raspberry Pi AI Camera“, kuri fiksuoja PCB plokštės vaizdus nustatyta  $1280 \times 1280$  pikselių raiška. Apšvietimo valdymo modulis sudarytas iš RGBW LED apšvietimo ir „Shelly RGBW“ valdiklio, leidžiančio perjungti baltą, raudoną, žalią ir mėlyną apšvietimo režimus. Duomenų apdorojimo ir inferencijos dalį sudaro „Raspberry Pi 5“ ir „Raspberry Pi AI HAT+ 26 TOPS“ modulis, kuriame vykdomi „HAILO8“ aplinkai paruošti „YOLO“ modeliai.

Sistemos veikimo seka yra tokia: pirmiausia pasirenkamas tiriamos PCB plokštės identifikatorius, „YOLO“ modelis ir apšvietimo režimas. Tada įjungiamas pasirinktas RGBW apšvietimas, kamera užfiksuoja PCB vaizdą, o vaizdas perduodamas „YOLO“ modeliui inferencijai atlikti. Modelis nustato aptiktų komponentų klases, koordinates ir pasitikėjimo reikšmes. Gauti rezultatai išsaugomi tekstiniuose arba lenteliniuose rezultatų failuose, kartu su informacija apie naudotą modelį, apšvietimo režimą, PCB orientaciją ir apdorojimo laiką.

Tokia funkcinė struktūra leidžia pakartotinai atlikti tuos pačius bandymus skirtingomis sąlygomis ir palyginti modelių veikimą pagal vienodus kriterijus. Dėl to eksperimentinė AOI sistema naudojama ne tik komponentams aptikti, bet ir „YOLO“ modelių, RGBW apšvietimo bei PCB orientacijos įtakai komponentų atpažinimo kokybei įvertinti.

## 2.2. Techninė įranga: kamera, Raspberry Pi, AI HAT+, RGBW apšvietimas

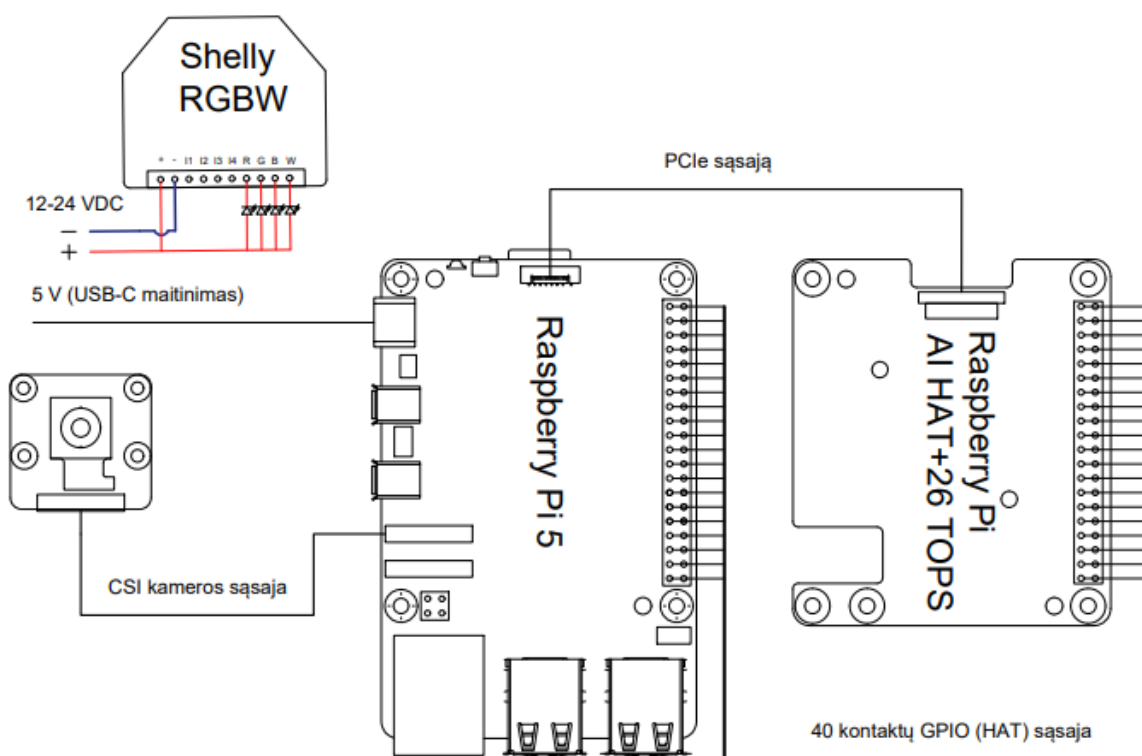
Šiame skyriuje projektuojama ir aprašoma dirbtiniu intelektu paremta spausdintinių plokščių paviršinio montavimo komponentų atpažinimo sistema, naudojanti RGBW apšvietimą ir objektų aptikimo algoritmus. Sistemos pagrindą sudaro „YOLO“ šeimos giliojo mokymosi modeliai, kurie leidžia PCB vaizduose nustatyti komponentų klases, koordinates ir aptikimo pasitikėjimo reikšmes. Sukurta eksperimentinė AOI sistema naudojama standartizuotai PCB vaizdų duomenų bazei sudaryti, YOLO modelių veikimui įvertinti ir komponentų aptikimo kokybei palyginti skirtingomis apšvietimo bei PCB orientacijos sąlygomis. Projekte naudojama įranga:

- „Raspberry Pi 5“ vienplokštis kompiuteris [41]. Naudota 8 GB RAM versija su 128 GB duomenų laikmena, 64 bitų keturių branduolių „Arm Cortex-A76“ procesoriumi, veikiančiu 2,4 GHz dažniu, ir „VideoCore VII“ grafikos procesoriumi. Šis įrenginys naudotas kaip pagrindinis AOI sistemos valdymo ir duomenų apdorojimo modulis. Jis atsakingas už kameros valdymą, vaizdo fiksavimą, vaizdo perdavimą neuroniniam tinklui, „YOLO“ modelių paleidimą, aptikimo rezultatų įrašymą ir naudotojo sąsajos atvaizdavimą.
- „Raspberry Pi AI HAT+“ 26 TOPS modulis [42]. Tai dirbtinio intelekto spartinimo plokštė su „Hailo-8“ spartintuvu, skirta neuroninių tinklų skaičiavimams vykdyti. Modulis leidžia atlikti iki 26 trilijonų operacijų per sekundę ir sumažina pagrindinio „Raspberry Pi 5“ procesoriaus apkrovą. Šiame darbe „AI HAT+“ naudotas „YOLO“ modelių inferencijai vykdyti „HAILO8 / HAILORT“ aplinkoje.
- „Raspberry Pi AI Camera“ [43]. Tai kamera su „Sony IMX500“ 12 MP vaizdo jutikliu, 76° matymo lauku ir rankiniu būdu reguliuojamu fokusavimu. Kamera naudota PCB vaizdams fiksuoti, paviršinio montavimo komponentams vaizde išryškinti ir vienodoms vaizdo gavimo sąlygoms tyrimo metu palaikyti. Eksperimentų metu kameros fokusavimas nustatytas rankiniu būdu ir visų bandymų metu nekeistas.
- RGBW + WW LED juostos komplektas. Apšvietimo sistema naudota baltam, raudonam, žaliai ir mėlynai apšvietimo režimams sudaryti. Šie režimai reikalingi įvertinti, kaip skirtingas šviesos spektras veikia PCB komponentų matomumą ir „YOLO“ modelių aptikimo rezultatus.
- LED juostos valdiklis „Shelly Plus RGBW“ [44]. Valdiklis maitinamas 12–24 V DC įtampa ir leidžia individualiai valdyti RGBW LED kanalus. Valdymas vykdomas per vietinį „Wi-Fi“ tinklą, siunčiant užklausas iš „Raspberry Pi 5“ valdymo programos. Tokiu būdu apšvietimo režimai gali būti keičiami automatiškai, nekeičiant mechaninės sistemos geometrijos.
- IP55 stačiakampė skirstomoji dėžutė, kurios matmenys 300 × 220 × 120 mm. Ji naudota kaip eksperimentinės AOI sistemos korpusas. Korpusas pasirinktas todėl, kad leidžia vienoje uždaroje konstrukcijoje sumontuoti kamerą, RGBW LED apšvietimą, PCB laikymo zoną ir valdymo įrangą. Uždara dėžutės konstrukcija sumažina aplinkos apšvietimo įtaką ir padeda išlaikyti pastovią kameros, apšvietimo bei PCB plokštės tarpusavio padėtį.

Eksperimentinės sistemos parametrai. Kamera ir RGBW LED juosta įmontuotos korpuso viršutinėje dalyje. Korpuso aukštis yra 120 mm, todėl darbinis kameros atstumas iki PCB paviršiaus sudarė apie 105–110 mm, įvertinus kameros modulio ir objektyvo išsikišimą į korpuso vidų. RGBW LED juosta

taip pat pritvirtinta viršutinėje korpuso dalyje, todėl apšvietimo atstumas iki PCB paviršiaus buvo artimas kameros darbiniam atstumui. PCB plokštės buvo dedamos korpuso dugne į tą pačią pažymėtą padėtį, o orientacijos tyrimuose jos buvo pasukamos į iš anksto numatytas padėtis. Visi vaizdai fiksuoti uždarytame korpuse, todėl aplinkos šviesos įtaka buvo sumažinta. „Raspberry Pi 5“ maitintas atskiru 5 V USB-C maitinimo šaltiniu, o RGBW LED apšvietimas ir „Shelly“ valdiklis – atskiru 12–24 V DC maitinimo šaltiniu.

Paveiksle (žr. 18 pav.) pateikta suprojektuotos PCB komponentų atpažinimo AOI sistemos elektros jungimo schema, kurioje pavaizduoti pagrindiniai sistemos komponentai ir jų tarpusavio sąsajos. Sistema sukurta naudojant „Raspberry Pi 5“ kaip centrinį valdymo įrenginį, kuris sujungia vaizdo fiksavimo, duomenų apdorojimo, apšvietimo valdymo ir naudotojo sąsajos modulius. Kamera prijungta prie „Raspberry Pi 5“ naudojant CSI kameros sąsają.



18 pav. Elektros jungimo schema

Dirbtinio intelekto spartinimo modulis „AI HAT+“ prijungtas prie „Raspberry Pi 5“ per 40 kontaktų „GPIO / HAT“ sąsają ir PCIe jungtį. „GPIO / HAT“ sąsaja naudojama modulio maitinimui, mechaniniam integravimui ir valdymo signalams, o PCIe sąsaja, realizuota per FFC tipo juostinį kabelį, naudojama didesnės spartos duomenų perdavimui tarp „Raspberry Pi 5“ ir „Hailo-8“ spartintuvo.

Apšvietimo sistema valdoma „Shelly RGBW“ valdikliu, kuris maitinamas 12–24 V DC šaltiniu ir valdomas per „Wi-Fi“ ryšį. „Raspberry Pi 5“ maitinamas atskiru 5 V USB-C šaltiniu. Atskiras valdymo kompiuterio ir apšvietimo maitinimas pasirinktas siekiant sumažinti įtampos svyravimų įtaką vaizdo fiksavimui ir LED apšvietimo stabilumui.

Visa aprašyta eksperimentinė įranga integruota į vieną korpusą, sudarant vientisą automatizuotos optinės patikros AOI testavimo sistemą. Korpusas užtikrina nekintamą įrangos išdėstymą, fiksuotą

kameros ir PCB plokštės geometriją, pastovų apšvietimo atstumą bei apsaugą nuo išorinių aplinkos veiksnių, tokių kaip aplinkos apšvietimo pokyčiai ar mechaniniai trikdžiai. Įrangos išdėstymas korpuse pateiktas 19 pav.



19 pav. Įranga

Šioje integruotoje sistemoje atliekami tolesni tyrimai, susiję su skirtingų RGBW apšvietimo režimų, „YOLO“ modelių ir PCB orientacijos įtakos komponentų aptikimo kokybei vertinimu. Tokia konstrukcija leidžia sistemą naudoti kaip eksperimentinį AOI stendą, pritaikomą pakartotiniams bandymams ir tolesniam funkciniam plėtimui.

Naudojama kompiuterinė įranga:

- stacionarusis kompiuteris: „AMD Ryzen 5 5600X“ 6 branduolių procesorius, 32 GB RAM ir „NVIDIA GeForce RTX 3060“ 12 GB vaizdo plokštė;
- nešiojamasis kompiuteris: „AMD Ryzen 7 8845HS“ procesorius, 32 GB RAM ir „AMD Radeon 780M“ integruota grafika.


### 2.3. Apšvietimo režimai

Atlikus vaizdų fiksavimą skirtingais RGBW režimais nustatyta, kad kiekvienas apšvietimo režimas išryškina skirtingus PCB plokštės požymius. Todėl RGBW apšvietimas tyrime buvo naudojamas ne tik kaip pagalbinė vaizdo priemonė, bet ir kaip kontroliuojamas eksperimentinis kintamasis, darantis įtaką „YOLO“ modelio komponentų aptikimo rezultatams.

RGBW apšvietimo intensyvumas tyrime buvo nustatytas programiškai, naudojant „Shelly Plus RGBW“ valdiklio ryškumo parametą. Visiems apšvietimo režimams taikyta vienoda valdiklio reikšmė – 30 proc. Ši reikšmė reiškia santykinį valdiklio išėjimo ryškumą, perduodamą RGBW LED juostai per valdiklio vidinį PWM valdymą, o ne fiziškai išmatuotą apšvietimą liuksais. Atskirų spalvų režimuose aktyvuotas tik vienas LED kanalas: baltame režime  $W = 255$ , raudoname  $R = 255$ , žaliame  $G = 255$ , mėlyname  $B = 255$ , o kiti kanalai buvo išjungti. Prieš vaizdo fiksavimą po kiekvieno apšvietimo režimo įjungimo buvo taikoma 10 s stabilizavimo pauzė, kad LED apšvietimas ir kameros


ekspozicijos sąlygos nusistovėtų. Kadangi tyrime nebuvo naudotas liukšmetras, apšvietimo intensyvumas vertintas kaip santykinis valdiklio nustatymas, vienodas visiems lyginamiems RGBW režimams.

Baltas apšvietimas (žr. 20 pav.) tinka bendram PCB komponentų matomumui užtikrinti ir naudojamas kaip pagrindinis režimas. Šiame režime matomas geriausias plokštės vaizdas: PCB pagrindo spalva, komponentai, jungtys, integriniai grandynai, užrašai ir didesni SMD komponentai. Baltas apšvietimas leidžia aiškiausiai įvertinti bendrą komponentų išdėstymą plokštėje, todėl jis tinkamiausias komponentų lokalizavimui. Tyrime baltas režimas yra svarbiausias kaip bazinė sąlyga, nes pagal jį galima vertinti, ar modelis apskritai geba aptikti komponentus AOI stende.



20 pav. Baltas apšvietimas

Raudonas apšvietimas (žr. 21 pav.) išryškina komponentų kontūrus, šešėlius ir objektų siluetus. Šiame režime sumažėja natūralios spalvinės informacijos kiekis, todėl vaizde labiau matomi šviesumo skirtumai tarp komponentų ir PCB pagrindo. Raudoname režime PCB pagrindas tampa beveik vientisas, o komponentai matomi kaip tamsesnės sritys. Tai naudinga tada, kai reikia įvertinti, ar komponentas yra savo vietoje, ar jo kontūras aiškiai atsiskiria nuo plokštės paviršiaus. Raudonas apšvietimas ypač naudingas didesnių tamsių komponentų, integrinių grandynų, lizdų ir jungčių riboms išryškinti.




21 pav. Raudonas apšvietimas

Žalias apšvietimas (žr. 22 pav.) tinka smulkių SMD elementų riboms išryškinti ir jų matomumui PCB paviršiuje pagerinti. Šis režimas išryškina tamsius komponentų korpusus ir leidžia aiškiau matyti jų


kontūrus PCB fone. Taip pat išlaikomas pakankamas bendras plokštės matomumas, tačiau spalvinis skirtumas tarp PCB pagrindo ir apšvietimo sumažėja. Dėl to vaizde labiau dominuoja ne natūrali komponentų spalva, o jų tamsumo, kontūrų ir paviršiaus kontrasto skirtumai.

Vėlesni eksperimentiniai rezultatai patvirtino, kad žalias apšvietimas buvo antras pagal efektyvumą po balto apšvietimo. Naudojant žalią apšvietimą gauti 579 aptikimai, o komponentai aptikti 115 iš 144 vaizdų. Tai rodo, kad žalias režimas nėra toks universalus kaip baltas apšvietimas, tačiau jis gali būti naudingas smulkių SMD komponentų riboms ir tamsių korpusų kontrastui išryškinti.



22 pav. Žalias apšvietimas

Mėlynas apšvietimas (žr. 23 pav.) išryškina litavimo blizgesį, metalinius kontaktus, jungčių paviršius ir atspindžius.



23 pav. Mėlynas apšvietimas

Šiame režime PCB pagrindas tampa tamsesnis, o blizgūs metaliniai paviršiai išsiskiria ryškiau. Mėlyname režime labiausiai matomi šviesos atspindžiai nuo metalinių vietų, tokių kaip USB jungtys, ekranavimo elementai, litavimo aikštelės ir kontaktų zonos.

## 2.4. Programinė įranga ir duomenų srautai

Apmokytiesiems „YOLO“ šeimos modeliams pritaikyti eksperimentinėje AOI sistemoje naudota įterptinė vykdymo aplinka, sudaryta iš „Raspberry Pi 5“, „Raspberry Pi AI HAT+“ 26 TOPS“ modulio, „Raspberry Pi AI Camera“ su „Sony IMX500“ jutikliu, RGBW apšvietimo ir „Shelly RGBW“ valdiklio. Sistema skirta PCB vaizdams fiksuoti, apšvietimo režimams valdyti, „YOLO“ modelių inferencijai vykdyti ir aptikimo rezultatams atvaizduoti. Apmokytų modelių paruošimo ir vykdymo grandinė (žr. 24 pav.) kuriame parodyta, kaip „Ultralytics“ aplinkoje apmokytas .pt modelis per „DeGirum Cloud Compiler“ paruošiamas „HAILO8“ aplinkai, sukompiliuojamas į .hef formatą ir vykdomas „Raspberry Pi AI HAT+“ 26 TOPS modulyje.

Pagrindinis „YOLO“ modelio vykdymas atliekamas per „Raspberry Pi“ „AI HAT+ 26 TOPS“ modulį, kuriame naudojamas „Hailo-8“ neuroninių tinklų spartintuvas. Todėl modelio skaičiavimai atliekami ne „Raspberry Pi 5“ procesoriuje, o atskirame DI spartinimo modulyje.


„Raspberry Pi AI Camera“ šiame darbe naudojama atskirai kaip vaizdo fiksavimo modulis, skirtas PCB plokščių nuotraukoms gauti. Kameros vidinis „Sony IMX500“ neuroninių tinklų spartintuvas gali būti naudojamas atskiram modelio vykdymo režimui, tačiau jis nėra naudojamas su „AI HAT+“ skirtu .hef formatu. Pagrindiniame tyrimo vykdymo kelyje „YOLO“ modelio inferencija atliekama per „AI HAT+“ modulį, kuriame naudojamas „Hailo-8“ spartintuvas ir \*.hef modelio failas. „IMX500“ kameroje modeliai vykdomi tik naudojant jai pritaikytą atskirą modelio formatą, todėl tas pats .hef failas negali būti tiesiogiai naudojamas kameros spartintuve.

RGBW apšvietimas valdomas naudojant „Shelly RGBW“ valdiklį. „Raspberry Pi 5“ apšvietimo režimus valdo siųsdamas HTTP užklausas į „Shelly RGBW“ valdiklį, todėl tyrimo metu galima automatiškai įjungti baltą, raudoną, žalią arba mėlyną apšvietimą ir įvertinti jų įtaką PCB komponentų matomumui bei „YOLO“ aptikimo rezultatams.

Naudota programinė aplinka:

- „Raspberry Pi OS“ 64 bitų [51] operacinė sistema, įdiegta „Raspberry Pi 5“ įrenginyje;
- „Raspberry Pi Imager“ [52], naudotas operacinei sistemai į „microSD“ laikmeną įrašyti;
- „Python“ 3 [53], naudotas kameros, apšvietimo, modelio paleidimo ir rezultatų apdorojimo scenarijams įgyvendinti;
- „Picamera2“ [54], naudota „Raspberry Pi AI Camera“ kamerali valdyti ir 1 280 × 1 280 px vaizdai fiksuoti;
- „rpicam-apps“ [55], naudota kameros veikimui įgyvendinti bei demonstraciniams modeliams ir sisteminiams bandymams atlikti;
- „OpenCV“ [56], naudota vaizdams apdoroti ir aptikimo rezultatams atvaizduoti;
- „HailoRT“ / „hailo-all“ [57, 58], naudota „Raspberry Pi“ AI HAT+ 26 TOPS modulio tvarkyklėms ir vykdymo aplinkai realizuoti;
- „DeGirum PySDK“ [58], naudota „DeGirum Cloud Compiler“ paruoštam „HAILORT / HAILO8“ modeliui „Raspberry Pi“ sistemoje paleisti;
- „Requests“ [59] biblioteka, naudota „Shelly RGBW“ apšvietimui HTTP užklausomis valdyti;
- „Ultralytics Platform“ [46] naudota „YOLO“ šeimos modeliams apmokyti ir \*.pt formato modeliams eksportuoti;
- „Roboflow“ [45] naudota duomenų rinkiniui paruošti, vaizdams anotuoti ir duomenų bazei sudaryti.


Modeliai „Raspberry Pi“ sistemoje nėra apmokomi. Jie apmokomi „Ultralytics Platform“ aplinkoje, o „Raspberry Pi 5“ naudojamas tik programai vykdyti. Modelio paruošimo kelias pateiktas 35 paveiksle.



24 pav. „Hailo-8“ formato paruošimo kelias

Paveiksle (žr. 24 pav.) pateikta apmokyto „YOLO“ modelio paruošimo grandinė, skirta vykdymui eksperimentinėje AOI sistemoje. Pirmiausia „Ultralytics“ aplinkoje apmokytas modelis išsaugomas .pt formatu. Toliau modelis perduodamas į „DeGirum Cloud Compiler“ aplinką, kur jis paruošiamas ir sukompilijuojamas „HAILORT / HAILO8“ vykdymui. Kompiliavimo rezultatas yra „Hailo“ .hef formato modelis, kuris įkeliamas į „Raspberry Pi 5“ sistemą ir vykdomas naudojant „Raspberry Pi AI HAT+“ 26 TOPS modulį. Tokia grandinė leidžia atskirti modelio apmokymo etapą nuo modelio vykdymo etapo: modelis apmokomas kompiuterinėje aplinkoje, o realiaame AOI stende inferencija atliekama įterptinėje sistemoje su „Hailo-8“ spartintuvu.

- „IMX500“ formatas – naudojamas tik tuo atveju, jeigu modelį būtų norima vykdyti pačioje „Raspberry Pi AI Camera“ kameroje.



25 pav. „IMX500“ formato paruošimo kelias

„AI HAT+“ ir „AI Camera“ vidinis „IMX500“ spartintuvas nenaudojami kartu tam pačiam modeliui vykdyti, nes šie įrenginiai naudoja skirtingas modelių paruošimo ir vykdymo grandines. „AI HAT+“ modulis naudoja „Hailo-8“ spartintuvui skirtą \*.hef formatą, o „Sony IMX500“ kamera reikalauja atskiro „IMX500“ modelio formato. Todėl tas pats \*.hef modelis negali būti tiesiogiai vykdomas „AI Camera“ vidiniame spartintuve, o „IMX500“ skirtas modelis negali būti naudojamas „AI HAT+“ modulyje.

## 2.5. Duomenų rinkinio sudarymas ir anotavimas

Duomenų rinkinys buvo sudarytas naudojant „Roboflow“ platformą [45]. Pradinę vaizdų bazę sudarė 8 155 PCB plokščių nuotraukos be anotacijų. Toliau šios nuotraukos buvo paruoštos objektų aptikimo modelio apmokymui: atliktas duomenų išankstinis apdorojimas (angl. preprocessing):

- automatinė orientacija;
- dydžio keitimas – vaizdas turėjo tilpti į  $640 \times 640$  pikselius.

Duomenų plėtiniai (angl. *augmentations*) naudoti, siekiant padidinti mokymo duomenų įvairovę ir pagerinti modelio gebėjimą apibendrinti skirtingas PCB vaizdų sąlygas AOI sistemoje:

- išvestys vienam mokymo pavyzdžiui – 5;
- apvertimas: horizontaliai ir vertikalčiai;
- $90^\circ$  pasukimas: pagal laikrodžio rodyklę, prieš laikrodžio rodyklę ir apverčiant  $180^\circ$ ;
- pasukimas – nuo  $-15^\circ$  iki  $+15^\circ$ ;

- pilkos spalvos taikymas – 15 proc. vaizdų;
- triukšmas – iki 1,92 proc. pikselių.


Po duomenų išankstinio apdorojimo ir plėtinių pritaikymo suformuotas 34 447 anotuotų vaizdų duomenų rinkinys, kuriame iš viso pateiktos 305 073 anotacijos. Šis rinkinys suskirstytas į 32 818 mokymo (angl. *train*) vaizdų, 815 validacijos (angl. *validation*) vaizdų ir 814 testavimo (angl. *test*) vaizdų. Toks pasiskirstymas sudaro apie 95,3 proc. mokymo, 2,4 proc. validacijos ir 2,4 proc. testavimo duomenų. Validacijos ir testavimo rinkiniai yra mažesni, nes duomenų plėtiniai daugiausia buvo taikyti mokymo rinkiniui, o validacijos ir testavimo duomenys palikti mažiau modifikuoti, kad modelio veikimas būtų vertinamas su nepriklausomais vaizdais.

Duomenų rinkinyje yra šios elektronikos komponentų klasės, kurios apima dažniausiai paviršinio montavimo technologijoje (SMT) naudojamus elementus, tokius kaip:

- baterija (angl. *battery*) – elektrocheminis energijos šaltinis, skirtas tiekti nuolatinę įtampą ir maitinti elektronines grandines;
- induktorius (ritė) (angl. *inductor*) – komponentas, kaupiantis energiją magnetiniame lauke, naudojamas filtravimui, energijos kaupimui ir galios keitimo grandinėse;
- IC (angl. *integrated circuit*) integrinis grandynas – mikroelektroninis lustas, atliekantis skaitmenines arba analogines valdymo, skaičiavimo ar signalų apdorojimo funkcijas;
- jungtis (angl. *connector*) – komponentas, skirtas laidams, kabeliams ar kitoms plokštėms prijungti prie spausdintinės plokštės (PCB);
- kondensatorius (angl. *capacitor*) – komponentas, kaupiantis elektrinį krūvį ir naudojamas įtampos stabilizavimui, filtravimui bei signalų formavimui;
- kvarcinis rezonatorius (angl. *crystal resonator*) – komponentas, generuojantis stabilų dažninį signalą, naudojamą laikrodinėse ir sinchronizavimo grandinėse;
- LCD ekranas (angl. *liquid crystal display*) – skystųjų kristalų ekranas, naudojamas vizualiai informacijai atvaizduoti;
- LED (angl. *light emitting diode*) šviesos diodas – puslaidininkinis komponentas, skleidžiantis šviesą tekant srovei, naudojamas indikacijai arba apšvietimui;
- mygtukas (angl. *push button*) – mechaninis valdymo komponentas, skirtas trumpalaikiam elektrinės grandinės sujungimui;
- potenciometras (angl. *potentiometer*) – kintamos varžos komponentas, naudojamas įtampai reguliuoti arba signalui valdyti;
- relė (angl. *relay*) – elektromechaninis arba puslaidininkinis jungiklis, leidžiantis mažu valdymo signalu valdyti didesnes apkrovas;
- rezistorius (varža) (angl. *resistor*) – elektroninis komponentas, skirtas srovei riboti, įtampai dalyti ar signalams formuoti;
- saugiklis (angl. *fuse*) – apsauginis komponentas, nutraukiantis grandinę esant per didelei srovei;
- SMD kondensatorius (angl. *surface mount capacitor*) – paviršinio montavimo kondensatorius, naudojamas kompaktiškose elektroninėse grandinėse filtravimui realizuoti ir stabilizavimui užtikrinti;
- SMD rezistorius (angl. *surface mount resistor*) – paviršinio montavimo rezistorius, skirtas srovei riboti ir signalams formuoti miniatiūrinėse grandinėse;
- tantalinis kondensatorius (angl. *tantalum capacitor*) – kondensatoriaus tipas, pasižymintis dideliu talpumu ir stabilumu, naudojamas maitinimo grandinėse;

- toroidinis induktorius (angl. *toroidal inductor*) – induktoriaus tipas su žiedine šerdimi, pasižymintis mažais elektromagnetiniais nuostoliais ir efektyviu filtravimu;
- tranzistorius MOSFET (angl. *metal-oxide-semiconductor field-effect transistor*) – puslaidininkinis komponentas, naudojamas signalams stiprinti arba kaip elektroninis jungiklis galios grandinėse;
- TVS diodas (angl. *transient voltage suppressor diode*) – apsauginis komponentas, skirtas slopinti įtampos šuolius ir apsaugoti grandines nuo viršįtampių.

Šių komponentų klasių pasiskirstymas pagal jų kiekį duomenų rinkinyje pateikiamas 26 paveiksle, kuriame grafiškai atvaizduota kiekvienos klasės apimtis.



26 pav. Komponentų klasių kiekis „1“

Iš 26 paveikslo matyti, kad duomenų rinkinyje komponentų klasės pasiskirsčiusios netolygiai. Didžiausią dalį sudaro SMD kondensatoriai – 112 103 anotacijos ir SMD rezistoriai – 104 381 anotacija. Kartu šios dvi klasės sudaro apie 70,9 proc. visų anotacijų. Trečia pagal kiekį klasė yra integriniai grandynai – 28 474 anotacijos. Mažiausiai atstovaujamos klasės yra LCD ekranas – 75 anotacijos, relė – 160 anotacijų, baterija – 162 anotacijos, saugiklis – 231 anotacija ir potenciometas – 308 anotacijų.

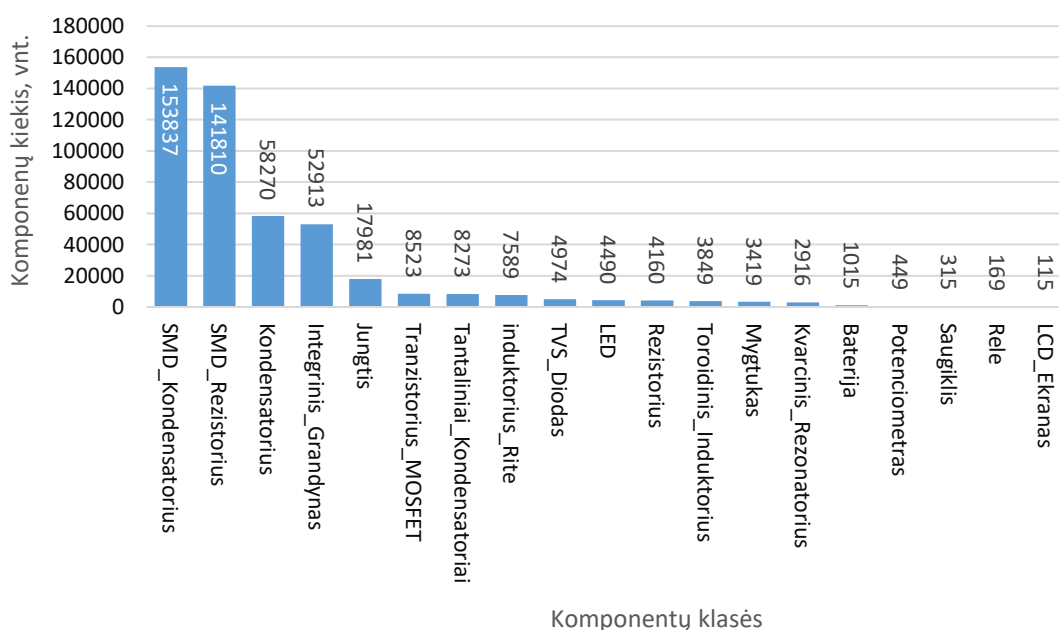
Toks klasių disbalansas gali turėti įtakos modelio mokymosi rezultatams. Modelis mokymo metu gauna daugiau pavyzdžių iš dažniausiai pasitaikančių klasių, todėl SMD kondensatorių, SMD rezistorių ir integrinių grandynų aptikimas gali būti stabilesnis. Tuo tarpu retai pasitaikančių klasių, tokių kaip LCD ekranas, relė, baterija ar saugiklis, aptikimo tikslumas gali būti mažesnis, nes modelis turi mažiau pavyzdžių šių komponentų požymiams išmokti. Dėl šios priežasties realaus AOI stendo rezultatus reikia vertinti ne tik pagal bendrą aptikimų skaičių, bet ir pagal tai, kokios komponentų klasės buvo geriausiai atstovaujamos mokymo duomenyse.

Paruoštas duomenų rinkinys buvo naudojamas „Roboflow“ aplinkoje pradiniam objektų aptikimo modeliui apmokyti. Apmokymui pasirinktas „Roboflow 3.0 Object Detection Accurate“ modelis, kuris buvo skirtas elektronikos komponentų klasėms ir jų koordinatėms PCB vaizduose nustatyti. Apmokytas modelis pasiekė: mAP@50 – 93,1 proc., mAP@50:95 – 80,0 proc., tikslumą – 93,0 proc., atgavimo rodiklį – 85,8 proc. Toliau šis modelis panaudotas duomenų bazei išplėsti, siekiant pagerinti mokymo duomenų apimtį ir kokybę, reikalingą „YOLO“ šeimos modelių apmokymui šiame tyrime įgyvendinti.

Išplėsta duomenų bazė apima 54 534 anotuotas nuotraukas, kuriose iš viso identifikuotos 475 067 anotacijos. Duomenų bazei plėsti naudotas stacionarusis kompiuteris su „AMD Ryzen 5 5600X“ 6 branduolių procesoriumi, 32 GB RAM ir „NVIDIA GeForce RTX 3060“ 12 GB vaizdo plokšte. Papildomos nuotraukos buvo anotuojamos naudojant „Python“ programavimo kalbos kodą ir iš anksto apmokyto „Roboflow“ objektų aptikimo modelio svorius.

Tokiu būdu sugeneruotos anotacijos laikomos pseudoanotacijomis, nes pirminės komponentų žymos buvo gautos automatiškai, remiantis modelio prognozėmis. Siekiant sumažinti klaidingų arba praleistų žymėjimų riziką, visos automatiškai sugeneruotos anotacijos buvo patikrintos rankiniu būdu. Rankinės patikros metu buvo vertinama, ar komponentams priskirtos teisingos klasės, ar ribojantys stačiakampiai atitinka komponentų padėtį vaizde ir ar nėra praleistų arba klaidingai pažymėtų objektų. Po rankinės patikros duomenų rinkinys naudotas galutiniams YOLO šeimos modeliams apmokyti, todėl pseudoanotacijų klaidų įtaka modelių mokymo rezultatams buvo sumažinta.

Duomenų rinkinys „2“ buvo suskirstytas į tris dalis: mokymo – 48 566 vaizdai (80,0 proc.), validacijos – 6 069 vaizdai (10,0 proc.) ir testavimo – 6 073 vaizdai (10,0 proc.). 27 paveiksle pateiktas elektronikos komponentų klasių pasiskirstymas duomenų bazėje.



27 pav. Komponentų klasių kiekis „2“

Iš 27 paveikslo matyti, kad galutiniame duomenų rinkinyje komponentų klasės pasiskirsčiusios netolygiai. Daugiausia anotacijų sudaro SMD kondensatoriai – 153 837 anotacijos, SMD rezistoriai – 141 810 anotacijų ir kondensatoriai – 58 270 anotacijų. Šios trys klasės sudaro didžiąją dalį visų duomenų rinkinio anotacijų, todėl modelis mokymo metu gauna daugiau pavyzdžių būtent šių komponentų požymiams išmokti.

Mažiausiai atstovaujamos klasės yra LCD ekranas – 115 anotacijų, relė – 169 anotacijos ir saugiklis – 315 anotacijų. Dėl tokio klasių disbalanso modelis gali geriau atpažinti dažniausiai pasitaikančius komponentus, tačiau retesnių klasių aptikimo tikslumas gali būti mažesnis. Tai svarbu vertinant realaus AOI stendo rezultatus, nes mažesnis kai kurių komponentų aptikimų skaičius gali būti susijęs ne tik su pasirinktu „YOLO“ modeliu ar apšvietimu, bet ir su tuo, kad šių klasių pavyzdžių mokymo duomenų rinkinyje buvo mažiau.

## 2.6. YOLO modelių paruošimas ir apmokymas

Šiame poskyryje pateikiamas tyrime naudotų „YOLO“ šeimos objektų aptikimo modelių aprašymas ir jų apmokymo proceso analizė. Modeliai parinkti siekiant įvertinti skirtingų architektūrinių sprendimų efektyvumą elektronikos komponentų aptikimo užduotyje, taikomoje eksperimentinėje AOI sistemoje. Toliau aptariami modelių architektūriniai ypatumai, apmokymo parametrai ir eksperimentiniai rezultatai, gauti mokymo metu.

„YOLOv5mu“ [47] yra patobulinta „YOLOv5“ modelio versija, kurioje integruota be atraminių langelių (angl. *anchor-free*) ir be objektiškumo įverčio (angl. *objectness-free*) veikianti išskaidytos aptikimo galvos (angl. *split head*) architektūra. Šis sprendimas leidžia efektyviau lokalizuoti objektus ir pagerina tikslumo bei skaičiavimo greičio santykį realaus laiko objektų aptikimo užduotyse. Lyginant su tradiciniu „YOLOv5“ modeliu, „YOLOv5u“ pasižymi didesniu lankstumu ir adaptyvumu įvairiuose scenarijuose.

„YOLOv8“ [48] yra objektų aptikimo modelių šeima, sukurta siekiant pagerinti realaus laiko aptikimo našumą, pasitelkiant modernias architektūrinės savybes. Modelyje naudojamos požymių išgavimo (angl. *backbone*) ir jų sujungimo (angl. *neck*) struktūros bei be atraminių langelių (angl. *anchor-free*) veikianti „split head“ aptikimo galva, leidžianti efektyviau lokalizuoti objektus ir pagerinti aptikimo tikslumą.

„YOLOv11“ [49] yra objektų aptikimo modelis, pasižymintis patobulinta architektūra, leidžiančia efektyviau išgauti vaizdo požymius ir tiksliau identifikuoti objektus. Modelyje naudojamos modernizuotos požymių išgavimo ir jų apdorojimo struktūros bei optimizuoti mokymo metodai, užtikrinantys didesnę veikimo greitį ir subalansuotą tikslumo bei našumo santykį. Dėl pažangių architektūrinių sprendimų „YOLOv11m“ pasiekia aukštesnę vidutinio tikslumo mAP reikšmę, naudodamas mažesnę parametru skaičių nei ankstesni modeliai, todėl yra skaičiavimo požiūriu efektyvus neprarandant tikslumo.

Šiame darbe nagrinėjamas „YOLOv26“ modelis [50], priklausantis „YOLO“ šeimos objektų aptikimo modeliams. Modelis pasižymi supaprastinta nuo pradžios iki pabaigos veikiančia (angl. *end-to-end*) architektūra, kurioje atsisakoma ne maksimalumo slopinimo NMS (angl. *non-maximum suppression*) etapo. Dėl to prognozės gali būti generuojamos tiesiogiai, sumažinant papildomo apdorojimo poreikį, delsos laiką ir skaičiavimo sąnaudas. Modelyje naudojamas „MuSGD“ optimizatorius, skirtas stabilesniam mokymui ir greitesnei konvergencijai užtikrinti. Taip pat

pateikiami patobulinimai segmentavimo, pozų nustatymo ir orientuotų objektų aptikimo užduotims. Šaltinyje [50] nurodoma, kad „YOLOv26“ gali pasiekti iki 43 proc. greitesnę inferenciją naudojant centrinių procesorių CPU, todėl modelis gali būti taikomas kraštiniuose įrenginiuose ir sistemose su ribotais skaičiavimo ištekliais. „YOLO“ šeimos modelių apmokymas buvo atliktas naudojant „Ultralytics“ platformą. Modeliai buvo apmokomi naudojant pirminę duomenų bazę, kurią sudaro 32 818 vaizdų mokymo, 815 validacijos ir 814 testavimo rinkiniai.

Mokymo metu buvo atlikti keli „YOLO“ šeimos modelių apmokymo etapai, keičiant duomenų rinkinio dydį, įvesties vaizdo raišką ir mokymo parametrus. Šiame poskyryje aprašoma modelių paruošimo ir apmokymo eiga, o kiekybiniai mokymo rezultatų palyginimai pateikiami 3.1 poskyryje.

Tyrimo buvo mokomi keturi objektų aptikimo modeliai: „YOLOv5MU“, „YOLOv8M“, „YOLOv11M“ ir „YOLOv26M“. Šie modeliai pasirinkti siekiant palyginti skirtingų „YOLO“ šeimos architektūrų pritaikomumą paviršinio montavimo elektronikos komponentams aptikti PCB vaizduose. Visi modeliai buvo skirti komponento klasei, koordinatėms ir aptikimo pasitikėjimo reikšmei nustatyti.

Modelių apmokymui naudoti du duomenų rinkiniai. Pirmuosiuose apmokymo etapuose naudota pradinė duomenų bazė, sudaryta iš 32 818 mokymo, 815 validacijos ir 814 testavimo vaizdų. Vėlesniuose apmokymo etapuose naudota išplėsta duomenų bazė, kurią sudarė 54 534 anotuoti vaizdai ir 475 067 anotacijos. Išplėstas duomenų rinkinys buvo suskirstytas į mokymo, validacijos ir testavimo dalis: 48 566 vaizdai skirti mokymui, 6 069 – validacijai ir 6 073 – testavimui.

Modelių mokymas buvo vykdomas keliais etapais. Pirmajame etape naudota  $640 \times 640$  pikselių įvesties vaizdų raiška, 100 epochų ir ankstyvojo stabdymo kriterijus „patience“ = 20. Antrajame etape buvo tikrinama didesnė ankstyvojo stabdymo reikšmė „patience“ = 50, siekiant įvertinti, ar ilgesnis mokymas pagerina modelių apibendrinimo gebėjimą.

Trečiajame etape naudota išplėsta duomenų bazė,  $640 \times 640$  pikselių raiška, 100 epochų ir „patience“ = 30. Ši reikšmė pasirinkta kaip kompromisas tarp per ankstyvo mokymo sustabdymo ir perteklinio mokymo trukmės didinimo. Šiame etape taip pat taikytas perkėlimo mokymasis (angl. transfer learning), kai kaip pradinė būseną buvo naudojami ankstesnio apmokymo etapo modelių svoriai.

Ketvirtajame apmokymo etape naudota  $1\,280 \times 1\,280$  pikselių įvesties vaizdų raiška, 100 epochų ir „patience“ = 30. Mokymas tęstas taikant perkėlimo mokymąsi, kai kaip pradinė būseną buvo naudojami trečiojo apmokymo etapo modeliai. Didesnė raiška pasirinkta todėl, kad PCB plokštėse esantys SMD komponentai yra smulkūs ir tankiai išdėstyti, todėl didesnis vaizdo detalumas leidžia geriau išsaugoti komponentų kontūrus ir pagerinti jų lokalizavimą. Kartu ši raiška padidina skaičiavimo sąnaudas ir mokymo trukmę, todėl ji vertinama kaip kompromisas tarp aptikimo kokybės ir praktinio taikymo AOI sistemoje.

Po apmokymo modeliai buvo paruošti vykdyti eksperimentinėje AOI sistemoje. „Ultralytics“ aplinkoje apmokyti modeliai pradiniam etape buvo saugomi .pt formatu. Kad modeliai galėtų veikti „Raspberry Pi AI HAT+“ modulyje, jie buvo konvertuojami ir kompiliuojami į „Hailo-8“ spartintuvui pritaikytą .hef formatą. Galutiniame AOI stende inferencija vykdyta naudojant „HAILORT / HAILO8“ aplinką ir „Raspberry Pi AI HAT+“ 26 TOPS modulį.

## 2.7. Kokybės vertinimo algoritmo struktūra

Šiame skyriuje aprašoma eksperimentinės AOI sistemos komponentų aptikimo algoritmo struktūra. Algoritmas skirtas PCB vaizdams fiksuoti, RGBW apšvietimui valdyti, „YOLO“ modelių inferencijai vykdyti ir aptikimo rezultatams išsaugoti. Vertinami pagrindiniai parametrai: aptikimų skaičius, komponento klasė, koordinatės, pasitikėjimo reikšmė ir inferencijos trukmė.

Sistemoje numatyti du veikimo režimai: realaus laiko AOI režimas ir stacionaraus kadro analizės režimas. Realaus laiko režimas naudojamas vaizdui stebėti ir rezultatams iškart atvaizduoti, o stacionaraus kadro režimas skirtas pakartojamiems bandymams, kai išsaugomi pradiniai vaizdai, anotuoti rezultatai ir CSV duomenys. Tokia struktūra leidžia palyginti skirtingų „YOLO“ modelių, RGBW apšvietimo ir PCB orientacijos įtaką komponentų aptikimui.

### 2.7.1. Realaus laiko AOI vykdymo režimas su RGBW apšvietimo valdymu

Realaus laiko AOI vykdymo režimas šiame darbe naudojamas kaip sistemos derinimo ir demonstracinis režimas. Jis skirtas patikrinti, ar teisingai veikia kamera, RGBW apšvietimo valdymas, „HAILORT / HAILO8“ modelio įkėlimas, „Raspberry Pi AI HAT+“ inferencija ir rezultatų atvaizdavimas „OpenCV“ lange. Šiuo režimu operatorius gali realiuoju laiku keisti apšvietimo spalvą, stebėti komponentų aptikimus ir įvertinti kameros fokusavimą bei apšvietimo tinkamumą prieš atliekant pagrindinius eksperimentus.

Pagrindiniai eksperimentiniai duomenys šiame darbe renkami stacionaraus kadro AOI analizės režimu, nes jame kiekvienam bandymui išsaugomas neapdorotas PCB vaizdas, anotuotas rezultatas ir CSV faile registruojami aptikimo duomenys. Todėl realaus laiko režimas nėra naudojamas kaip pagrindinis kiekybinių rezultatų rinkimo metodas, o taikomas sistemos veikimui patikrinti, derinti ir vizualiai demonstruoti.

Programoje numatyta galimybė pasirinkti vieną iš keturių „HAILORT / HAILO8“ vykdymui paruoštų „YOLO“ šeimos modelių:

- „YOLOv5m“, 1280 × 1280, „HAILORT / HAILO8“;
- „YOLOv8m“, 1280 × 1280, „HAILORT / HAILO8“;
- „YOLOv11m“, 1280 × 1280, „HAILORT / HAILO8“;
- „YOLOv26m“, 1280 × 1280, „HAILORT / HAILO8“.

Modeliai saugomi vietiniame kataloge: „~/aoi\_pcb/models“.

Prieš įkeliant pasirinktą modelį, programa patikrina, ar modelio aplanke yra \*.json ir \*.hef failai. \*.json failas naudojamas modelio konfigūracijai aprašyti, o \*.hef failas yra „Hailo“ spartintuvui sukompiliuotas vykdymo failas. Jeigu bent vieno iš šių failų nėra, programa pateikia klaidos pranešimą ir modelio nepaleidžia.

Modelis įkeliamas naudojant „DeGirum PySDK“ bibliotekos funkciją „dg.load\_model()“. Modeliui vykdyti nurodomas lokalus inferencijos režimas „inference\_host\_address="@local"“.

Neuroninio tinklo skaičiavimai atliekami vietinėje „Raspberry Pi“ sistemoje, naudojant „HAILORT / HAILO8“ vykdymo aplinką ir „Raspberry Pi AI HAT+“ modulį. Visi modeliai vykdomi su 1 280 × 1 280 pikselių įvesties raiška.

Programoje naudota diagnostinė aptikimo riba „CONF\_THRESHOLD = 0,01“, skirta užregistruoti visus modelio gražinamus aptikimus, įskaitant mažo pasitikėjimo prognozes. Tai leido patikrinti modelių veikimą skirtingomis apšvietimo ir PCB orientacijos sąlygomis. Rezultatų analizėje patikimesniems aptikimams papildomai taikoma 0,1 pasitikėjimo riba, todėl 0,01 laikoma diagnostine registravimo riba, o 0,1 – praktinio vertinimo kriterijumi.

Toks slenkstis pasirinktas diagnostikos tikslu. Jis leidžia patikrinti, ar modelis gražina aptikimus, net jei jo pasitikėjimo reikšmė yra labai maža. Tai naudinga derinant modelio paleidimą, kameros vaizdo formatą, apšvietimą ir „HAILORT / HAILO8“ vykdymo aplinką. Galutiniams rezultatams vertinti toks žemas slenkstis nėra optimalus, nes gali padidinti klaidingų aptikimų kiekį. Todėl eksperimentinių rezultatų palyginime gali būti papildomai taikomas didesnis slenkstis.

Kamera valdoma naudojant „Picamera2“ biblioteką. Vaizdas fiksuojamas RGB888 formatu, 1280 × 1280 pikselių raiška. Kadangi „OpenCV“ ir „DeGirum“ modelio vykdymas su „image\_backend="opencv"“ naudoja BGR spalvų formatą, prieš inferenciją vaizdas konvertuojamas iš RGB į BGR formatą. Tai atliekama naudojant komandą „cv2.cvtColor(frame\_rgb, cv2.COLOR\_RGB2BGR)“.

Papildomai programoje įtraukta spalvų atvaizdavimo korekcija „CONVERT\_OVERLAY\_RGB\_TO\_BGR = True“. Ji reikalinga tam, kad rezultatų lange fizinės LED apšvietimo spalvos būtų rodomos teisingai. Tai svarbu, nes neteisinga RGB ir BGR kanalų tvarka gali iškraipyti atvaizduojamas spalvas ir apsunkinti skirtingų apšvietimo režimų palyginimą.

RGBW LED apšvietimas valdomas per „Shelly RGBW“ valdiklį, kuris prijungtas prie vietinio belaidžio tinklo. Apšvietimo režimai keičiami iš „Raspberry Pi 5“ siunčiant HTTP užklausas į valdiklį. Kadangi naudojamas GEN2 tipo „Shelly“ valdiklis, apšvietimui valdyti taikomas RPC metodas RGBW.Set.

Tokiu būdu programoje galima įjungti arba išjungti apšvietimą, nustatyti RGBW kanalų reikšmes ir reguliuoti šviesos ryškumą. Programoje apibrėžti keturi apšvietimo režimai (žr. 30 lentelę). Visiems režimams nustatyta vienoda „Shelly RGBW“ valdiklio programinė ryškumo reikšmė – 30 proc. Ši reikšmė reiškia ne fiziškai išmatuotą apšvietą liuksais, o santykinį valdiklio ryškumo nustatymą, perduodamą „Shelly“ valdikliui kaip bendras LED išėjimo ryškumo parametras.

**30 lentelė.** Apšvietimo režimai

Apšvietimo režimas	RGBW reikšmė	Ryškumas, proc.
Baltas	(0, 0, 0, 255)	30
Raudonas	(255, 0, 0, 0)	30
Žalias	(0, 255, 0, 0)	30
Mėlynas	(0, 0, 255, 0)	30

Vienoda 30 proc. ryškumo reikšmė pasirinkta empiriškai, atliekant pirminius vaizdo fiksavimo bandymus. Didesnis ryškumas sukeldavo stipresnius atspindžius nuo metalizuotų kontaktinių aikštelių, litavimo vietų ir jungčių, todėl pablogėdavo komponentų kontūrų matomumas. Mažesnis ryškumas nepakankamai išryškindavo smulkius SMD komponentus. Todėl 30 proc. reikšmė pasirinkta kaip kompromisas tarp pakankamo PCB apšvietimo ir sumažinto vaizdo persotinimo. Kadangi visiems režimams taikyta ta pati ryškumo reikšmė, tyrime lyginama apšvietimo spalvos, o ne skirtingo intensyvumo įtaka komponentų aptikimo rezultatams.

Pakeitus apšvietimo režimą, programa laukia 10 sekundžių „LIGHT\_STABILIZATION\_TIME = 10“. Šis stabilizavimo laikas parinktas empiriškai, įvertinus RGBW LED juostos ir „Shelly RGBW“ valdiklio veikimą. Perjungiant apšvietimo režimą, ankstesnis LED kanalas neišsijungia momentiška, o naujas kanalas įsijungia palaipsniui. Todėl, siekiant išvengti tarpinių apšvietimo būsenų ir užtikrinti, kad vaizdas būtų fiksuojamas jau nusistovėjus pasirinktam apšvietimo režimui, prieš inferenciją taikoma 10 sekundžių pauzė. Kamera po paleidimo papildomai stabilizuojama 2 sekundes „CAMERA\_WARMUP\_TIME = 2“, kad prieš vaizdo fiksavimą nusistovėtų kameros veikimo režimas.

Programoje numatyti du darbo režimai: rankinis ir automatinis. Rankiniu režimu naudotojas gali pasirinkti apšvietimo spalvą ir išsaugoti einamąjį rezultatą. Valdymas atliekamas „OpenCV“ lange naudojant klaviatūros komandas:

- 1 – baltas apšvietimas;
- 2 – raudonas apšvietimas;
- 3 – žalias apšvietimas;
- 4 – mėlynas apšvietimas;
- 0 – apšvietimas išjungiamas;
- s – išsaugomas einamasis rezultatas;
- q – programa sustabdoma.

Automatinis režimas paleidžiamas paspaudus „A“ klavišą. Šiuo režimu programa iš eilės įjungia baltą, raudoną, žalią ir mėlyną apšvietimus. Kiekvienam apšvietimo režimui atliekama inferencija, o gautas vaizdas automatiškai išsaugomas rezultatų kataloge. Tokia seka leidžia tą pačią PCB plokštę tirti keičiant tik apšvietimo spalvą.

Kiekvienos inferencijos metu apskaičiuojamas modelio vykdymo laikas milisekundėmis. Ši reikšmė pateikiama ant rezultatų vaizdo kartu su modelio pavadinimu ir naudotu apšvietimo režimu. Papildomai terminale išvedamas aptikimų skaičius „{len(detections)}“.

Ši diagnostinė eilutė leidžia įvertinti, ar modelis grąžina aptikimus prie konkretaus apšvietimo režimo ir pasirinktos pasitikėjimo ribos. Jeigu aptikimų skaičius lygus nuliui, galima tikrinti modelio suderinamumą, įvesties formatą, apšvietimą, kameros fokusavimą arba \*.hef modelio veikimą. Aptikti objektai terminale pateikiami nurodant naudotą modelį, apšvietimo režimą, komponento klasę, pasitikėjimo reikšmę ir ribojančio stačiakampio koordinatas. Jeigu DeGirum biblioteka grąžina vaizdą su aptikimo žymomis, naudojamas „result.image\_overlay“. Jeigu šis metodas neveikia, naudojama atsarginė „draw\_fallback()“ funkcija, kuri su „OpenCV“ nubrėžia ribojančius stačiakampius ir šalia jų pateikia klasės pavadinimą bei pasitikėjimo reikšmę. Rezultatai išsaugomi kataloge „~/aoi\_pcb/results“.

Failo pavadinime automatiškai įrašomas PCB plokštės identifikatorius, naudotas modelis, apšvietimo režimas ir laiko žyma. Tokia struktūra leidžia atsekti, kokiomis sąlygomis buvo gautas kiekvienas rezultatas. Programos pabaigoje apšvietimas išjungiamas, kamera sustabdoma, o visi „OpenCV“ langai uždaromi. Tai užtikrina saugų sistemos sustabdymą ir leidžia pakartotinai paleisti AOI standą be papildomo įrangos perkrovimo.

## 2.7.2. Stacionaraus kadro AOI analizės režimas su RGBW apšvietimo seka

Ši programa išlaiko pagrindines ankstesnės programos funkcijas: „YOLO“ modelio pasirinkimą, „Raspberry Pi AI Camera“ valdymą, „Shelly RGBW“ apšvietimo valdymą, „HAILORT / HAILO8“ modelio vykdymą ir rezultatų atvaizdavimą. Tačiau papildomai įtraukti keturi svarbūs eksperimentiniai elementai:

- neapdorotos nuotraukos išsaugojimas – programa kiekvienam apšvietimo režimui išsaugo originalų PCB vaizdą be aptikimo žymų, o tai leidžia vėliau pakartotinai patikrinti, koks vaizdas buvo naudotas inferencijai;
- anotuoto rezultato išsaugojimas – po „YOLO“ modelio inferencijos sukuriamas vaizdas su aptiktais komponentais, klasėmis, tikimybėmis ir ribojančiais stačiakampiais; šis rezultatas saugomas atskirai nuo pradinės nuotraukos;
- rezultatų registravimas CSV faile (žr. 31 lentelę) – kiekvienas aptikimas įrašomas į CSV failą; įrašomi tokie duomenys: laiko žyma, PCB identifikatorius, modelio pavadinimas, apšvietimo režimas, aptikimų skaičius, inferencijos laikas, komponento klasė, pasitikėjimo reikšmė, ribojančio stačiakampio koordinatės, pradinės nuotraukos kelias ir anotuoto rezultato kelias;
- apšvietimas pasirenkamas pradžioje – viena spalva arba automatinė RGBW seka.

**31 lentelė.** CVS duomenys

CSV laukas	Reikšmės pavyzdys
Laiko žyma	2026-05-09 21:00:12
PCB identifikatorius	Arduino mega.12
Modelis	YOLOv5mu--1280x1280_quant_hailort_hailo8_1
Apšvietimo režimas	Baltas
Aptikimų skaičius	9
Inferencijos laikas, ms	531,36
Komponento klasė	Integrinis_Grandynas
Pasitikėjimo reikšmė	0,9648
Ribojančio stačiakampio koordinatės	[516,62; 747,46; 733,62; 966,73]
Pradinė nuotrauka	..._white_20260509_210011_raw.jpg
Anotuotas rezultatas	..._white_20260509_210012_annotated.jpg

Skirtingai nei ankstesnėje programoje, šiame kode kamera konfigūruojama statinių vaizdų fiksavimui naudojant komandą „create\_still\_configuration()“. Tai reiškia, kad programa orientuota ne į nuolatinį vaizdo srautą, o į atskirų nuotraukų fiksavimą tyrimo sąlygomis. Kiekvienam apšvietimo režimui programa pirmiausia išsaugo neapdorotą PCB vaizdą kataloge „~/aoi\_pcb/images“.

Išsaugotas vaizdas perskaitomas iš failo ir perduodamas „YOLO“ modeliui. Tokiu būdu užtikrinama, kad inferencijai naudotas vaizdas yra tas pats, kuris saugomas kaip pradinis eksperimentinis duomuo. Po inferencijos sugeneruojamas anotuotas vaizdas su aptiktais komponentais. Jis išsaugomas kataloge „~/aoi\_pcb/results“. Papildomai visi aptikimo rezultatai įrašomi į CSV failą „~/aoi\_pcb/logs/still\_inference\_results.csv“.

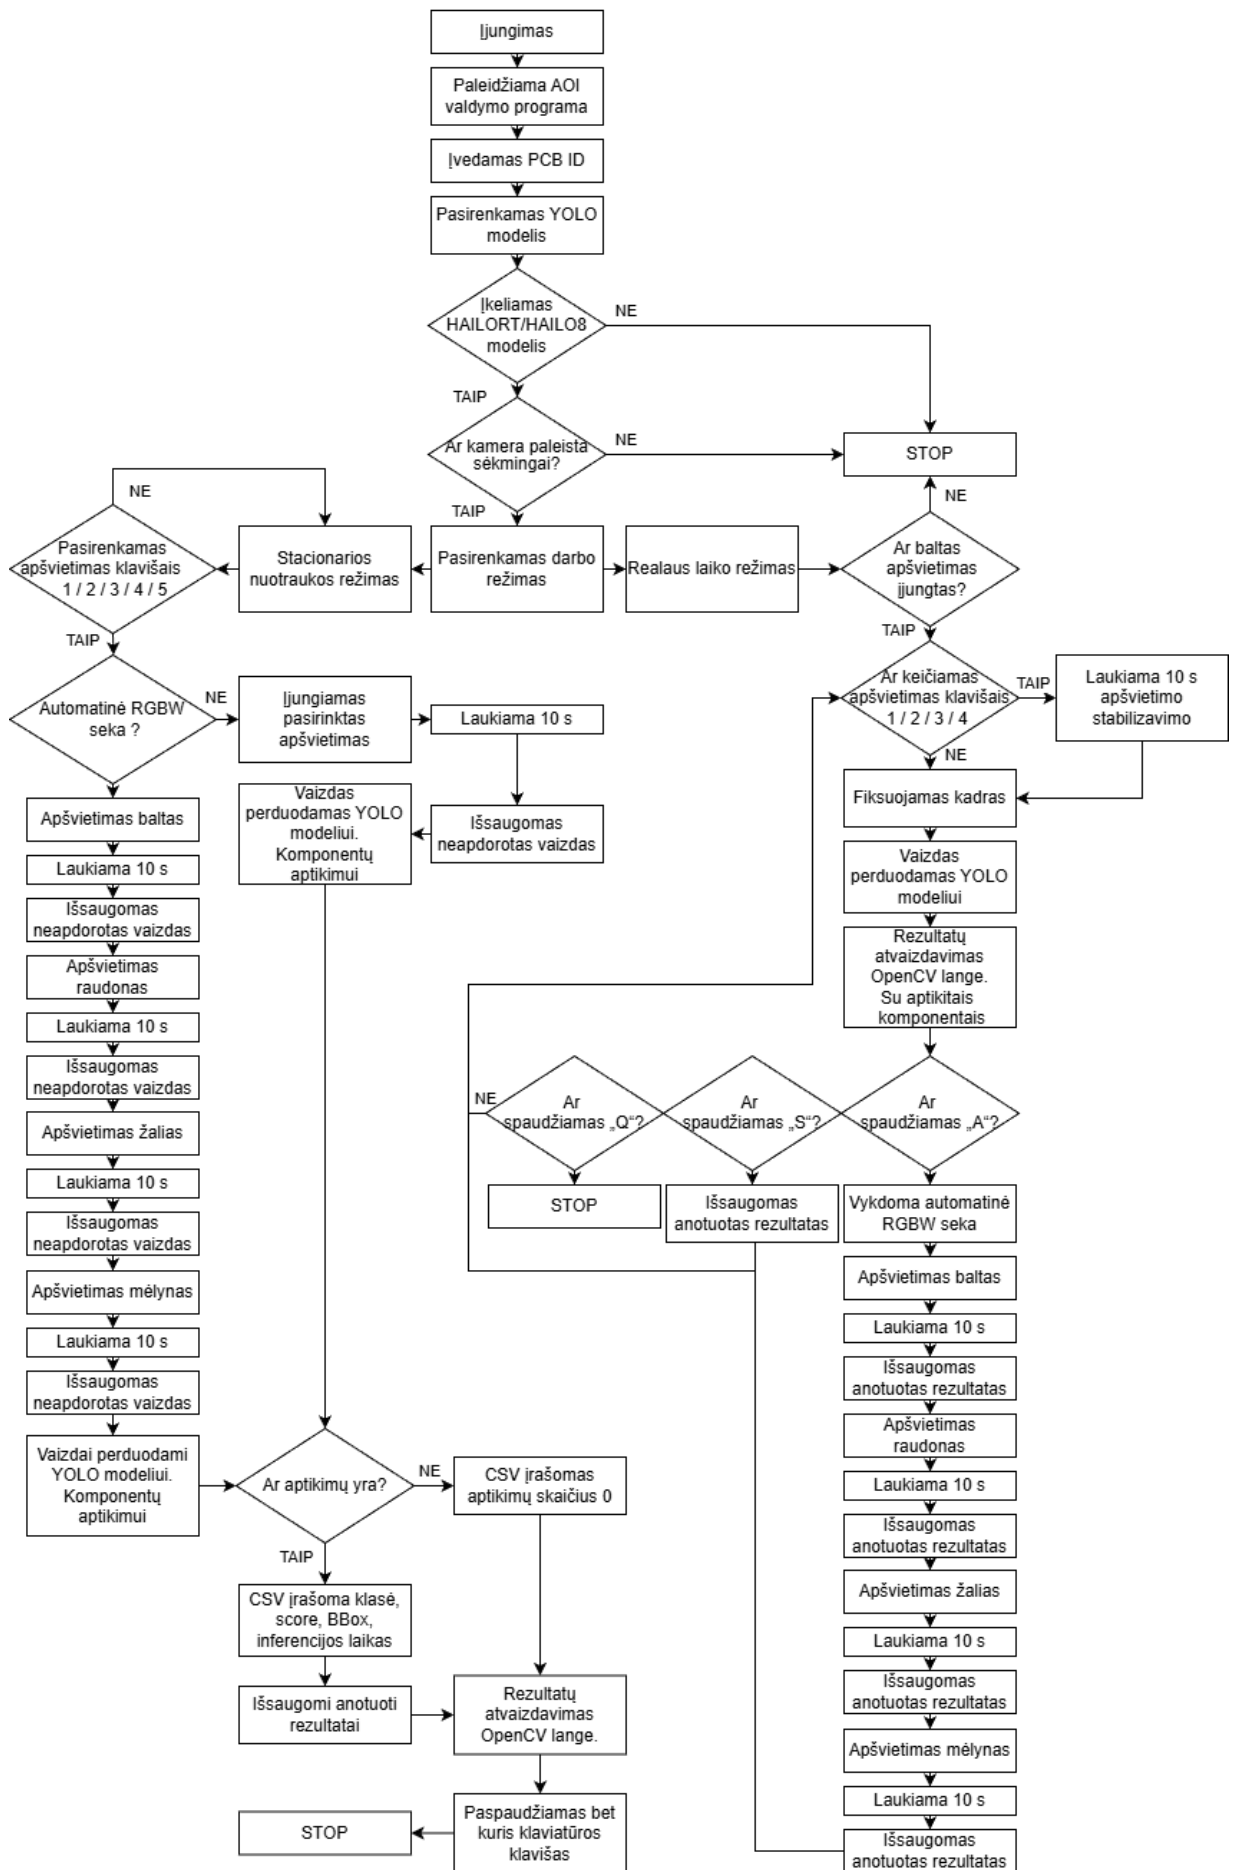
Jeigu modelis neaptinka nė vieno objekto, CSV faile įrašoma eilutė su aptikimų skaičiumi „0“. Tai leidžia fiksuoti ne tik sėkmingus aptikimus, bet ir tuos atvejus, kai tam tikras modelis arba apšvietimo režimas aptikimų nepateikė.

28 paveiksle pateiktas supaprastintas vientisas AOI sistemos valdymo algoritmas, sudarytas sujungiant du programinius režimus: stacionarios nuotraukos tyrimo režimą ir realaus laiko komponentų aptikimo režimą. Sistema skirta PCB plokščių optinei kontrolei, kai vaizdai fiksuojami kamera, apšviečiami skirtingais RGBW apšvietimo režimais ir perduodami „YOLO“ šeimos neuroniniam tinklui PCB komponentams aptikti.

Algoritmas pradedamas nuo sistemos įjungimo ir AOI valdymo programos paleidimo. Vartotojas įveda tiriamos PCB plokštės identifikacinį numerį, kuris vėliau naudojamas išsaugomų vaizdų ir rezultatų failų pavadinimuose. Toliau pasirenkamas vienas iš keturių „YOLO“ modelių: „YOLOv5mu“, „YOLOv8m“, „YOLOv11m“ arba „YOLOv26m“. Visi modeliai naudojami su  $1\,280 \times 1\,280$  pikselių įvesties vaizdu ir „HAILORT / HAILO8“ inferencijos aplinka.

Pasirinkus modelį, tikrinama, ar jis gali būti įkeltas į sistemą. Tam naudojamas modelio aplanko patikrinimas, kuriame turi būti \*.json ir \*.hef failai. Jeigu modelis neįkeliamas, algoritmas pereina į klaidos arba stabdymo būseną. Jeigu modelis įkeliamas sėkmingai, inicijuojama „Picamera2“ kamera. Kamera naudojama RGB888 formatu, o užfiksuotas vaizdas prieš inferenciją konvertuojamas į BGR formatą, nes „OpenCV“ ir „DeGirum“ aplinka naudoja BGR vaizdo formatą.

Toliau pasirenkamas darbo režimas. Algoritme išskiriamos dvi pagrindinės šakos: stacionarios nuotraukos režimas ir realaus laiko režimas. Realaus laiko režimas skirtas nuolatiniam vaizdo fiksavimui, komponentų aptikimui ir rezultatų peržiūrai „OpenCV“ lange.



28 pav. Režimu algoritmas

**Stacionarios nuotraukos režime** vartotojas pasirenka apšvietimą klavišais „1“, „2“, „3“, „4“ arba „5“. Apšvietimo režimai atitinka baltą, raudoną, žalią ir mėlyną šviesą arba automatinę RGBW seką. Kiekvieną apšvietimo režimą valdo „Shelly RGBW“ GEN2 valdiklis, o šviesos intensyvumas nustatomas 30 proc. Po kiekvieno apšvietimo perjungimo laukiama 10 s, kad apšvietimas stabilizuotųsi.

Jeigu pasirenkama automatinė RGBW seka, sistema paeiliui įjungia baltą, raudoną, žalią ir mėlyną apšvietimus. Kiekviename etape po 10 s stabilizavimo išsaugomas neapdorotas PCB vaizdas. Po visų pasirinktų apšvietimo režimų vaizdai perduodami „YOLO“ modeliui komponentams aptikti. Modelis grąžina aptikimų skaičių, komponento klasę, pasitikėjimo reikšmę, ribojančio langelio koordinatės ir inferencijos laiką.

Jeigu aptikimų nėra, CSV faile įrašomas aptikimų skaičius „0“. Jeigu aptikimai yra, CSV faile registruojama komponento klasė, „score“ reikšmė, „BBox“ koordinatės ir inferencijos laikas. Po to išsaugomi anotuoti rezultatai su pažymėtais aptiktais komponentais.

**Realaus laiko režime** sistema pradžioje įjungia baltą apšvietimą. Vėliau operatorius gali keisti apšvietimą klavišais „1“, „2“, „3“ ir „4“, išsaugoti esamą rezultatą klavišu „S“, paleisti automatinę RGBW seką klavišu „A“ arba sustabdyti programą klavišu „Q“. Kiekvieno ciklo metu fiksuojamas kadras, vaizdas perduodamas „YOLO“ modeliui, atliekamas komponentų aptikimas, o rezultatai atvaizduojami „OpenCV“ lange kartu su modelio pavadinimu, apšvietimo režimu ir inferencijos laiku milisekundėmis.

Algoritmo pabaigoje rezultatai atvaizduojami „OpenCV“ lange. Stacionarios nuotraukos režime programa laukia, kol vartotojas paspaus bet kurį klaviatūros klavišą arba „Q“ realaus laiko režime. Paspaudus klavišą, vykdomas sistemos sustabdymas: išjungiamas RGBW apšvietimas, sustabdoma kamera ir uždaromi „OpenCV“ langai.

## **2.8. Eksperimento planas ir vertinimo kriterijai**

Tyrime etape buvo vertinamas „YOLO“ šeimos neuroninių tinklų pritaikomumas elektronikos komponentams aptikti automatinės optinės patikros (AOI) sistemoje. Tyrimas atliktas naudojant sukurtą eksperimentinį standą. Visi modeliai buvo tiriami vienodomis sąlygomis, naudojant tą patį 1 280 × 1 280 pikselių įvesties vaizdo dydį. Tokia raiška pasirinkta todėl, kad visi modeliai buvo paruošti būtent šiai įvesčiai ir vykdomi „HAILORT / HAILO8“ aplinkoje.

Tyrimas atliktas stacionarios nuotraukos režimu. Šis režimas pasirinktas todėl, kad leidžia užfiksuoti kiekvieną PCB vaizdą su konkrečiu apšvietimu ir po to atlikti inferenciją pasirinktu „YOLO“ modeliui. Tokiu būdu kiekvienam bandymui buvo išsaugotas ne tik anotuotas rezultatas, bet ir originalus neapdorotas vaizdas, todėl rezultatus buvo galima vėliau patikrinti rankiniu būdu.

Eksperimentuose buvo tiriamos 9 skirtingos elektronikos plokštės: „Arduino Mega“, „Arduino Leonardo“, „Arduino Uno“, „ESP32 WROOM“, „ESP32 WROOM S3-N16R8“, „Raspberry Pi 5“, „SpeedyBee 60A“, „TZT“ ir papildoma ESP32 mikrovaldiklio plokštė. Šios plokštės pasirinktos todėl, kad jos skiriasi komponentų kiekiu, išdėstymu, dydžiu, spalva ir konstrukcija. Vienose plokštėse dominuoja didesni jungčių, integrinių grandynų ir maitinimo elementų korpusai, kitose – smulkesni SMD komponentai, išdėstyti tankiau.

Toks plokščių pasirinkimas leidžia įvertinti ne vieno konkretaus gaminio, o skirtingų PCB tipų aptikimo sąlygas. Skirtinga PCB pagrindo spalva, komponentų tankis, dydis ir išdėstymas sudaro realioms AOI testavimo sąlygoms artimesnę situaciją, nes praktikoje tikrinamos plokštės nėra vienodos. Todėl šios 9 plokštės naudotos siekiant įvertinti, kaip „YOLO“ modeliai aptinka komponentus esant skirtingam komponentų matomumui, kontrastui ir išdėstymui PCB paviršiuje.


Tyrimo metu programoje naudota diagnostinė aptikimo pasitikėjimo riba „CONF\_THRESHOLD = 0,01“. Ši riba buvo skirta visiems modelio gražinamiems aptikimams užregistruoti CSV faile, įskaitant ir mažo pasitikėjimo prognozes. Todėl bendras aptikimų skaičius rezultatų lentelėse apskaičiuotas pagal 0,01 ribą.

Kad bendras aptikimų skaičius nebūtų vertinamas kaip vienintelis kokybės rodiklis, rezultatų analizėje papildomai pateikiamas aptikimų su didesniu pasitikėjimu skaičius. Lentelėse atskirai nurodomi aptikimai, kurių pasitikėjimo reikšmė yra ne mažesnė kaip 50 proc. Taip atskiriami visi užregistruoti aptikimai nuo patikimesnių modelio prognozių.

Kiekvieno bandymo rezultatai buvo automatiškai įrašomi į CSV failą. CSV faile buvo saugomi šie laukai: bandymo data ir laikas, tiriamos PCB plokštės pavadinimas, naudoto „YOLO“ modelio pavadinimas, apšvietimo režimas, aptiktų objektų skaičius, vieno vaizdo inferencijos laikas milisekundėmis, aptikto komponento klasė, modelio pasitikėjimo reikšmė, aptikto objekto ribojančio langelio koordinatės, neapdoroto vaizdo failo kelias ir anotuoto rezultato failo kelias.

Kiekviena plokštė buvo tiriama keturiose orientacijose, atitinkančiose laikrodžio padėtis: 12 val., 3 val., 6 val. ir 9 val. Tokiu būdu buvo vertinama, ar „YOLO“ modelio aptikimo kokybė priklauso nuo PCB pasukimo kampo. 12 val. padėtis laikyta pradine plokštės orientacija ir atitiko 0° pasukimą. 3 val. padėtis atitiko 90° pasukimą pagal laikrodžio rodyklę, 6 val. – 180° pasukimą, o 9 val. – 270° pasukimą pagal laikrodžio rodyklę.

Pateikta PCB plokštė (žr. 29 pav.) užfiksuota naudojant skirtingus RGBW apšvietimo režimus. Pirmame vaizde matomas baltas apšvietimas, antrame – raudonas, trečiame – žalias, ketvirtame – mėlynas. Ši seka buvo naudojama kiekvienai tiriamai PCB plokštei ir kiekvienai jos orientacijai. Tokiu būdu buvo galima įvertinti, kaip skirtingas apšvietimo spektras veikia komponentų matumą, kontrastą ir „YOLO“ modelio aptikimo rezultatus.



29 pav. RGBW apšvietimo seka

Tyrimo metu buvo siekiama išlaikyti nepakitusius parametrus: kameros aukštį, fokusavimą, apšvietimo ryškumą, modelio įvesties dydį ir pasitikėjimo ribą. Kameros atstumas iki PCB paviršiaus sudarė apie 105–110 mm. Keitėsi tik trys pagrindiniai veiksniai: naudojamas „YOLO“ modelis, RGBW apšvietimo režimas ir PCB plokštės orientacija.

Tyrimo tikslas nebuvo vien tik pasiekti kuo didesnę aptikimų skaičių. Pagrindinis tikslas buvo įvertinti, kaip „YOLO“ šeimos modeliai veikia eksperimentinio AOI stendo sąlygomis, kai keičiami trys pagrindiniai veiksniai: „YOLO“ modelis, RGBW apšvietimo režimas ir PCB plokštės orientacija.

Modelių veikimas vertintas pagal kelis kriterijus: bendrą aptikimų skaičių, vaizdų su aptikimais skaičių, aptikimus su ne mažesne kaip 50 proc. pasitikėjimo reikšme, klaidingų žymėjimų skaičių ir vidutinį inferencijos laiką. Bendras aptikimų skaičius leidžia įvertinti modelio jautrumą, o aptikimai su  $\geq 50$  proc. pasitikėjimu parodo patikimesnes modelio prognozes. Klaidingi žymėjimai naudojami aptikimo kokybei įvertinti, o inferencijos laikas leidžia nustatyti, ar modelis tinkamas praktiniam AOI sistemos taikymui.

## **2.9. Skyriaus išvados**

1. Įgyvendinant 2 uždavinį, suprojektuota ir realizuota eksperimentinė AOI sistema, sudaryta iš „Raspberry Pi 5“, „Raspberry Pi AI HAT+ 26 TOPS“, „Raspberry Pi AI Camera“, RGBW apšvietimo ir „Shelly RGBW“ valdiklio. Sistema leido fiksuoti PCB vaizdus, valdyti apšvietimo režimus, vykdyti „YOLO“ modelių inferenciją „HAILORT / HAILO8“ aplinkoje ir registruoti aptikimų rezultatus CSV faile.
2. Įgyvendinant 3 uždavinį, modeliams apmokyti paruošta išplėsta duomenų bazė, kurią sudarė 54 534 anotuotos nuotraukos ir 475 067 anotacijos. Duomenys suskirstyti į mokymo, validacijos ir testavimo rinkinius: 48 566 / 6 069 / 6 073 vaizdai, t. y. 80 / 10 / 10 proc. santykiu. Ši duomenų bazė naudota „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“ modeliams apmokyti ir paruošti eksperimentinei AOI sistemai.

### 3. YOLOvX šeimos neuroninių tinklų tyrimas

Šiame skyriuje pateikiami eksperimentinio AOI stendo tyrimo rezultatai. Analizuojami „YOLO“ šeimos modelių mokymo rezultatai, jų veikimas realiame AOI stende, RGBW apšvietimo įtaka komponentų aptikimui, PCB orientacijos poveikis ir inferencijos trukmė. Taip pat aptariamas neatitikimas tarp modelių mokymo metrikų ir realiomis AOI stendo sąlygomis gautų rezultatų.

#### 3.1. YOLO modelių mokymo rezultatų palyginimas

Šiame poskyryje pateikiami „YOLOv5m“, „YOLOv8m“, „YOLOv11m“ ir „YOLOv26m“ modelių mokymo rezultatų palyginimai. Kadangi modeliai buvo mokyti keliais etapais, pagrindinis dėmesys skiriamas galutiniam, ketvirtajam apmokymo etapui, kuriame naudotas išplėstas duomenų rinkinys ir  $1280 \times 1280$  pikselių įvesties vaizdo raiška.

Modeliams mokyti (žr. 32 lentelę) taikyti šie pagrindiniai parametrai: 100 epochų, ankstyvojo stabdymo kriterijus (angl. *patience*) – 20 epochų. Šis parametras reiškia, kad modelio mokymas automatiškai sustabdomas, jei per 20 iš eilės epochų nepastebimas validacijos rezultatų pagerėjimas. Mokymo metu naudota įvesties vaizdų raiška –  $640 \times 640$  pikselių.

32 lentelė. Pirmojo modelių apmokymo etapo rezultatai

Modelis	Dydis, Mb	Epochos, vnt.	Trukmė, val.	mAP0.5, proc.	mAP0.5:0.95, proc.	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.
„YOLOv5m“	48	72	5:45	90,6	77,0	87,8	90,3
„YOLOv8m“	50	79	9:47	91,9	77,8	86,4	89,8
„YOLOv11m“	39	49	5:03	91,9	77,3	87,6	91,4
„YOLOv26m“	42	50	5:26	90,8	75,8	86,8	89,8

\* čia raidė „m“ YOLO modelių pavadinimuose nurodo modelio dydžio kategoriją, kuri apibrėžia tinklo gylį, sluoksnių skaičių ir parametrų kiekį. „m“ (angl. *medium*) – tai kompromisinis variantas tarp mažesnių („n“ – nano, „s“ – small) ir didesnių („l“ – large, „x“ – extra large) modelių.

Apmokymo metu didžiausią mAP0.5 reikšmę 91,9 proc. pasiekė „YOLOv8m“ ir „YOLOv11m“ modeliai, tuo tarpu „YOLOv5m“ ir „YOLOv26m“ modelių tikslumas buvo mažesnis – 90,6 proc. ir 90,8 proc. Vertinant griežtesnį kriterijų mAP0.5:0.95, geriausi rezultatai taip pat stebimi „YOLOv8m“ 77,8 proc. ir „YOLOv11m“ 77,3 proc. modeliuose, kas rodo geresnį objektų lokalizavimo tikslumą.

Tačiau, nepaisant pakankamai aukštų bendrųjų tikslumo rodiklių, siekiančių iki 87,8 proc., ir „atgavimo“ rodiklių, siekiančių iki 91,4 proc., nė vienas modelis nesugebėjo patikimai aptikti visų elektronikos komponentų klasių. Dalis komponentų, ypač rečiau pasitaikantys elementai, buvo neaptinkami.

Nepakankamas visų komponentų klasių aptikimas galėjo būti susijęs su per maža ankstyvojo stabdymo parametro reikšme. Šiame apmokymo etape ankstyvojo stabdymo kriterijus buvo lygus 20 epochų, todėl modelių mokymas galėjo būti sustabdytas dar nepasiekus stabilesnių validacijos rezultatų. Dėl šios priežasties kitame apmokymo etape šio parametro reikšmė buvo padidinta iki 50 epochų (žr. 32 lentelę), siekiant sudaryti sąlygas modeliams ilgiau mokytis ir įvertinti, ar ilgesnis mokymas pagerina komponentų aptikimo rezultatus.

**33 lentelė.** Antrojo modelių apmokymo etapo rezultatai

Modelis	Dydis, Mb	Epochos	Trukmė, val.	mAP0.5 (proc.)	mAP0.5:0.95 (proc.)	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.
„YOLOv8m“	50	90	7:30	91,9	77,6	89,6	88,2
„YOLOv11m“	39	79	7:57	91,9	77,3	87,6	91,4
„YOLOv26m“	42	99	10:35	90,1	75,3	88,4	88,4

Šiuo etapu buvo apmokyti tik trys modeliai (žr. 33 lentelę), kadangi apmokymo metu nustatyta, kad papildomai treniruojami modeliai nepasiekia reikšmingai geresnių aptikimo rezultatų, o jų tikslumo rodikliai išlieka panašūs arba mažesni. Dėl šios priežasties „YOLOv5mu“ modelis nebuvo pakartotinai treniruojamas, nes tikėtasi analogiškų rezultatų.

Analizuojant antrojo apmokymo etapo rezultatus pastebėta, kad padidinus ankstyvojo stabdymo parametro (angl. *patience*) reikšmę iki 50 epochų, reikšmingo modelių kokybės pagerėjimo nebuvo gauta. Nors kai kurių modelių mAP0.5 reikšmės išliko panašios ir siekė iki 91,9 proc., bendri tikslumo rodikliai nepagerėjo, o atskirais atvejais buvo mažesni negu pirmajame apmokymo etape. Tai rodo, kad ilgesnis mokymas šiame etape nebuvo efektyvus ir nesuteikė aiškaus modelių apibendrinimo gebėjimo pagerėjimo. Dėl šios priežasties tolesniuose apmokymo etapuose buvo koreguojami mokymo parametrai, siekiant geresnio balanso tarp mokymo trukmės, ankstyvojo stabdymo kriterijaus ir validacijos rezultatų.

Modelių apmokymo metu taip pat naudoti iš anksto apmokyti modeliai (angl. *parent model*), kurių svoriai pritaikyti kaip pradinė būseną. Toks metodas atitinka perkėlimo mokymosi (angl. *transfer learning*) principą, leidžiantį pasinaudoti jau išmoktais požymiais, Toks metodas atitinka perkėlimo mokymosi principą ir leidžia pasinaudoti jau išmoktais požymiais, tačiau šiame etape jis nesuteikė reikšmingo modelių apibendrinimo gebėjimo pagerėjimo.

Papildomai, „YOLOv26m“ modeliui buvo koreguoti apmokymo parametrai pagal „Ultralytics“ platformoje pateikiamas rekomendacijas (naudotas MuSGD optimizatorius, mokymosi sparta – 0,00038, impulso koeficientas – 0,882, mastelio keitimas – 0,95, „mixup“ – 0,427, „close\_mosaic“ – 10), siekiant pagerinti modelio konvergenciją ir aptikimo tikslumą. Šie pakeitimai turėjo įtakos modelio apmokymo trukmei.

Tolimesniuose „YOLO“ šeimos modelių apmokymo etapuose buvo naudojama išplėsta duomenų bazė, kurią sudarė 54 534 anotuoti vaizdai ir 475 067 anotacijos. Duomenų rinkinys buvo papildytas padidinant vaizdų kiekį ir pridėdant naujų anotacijų, siekiant pagerinti modelių gebėjimą aptikti elektronikos komponentus. Duomenų rinkinys suskirstytas į tris dalis: mokymo rinkinį – 48 566 vaizdai, validacijos rinkinį – 6 069 vaizdai ir testavimo rinkinį – 6 073 vaizdai. Toks padalijimas atitiko 80 / 10 / 10 proc. santykį. Elektronikos komponentų klasių pasiskirstymas išplėstoje duomenų bazėje pateiktas 27 paveiksle.

Modeliams mokytis (žr. 34 lentelę) taikyti šie pagrindiniai parametrai: 100 epochų, ankstyvojo stabdymo kriterijus – 30 epochų. Šio parametro reikšmė parinkta empiriškai, atsižvelgiant į ankstesnių eksperimentų rezultatus, kai 20 epochų buvo nepakankama siekiant stabilaus modelio konvergavimo, o 50 epochų buvo perteklinė reikšmė, nepagrįstai ilginanti mokymo trukmę. Taikytas

perkėlimo mokymasis (angl. *transfer learning*), kai kaip pradinė būseną buvo naudojami pirmojo modelių apmokymo etapo metu gauti modeliai (angl. *parent model*). Naudota įvesties vaizdų raiška –  $640 \times 640$  pikselių.

**34 lentelė.** Trečiojo modelių apmokymo etapo rezultatai

Modelis	Dydis, Mb	EPOCHOS, vnt.	Trukmė, val.	mAP0.5, proc.	mAP0.5:0.95, proc.	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.
„YOLOv5mu“	48	99	6:46	93,5	78,3	86,8	88,1
„YOLOv8m“	50	92	6:35	94,0	78,4	89,2	87,0
„YOLOv11m“	39	90	7:47	94,6	79,4	86,8	91,3
„YOLOv26m“	42	99	9:05	93,9	78,7	89,4	87,0

Iš pateiktų rezultatų matyti (žr. 34 lentelę), kad trečiojo apmokymo etapo metu visi „YOLO“ šeimos modeliai pasiekė aukštesnius aptikimo tikslumo rodiklius, lyginant su ankstesniais etapais. Didžiausią mAP0.5 reikšmę pasiekė „YOLOv11m“ modelis – 94,6 proc., o „YOLOv8m“ ir „YOLOv26m“ modeliai pasiekė atitinkamai 94,0 proc. ir 93,9 proc. „YOLOv5mu“ modelio rezultatas taip pat pagerėjo iki 93,5 proc., kas rodo bendrą modelių veikimo stabilizaciją.

Vertinant griežtesnį mAP0.5:0.95 kriterijų, geriausi rezultatai gauti naudojant „YOLOv8m“ ir „YOLOv11m“ modelius – atitinkamai 77,8 proc. ir 77,3 proc. Tai rodo geresnį objektų lokalizavimo tikslumą. Taip pat pastebima, kad bendras modelių tikslumas padidėjo iki 89,4 proc., o tai patvirtina pagerėjusį modelių gebėjimą apibendrinti naujus duomenis.

Modeliams mokytis (žr. 35 lentelę) taikyti šie pagrindiniai parametrai: 100 epochų, ankstyvojo stabdymo kriterijus – 30 epochų. Taikytas perkėlimo mokymasis (angl. *transfer learning*), kai kaip pradinė būseną buvo naudojami trečiojo apmokymo etapo modeliai. Mokymo metu naudota įvesties vaizdų raiška –  $1\,280 \times 1\,280$  pikselių. Ši raiška pasirinkta todėl, kad PCB plokštėse esantys SMD komponentai yra smulkūs ir tankiai išdėstyti, todėl didesnis vaizdo detalumas leidžia tiksliau išskirti komponentų kontūrus, pagerinti jų lokalizavimą ir sumažinti mažų objektų praleidimo tikimybę.

Tačiau  $1\,280 \times 1\,280$  pikselių raiškos naudojimas sudaro kompromisą tarp aptikimo kokybės ir skaičiavimo sąnaudų. Didesnė įvesties raiška padidina vaizde išsaugomų detalių kiekį, tačiau kartu ilgina modelių mokymo trukmę, didina atminties poreikį ir gali padidinti inferencijos laiką realioje AOI sistemoje. Todėl šiame darbe  $1\,280 \times 1\,280$  pikselių raiška pasirinkta kaip tinkamas kompromisas, leidžiantis pagerinti smulkių PCB komponentų aptikimą, bet kartu išlaikyti modelių pritaikomumą eksperimentiniame „Raspberry Pi AI HAT+“ pagrindu veikiančiame AOI stende.

**35 lentelė.** Ketvirtojo modelių apmokymo etapo rezultatai

Modelis	Dydis, Mb	EPOCHOS, vnt.	Trukmė, val.	mAP0.5, proc.	mAP0.5:0.95, proc.	Tikslumas, proc.	„Atgavimo“ rodiklis, proc.
„YOLOv5mu“	48	99	22:26	94,3	79,1	90,5	88,8
„YOLOv8m“	50	99	25:00	94,6	79,6	87,5	91,1
„YOLOv11m“	39	99	27:00	94,8	80,8	89,7	90,2
„YOLOv26m“	42	99	42:00	94,7	79,9	87,6	89,3

Iš pateiktų rezultatų matyti (žr. 35 lentelę), kad ketvirtojo apmokymo etapo metu visi „YOLO“ šeimos modeliai pasiekė aukščiausius aptikimo tikslumo rodiklius viso tyrimo metu. Didžiausią mAP0.5 reikšmę pasiekė „YOLOv11m“ modelis – 94,8 proc., o „YOLOv26m“ ir „YOLOv8m“ modeliai pasiekė 94,7 proc. ir 94,6 proc. „YOLOv5mu“ modelio rezultatas taip pat pagerėjo iki 94,3 proc., kas rodo bendrą modelių veikimo stabilizaciją. Vertinant griežtesnį kriterijų mAP0.5:0.95, geriausią rezultatą pasiekė „YOLOv11m“ modelis – 80,8 proc., kas rodo geriausią objektų lokalizavimo tikslumą.

Taip pat matoma, kad bendras modelių tikslumas siekia iki 90,5 proc., o „atgavimo“ rodikliai – iki 91,1 proc., kas rodo pagerėjusį modelių gebėjimą apibendrinti naujus duomenis. Tačiau šie rezultatai pasiekti padidėjus mokymo trukmei, kas rodo didesnių įvesties vaizdų (1280 × 1280 pikselių) ir sudėtingesnio mokymo proceso įtaką skaičiavimo sąnaudoms.

Lyginant modelių apmokymo etapus, nustatyta aiški tikslumo didėjimo tendencija nuo ankstesnių etapų iki trečiojo ir ketvirtojo etapų. Trečiajame etape, taikant perkėlimo mokymą (angl. *transfer learning*), „patience“ = 30 ir 640×640 pikselių raišką, modeliai pasiekė mAP0.5 reikšmes nuo 93,5 proc. „YOLOv5mu“ iki 94,6 proc. „YOLOv11m“, o mAP0.5:0.95 – iki 79,4 proc.

Ketvirtajame etape, padidinus įvesties vaizdų raišką iki 1 280×1 280 pikselių ir tęsiant mokymą iš ankstesnio etapo modelių, tikslumas dar padidėjo – mAP0.5 pasiekė 94,3–94,8 proc., o geriausią rezultatą pasiekė „YOLOv11m“ modelis – 94,8 proc., tuo tarpu mAP0.5:0.95 išaugo iki 80,8 proc. Tačiau kartu reikšmingai padidėjo mokymo trukmė – nuo ~6–9 val. trečiajame etape iki net 22–42 val. ketvirtajame etape, kas rodo didesnių vaizdų ir sudėtingesnio mokymo įtaką skaičiavimo sąnaudoms.

### 3.2. YOLO modelių veikimas realiame AOI stende

Tyrime iš viso gauti 576 eksperimentiniai vaizdai. Eksperimento struktūra sudaryta iš 4 „YOLO“ modelių, 9 PCB plokščių, 4 PCB orientacijų ir 4 RGBW apšvietimo režimų. Vienam modeliui teko 144 vaizdai, nes kiekvienas modelis buvo tikrinamas su visomis PCB plokštėmis, visomis orientacijomis ir visais apšvietimo režimais.

36 lentelė. Eksperimento struktūrą

Eksperimento veiksnys	Skaičius vnt.
Tiriamų YOLO modelių skaičius	9
PCB orientacijų skaičius	4
RGBW apšvietimo režimų skaičius	4
Vienam modeliui tenkantis vaizdų skaičius	144
Bendras eksperimentinių vaizdų skaičius	576

Bendras vaizdų skaičius apskaičiuotas taip: 4 „YOLO“ modeliai × 9 PCB plokštės × 4 orientacijos × 4 RGBW apšvietimo režimai: 576 vaizdai.

Pagal bendrą aptikimų skaičių geriausiai pasirodė „YOLOv8m“ modelis (žr. 37 lentelę). Jis aptiko 949 komponentus, iš kurių 146 aptikimai turėjo ne mažesnę kaip 50 proc. pasitikėjimo rodiklį. Didžiausias šio modelio pasitikėjimo balas siekė 0,96, t. y. 96 proc., o vidutinis vieno vaizdo apdorojimo laikas buvo 120,76 ms. Nors „YOLOv8m“ turėjo 58 klaidingus žymėjimus, klaidingų žymėjimų santykis, lyginant su bendru aptikimų skaičiumi, buvo mažesnis negu „YOLOv5mu“ ir

„YOLOv11m“ modelių. Tai rodo, kad „YOLOv8m“ geriausiai padengė PCB komponentus eksperimentiniame AOI stende.

**37 lentelė.** Bendras YOLO modelių palyginimas eksperimentiniame AOI stende

Modelis	Vaizdų skaičius, vnt.	Aptikimų skaičius, vnt.	Vaizdai su aptikimais, vnt.	Didž. pasitikėjimo rodiklis, proc.	Aptikimai su pasitikėjimu $\geq 50$ proc.	Vidurkis, ms	Klaidingi žymėjimai, vnt.
„YOLOv5mu“	144	888	114	96,0	141	210,15	88
„YOLOv8m“	144	949	110	96,0	146	233,77	58
„YOLOv11m“	144	297	80	93,0	89	288,72	36
„YOLOv26m“	144	78	50	22,0	0	441,02	0

„YOLOv5mu“ modelis (žr. 37 lentelę) aptiko 888 komponentus ir turėjo daugiausia vaizdų su bent vienu aptikimu – 114 iš 144 vaizdų. Šio modelio didžiausias pasitikėjimo rodiklis siekė 96 proc., o aptikimų, kurių pasitikėjimo rodiklis buvo ne mažesnis kaip 50 proc., gauta 141. Be to, „YOLOv5mu“ buvo greičiausias iš visų modelių – vidutinis apdorojimo laikas siekė 210,15 ms. Tačiau rankinės peržiūros metu nustatyti 88 klaidingi žymėjimai.

„YOLOv11m“ modelis mokymo metu pasiekė geriausius kokybinius rodiklius, tačiau realiame AOI stende aptiko mažiau komponentų negu „YOLOv5mu“ ir „YOLOv8m“ modeliai. Eksperimentų metu „YOLOv11m“ aptiko 297 komponentus, vaizdai su aptikimais sudarė 80 iš 144, o aptikimų, kurių pasitikėjimo reikšmė buvo ne mažesnė kaip 50 proc., gauta 89. Didžiausias pasitikėjimo rodiklis siekė 93 proc., vidutinis inferencijos laikas buvo 288,72 ms, o rankinės peržiūros metu nustatyti 36 klaidingi žymėjimai.

Šis rezultatas rodo neatitikimą tarp mokymo metu gautų metrikų ir realaus stendo veikimo. Ketvirtajame apmokymo etape „YOLOv11m“ pasiekė geriausią mAP0.5 reikšmę – 94,8 proc. ir mAP0.5:0.95 reikšmę – 80,8 proc., tačiau praktiniame AOI stende modelis buvo mažiau jautrus ir pateikė mažiau aptikimų. Tokį skirtumą galėjo lemti mokymo duomenų ir realaus stendo vaizdų neatitikimas: skirtingas apšvietimas, kameros fokusavimas, PCB plokščių padėtis, komponentų mastelis, atspindžiai ir fonas. Mokymo metrikos apskaičiuojamos naudojant validacijos ir testavimo duomenų rinkinį, o realiame stende modelis veikia su kitomis optinėmis sąlygomis, todėl aukštas mAP rezultatas ne visada tiesiogiai reiškia didžiausią aptikimų skaičių praktiniame bandyme.

Dėl šios priežasties „YOLOv11m“ galima vertinti kaip geriausiai apmokytą modelį pagal mokymo metrikas, tačiau ne kaip geriausiai veikusį modelį realiame AOI stende. Praktiniuose eksperimentuose geresnį komponentų padengimą parodė „YOLOv8m“, nes jis aptiko daugiau objektų ir turėjo didesnę patikimų aptikimų skaičių.

„YOLOv26m“ modelis pasirodė silpniausiai pagal aptikimų kiekį. Jis aptiko tik 78 komponentus, o aptikimai buvo užfiksuoti 50 iš 144 vaizdų. Didžiausias pasitikėjimo rodiklis siekė tik 22 proc., o aptikimų, kurių pasitikėjimo rodiklis buvo ne mažesnis kaip 50 proc., nebuvo. Vidutinis apdorojimo laikas buvo didžiausias – 441,02 ms. Nors rankinės peržiūros metu klaidingų žymėjimų nenustatyta, šis rezultatas negali būti laikomas geriausiu, nes modelis aptiko labai mažai komponentų. Tai rodo, kad „YOLOv26m“ šioje realaus AOI stendo aplinkoje buvo nepakankamai jautrus.

### 3.3. RGBW apšvietimo įtaka komponentų aptikimui

RGBW apšvietimo režimų įtaka vertinta siekiant nustatyti, kaip skirtingas apšvietimo spektras veikia PCB komponentų matomumą ir „YOLO“ modelių aptikimo rezultatus. Eksperimentuose naudoti keturi apšvietimo režimai: baltas, raudonas, žalias ir mėlynas. Visi režimai buvo taikomi tomis pačiomis sąlygomis, naudojant tą patį AOI stendą, tą pačią kameros padėtį, 1 280 × 1 280 pikselių vaizdo raišką ir tuos pačius „YOLO“ modelius.

Apšvietimo poveikis vertintas pagal bendrą aptikimų skaičių, vaizdų su aptikimais skaičių, didžiausią ir mažiausią pasitikėjimo koeficientą. Kadangi PCB paviršiuje yra skirtingų spalvų komponentų, metalizuotų kontaktinių aikštelių ir šviesą atspindinčių litavimo zonų, apšvietimo spalva gali keisti komponentų kontrastą fono atžvilgiu. Dėl šios priežasties skirtingi RGBW režimai gali turėti tiesioginę įtaką komponentų lokalizavimo stabilumui ir aptikimų skaičiui.

**38 lentelė.** RGBW apšvietimo įtaka aptikimų skaičiui

Apšvietimas	Vaizdų skaičius, vnt.	Aptikimų skaičius, vnt.	Vaizdai su aptikimais, vnt.	Didž. pasitikėjimo koeficientas, proc.	Mažiausias pasitikėjimo balas, proc.
Baltas	144	1353	138	96,9	1
Žalias	144	579	115	96,5	1
Raudonas	144	234	75	95,4	1
Mėlynas	144	45	26	70,0	1

Geriausias rezultatas gautas naudojant baltą apšvietimą. Šiuo režimu iš 144 vaizdų komponentai buvo aptikti 138 vaizduose. Bendras aptikimų skaičius siekė 1 353 vnt., o didžiausias pasitikėjimo koeficientas buvo 96,9 proc. Tai rodo, kad baltas apšvietimas geriausiai išryškino bendrą PCB plokštės struktūrą, komponentų kontūrus ir jų ribas. Baltas apšvietimas apima platesnį matomos šviesos spektrą, todėl komponentų forma, korpusų spalva, žymėjimai ir kontrastas PCB pagrindo atžvilgiu buvo matomi stabiliau.

Žalias apšvietimas buvo antras pagal efektyvumą. Šiuo režimu aptikimai gauti 115 iš 144 vaizdų. Bendras aptikimų skaičius siekė 579 vnt., o didžiausias pasitikėjimo koeficientas buvo 96,5 proc. Tai rodo, kad žalias režimas gerai išryškino tamsių komponentų kontūrus, smulkių SMD elementų ribas ir kontrastą tarp komponentų bei PCB paviršiaus. Žalias apšvietimas galėjo būti efektyvus todėl, kad daliai tamsių komponentų ir PCB paviršiaus sudarė aiškesnį toninį skirtumą, todėl YOLO modeliams buvo lengviau lokalizuoti komponentų ribas.

Raudonas apšvietimas davė mažesnę aptikimų skaičių. Šiuo režimu komponentai aptikti 75 iš 144 vaizdų. Bendras aptikimų skaičius siekė 234 vnt., o didžiausias pasitikėjimo koeficientas buvo 95,4 proc. Nors didžiausias pasitikėjimo koeficientas išliko gana aukštas, bendras aptikimų kiekis buvo gerokai mažesnis negu balto ir žalio apšvietimo atvejais. Tai rodo, kad raudonas apšvietimas kai kuriais atvejais leido patikimai aptikti atskirus komponentus, tačiau bendram komponentų atpažinimui buvo mažiau efektyvus. Tikėtina, kad raudonas apšvietimas sumažino kai kurių komponentų ir PCB pagrindo kontrastą, todėl dalis smulkių SMD elementų buvo sunkiau atskiriami nuo fono.

Silpniausias rezultatas gautas naudojant mėlyną apšvietimą. Šiuo režimu komponentai aptikti tik 26 iš 144 vaizdų. Bendras aptikimų skaičius buvo tik 45 vnt., o didžiausias pasitikėjimo koeficientas

siekė 70,0 proc. Tai rodo, kad mėlynas apšvietimas nėra tinkamas bendram komponentų aptikimui. Mėlyna šviesa galėjo labiau išryškinti metalinių kontaktų, jungčių ir litavimo zonų atspindžius, tačiau kartu sumažinti bendrą komponentų formos ir korpusų matomumą. Dėl stipresnių atspindžių ir mažesnio kontrasto tarp kai kurių komponentų bei PCB pagrindo „YOLO“ modeliams buvo sunkiau stabiliai aptikti komponentus.

Galima teigti, kad RGBW apšvietimo režimas turėjo reikšmingą įtaką komponentų aptikimo rezultatams. Baltas apšvietimas buvo efektyviausias, nes užtikrino didžiausią aptikimų skaičių – 1 353 vnt. – ir didžiausią vaizdų su aptikimais dalį. Žalias apšvietimas buvo tinkamas smulkių SMD komponentų riboms ir tamsių korpusų kontrastui vertinti. Raudonas apšvietimas kai kuriais atvejais išryškino kontūrus ir šešėlius, tačiau sumažino bendrą aptikimų skaičių. Mėlynas apšvietimas buvo silpniausias komponentų aptikimui, nes labiau išryškino blizgius metalinius paviršius ir atspindžius, o ne bendrą komponentų formą. Todėl šiame tyrime bendram PCB komponentų aptikimui tinkamiausias buvo baltas RGBW apšvietimo režimas.

### 3.4. PCB orientacijos įtaka komponentų aptikimui

PCB pasukimo tyrimas atliktas todėl, kad komponentų aptikimo rezultatai gali priklausyti ne tik nuo modelio ar apšvietimo, bet ir nuo objekto orientacijos vaizde. Pasukus plokštę, keičiasi komponentų tekstūrų kryptis, kontaktų ir korpusų šešėliai, šviesos atspindžiai nuo metalinių paviršių bei smulkių SMD komponentų matomumas. Be to, „YOLO“ modelių aptikimo stabilumui įtakos gali turėti ir mokymo duomenų pasiskirstymas: jeigu tam tikros komponentų klasės mokymo duomenyse dažniau buvo pateiktos viena kryptimi, pasukus PCB plokštę modelio aptikimo tikslumas gali sumažėti. Tai ypač aktualu mažiems komponentams, kurių ribojančių stačiakampių lokalizacija jautresnė net nedideliems kontūrų, šešėlių ar kontrasto pokyčiams.

Todėl šiame tyrime PCB orientacija buvo įtraukta kaip atskiras eksperimento veiksnys, leidžiantis įvertinti, ar „YOLO“ modeliai išlaiko komponentų aptikimo stabilumą, kai ta pati plokštė vaizde pateikiama skirtingomis pasukimo padėtimis.

**39 lentelė.** PCB orientacijos įtaka aptikimui

PCB orientacija	Vaizdų skaičius, vnt.	Aptikimų skaičius, vnt.	Vaizdai su aptikimais, vnt.	Didž. pasitikėjimo koeficientas, proc.	Mažiausias pasitikėjimo balas, proc.
12 val. / 0°	144	567	92	96,5	1
3 val. / 90°	144	544	91	96,9	1
6 val. / 180°	144	543	86	96,9	1
9 val. / 270°	144	557	85	96,9	1

PCB plokštės orientacijos įtaka komponentų aptikimui pateikta 36 lentelėje. Vertinimui naudotos keturios PCB padėtys: 12 val. / 0°, 3 val. / 90°, 6 val. / 180° ir 9 val. / 270°. Kiekvienai orientacijai buvo analizuojami 144 vaizdai, gauti naudojant skirtingus „YOLO“ modelius ir RGBW apšvietimo režimus.

Daugiausia aptikimų gauta tada, kai PCB plokštė buvo 12 val. / 0° orientacijoje. Šioje padėtyje bendras aptikimų skaičius siekė 567vnt., o komponentai buvo aptikti 92 vaizduose. Didžiausias pasitikėjimo koeficientas buvo 96,5 proc., o mažiausias – 1 proc. Tai rodo, kad pradinė PCB orientacija sudarė palankiausias sąlygas komponentų aptikimui.

3 val. / 90° orientacijoje gauti 544 aptikimai, o komponentai buvo aptikti 91 vaizde. Didžiausias pasitikėjimo koeficientas siekė 96,9 proc., Tai rodo, kad pasukus PCB plokštę 90° kampu modeliai vis dar gebėjo aptikti komponentus, tačiau bendras aptikimų skaičius sumažėjo nuo 567 iki 544.

6 val. / 180° orientacijoje gautas mažiausias bendras aptikimų skaičius – 543 aptikimai. Komponentai aptikti 86 vaizduose, o didžiausias pasitikėjimo koeficientas siekė 96,9. Mažesnis vaizdų su aptikimais skaičius rodo, kad 180° pasukimas daliai modelių apsunkino komponentų atpažinimą.

9 val. / 270° orientacijoje gauti 557 aptikimai, o komponentai buvo aptikti 85 vaizduose. Didžiausias pasitikėjimo koeficientas taip pat siekė 96,9 proc. Tačiau vaizdų su aptikimais skaičius buvo mažiausias iš visų orientacijų.

Visose PCB orientacijose mažiausias užregistruotas pasitikėjimo koeficientas buvo 1 proc., tačiau eksperimento metu YOLO aptikimams buvo taikoma pasitikėjimo balo 0,01 riba. Tai reiškia, kad praktiniam komponentų vertinimui patikimais laikomi tie aptikimai, kurių pasitikėjimo balas yra ne mažesnis kaip 0,01. Todėl PCB orientacijos įtaka buvo vertinama ne tik pagal mažiausią ar didžiausią pasitikėjimo balą, bet pirmiausia pagal bendrą aptikimų skaičių ir vaizdų su aptikimais kiekį.

### 3.5. Inferencijos trukmės ir praktinio taikymo analizė

Inferencijos trukmė yra vienas svarbiausių praktinio AOI sistemos taikymo rodiklių, nes ji parodo, per kiek laiko modelis apdoroja vieną PCB vaizdą ir pateikia komponentų aptikimo rezultatus. Šiame tyrime inferencijos laikas buvo automatiškai registruojamas CSV faile kiekvieno bandymo metu. Kadangi vienas vaizdas CSV faile gali turėti kelias eilutes, jei jame aptikti keli komponentai, inferencijos trukmės analizėje naudoti unikalūs vaizdai pagal pradinės nuotraukos failo kelią.

**40 lentelė.** YOLO modelių inferencijos trukmės palyginimas eksperimentiniame AOI stende

Modelis	Vaizdų skaičius, vnt.	Vidutinė inferencijos trukmė, ms.	Min. trukmė, ms.	Maks. trukmė, ms.	Vidutinė sparta, FPS
„YOLOv5mu“	144	210,15	98,98	553,67	4,76
„YOLOv8m“	144	233,77	115,24	1201,11	4,28
„YOLOv11m“	144	288,72	179,77	646,57	3,46
„YOLOv26m“	144	441,02	325,3	1116,55	2,27

Iš 37 lentelės matyti, kad pagal vidutinę inferencijos trukmę greičiausiai veikė „YOLOv5MU“ modelis – 210,15 ms vienam vaizdai. „YOLOv8m“ modelio vidutinė inferencijos trukmė buvo 233,77 ms, „YOLOv11m“ – 288,72 ms, o „YOLOv26m“ buvo lėčiausias – 441,02 ms vienam vaizdai. Pagal vidutinę spartą „YOLOv5mu“ pasiekė 4,76 FPS, „YOLOv8m“ – 4,28 FPS, „YOLOv11m“ – 3,46 FPS, o „YOLOv26m“ – 2,27 FPS.

Mažiausia užfiksuota inferencijos trukmė taip pat buvo „YOLOv5mu“ modelio atveju – 98,98 ms. „YOLOv8m“ mažiausia trukmė siekė 115,24 ms, „YOLOv11m“ – 179,77 ms, o „YOLOv26m“ – 325,38 ms. Maksimalios trukmės reikšmės rodo, kad kai kuriais atvejais apdorojimo laikas padidėdavo. Tai galėjo lemti didesnis aptiktų objektų kiekis vaizde, rezultatų anotavimas arba sistemos apkrova vykdant inferenciją „Raspberry Pi AI HAT+“ aplinkoje.

Praktinio taikymo požiūriu vien inferencijos trukmė nėra pakankamas kriterijus modeliui pasirinkti. „YOLOv5mu“ veikė greičiausiai, tačiau turėjo daugiau klaidingų žymėjimų. „YOLOv8m“ veikė šiek

tiek lėčiau, bet realiame AOI stende aptiko daugiausia komponentų ir turėjo mažiau klaidingų žymėjimų. „YOLOv11m“ mokymo metu pasiekė geriausius mAP rodiklius, tačiau realiame stende veikė lėčiau ir aptiko mažiau objektų. „YOLOv26m“ šiame eksperimente buvo mažiausiai tinkamas praktiniam taikymui, nes jo inferencijos trukmė buvo didžiausia, o aptikimų skaičius – mažiausias.

Todėl praktiniam eksperimentinės AOI sistemos taikymui tinkamiausias laikomas „YOLOv8m“ modelis. Jis neužtikrino trumpiausios inferencijos trukmės, tačiau sudarė geriausią balansą tarp komponentų aptikimo kiekio, patikimesnių aptikimų skaičiaus, klaidingų žymėjimų kiekio ir apdorojimo spartos.

### **3.6. Mokymo rezultatų ir realaus stendo rezultatų neatitikimo aptarimas**

Lyginant „YOLO“ modelių mokymo rezultatus ir realaus AOI stendo bandymus nustatytas svarbus neatitikimas. Ketvirtojo apmokymo etapo metu geriausius mokymo rodiklius pasiekė „YOLOv11m“ modelis: mAP0.5 reikšmė siekė 94,8 proc., mAP0.5:0.95 – 80,8 proc., tikslumas – 89,7 proc., o „atgavimo“ rodiklis – 90,2 proc. Pagal šias mokymo metrikas „YOLOv11m“ buvo geriausiai apmokytas modelis. Tačiau realiame eksperimentiniame AOI stende šis modelis aptiko tik 297 komponentus ir pagal bendrą aptikimų skaičių nusileido „YOLOv5mu“ bei „YOLOv8m“ modeliams.

Realiuose bandymuose geriausią komponentų padengimą parodė „YOLOv8m“ modelis. Jis aptiko 949 komponentus, iš kurių 146 aptikimai turėjo ne mažesnę kaip 50 proc. pasitikėjimo reikšmę. „YOLOv5mu“ aptiko 888 komponentus ir buvo greičiausias pagal vidutinę inferencijos trukmę – 210,15 ms vienam vaizdai, tačiau turėjo daugiausia klaidingų žymėjimų – 88 vnt. „YOLOv8m“ vidutinė inferencijos trukmė siekė 233,77 ms, o klaidingų žymėjimų skaičius buvo mažesnis – 58 vnt. Todėl praktiniu požiūriu „YOLOv8m“ sudarė geresnį balansą tarp aptikimų skaičiaus, patikimesnių aptikimų, klaidingų žymėjimų ir apdorojimo trukmės.

Šis skirtumas parodo, kad mokymo metu gautos mAP, tikslumo ir „atgavimo“ reikšmės ne visada tiesiogiai nusako modelio veikimą realiame AOI stende. Mokymo metrikos apskaičiuojamos naudojant paruoštą validacijos arba testavimo duomenų rinkinį, kuriame vaizdai, anotacijos ir objektų pasiskirstymas atitinka mokymo duomenų struktūrą. Tuo tarpu realiame stende modeliai veikia su kitomis optinėmis sąlygomis: fiksuotu kameros aukščiu, realiu PCB paviršiaus atspindžiu, RGBW apšvietimu, skirtingomis PCB plokštėmis, komponentų tankiu, orientacija ir fonu. Dėl šios priežasties susidaro mokymo duomenų ir realaus stendo vaizdų neatitikimas.

Vienas pagrindinių neatitikimo veiksnių yra apšvietimas. Realiame stende buvo naudojami keturi RGBW režimai: baltas, raudonas, žalias ir mėlynas. Rezultatai parodė, kad baltas apšvietimas davė 1353 aptikimus, žalias – 579, raudonas – 234, o mėlynas – tik 45 aptikimus. Tai reiškia, kad komponentų matomumas labai priklausė nuo apšvietimo spektro, kontrasto ir atspindžių. Jei mokymo duomenų rinkinyje nebuvo pakankamai tokių pačių apšvietimo sąlygų, realiame stende modelio aptikimo rezultatai galėjo sumažėti, net jei mokymo metu mAP rodikliai buvo aukšti.

Kitas svarbus veiksnys yra duomenų rinkinio ir realių PCB plokščių skirtumas. Modeliai buvo mokomi naudojant anotuotus PCB vaizdus, tačiau realiame stende naudotos 9 skirtingos PCB plokštės, kurios skyrėsi komponentų kiekiu, išdėstymu, dydžiu, spalva ir konstrukcija. Tokios sąlygos yra artimesnės praktiniam AOI taikymui, bet kartu sudėtingesnės negu standartizuotas mokymo arba validacijos rinkinys. Todėl modelis, kuris mokymo metu geriau lokalizavo objektus pagal testavimo duomenis, realiame stende nebūtinai pateikė daugiausia aptikimų.

Neatitikimą galėjo padidinti ir klasių disbalansas duomenų rinkinyje. Kai kurios komponentų klasės, pavyzdžiui, SMD kondensatoriai ir SMD rezistoriai, sudarė didelę anotacijų dalį, o retesnės klasės buvo atstovaujamos mažesniu kiekiu. Dėl to modeliai galėjo geriau atpažinti dažniausiai pasitaikančius komponentus ir prasčiau aptikti retesnius arba kitokios formos objektus. Realiame AOI stende, kuriame plokštėse yra skirtingų komponentų kombinacijų, ši problema tampa labiau pastebima.

Taip pat svarbu tai, kad mokymo rezultatų ir realaus stendo rezultatų vertinimo kriterijai skiriasi. Mokymo metu modelių kokybė vertinama pagal mAP0.5, mAP0.5:0.95, tikslumą ir „atgavimo“ rodiklį. Realiame stende papildomai vertintas bendras aptikimų skaičius, vaizdų su aptikimais skaičius, aptikimai su ne mažesne kaip 50 proc. pasitikėjimo reikšme, klaidingi žymėjimai ir inferencijos trukmė. Todėl realaus stendo rezultatai geriau atspindi praktinį modelio tinkamumą AOI sistemai, o ne vien tik jo mokymo metu pasiektą statistinį tikslumą.

„YOLOv26m“ atvejis taip pat patvirtina, kad vien aukšti mokymo rodikliai negarantuoja gero praktinio veikimo. Ketvirtajame apmokymo etape „YOLOv26m“ pasiekė mAP0.5 = 94,7 proc., tačiau realiam AOI stende aptiko tik 78 komponentus, neturėjo nė vieno aptikimo su ne mažesne kaip 50 proc. pasitikėjimo reikšme ir pasižymėjo didžiausia vidutine inferencijos trukme – 441,02 ms. Tai rodo, kad šioje HAILORT / HAILO8 ir „Raspberry Pi AI HAT+“ vykdymo aplinkoje šis modelis buvo nepakankamai jautrus praktiniam komponentų aptikimui.

Apibendrinant galima teigti, kad „YOLOv11m“ buvo geriausias pagal mokymo metrikas, tačiau „YOLOv8m“ buvo tinkamesnis realiam AOI stendo taikymui. Šis rezultatas yra svarbus, nes parodo, kad modelio pasirinkimas praktinei elektronikos optinės kontrolės sistemai negali būti grindžiamas vien tik mokymo mAP reikšmėmis. Reikia papildomai įvertinti modelio veikimą realiomis sąlygomis: apšvietimo poveikį, PCB orientaciją, aptikimų skaičių, klaidingus žymėjimus, pasitikėjimo reikšmes ir inferencijos trukmę. Todėl šiame darbe praktiniam eksperimentinės AOI sistemos taikymui tinkamiausiu laikomas „YOLOv8m“ modelis, naudojamas su baltu RGBW apšvietimu ir 1 280 × 1 280 pikselių įvesties vaizdu.

### 3.7. Skyriaus išvados

1. Ketvirtajame apmokymo etape, naudojant 1 280 × 1 280 pikselių įvesties raišką, geriausią mokymo rezultatą pasiekė „YOLOv11m“ modelis: mAP0.5 = 94,8 proc., mAP0.5:0.95 = 80,8 proc., tikslumas – 89,7 proc., o „atgavimo“ rodiklis – 90,2 proc. Tačiau šis rezultatas parodė tik modelio kokybę mokymo ir validacijos aplinkoje, todėl vėliau buvo būtina patikrinti modelių veikimą realiam AOI stende.
2. Įgyvendinant 4 uždavinį, realiam AOI stende atlikti bandymai su 4 YOLO modeliais, 9 PCB plokštėmis, 4 PCB orientacijomis ir 4 RGBW apšvietimo režimais. Iš viso gauti 576 eksperimentiniai vaizdai. Daugiausia objektų aptiko „YOLOv8m“ modelis – 949 aptikimai, t. y. vidutiniškai 6,59 aptikimo vienam vaizdai. „YOLOv5mu“ aptiko 888 objektus, „YOLOv11m“ – 297 objektus, o „YOLOv26m“ – 78 objektus. Todėl pagal komponentų padengimą realiam stende geriausiai pasirodė „YOLOv8m“ modelis.
3. Pagal vidutinę inferencijos trukmę greičiausiai veikė „YOLOv5mu“ modelis – 210,15 ms vienam vaizdai. „YOLOv8m“ vidutinė inferencijos trukmė buvo 233,77 ms, „YOLOv11m“ – 288,72 ms, o „YOLOv26m“ – 441,02 ms. Nors „YOLOv5mu“ buvo greičiausias, jis turėjo daugiau klaidingų

- žymėjimų. Todėl praktiniu požiūriu geriausią balansą tarp aptikimų skaičiaus, klaidingų žymėjimų kiekio ir inferencijos trukmės parodė „YOLOv8m“ modelis.
4. RGBW apšvietimo režimų palyginimas parodė, kad apšvietimas turėjo didelę įtaką komponentų aptikimui. Geriausias rezultatas gautas naudojant baltą apšvietimą – 1 353 aptikimai. Žalias apšvietimas davė 579 aptikimus, raudonas – 234, o mėlynas – tik 45 aptikimus. Todėl šiame AOI stende paviršinio montavimo komponentų optiniam aptikimui tinkamiausias buvo baltas RGBW apšvietimo režimas.
  5. PCB orientacijos analizė parodė, kad plokštės pasukimas turėjo mažesnę įtaką negu apšvietimo režimas ar modelio pasirinkimas. Daugiausia aptikimų gauta 12 val. / 0° orientacijoje – 567 aptikimai, o mažiausiai 6 val. / 180° orientacijoje – 543 aptikimai. Skirtumas tarp didžiausio ir mažiausio aptikimų skaičiaus sudarė 24 aptikimus, t. y. apie 4,3 proc., todėl galima teigti, kad PCB orientacijos poveikis bendram aptikimų skaičiui buvo nedidelis.
  6. Nustatytas neatitikimas tarp mokymo rezultatų ir realaus AOI stendo rezultatų. Nors „YOLOv11m“ mokymo metu pasiekė geriausias mAP rodiklius, realiame stende daugiausia komponentų aptiko „YOLOv8m“. Tai rodo, kad modelio pasirinkimas praktinei AOI sistemai negali būti grindžiamas vien mokymo metrikomis. Būtina papildomai vertinti realias optines sąlygas: apšvietimą, PCB orientaciją, kameros fokusavimą, komponentų mastelį, klaidingus žymėjimus ir inferencijos trukmę.

## Išvados

1. Nustatyta, kad PCB ir PCBA kokybės kontrolei taikomi klasikiniai vaizdo apdorojimo, ML, DL, AOI, AXI, ICT ir „YOLO“ šeimos metodai. Klasikiniai ML metodai literatūroje pasiekia aukštus tikslumo rodiklius – 95,65–100 proc., tačiau jie dažnai priklauso nuo rankiniu būdu parinktų požymių, etaloninių vaizdų ir stabilių apšvietimo sąlygų. „YOLO“ tipo objektų aptikimo modeliai pasirinkti todėl, kad vieno vaizdo apdorojimo metu leidžia nustatyti komponento klasę, koordinates ir pasitikėjimo reikšmę, todėl geriausiai atitinka šiame darbe kuriamos AOI sistemos tikslą – aptikti paviršinio montavimo komponentus PCB vaizduose.
2. Suprojektuota ir realizuota eksperimentinė automatizuotos optinės patikros AOI sistema, sudaryta iš „Raspberry Pi 5“, „Raspberry Pi AI HAT+ 26 TOPS“, „Raspberry Pi AI Camera“ su „Sony IMX500“ jutikliu, RGBW apšvietimo ir „Shelly RGBW“ valdiklio. Sistema leidžia fiksuoti 1 280 × 1 280 pikselių PCB vaizdus, valdyti baltą, raudoną, žalią ir mėlyną apšvietimo režimus, vykdyti „YOLO“ modelių inferenciją HAILORT / HAILO8 aplinkoje ir registruoti aptikimo rezultatus CSV faile. Tokia įrangos struktūra sudarė sąlygas pakartojamiems komponentų aptikimo bandymams atlikti realiomis AOI stendo sąlygomis.
3. Sukurtas ir ištirtas „YOLO“ šeimos modeliais pagrįstas PCB komponentų aptikimo kokybės vertinimo algoritmas. Šiame darbe kokybės vertinimu laikomas ne bendras visos PCBA plokštės kokybės įvertinimas, o komponentų aptikimo kokybės analizė pagal aptikimų skaičių, komponento klasę, koordinates, pasitikėjimo reikšmę, klaidingus žymėjimus ir inferencijos laiką. Modeliams apmokyti naudota išplėsta duomenų bazė, sudaryta iš 54 534 anotuočių nuotraukų ir 475 067 anotacijų. Ketvirtajame apmokymo etape geriausią mokymo rezultatą pasiekė „YOLOv11m“ modelis:  $mAP_{0.5} = 94,8$  proc.,  $mAP_{0.5:0.95} = 80,8$  proc., tikslumas – 89,7 proc., atgavimo rodiklis – 90,2 proc.
4. Eksperimentiškai patvirtinta, kad sukurta AOI sistema veikia realiomis elektronikos gaminių testavimo sąlygomis, tačiau aptikimo rezultatai priklauso nuo „YOLO“ modelio, apšvietimo režimo ir PCB orientacijos. Iš viso atlikti bandymai su 4 „YOLO“ modeliais, 9 PCB plokštėmis, 4 orientacijomis ir 4 RGBW apšvietimo režimais, todėl gauti 576 eksperimentiniai vaizdai. Realiame stende daugiausia komponentų aptiko „YOLOv8m“ modelis – 949 aptikimai, nors mokymo metu geriausių  $mAP$  rodiklius pasiekė „YOLOv11m“. Greičiausias buvo „YOLOv5mu“ modelis – 210,15 ms/vaizdui, tačiau praktiniu požiūriu geriausią balansą tarp aptikimų skaičiaus, klaidingų žymėjimų ir inferencijos trukmės parodė „YOLOv8m“. Apšvietimo tyrimas parodė, kad tinkamiausias buvo baltas RGBW apšvietimas – 1 353 aptikimai, žalias apšvietimas davė 579 aptikimus, raudonas – 234, o mėlynas – 45. Todėl praktiniam šios AOI sistemos taikymui rekomenduojama naudoti „YOLOv8m“ modelį, baltą RGBW apšvietimą ir 1 280 × 1 280 pikselių įvesties vaizdą.

## Rekomendacijos tolimesniam darbui

1. Tolesniuose tyrimuose rekomenduojama išplėsti PCB vaizdų duomenų rinkinį, įtraukiant daugiau skirtingų plokščių, komponentų tipų, spalvų, paviršiaus tekstūrų ir realių gamybinių defektų pavyzdžių. Tai leistų sumažinti klasių disbalanso įtaką ir pagerinti rečiau pasitaikančių komponentų aptikimo tikslumą.
2. Rekomenduojama papildomai tirti apšvietimo parametrus, neapsiribojant tik RGBW spalvų režimais. Tikslinga įvertinti skirtingą apšvietimo intensyvumą, šviesos kritimo kampą, LED juostos padėtį ir difuzoriaus naudojimą. Tai padėtų sumažinti atspindžius nuo metalinių kontaktų ir pagerinti smulkių SMD komponentų matomumą.
3. Tolesniame darbe rekomenduojama papildyti algoritmą ne tik komponentų aptikimu, bet ir komponentų kokybės požymių vertinimu. Aptikus komponentą būtų galima papildomai analizuoti jo padėtį, orientaciją, poslinkį, trūkumą arba netinkamą klasę. Tokiu būdu sistema būtų išplėsta nuo komponentų aptikimo iki išsamesnio PCB kokybės vertinimo.
4. Rekomenduojama atlikti papildomą mokymo duomenų ir realaus AOI stendo vaizdų suderinimo analizę. Tyrimo rezultatai parodė, kad geriausi mokymo mAP rodikliai ne visada sutampa su geriausiai realaus stendo rezultatais, todėl tikslinga į mokymo rinkinį įtraukti daugiau vaizdų, gautų būtent sukurtame AOI stende su tuo pačiu kameros aukščiu, fokusavimu ir RGBW apšvietimu.

## Literatūros ir informacijos šaltinių sąrašas

1. LING, Q., ISA, N. A. M. Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey. *IEEE Access* [interaktyvus]. 2023, 15921–15944 [žiūrėta 2025-03-09]. Prieiga per: DOI: [10.1109/ACCESS.2023.3245093](https://doi.org/10.1109/ACCESS.2023.3245093).
2. XU, Y., YANG, G., LUO, J., HE, J. An electronic component recognition algorithm based on deep learning with a faster SqueezeNet. *Mathematical Problems in Engineering* [interaktyvus]. 2020, 1–11 [žiūrėta 2025-03-12]. Prieiga per: DOI: [10.1155/2020/2940286](https://doi.org/10.1155/2020/2940286).
3. ROU, H., RAY, S., RAJA, S., IHSAN, U., HENDRAWATI, T. D. Printed circuit board (PCB) defect detection using deep learning. *International Conference on Metaverse and Current Trends in Computing (ICMCTC)* [interaktyvus]. 2025 [žiūrėta 2025-03-19]. Prieiga per: DOI: [10.1109/ICMCTC62214.2025.11196526](https://doi.org/10.1109/ICMCTC62214.2025.11196526).
4. JOSHI, P. M., AREY, S. N., ARYA, D., MALI, A. T., MHETRE, N. R., KIRVE, M. D., AHER, M. A., PENDHARI, S. K. Revolutionizing automotive electronics: The transformative impact of AI and machine learning in manufacturing. *1<sup>st</sup> International Conference on AIML – Applications for Engineering & Technology (ICAET)* [interaktyvus]. 2025, 1–8 [žiūrėta 2025-04-21]. Prieiga per: DOI: [10.1109/ICAET63349.2025.10932220](https://doi.org/10.1109/ICAET63349.2025.10932220).
5. CHANG, C.-J., HWANG, Y.-T. Efficient image alignment scheme for automated optical inspection of printed circuit boards. *IEEE International Conference on Consumer Electronics – Asia (ICCE-Asia)* [interaktyvus]. 2024, 1–4 [žiūrėta 2025-04-16]. Prieiga per: DOI: [10.1109/ICCE-Asia63397.2024.10774058](https://doi.org/10.1109/ICCE-Asia63397.2024.10774058).
6. VOIGT, C., HARNECKER, L., KIRCHBERGER, M., FRANKE, J. An analysis of redundancy in high volume high mix quality testing systems in electronics production. *44<sup>th</sup> International Spring Seminar on Electronics Technology (ISSE)* [interaktyvus]. 2021, 1–6 [žiūrėta 2025-04-12]. Prieiga per: DOI: [10.1109/ISSE51996.2021.9467650](https://doi.org/10.1109/ISSE51996.2021.9467650).
7. SCHWEBIG, A. I. M., TUTSCH, R. Intelligent fault detection of electrical assemblies using hierarchical convolutional networks for supporting automatic optical inspection systems. *Journal of Sensors and Sensor Systems* [interaktyvus]. 2020, 363–374 [žiūrėta 2025-05-03]. Prieiga per: <https://doi.org/10.5194/jsss-9-363-2020>.
8. ARAS, K., SAIF, S. S., GIUSEPPI, A., COSKUN, V. Automated optical inspection for quality control in PCBA assembly lines: A case study for point of sale devices production lines. *International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA)* [interaktyvus]. 2024, 1–8 [žiūrėta 2025-04-08]. Prieiga per: DOI: [10.1109/HORA61326.2024.10550768](https://doi.org/10.1109/HORA61326.2024.10550768).
9. HSIEH, C.-Y., TSENG, L.-S., CHEN, Y.-H., TSAI, C.-H., WU, C.-H. Deep-learning methods for defect inspection of plated through holes with clustering-based auto-labeling and GAN-based model training. *IEEE Access* [interaktyvus]. 2024, 12, 190598–190610 [žiūrėta 2026-02-14]. Prieiga per: DOI: [10.1109/ACCESS.2024.3515463](https://doi.org/10.1109/ACCESS.2024.3515463).
10. WELLINGTON, W. C., HOSAMANI, A. S., ACHARYA, C. D., DHANUSH, K. N., SAHOO, R. PCB defect detection by using deep learning algorithm. *IEEE North Karnataka Subsection Flagship International Conference (NKCon)* [interaktyvus]. 2025 [žiūrėta 2026-03-16]. Prieiga per: DOI: [10.1109/NKCon66957.2025.11345734](https://doi.org/10.1109/NKCon66957.2025.11345734).
11. GENG, Z., YANG, X., SUN, H., LI, Z. FC-YOLO: Frequency-coordinate collaborative network for component inspection in AOI systems. *IEEE Transactions on Instrumentation and Measurement* [interaktyvus]. 2026, 75, 2501510 [žiūrėta 2026-03-15]. Prieiga per: DOI: [10.1109/TIM.2026.3657528](https://doi.org/10.1109/TIM.2026.3657528).

12. PARK, J.-M., YOO, Y.-H., KIM, U.-H., LEE, D., KIM, J.-H. D<sup>3</sup>PointNet: Dual-level defect detection PointNet for solder paste printer in surface mount technology. *IEEE Access* [interaktyvus]. 2020, 140310–140323 [žiūrėta 2025-05-03]. Prieiga per: DOI: [10.1109/ACCESS.2020.3013291](https://doi.org/10.1109/ACCESS.2020.3013291).
13. PARK, J.-Y., HWANG, Y., LEE, D., KIM, J.-H. MarsNet: Multi-label classification network for images of various sizes. *IEEE Access* [interaktyvus]. 2020, 21832–21847 [žiūrėta 2025-04-17]. Prieiga per: DOI: [10.1109/ACCESS.2020.2969217](https://doi.org/10.1109/ACCESS.2020.2969217).
14. WEISS, E. Preventing corrosion-related failures in electronic assembly: A multicase study analysis. *IEEE Transactions on Components, Packaging and Manufacturing Technology* [interaktyvus]. 2023, 743–752 [žiūrėta 2025-04-19]. Prieiga per: DOI: [10.1109/TCPMT.2023.3285776](https://doi.org/10.1109/TCPMT.2023.3285776).
15. SA'AT, M. H. M., JAMALUDDIN, M. H., AMEERDIN, M. I. M., SHUKOR, A. Z., IZUDDIN, T. A., IBRAHIM, M. M., SUKIMAN, M. S. Integration of artificial intelligence with conventional X-ray inspection for improved solder void detection in SSDC SiC modules. *IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAJET)* [interaktyvus]. 2024, 1–6 [žiūrėta 2025-04-10]. Prieiga per: DOI: [10.1109/IICAJET62352.2024.10730272](https://doi.org/10.1109/IICAJET62352.2024.10730272).
16. SCHMIDT, K., THIELEN, N., VOIGT, C., SEIDEL, R., FRANKE, J., MILDE, Y., BÖNIG, J., BEITINGER, G. Enhanced X-ray inspection of solder joints in SMT electronics production using convolutional neural networks. *IEEE 26<sup>th</sup> International Symposium for Design and Technology in Electronic Packaging (SIITME)* [interaktyvus]. 2020, 1–6 [žiūrėta 2025-04-11]. Prieiga per: DOI: [10.1109/SIITME50350.2020.9292292](https://doi.org/10.1109/SIITME50350.2020.9292292).
17. ZHANG, Q., ZHANG, M., GAMANAYAKE, C., YUEN, C., GENG, Z., JAYASEKARAAND, H., ZHANG, X., WOO, C.-W., LOW, J., LIU, X. Deep learning based defect detection for solder joints on industrial X-ray circuit board images. *8<sup>th</sup> IEEE International Conference on Industrial Informatics (INDIN)* [interaktyvus]. 2020, 1–6 [žiūrėta 2025-04-13]. Prieiga per: DOI: [10.1109/INDIN45582.2020.9442142](https://doi.org/10.1109/INDIN45582.2020.9442142).
18. LEE, H., KIM, N.-W., LEE, J., KO, S.-K. Convolutional transformer-based deblurring model for X-ray images. *International Technical Conference on Circuits / Systems, Computers and Communications (ITC-CSCC)* [interaktyvus]. 2023, 1–6 [žiūrėta 2025-04-14]. Prieiga per: DOI: [10.1109/ITC-CSCC58803.2023.10212709](https://doi.org/10.1109/ITC-CSCC58803.2023.10212709).
19. JEON, M., YOO, S., KIM, S.-W. A contactless PCBA defect detection method: Convolutional neural networks with thermographic images. *IEEE Transactions on Components, Packaging and Manufacturing Technology* [interaktyvus]. 2022, 489–501 [žiūrėta 2025-04-20]. Prieiga per: DOI: [10.1109/TCPMT.2022.3147319](https://doi.org/10.1109/TCPMT.2022.3147319).
20. LING, Q., ISA, N. A. M., ASAARI, M. S. M. Precise detection for dense PCB components based on modified YOLOv8. *IEEE Access* [interaktyvus]. 2023, 116545–116560 [žiūrėta 2025-03-12]. Prieiga per: DOI: [10.1109/ACCESS.2023.3325885](https://doi.org/10.1109/ACCESS.2023.3325885).
21. KOLACHI, K., RAZA, A., KHAN, M., SARANG, S. A. Fault detection and quality inspection of printed circuit board using YOLO-v7 algorithm of deep learning. *7<sup>th</sup> International Multi-Topic ICT Conference (IMTIC)* [interaktyvus]. 2023, 1–6 [žiūrėta 2025-04-18]. Prieiga per: DOI: [10.1109/IMTIC58887.2023.10178512](https://doi.org/10.1109/IMTIC58887.2023.10178512).
22. HUANG, X., LI, W. A novel PCB defect detection network based on the improved YOLOv8 with fusion of hybrid attention transformer and bidirectional feature pyramid network. *4<sup>th</sup> International Conference on Artificial Intelligence, Robotics, and Communication (ICAIRC)* [interaktyvus]. 2024, 207–211 [žiūrėta 2026-02-12]. Prieiga per: DOI: [10.1109/ICAIRC64177.2024.10900305](https://doi.org/10.1109/ICAIRC64177.2024.10900305).

23. AN, J., SHI, Z. YOLOv8n-enhanced PCB defect detection: A lightweight method integrating spatial-channel reconstruction and adaptive feature selection. *Applied Sciences* [interaktyvus]. 2024, 14, 7686 [žiūrėta 2026-02-13]. Prieiga per: DOI: [10.3390/app14177686](https://doi.org/10.3390/app14177686).
24. GAO, C., BAI, M., LIAN, X., HU, X., HAN, S., CHEN, S. PCB defect detection method based on G-YOLOv8. *International Conference on Cyber-Physical Social Intelligence (ICCSI)* [interaktyvus]. 2024 [žiūrėta 2026-03-17]. Prieiga per: DOI: [10.1109/ICCSI62669.2024.10799473](https://doi.org/10.1109/ICCSI62669.2024.10799473).
25. YU, H., MANEETHAM, D., RABGYAL, T. Performance evaluation of YOLOv12 series models for defect detection in PCB manufacturing. *International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)* [interaktyvus]. 2025, 687–694 [žiūrėta 2025-03-18]. Prieiga per: DOI: [10.1109/ICIMCIS68501.2025.11326959](https://doi.org/10.1109/ICIMCIS68501.2025.11326959).
26. WANG, Y., LI, Y., KAYES, D. M. S., ABDULLAHI, H. S., GAO, S., ZHANG, H., SONG, Z., LV, P. Research on a lightweight PCB detection algorithm based on AE-YOLO. *IEEE Access* [interaktyvus]. 2024, 12, 109367–109379 [žiūrėta 2025-03-20]. Prieiga per: DOI: [10.1109/ACCESS.2024.3439523](https://doi.org/10.1109/ACCESS.2024.3439523).
27. ANCHA, V. K., GONUGUNTLA, V., VADDI, R. TR-YOLO: An enhanced model for PCB mixed defect detection and classification. *International Conference on Electronics, AI and Computing (EAIC)* [interaktyvus]. 2025 [žiūrėta 2025-03-21]. Prieiga per: DOI: [10.1109/EAIC66483.2025.11101424](https://doi.org/10.1109/EAIC66483.2025.11101424).
28. MALIN, B., KALGANOVA, T., DANSKINS, J., GILCHRIST, J. R. PCB Image analysis: A comparison of visible, infrared & X-ray wavelengths. *IEEE Physical Assurance and Inspection of Electronics (PAINE)* [interaktyvus]. 2023, 743–752 [žiūrėta 2025-04-09]. Prieiga per: DOI: [10.1109/PAINE56030.2022.10014963](https://doi.org/10.1109/PAINE56030.2022.10014963).
29. QIU, T., KHOO, L., TAN, J., LOO, A. Capacitive-based wire bonding defects detection method for integrated circuit package in strip form with hybrid threshold setting algorithm. *IEEE 25<sup>th</sup> Electronics Packaging Technology Conference (EPTC)* [interaktyvus]. 2023, 918–920 [žiūrėta 2025-04-15]. Prieiga per: DOI: [10.1109/EPTC59621.2023.10457591](https://doi.org/10.1109/EPTC59621.2023.10457591).
30. QIU, T., TEK, C. K. A., HUANG, S. Y.A. Compact high-resolution resonance-based capacitive sensor for defects detection on PCBAs. *IEEE Access* [interaktyvus]. 2020, 203758–203768 [žiūrėta 2025-04-22]. Prieiga per: DOI: [10.1109/ACCESS.2020.3036884](https://doi.org/10.1109/ACCESS.2020.3036884).
31. LIANG, S. A paradigm of automatic ICT testing system development in practice. *IEEE International Instrumentation and Measurement Technology Conference (I2MTC)* [interaktyvus]. 2020, 1–6 [žiūrėta 2025-04-23]. Prieiga per: DOI: [10.1109/ARIS50834.2020.9205770](https://doi.org/10.1109/ARIS50834.2020.9205770).
32. KHAN, R. A., YOUSAF, S., ROBERTS, G. W. An in-circuit test method for measuring the bonding resistances of individual IC pins from an interconnected multiple IC assembly of flexible hybrid electronics. *IEEE Transactions on Circuits and Systems II: Express Briefs* [interaktyvus]. 2023, 939–943 [žiūrėta 2025-04-24]. Prieiga per: DOI: [10.1109/TCSII.2022.3219462](https://doi.org/10.1109/TCSII.2022.3219462).
33. YEN, M.-H., TSOU, C.-H., LIN, S.-C., CHANG, C.-W., LIN, Y.-H., KU, Y.-F. VLSI implementation of RISC MCU with in-circuit debugger. *IEEE 5<sup>th</sup> International Conference on Knowledge Innovation and Invention (ICKII)* [interaktyvus]. 2022, 63–68 [žiūrėta 2025-04-25]. Prieiga per: DOI: [10.1109/ICKII55100.2022.9983595](https://doi.org/10.1109/ICKII55100.2022.9983595).
34. SINDEL, T., THIELEN, N., MAHR, F., REICHENSTEIN, T., ERDOGAN, H., FRANKE, J. Data-driven bed of nails wear analysis for the in-circuit-testing of electronic modules. *29<sup>th</sup> IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*

- [interaktyvus]. 2024, 1–8 [žiūrėta 2025-04-26]. Prieiga per: DOI: [10.1109/ETFA61755.2024.10710880](https://doi.org/10.1109/ETFA61755.2024.10710880).
35. JURJ, S. L., ROTAR, R., BRINCOVAN, I., OPRITOIU, F., VLADUTIU, M. Evaluating the knowledge in test engineering education using a solar-powered remote-controlled flying probe-inspired in-circuit tester. *IEEE 30<sup>th</sup> International Symposium for Design and Technology in Electronic Packaging (SIITME)* [interaktyvus]. 2024, 1–8 [žiūrėta 2025-04-28]. Prieiga per: DOI: [10.1109/SIITME63973.2024.10814796](https://doi.org/10.1109/SIITME63973.2024.10814796).
  36. JURJ, S. L., ROTAR, R., OPRITOIU, F., VLADUTIU, M. Affordable flying probe-inspired in-circuit tester for printed circuit boards evaluation with application in test engineering education. *IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)* [interaktyvus]. 2020, 1–6 [žiūrėta 2025-04-28]. Prieiga per: DOI: [10.1109/EEEIC/ICPSEurope49358.2020.9160639](https://doi.org/10.1109/EEEIC/ICPSEurope49358.2020.9160639).
  37. JURJ, S. L., ROTAR, R., OPRITOIU, F., VLADUTIU, M. Hybrid testing of a solar tracking equipment using in-circuit testing and JTAG debugging strategies. *IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)* [interaktyvus]. 2021, 1–10 [žiūrėta 2025-04-28]. Prieiga per: DOI: [10.1109/EEEIC/ICPSEurope51590.2021.9584639](https://doi.org/10.1109/EEEIC/ICPSEurope51590.2021.9584639).
  38. ROTAR, R., JURJ, S. L., ROHATINOVICI, N. C., BRINCOVAN, R., OPRITOIU, F., VLADUTIU, M. Improved flying probe-inspired in-circuit tester for practical laboratory activities. *IEEE 29<sup>th</sup> International Symposium for Design and Technology in Electronic Packaging (SIITME)* [interaktyvus]. 2023, 1–6 [žiūrėta 2025-04-28]. Prieiga per: DOI: [10.1109/SIITME59799.2023.10430652](https://doi.org/10.1109/SIITME59799.2023.10430652).
  39. BEHERA, A. K., BENEGLIAMO, M., MORICONI, L., ORECCHINI, G., PALAZZI, V., ALIMENTI, F. In-Circuit self-test (ICST) of power MOS transistors: Measuring gate charge as an indicator of oxide stress and device reliability. *IEEE International Symposium on Systems Engineering (ISSE)* [interaktyvus]. 2024, 1–6 [žiūrėta 2025-04-29]. Prieiga per: DOI: [10.1109/ISSE63315.2024.10741096](https://doi.org/10.1109/ISSE63315.2024.10741096).
  40. TIAN, L., XIAO, N., LI, A., ZHENG, S., BIAN, H., YANG, J. Fault localization on test coverage and functional issue for SoC product with combining bench and pattern test. *IEEE International Symposium on the Physical and Failure Analysis of Integrated Circuits (IPFA)* [interaktyvus]. 2024, 1–8 [žiūrėta 2025-05-30]. Prieiga per: DOI: [10.1109/IPFA61654.2024.10691110](https://doi.org/10.1109/IPFA61654.2024.10691110).
  41. *Raspberry Pi 5 – 8 GB* [interaktyvus]. 2023 [žiūrėta 2025-10-29]. Prieiga per: [https://raspberrypi.dk/en/product/raspberry-pi-5-8-gb/?\\_gl=1\\*1bgev8t\\*\\_up\\*MQ..\\*\\_ga\\*MTc2ODIzNjI1MS4xNzY4MDU5Njk3\\*\\_ga\\_3X2SL2XXEJ\\*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk3NjEkajYwJGwwJGgw](https://raspberrypi.dk/en/product/raspberry-pi-5-8-gb/?_gl=1*1bgev8t*_up*MQ..*_ga*MTc2ODIzNjI1MS4xNzY4MDU5Njk3*_ga_3X2SL2XXEJ*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk3NjEkajYwJGwwJGgw).
  42. *Raspberry Pi AI HAT+ 26 TOPS* [interaktyvus]. 2024 [žiūrėta 2025-10-29]. Prieiga per: [https://raspberrypi.dk/en/product/raspberry-pi-ai-hat-26-tops/?\\_gl=1\\*eaqirb\\*\\_up\\*MQ..\\*\\_ga\\*MTc2ODIzNjI1MS4xNzY4MDU5Njk3\\*\\_ga\\_3X2SL2XXEJ\\*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk3MDUkajUyJGwwJGgw](https://raspberrypi.dk/en/product/raspberry-pi-ai-hat-26-tops/?_gl=1*eaqirb*_up*MQ..*_ga*MTc2ODIzNjI1MS4xNzY4MDU5Njk3*_ga_3X2SL2XXEJ*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk3MDUkajUyJGwwJGgw).
  43. *Raspberry Pi AI Camera* [interaktyvus]. 2024 [žiūrėta 2025-10-29]. Prieiga per: [https://raspberrypi.dk/en/product/raspberry-pi-ai-camera/?\\_gl=1\\*pisx60\\*\\_up\\*MQ..\\*\\_ga\\*MTc2ODIzNjI1MS4xNzY4MDU5Njk3\\*\\_ga\\_3X2SL2XXEJ\\*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk4OTYkajUyJGwwJGgw](https://raspberrypi.dk/en/product/raspberry-pi-ai-camera/?_gl=1*pisx60*_up*MQ..*_ga*MTc2ODIzNjI1MS4xNzY4MDU5Njk3*_ga_3X2SL2XXEJ*czE3NjgwNTk2OTcjbzEkZzEkdDE3NjgwNTk4OTYkajUyJGwwJGgw).
  44. *Shelly Plus RGBW PM* [interaktyvus]. 2026 [žiūrėta 2025-11-01]. Prieiga per: <https://kb.shelly.cloud/knowledge-base/shelly-plus-rgbw-pm>.

45. *Roboflow: Computer vision tools for developers and enterprises* [interaktyvus]. 2026 [žiūrėta 2025-11-05]. Prieiga per: <https://roboflow.com/>.
46. Nemokamai apmokykite ir diegkite YOLO modelius „Ultralytics“ platformoje [interaktyvus]. 2014 [žiūrėta 2026-01-04]. Prieiga per: <https://platform.ultralytics.com/>.
47. *Ultralytics YOLOv5 – Ultralytics YOLO dokumentai* [interaktyvus]. 2023 [žiūrėta 2026-02-04]. Prieiga per: <https://docs.ultralytics.com/models/yolov5/>.
48. *Ultralytics YOLOv8 – Ultralytics YOLO dokumentai* [interaktyvus]. 2023 [žiūrėta 2026-02-04]. Prieiga per: <https://docs.ultralytics.com/models/yolov8/#overview>.
49. *Ultralytics YOLO11 – Ultralytics YOLO dokumentai* [interaktyvus]. 2024 [žiūrėta 2026-02-04]. Prieiga per: <https://docs.ultralytics.com/models/yolo11/>.
50. *Ultralytics YOLO26 – Ultralytics YOLO dokumentai* [interaktyvus]. 2025 [žiūrėta 2026-02-04]. Prieiga per: <https://docs.ultralytics.com/models/yolo26/>
51. *Raspberry Pi OS - Raspberry Pi dokumentacija* [interaktyvus]. 2026 [žiūrėta 2026-03-05]. Prieiga per: <https://www.raspberrypi.com/documentation/computers/os.html>.
52. *Raspberry Pi programinė įranga* [interaktyvus]. 2026 [žiūrėta 2026-03-05]. Prieiga per: <https://www.raspberrypi.com/software/>.
53. *Python 3.14.5 dokumentacija* [interaktyvus]. 2026 [žiūrėta 2026-03-06]. Prieiga per: <https://docs.python.org/3/>.
54. *Raspberrypi picamera2: „libcamera“ pagrindu sukurta Python biblioteka* [interaktyvus]. 2021 [žiūrėta 2026-03-06]. Prieiga per: <https://github.com/raspberrypi/picamera2>.
55. *Raspberry Pi / Rpicam programos* [interaktyvus]. 2020, 2021 [žiūrėta 2026-03-06]. Prieiga per: <https://github.com/raspberrypi/rpicam-apps>
56. *OpenCV: OpenCV moduliai* [interaktyvus]. 2026 [žiūrėta 2026-03-06]. Prieiga per: <https://docs.opencv.org/4.x/>.
57. *Dirbtinio intelekto programinė įranga – Raspberry Pi dokumentacija* [interaktyvus]. 2026 [žiūrėta 2026-03-06]. Prieiga per: <https://www.raspberrypi.com/documentation/computers/ai.html>.
58. *Hailo, PySDK, DeGirum „Hailo“ vykdymo aplinkos diegimo procedūros „PySDK“* [interaktyvus]. 2026 [žiūrėta 2026-03-06]. Prieiga per: <https://docs.degirum.com/pysdk/runtimes-and-drivers/hailort>.
59. *Užklauso: HTTP žmonėms. Užklauso 2.34.0.dev1 dokumentacija* [interaktyvus]. 2026 [žiūrėta 2026-03-06]. Prieiga per: <https://requests.readthedocs.io/en/latest/>.