



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Funkcinio testavimo efektyvumas elektronikos pramonėje

Baigiamasis magistro projektas

Dominykas Mendelis

Projekto autorius

Prof. Mindaugas Žilys

Vadovas

Kaunas, 2025



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Funkcinio testavimo efektyvumas elektronikos pramonėje

Baigiamasis magistro projektas

Elektronikos inžinerija (6211EX012)

Dominykas Mendelis

Projekto autorius

Prof. Mindaugas Žilys

Vadovas

Prof. Vaidotas Marozas

Recenzentas

Kaunas, 2025



Kauno technologijos universitetas

Elektros ir elektronikos fakultetas

Dominykas Mendelis

Funkcinio testavimo efektyvumas elektronikos pramonėje

Akademinių 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.

Dominykas Mendelis

Patvirtinta elektroniniu būdu

Mendelis Dominykas. Funkcinio testavimo efektyvumas elektronikos pramonėje. Magistro baigiamasis projektas / vadovas prof. dr. Mindaugas Žilys; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Elektronikos inžinerija, inžinerijos mokslai.

Reikšminiai žodžiai: funkcinis testavimas, mašininis mokymasis, anomalijų aptikimas, elektronikos gamyba, testavimo efektyvumas.

Kaunas, 2025. 57 p.

Santrauka

Funkciniai bandymai yra labai svarbūs siekiant užtikrinti elektroninių prietaisų kokybę ir patikimumą prieš juos pateikiant vartotojams. Kadangi elektronikos komponentai tampa vis sudėtingesni, funkcinio testavimo efektyvumo didinimas tampa vis svarbesniu iššūkiu elektronikos gamybos paslaugoms. Šiame darbe žvelgiama į tai, kaip pasiekti didesnę efektyvumą naudojant šiuolaikines technologijas, pavyzdžiui, didžiųjų duomenų analizę, mašininį mokymąsi ir neuroninius tinklus. Jame nagrinėjami įvairūs testavimo metodai, analizuojami pagrindiniai veiksniai, tokie kaip pirmojo perdavimo išeiga ir testavimo ciklo trukmė, ir nagrinėjama, kaip prognozių analitika gali padėti pastebėti ir pašalinti testavimo neefektyvumą. Darbe taip pat siūloma pradinė sistema, kaip į testavimo procesą įtraukti šiuolaikinius algoritmus, siekiant sutrumpinti vykdymo laiką, sumažinti klaidingų gedimų skaičių ir padidinti bendrą produkcijos kokybę. Išvados rodo, kad taikant dirbtiniu intelektu paremtus metodus, galima gerokai padidinti bandymų tikslumą ir efektyvumą, o tai lemtų mažesnes sąnaudas ir didesnę išeigą elektronikos gamybos pramonėje.

Mendelis Dominykas. Efficiency of Functional Testing in Electronics Industry. Master's Final Degree Project / supervisor Prof. Dr. Mindaugas Žilys; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): Electronics Engineering, Engineering Sciences.

Keywords: functional testing, machine learning, anomaly detection, electronics manufacturing, test efficiency.

Kaunas, 2025. 57 p.

Summary

Functional testing is essential for ensuring the quality and reliability of electronic devices before they are released to consumers. As electronic components become more complex, making functional testing more efficient is becoming an increasingly important challenge for Electronics Manufacturing Services. This research peers to achieve higher efficiency by using modern technologies like big data analytics, machine learning and neural networks. It examines different testing approaches, analyses key factors such as first pass yield and test cycle time and explores how predictive analytics can help spot and fix testing inefficiencies. Final work also proposes a starting framework for incorporating modern algorithms into testing process to reduce execution time, minimize false failures and boost overall production quality. Findings show that using AI-driven techniques can possibly greatly improve testing accuracy and efficiency, which would lead to lower costs and higher yields in electronics manufacturing industry

Turinys

Lentelių sąrašas	7
Paveikslų sąrašas	8
Santrumpų ir terminų sąrašas	10
Įvadas.....	11
1. Literatūros apžvalga	12
1.1. Testavimo efektyvumo apibrėžimo apžvalga	14
1.2. Matavimo sistemos analizė.....	15
1.3. Testavimo įrangų metodologijų palyginimas	16
1.4. Literatūroje apžvelgti efektyvumo gerinimo metodai	18
1.4.1. Elektronikos įrenginių defektų aptikimas, naudojant neuroninius tinklus	18
1.4.2. Testavimo trukmės optimizacija.....	21
1.4.3. Statistinių algoritmų panaudojimas bei duomenų analizė	21
1.5. Literatūros apžvalgos išvados.....	22
2. Testavimo rezultatų kaupimo sistema	24
2.1. FPY rodiklio pokyčio analizė	24
2.2. Charakteringų testavimo rezultatų apžvalga ir analizės gairės.....	26
2.3. Testavimo rezultatų kaupimo sistemos išvados	28
3. Siūloma testavimo įranga efektyvumui didinti.....	29
3.1. Reikšmingų testavimo rezultatų identifikavimas	31
3.1.1. Atlikta matavimo sistemos analizė	31
3.1.2. Testavimo metu fiksuotų neatitiktikčių analizė	33
3.1.3. Galutiniai pasirinkti testavimo žingsniai	34
3.2. Charakteringų testavimų analizė	36
3.2.1. Paleidimo srovės testavimo analizė.....	36
3.2.2. CAN komunikacijos įtampos impulso testavimas.....	37
3.3. Siūlomos testavimo įrangos efektyvumui didinti išvados	38
4. Eksperimentiniai tyrimai ir testavimo efektyvumo įvertinimas	40
4.1. CAN komunikacijos testavimo efektyvumo gerinimo metodologija.....	40
4.2. Mašininio mokymosi modelio kūrimas testavimo nuokrypiams atpažinti.....	43
4.3. Mašininio mokymosi modelio kūrimas testavimo anomalijoms atpažinti	46
4.4. Sukurtų modelių testavimas bei derinimas	49
4.4.1. Nuokrypio aptikimo modelio testavimas.....	50
4.4.2. Anomalijų aptikimo modelio testavimas.....	50
4.5. Neuroninio tinklo metodologijos metodo pritaikymas paleidimo srovės matavimo kontrolei	53
4.6. Eksperimentinių tyrimų išvados	54
Išvados	55
Literatūros sąrašas	56
Priedai.....	58
1 priedas. „Matlab“ programos kodas	58

Lentelių sąrašas

1 lentelė. „Keysight“ E2230C TS-5040 techninės galimybės [17]	13
2 lentelė. Skirtingų testavimo technologijų palyginimas.....	17
3 lentelė. Pagrindiniai rodikliai, apskaičiuoti pagal Gauso skirstinį	27
4 lentelė. Instrumentai, naudojami fikstūros viduje ar prijungiami per išorinę jungtį	30
5 lentelė. Gautos determinacijos koeficiento reikšmės prie skirtingų modelių.....	44
6 lentelė. Gauti determinacijos koeficientai, lyginant skirtingas mokymo technologijas	47
7 lentelė. Determinacijos koeficiento bei vidutinės kvadratinės paklaidos reikšmės, pasitelkus kryžminę validaciją.....	51
8 lentelė. Gauti rezultatai, kai MM modeliai sujungti, naudojant „Bagging“ technologiją	52
9 lentelė. Apskaičiuoti „Precision“, „Recall“ bei „F1“ parametrų įvertinimai	53

Paveikslų sąrašas

1 pav. „Keysight“ E2230C TS-5040 funkcinio testavimo įranga [17].....	12
2 pav. PXI išeiga (pav. a) ir LXI išeiga (pav. b) [18].....	13
3 pav. Tenkinamas ir netenkinamas matavimo išsidėstymas Gauso skirstinyje. Čia LSL – žemesnė testo specifikacijos matavimo riba, USL – aukštesnė [30].....	16
4 pav. Skirtingos testavimo technologijos: iš viršaus – skraidančio zondo (flying probe), adatų lovos (needle bed) ir šoninės prieigos (side access) technologijos [18]	17
5 pav. Skirtingi defektai PCB plokštėse [6]	19
6 pav. Tradicinio neuro tinklo panaudojimas spausdintinių montažo plokščių defektams aptikti [8]	19
7 pav. ViT technologija, pritaikyta aptikti spausdintinių plokščių defektus [14].....	20
8 pav. Trijų fazių išlyginamoji grandinė [15].....	20
9 pav. Grandinės išėjimo grandinė, kai VT1 yra brokuotas [15]	20
10 pav. Gamybos procesos automatizavimas [23]	21
11 pav. Struktūrinė duomenų analizės schema.....	24
12 pav. FPY ir panašių rodiklių stebėjimas	25
13 pav. FPY rodiklio kitimas per skirtingus mėnesius	26
14 pav. Multimetro matavimo išsibarstymas.....	26
15 pav. Mikrovaldiklio maitinimo įtampos matavimų pasiskirstymas Gauso skirstinyje.....	27
16 pav. Tiriamas objektas tyrime	29
17 pav. Testavimo adatų lova, fikstūra.....	30
18 pav. Gauti pajėgumo indeksai, kiekvienam testavimo žingsniui	32
19 pav. Testavimo įrangos ketvirčio FPY rezultatai	33
20 pav. Neatitikčių skaičiaus pasiskirstymas testo žingsniuose	34
21 pav. Gauti testavimo rezultatai, po baterijos įtampos komutacijos	36
22 pav. Tikslingas paleidimo srovės testo signalas	36
23 pav. Probleminis palaiedimo srovės testo signalas.....	37
24 pav. Paleidimo srovės matavimo rezultatai	37
25 pav. Paskutiniai gauti CAN komunikacijos žemo lygio įtampos matavimai	38
26 pav. Gauti rezultatai Gauso skirstinyje	38
27 pav. Testavimo metodologijos plėtros planas, CAN komunikacijos patikrai	41
28 pav. CAN komunikacijos įtampos rezultatai.....	41
29 pav. CAN komunikacijos impulso signalais	42
30 pav. Filtruotos CAN komunikacijos įtampos	42
31 pav. Gauti Pirsono koreliacijos ryšio koeficientai tarp parametrų prieš filtravimą (a) bei po filtravimo (b)	42
32 pav. Apskaičiuota Spirmano koreleacijos matrica tarp parametrų prieš (a) ir po filtravimo (b)..	43
33 pav. Gautos prognozuotos reikšmės, naudojant treniravimo duomenis, kai naudojamas „Random Forest“ modelis.....	45
34 pav. Parametrų svarbumas, dreifo aptikimų MM modelyje	45
35 pav. Gautos parametrų priklausomybės nuo prognozuojamos įtampos	46
36 pav. Gauti prognozių rezultatai anomalijų aptikimui. Viršuje – „LSBoost“ mokymo technologija, žemiau „Bagging“.....	47
37 pav. Parametrų svarbumas, anomalijų aptikimo MM modelyje.....	48
38 pav. Įtampos impulse prognozės priklausomybė nuo matavimo trukmės.....	48

39 pav. Įtampos impulso metu spėjimų priklausomybė nuo temperatūros bei įtampos prieš impulsą	49
40 pav. Teikiamų duomenų pasiskirstymas, kurie buvo naudojami apmokymui bei testavimui.....	49
41 pav. Realios ir prognozuojamos vertės, kai dreifo aptikimo modeliui pateikiamas naujas duomenų paketas	50
42 pav. Gauti testavimo rezultatai, testuojant anomalijų aptikimo MM modelį	51
43 pav. Parametrų svarbumas MM modeliuose.	52
44 pav. Kombinuoto MM modelio prognozės su naujais testavimo duomenimis	53
45 pav. Neuroninio tinklo metodologijos pritaikymas paleidimo srovės testavimo žingsniui.....	54

Santrumpų ir terminų sąrašas

Santrumpos:

ICT – grandinės testas (angl. *In-circuit testing*);

SMT – paviršinio montažo technologija (angl. *Surface-mount technology*);

I²C – vienas iš sinchroninių komunikacijos protokolų (angl. *Inter-Integrated Circuit*);

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

CAN – valdiklio mazgo magistralė (angl. *Controller area network*);

EOL – linijos testavimas (angl. *End-of-line*);

FCT – funkcinis testavimas (angl. *Functional testing*);

FPY – pirmojo perėjimo išeiga (angl. *First-pass yield*);

MM – mašininis mokymasis (angl. *Machine Learning*);

PCB – spausdintinio montažo plokštė (angl. *Printed Circuit Board*);

CPK – proceso pajėgumo indeksas (angl. *Process Capability Index*);

Ivadas

Elektronikos gaminių funkcinis testavimas atlieka svarbų vaidmenį tikrinant, ar sistema veikia taip, kaip numatyta, kol pasiekia galutinį vartotoją. Skirtingai nuo elektromagnetinio suderinamu bandymų ar prototipavimo, kurių metu daugiausia dėmesio skiriama atitinkamai atitikčiai reguliavimo standartams ir pradiniam projekto patvirtinimui, pramonėje testavimai atliekami teikiant elektronikos gamybos paslaugas bei yra orientuoti į galutinių gaminių eksploatacinių savybių užtikrinimą. Didėjant elektronikos komponentų integracijos lygiui, paruošti elektronikos įrenginius testavimui darosi vis sunkiau, kadangi dažnai jiems reikia išvestų testavimo taškų [1]. Dėl šios priežasties, šiomis dienomis funkcinis testavimas yra vis aktualesnis. Funkcinis testavimas patikrina surinktos spausdintinės plokštės funkcionalumą, tai pagrinde apima mikroprocesorių, atminties, sensorių ar kitų integrinių grandynų funkcionalumą elektronikos įrenginyje [2]. Efektyvus funkcinis testavimas turėtų ne tik užtikrinti aukštą testo apibrėžties lygį, bet ir būti greitas, stabilus bei finansiškai naudingas. Dėl šios priežasties, šiame darbe bus analizuojami įvairūs metodai ir priemonės, galinčios padidinti funkcinio testavimo efektyvumą elektronikos pramonėje, siekiant pagerinti testavimo proceso bei galutinių gaminių kokybę.

Darbo tikslas – ištirti funkcinio testavimo efektyvumą elektronikos pramonėje, identifikuoti esamas problemas ir pasiūlyti inovatyvius metodus bei sprendimus, siekiant pagerinti testavimo proceso tikslumą ir našumą, naudojant testavimo rezultatų analizę ir modernias technologijas;

keliama darbo uždaviniai:

1. atlikti testavimo metodologijų literatūros apžvalgą;
2. sukurti testavimo duomenų rinkimo architektūrą;
3. atlikti eksperimentinių duomenų analizę;
4. suprojektuoti algoritmą testavimo efektyvumui vertinti;
5. pasiūlyti metodus testavimo efektyvumui gerinti.

1. Literatūros apžvalga

Funkcinio testavimo metodologija yra būtina siekiant įvertinti, ar įrenginys atlieka numatytas funkcijas, ypač kompleksiškuose grandinių mazguose. Lyginant su kitomis testavimo metodologijomis, kaip ICT (angl. *In-Circuit-Testing*) ar AOI (angl. *Automatic Optical Inspection*), kurios efektyviai aptinka gamybos defektus, funkcinis testavimas reikalauja sudėtingesnio bei gilesnio lygio testavimo [3]. Suprantant šiuolaikinės elektronikos spartą, dėl didėjančio sistemų sudėtingumo, kurį lemia daugybės integrinių grandynų ir jutiklių integracija, funkcinis testavimas tapo dar svarbesnis [4]. Dažniausiai naudojama funkcinio testo įrangos struktūra susidaro iš trijų pagrindinių dalių.

- **Instrumentų montavimo struktūra** (angl. *Rack*) – modulinė konstrukcija, skirta matavimo prietaisų montavimui funkcinio testavimo metu. Ši struktūra užtikrina patikimą įrangos išdėstymą, vėsinimą bei patogų priemonių sujungimą. Rekomenduojama naudoti patikrintų gamintojų prietaisus, kaip „National Instruments“, „Rohde & Schwarz“, „Keysight“ ir reguliariai juos kalibruoti bei sertifikuoti, siekiant aukšto sistemos stabilumo.
- **Testavimo fikstūra** – įrankis, kuris dažniausiai naudojamas specialius zondus ar adatas, prisijungia prie įrenginio, kuris bus testuojamas. Prisijungimas prie įrenginio vyksta per spausdintinėje plokštėje išdėliotus testavimo taškus ar išvestas įrenginio jungtes. Testavimo fikstūra dažniausiai naudoja tokias technologijas kaip adatų lova (angl. *Needle Bed*), spyruokliuojantis išvadas (angl. *Pogo Pin*) ir kt.
- **Programinė dalis** – algoritmas, dažniausiai aprašomas aukšta, struktūrizuota programavimo kalba, kaip „LabView“ ar „TestStand“. Programinė įranga automatizuoja testavimo eigą, užtikrina tikslumą ir stabilumą bei suteikia galimybę lanksčiai keisti testo parametrus. Šioje vietoje ypatingai svarbu įvertinti instrumentų komunikacijos sąsajų galimybes ir sėkmingai jas derinti. Ne retai instrumentų gamintojai pateikia programines tvarkykles, kur matavimai derinami su programa.

Paruošta pavyzdinė testavimo įranga pavaizduota 1 paveiksle. Tai „Keysight“ gamintojo testavimo įranga, kuri paruošta testo kūrimui ir ženkliai sumažina projektavimo laiką. Sistemoje aiškiai matomos trys esminės dalys, apibrėžtos anksčiau.



1 pav. „Keysight“ E2230C TS-5040 funkcinio testavimo įranga [17]

Atvaizduotos „Keysight“ įrangos techninės galimybės pažymėtos 1 lentelėje. Dažnai įrangos būna vertinamos savo lankstumu bei instrumentu įvairumu, jog būtų galima testuoti įvairius įrenginius, nuo ypatingai paprastų iki kompleksiškų.

1 lentelė. „Keysight“ E2230C TS-5040 techninės galimybės [17]

RF komutavimas	1x4 RF komutavimo galimybė (DC 3 GHz)
Maitinimo šaltinis	Iki 400W galios užmaitinimo galimybė
Išmatavimai	2,020 (H) x 600 (W) x 905 (D) mm
Signalų komutavimas	112x4 matrica
Apkrovos komutavimas	32x7.5 A; 40x5 A; 192x 2 A
Matavimas	6.5 skaitmenos multimetras, 2x350 MHz skaitiklis
Stimulus	Vieno kanalo 14-bit; Dviejų kanalų, 30 MHz, signalų generatorius
Duomenų kaupiklis	4 kanalų, 16 bitų duomenų kaupiklis (DAQ)
Instrumentų sąsajos	GPIO, LXI, PXI, PXIe
Aplikacijos	ABS sensoriai, klimato kontrolės sistema, mažoji elektronika, ECU

Visi naudojami aparatinės dalies komponentai priklauso „Keysight“ gamintojui, todėl detalesnė techninė informacija pateikiama matavimo prietaisų duomenų lapuose. Prisijungimui prie fikstūros reikalingos instrumentų prisijungimo sąsajos, reikalingi standartai apibrėžiami žemiau [6, 18].

1. GPIB (Bendrosios paskirties sąsajos magistralė):
 - senesnis, bet vis dar plačiai naudojamas standartas, skirtas prijungti ir valdyti prietaisus bandymų aplinkoje;
 - lygiagrečiojo ryšio sąsaja - prie vieno valdiklio galima prijungti daug prietaisų.
2. LXI (LAN eXtensions for Instrumentation):
 - modernesnis standartas, kuriame prietaisams prijungti naudojamas Ethernet;
 - jis leidžia nuotoliniu būdu valdyti per LAN, todėl jį galima lengviau ir lanksčiau pritaikyti paskirstytoms sistemoms.
3. PXI (PCI eXtensions for Instrumentation):
 - modulinė platforma, skirta automatizuotiems bandymams, kurioje PCI (Peripheral Component Interconnect) standartas derinamas su didelio našumo prietaisais;
 - PXI sistemas dažnai sudaro važiuoklė su lizdais keliems modulinėms prietaisams, todėl jos yra labai kompaktiškos ir galingos atliekant bandymus.
4. PXIe (PCI eXtensions for Instrumentation Express):
 - tai PXI plėtinys su papildomais „PCI Express“ privalumais, užtikrinančiais didesnę pralaidumą ir spartesnę duomenų perdavimą;
 - paprastai naudojamas didelės spartos ir didelio tikslumo bandymų programose.

Šiais laikais dažniausiai naudojamos sąsajos išlieka PXI ar LXI (2 pav.).



2 pav. PXI išeiga (pav. a) ir LXI išeiga (pav. b) [18]

Apibendrinant galima teigti, jog „Keysight“ E2230C TS-5040 funkcinio testavimo įranga susidaro iš gamintojo instrumentų ir turi integruotas išeigas į atitinkamas sąsajas. Gamintojas nurodo, jog sistema gali būti valdoma jų sukurta programine įranga, kuri gali būti integruota ir į kitas platformas, pavyzdžiui „TestStand“. Vis dėlto, testavimo įranga nėra tinkama įrenginiams, kuriems reikalingas didesnis galios arba signalų apdorojimo pajėgumas. Instrumentų stovas neturi ne tik oscilografo ar spektro analizatoriaus, kurie stipriai susiję su signalų apdorojimu, bet ir didelės galios instrumentų ar apkrovos modulių, todėl sistemos taikymo sritis yra ribota[17]. Dėl šių priežasčių tokio tipo įranga dažnai projektuojama pritaikant ją specifinėms gaminių grupėms. Toliau šiame skyriuje bus nagrinėjamos naudojamos technologijos ir skirtingos funkcinio testavimo metodologijos, siekiant detaliau suprasti efektyvumo apibrėžimą ir jo tobulinimo metodus. Akivaizdu, kad šiuolaikinės pažangios technologijos daro įtaką funkcinio testavimo tendencijoms, todėl vis dažniau siekiama automatizuoti testavimo įrangą ir sumažinti žmogaus įsikišimą į elektronikos testavimo procesus. Taip pat nagrinėjamos dirbtinio intelekto panaudojimo galimybės, siekiant toliau optimizuoti testavimo efektyvumą [7].

1.1. Testavimo efektyvumo apibrėžimo apžvalga

Funkcinis testavimas yra glaudžiai susijęs su pramone, tačiau pakankamai sudėtingas rodiklis, kuris apima keletą parametrų. Neatsižvelgiant į tai, kad pramonėje laikas ir automatizavimas yra prioritetas, testavimo metu ypatingai svarbu aptikti gamybos klaidas, patikrinti įrenginio funkcionalumą bei užtikrinti kokybę [2, 10]. Svarbų vaidmenį testavimo metu atlieka testo apibrėžtis (angl. *test coverage*), kuri apibūdina testo išpildymą ir idealiu atveju turėtų siekti 100%. Toliau aprašomi pagrindiniai parametrai, naudojami testavimo proceso našumui vertinti.

- FPY (angl. *First Pass Yield*) – įrenginių atitikimas testavimo sąlygoms iš pirmo karto, % – tai parametras, kuris parodo, kiek gamybos vienetų pereina testavimą be papildomų pataisų.
- Testo apibrėžtis – parodo, kiek įvairių testavimo atvejų buvo atlikta, literatūroje gali būti minimas kaip testo dengiamumas, matavimo vienetas - %.
- Matavimo trukmė – laiko intervalas, reikalingas atlikti vienam matavimui, matavimo vienetas - s.
- Testo operacijos trukmė – laiko intervalas, per kurį atliekama viena testavimo iteracija, matavimo vienetas - s.

Nors šie parametrai yra svarbūs ir padeda įvertinti testavimo efektyvumą, vis tik literatūroje minimas galutinis tikslas yra produkto kokybės užtikrinimas bei matavimo stabilumas. Dėl šios priežasties, dažnai testavimo ir gamybos procesų sėkmės vertinimas priklauso nuo galutinio defektų skaičiaus ir stabilumo, kuris tiesiogiai susijęs su pajėgumo indeksu CPK.

Pajėgumo indeksas yra esminis rodiklis, vertinantis gamybos proceso stabilumą ir gebėjimą gaminti produktus, atitinkančius kokybės reikalavimus. CPK rodiklis įvertina, kiek produktų atitinka specifikacijas ir ar gamybos procesas yra pakankamai stabilus, kad būtų išvengta defektų. Aukštas CPK indeksas rodo, kad gamybos procesas yra labai pajėgus ir stabilus, tokiu atveju gaminiai atitinka užduotus reikalavimus. Tai tiesiogiai susiję su galutinės gamybos kokybės užtikrinimu, nes testavimo procesas turi būti ne tik išsamus, bet ir orientuotas į galutinio produkto atitiktį aukštiesiems kokybės standartams. Ši išplėtotą apžvalga parodo, kad testavimo kokybė ir įvairūs testavimo parametrai, kaip FPY ir testo dengiamumas, yra tik dalis viso proceso, o galutinis tikslas yra užtikrinti aukštą gamybos stabilumą ir kokybę, kurie gali būti matuojami taikant CPK indeksą.

1.2. Matavimo sistemos analizė

Literatūroje funkcinio testavimo įranga dažnai apibrėžiama kaip matavimo sistema, nes jos veikimas tiesiogiai priklauso nuo matavimo instrumentų tikslumo, stabilumo bei duomenų apdorojimo greičio. Toks apibrėžimas yra logiškas, nes funkcinis testavimas stipriai priklauso nuo matavimo instrumentų tikslumo, stabilumo bei duomenų apdorojimo greitaveikos ar valdymo sąsajos. Žinoma, kad funkcinio testavimo įrangos yra projektuojamos pagal gamintojo bei kliento sutarta testavimo reikalavimo specifikaciją, kurioje apibrėžiami įvairūs matavimai bei funkcijų tikrinimo reikalavimai [20]. Vertinant sistemos stabilumą, analizė atliekama kiekvienam matavimui atskirai. Analizei naudojami pagrindiniai statistiniai parametrai – standartinis nuokrypis, dispersija, imtis ir kt. Literatūroje minima, kad vienas iš pagrindinių efektyvumo bei stabilumo nustatymo metodų, kurie naudojami testo įrangų kūrimo inžinierių, yra matavimo sistemos analizė, kurioje stabilumas vertinamas tiek testavimo įrangos, tiek testuojamo įrenginio atžvilgiu. Suprantama, kad įrangoje esantys instrumentai turi apibrėžtą matavimo tikslumą bei rezoliuciją, kas gali netenkinti testavimo specifikacijos, o testuojamas įrenginys turi per didelę matavimo toleranciją dėl prastai pasirinktų komponentų [9]. Skirtingi metodai yra naudojami apibrėžiant testavimo įrangos bei testuojamo įrenginio stabilumą, jie aprašomi toliau.

- **Matavimo sistemos pasikartojimo analizė** – atliekama, kai siekiama įvertinti testavimo įrangos stabilumą. Tokiam įvertinimui, testuojamas tas pats įrenginys nemažiau 10 kartų. Svarbu įsitikinti, kad testavimo sistema veikia tikslingai ir turi minimalias nuokrypių galimybes, čia svarbiausias rodiklis – įrangos variacija, apskaičiuojama pagal 1 formulę.

$$EV = \frac{6 \cdot \sigma}{L_U - L_L} \cdot 100 \% \quad (1)$$

čia: L_U – aukštesnė rekomenduojama matavimo riba; L_L – žemesnė rekomenduojama matavimo riba; σ – standartinis nuokrypis; EV – įrangos variacija.

- **Matavimo sistemos nuokrypių analizė** – atliekama, kai siekiama įvertinti testuojamo įrenginio stabilumą. Įvertinimui testuojami nemažiau 10 skirtingų tų pačių elektronikos gaminių. Taip įvertinamas įmanomas matavimų išsibarstymas. Čia svarbiausias rodiklis – pajėgumo indeksas, apskaičiuojamas pagal žemiau pateikiamą formulę.

$$CPK = \min \left(\frac{L_U - \mu}{3 \cdot \sigma}, \frac{\mu - L_L}{3 \cdot \sigma} \right); \quad (2)$$

čia: L_U – aukštesnė rekomenduojama matavimo riba; L_L – žemesnė rekomenduojama matavimo riba; μ – matavimo vidurkis; CPK – proceso pajėgumo indeksas.


Svarbu gebėti atskirti įrangos ir įrenginio stabilumą, remiantis pateiktais parametrais. Atliekant matavimo sistemos pasikartojimo analizę, literatūroje bei pramonėje dažnai minimos tokios EV rodiklio direktyvos, kaip pavaizduotos žemiau [9]:

- $EV > 30 \%$, sistema laikoma nestabili;
- $10 \% \leq EV \leq 30 \%$, sistema laikoma stabili, bet gali būti tobulinama;
- $EV < 10 \%$, sistema laikoma nestabili.

Panašiai įvertinamas ir pajėgumo indeksas CPK. Literatūroje dažnai minima, kad CPK indekso riba yra 1 reikšmė, vis dėlto, pramonės praktikoje dažnai numatomas griežtesnis įvertinimas. Parametro direktyvos nurodomos toliau

- $CPK > 1,67$, procesas laikomas pajėgiu;
- $1,33 \leq CPK \leq 1,67$, procesas laikomas pajėgiu, tačiau jį galima gerinti;
- $CPK < 1,33$, procesas yra nepajėgus, būtina imtis veiksmų.

Taigi, kai tiriama pasikartojimo analizė, tikimasi, kad EV reikšmė būtų kuo mažesnė arba bent jau mažesnė nei 10 %, kai tiriamas testavimo įrangos nuokrypis, tikimasi, jog CPK indeksas būtų kuo didesnės reikšmės ar bent jau didesnis už 1,67 vertę. Analizių apibendrinimas dažnai pateikiamas Gauso skirstinyje. Pagal matavimo išsidėstymą Gauso skirstinyje, dažnai galima nuspėti ar EV bei CPK kriterijai yra tenkinami. Tikimasi, jog intensyviausias matavimo išsidėstymas būtų centre, tarp matavimo testo specifikacijoje ribų. 3 paveiksle pateikiami pavyzdžiai, kai matavimo išsidėstymas atitinka arba neatitinka kriterijų įverčius Gauso skirstinyje.



3 pav. Tenkinamas ir netenkinamas matavimo išsidėstymas Gauso skirstinyje. Čia LSL – žemesnė testo specifikacijos matavimo riba, USL – aukštesnė [30]


Ši analizės koncepcija taikoma tiek pasikartojimo, tiek nuokrypių analizėms – pagrindinis skirtumas slypi matavimų imtyje. Pasikartojimo analizėje testuojamas tas pats įrenginys, o nuokrypių analizėje – skirtingi, bet analogiški gaminiai. Matavimo sistemos analizė atlieka svarbų vaidmenį vertinant testavimo įrangos efektyvumą, tačiau jos rezultatai daugiausia priklauso nuo pasirinktų instrumentų precizikos ir testo specifikacijos reikalavimų. Tinkamai parinkus matavimo įrangą, metodikas ir specifikacijos ribas, galima reikšmingai pagerinti sistemos stabilumą. Tinkamai parinkti veiksniai didina tiek gamybos, tiek testavimo procesų efektyvumą [11].

1.3. Testavimo įrangų metodologijų palyginimas

Šiame skyriuje apžvelgiami dažniausiai taikomų funkcinio testavimo technologijų privalumai ir trūkumai. Toliau pristatomos trys technologijos, kurios šiuo metu yra plačiausiai naudojamos funkciname testavime (4 pav.).

- **Skraidančio zondo technologija** (angl. *Flying probe*) – leidžia testuoti spausdintines plokštes, naudojant judančius zondus, kurie automatiškai atlieka matavimus ir testus be specialių fikstūrų.

- **Adatų lovos technologija** (angl. *Needle bed*) – naudoja specializuotą fikstūrą su daugeliu adatų, kurios tiesiogiai kontaktuoja su spausdintinės plokštės testavimo taškais.
- **Šoninės prieigos technologija** (angl. *Side Access*) – suteikia galimybę pasiekti testavimo taškus iš šonų, naudojant specialius zondus arba priemones, skirtas sudėtingoms plokštėms su dideliu komponentų tankumu.



4 pav. Skirtingos testavimo technologijos: iš viršaus – skraidančio zondo (flying probe), adatų lovos (needle bed) ir šoninės prieigos (side access) technologijos [18]

Technologijų apibrėžimai padeda geriau suprasti jų taikymo sritis, o toliau pateikiami pagrindiniai šių metodų privalumai ir trūkumai leidžia įvertinti skirtingų technologijų efektyvumo aspektus. 2 lentelėje technologijos lyginamos tarpusavyje pagal pasirinktus efektyvumo kriterijus. Nors toks palyginimas nėra visiškai tikslus, jis leidžia preliminariai įvertinti technologijų tinkamumą skirtingoms situacijoms. Tikslesniam vertinimui būtina analizuoti konkrečius atvejus, kai naudojama ta pati testavimo įranga ir identiški įrenginiai. Technologijos efektyvumas dažnai priklauso nuo testuojamo įrenginio konstrukcijos. Pavyzdžiui, adatų lovos metodas gali būti ribotas, jei spausdintinėje plokštėje nėra pakankamo skaičiaus testavimo taškų.

2 lentelė. Skirtingų testavimo technologijų palyginimas

Palyginimo sritis	Skraidantis zondas	Adatų lova	Šoninė prieiga
Testavimo greitis	Vidutinis	Greitas	Vidutinis
Kaina	Maža	Aukšta	Vidutinė

Lankstumas	Didelis	Mažas	Vidutinis
Tikslumas	Aukštas	Aukštas	Vidutinis
Įrenginio sudėtingumas	Tinka įvairiems įrenginiams	Tinka standartiniams įrenginiams	Tinka aukšto kompleksiško įrenginiams
Paruošimo laikas	Mažas	Aukštas	Vidutinis
Priežiūra, kalibravimas	Mažas	Aukštas	Vidutinis
Kompaktiškumas	Aukštas, tinka mažoms ir vidutinėms gamyboms	Mažas, tik didesnio kiekio gamyboms	Vidutinis, galima bandyti pritaikyti
Integracija	Gali būti pritaikoma	Sunkiau pritaikoma, reikalingas modifikavimas	Sunkiau pritaikoma, reikalingas modifikavimas
Dengiamumas	Vidutinis	Aukštas	Vidutinis
Paprastumas	Vidutinis	Aukštas	Vidutinis


Lentelėje pateiktas palyginimas leidžia identifikuoti stipriausias kiekvienos testavimo technologijos savybes ir jų taikymo kontekstus. Vis dėlto, norint tiksliau įvertinti efektyvumą, būtina atlikti analizę realiomis testavimo sąlygomis, kai vertinamos tos pačios funkcijos skirtingomis technologijomis.

1.4. Literatūroje apžvelgti efektyvumo gerinimo metodai

Literatūroje funkcinio testavimo efektyvumas dažniausiai siejamas su defektų mažinimu, automatizavimo lygiu bei proceso kokybe. Elektronikos gaminių testavimo sėkmė, kaip ir kitų gamybos etapų, paprastai vertinama pagal greitį ir kokybinius rodiklius. Šiuolaikinėse gamybos sistemose siekiama kuo didesnio proceso automatizavimo, kad būtų užtikrintas testavimo greitis ir sumažintas žmogaus įsikišimo poreikis. Automatizuotos sistemos leidžia efektyviau valdyti laiką ir sumažinti gamybos sąnaudas, taip optimizuojant finansinių išteklių panaudojimą [10]. Vertinant testavimo įrangos efektyvumą, literatūroje dažnai išskiriamas FPY rodiklis, kuris atspindi, kokia gaminių dalis tenkina testavimo sąlygas iš pirmo karto. Idealiu atveju FPY reikšmė turėtų siekti 100 %, nes tai reikštų maksimalų testavimo ir gamybos efektyvumą. FPY glaudžiai susijęs su testavimo apibrėžtimi, nes kuo daugiau testų padengiama, tuo didesnė tikimybė užfiksuoti defektus pirmo bandymo metu [1].


1.4.1. Elektronikos įrenginių defektų aptikimas, naudojant neuroninius tinklus

Literatūroje aprašyti atvejai, kai spausdintinių montažo plokščių defektai aptinkami naudojant neuroninius tinklus. Šie metodai leidžia automatizuotai analizuoti vaizdus ar matavimo duomenis, siekiant identifikuoti netipinius modelius ar pažeidimus [8]. Suprantama, kad spausdintinės plokštės konstrukcija yra tiesiogiai susijusi su testo dengiamumu. Kaip jau buvo minėta, dėl didelio komponentų kiekio ir mažėjančios erdvės, projektuotojai vis dar privalo numatyti pakankamą skaičių testavimo taškų, kad būtų užtikrintas sklandus testavimo procesas. Vis dėlto, nemaža dalis defektų vis dar aptinkama pačiose spausdintinėse plokštėse (5 pav.).




5 pav. Skirtingi defektai PCB plokštėse [6]

Defektų aptikimui literatūroje siūlomas sprendimas, paremtas mašininio mokymusi, tiksliau – neuroniniu tinklu [8]. Šiuo metu neuroniniai tinklai plačiai taikomi įvairiose srityse, įskaitant ir spausdintinių montažo plokščių defektų aptikimą. Neuroninio tinklo struktūra paprastai susideda iš įėjimo, išėjimo ir paslėptų sluoksnių. Tinkle pateikiant dažniausiai pasitaikančių defektų pavyzdžius, paslėpti sluoksniai gali išmokyti juos atpažinti ir testavimo metu nurodyti galimus defektus ar rizikas [12] (6 pav.).




6 pav. Tradicinio neuro tinklo panaudojimas spausdintinių montažo plokščių defektams aptikti [8]

Tobulėjant neuroninių tinklų technologijoms, literatūroje pristatyta ir regos transformacijos (toliau – ViT) metodika, leidžianti tinklui geriau įvertinti vaizdų struktūrą ir padėti erdvėje [14]. Pateikta diagrama, kurioje vaizduojama, kaip ViT technologija gali būti pritaikoma spausdintinių plokščių defektų aptikimui [15] (7 pav.).




7 pav. ViT technologija, pritaikyta aptikti spausdintinių plokščių defektus [14]

Vis dėlto, spausdintinių plokščių defektų aptikimas dažniausiai vykdomas dar prieš įrenginiui pasiekiant funkcinio testavimo etapą gamybos procese. Daugiau praktinės naudos funkcinio testavimo kontekste gali turėti neuroninių tinklų taikymas galios elektronikos įėjimo grandinės patikrinimui. 8 paveiksle pavaizduota grandinė, susidedanti iš šešių tiristorių – tai trijų fazių išlyginamoji schema.



8 pav. Trijų fazių išlyginamoji grandinė [15]

Taikant neuroninius tinklus ir pasitelkiant vaizdų apdorojimą, galima identifikuoti, kuris tiristorius turi defektą, remiantis grandinės išėjimo oscilogramos pokyčiais. 9 paveiksle pateikta U_d įtampos oscilograma, kuomet yra brokuotas VT1 tiristorius.




9 pav. Grandinės išėjimo grandinė, kai VT1 yra brokuotas [15]

Tai yra vienas iš galimų defektuotos grandinės atvejų, kai VT1 tiristorius sukelia trumpąjį jungimą. Toks defektas tiesiogiai atsispindi grandinės išėjimo oscilogramoje. Šiuos pokyčius galima nustatyti analizuojant įtampos pikų laiką ir lyginant juos su normaliu veikimu. Apdorojus šiuos duomenis neuroninio tinklo paslėptuose sluoksniuose, galima tiksliai identifikuoti defektą ir nustatyti konkretų tiristorių, sukeliantį gedimą [15, 26].

1.4.2. Testavimo trukmės optimizacija

Šiame skyriuje nagrinėjami metodai, kurie leidžia optimizuoti testavimo eigą bei sumažinti testavimo trukmę [16]. Išsamiau vertinant automatizavimo įtaką elektronikos pramonėje, pastebima, jog ji turi didelę reikšmę visame gamybos cikle. Gamyboje jau ilgą laiką taikomos konvejerinės sistemos, kuriose žmogaus įsikišmas minimalus – tai padeda sumažinti klaidų tikimybę. Vis dėlto, automatizavimas sukuria ir papildomų resursų poreikį, kai procedūros turi būti nuolat stebimos bei prižiūrimos [23] (10 pav.).



10 pav. Gamybos procesos automatizavimas [23]

Vis dėlto, procesų automatizavimui pritaikomos ir modernios technologijos, tokios kaip daiktų internetas bei realaus laiko stebėseną. Šios priemonės leidžia optimizuoti ir spartinti gamybos procesus, įskaitant ir elektronikos testavimo procedūras. Toks optimizavimas reikalauja papildomų investicijų, kurios ne visuomet atsiperka, ypač sudėtingoje ir plataus masto elektronikos pramonėje [24, 25].

1.4.3. Statistinių algoritmų panaudojimas bei duomenų analizė

Matematiniai algoritmai užima svarbią vietą elektronikos testavimo procesuose. Jie leidžia sistemingai analizuoti didelius duomenų kiekius ir optimizuoti testavimo eigą. Tradicinės statistikos metodikos, tokios kaip regresinė analizė, jau seniai naudojamos siekiant nustatyti ryšius tarp

testavimo parametrų ir gauto signalo charakteristikų. Pastaraisiais metais, algoritmų taikymas kito į sudėtingesnius metodus – klasifikacijos ir grupavimo algoritmus, skirtus aptikti paslėptas anomalijas bei segmentuoti duomenis pagal galimus gedimų tipus. Šiame kontekste, matematiniai modeliai suteikia galimybę ne tik optimizuoti esamus procesus, bet ir kurti prognozavimo sistemas, kurios iš anksto aptinka nepagrįstus svyravimus bei neatitikimus testavimo metu. Toliau pristatomos ir vertinamos pagrindinės metodikos, kuriomis remiantis galima sukurti sprendimus, pritaikomus realiuose gamybos procesuose, kurie padeda mažinti klaidų kiekį ir didinti bendrą testavimo sistemos efektyvumą. Atlikus apžvalgą, išskirtos pagrindinės matematikos algoritmų technologijos, naudojamos elektronikos pramonėje.

- **Regresinė analizė** – tai statistinis metodas, leidžiantis nustatyti ir įvertinti priklausomybės ryšius tarp vieno priklausomo kintamojo ir vieno ar kelių nepriklausomų kintamųjų. Elektronikos testavime ši analizė gali būti naudojama prognozuoti matavimo reikšmes arba tikimybę, kad tam tikras vienetas netenkins testavimo sąlygų dėl nustatytų parametrų pokyčių.
- **Klasifikacija** – tai priemonė, leidžianti priskirti duomenis vienai iš anksto nustatytų kategorijų, remiantis jų savybėmis. Elektronikos testavimo kontekste, klasifikavimo algoritmai gali padėti automatiškai identifikuoti įrenginius, kurie, tikėtina, patirs gedimą, dar prieš įvykstant faktinei testo nesėkmei.
- **Kvantilių analizė** – tai duomenų skirstymo metodas, padedantis įvertinti, kaip duomenys pasiskirsto intervale. Kvantilai, tokie kaip medianos ar 95-ojo procentilio reikšmės, leidžia aptikti netipinius matavimus arba vienetus, kurie patenka į rizikingas zonas pagal testavimo rezultatus.

Pavieniai šie metodai gali būti ne efektyvūs, vis dėlto, matematikos ar statistikos technologijos yra dažnai integruojamos į duomenų stebėsenos sistemas ar dirbtinio intelekto, mašininio mokymosi modelius.

Taip pat, šiuolaikinėje elektronikos gamyboje testavimo duomenų analizė ir nuolatinė stebėseną tampa vienu svarbiausių efektyvumo didinimo veiksnių. Literatūroje pabrėžiama, kad didėjant testuojamų įrenginių kiekiui ir sudėtingumui, atsiranda būtinybė naudoti didžiųjų duomenų (angl. Big Data) analizės metodus, leidžiančius ne tik saugoti, bet ir prasmingai interpretuoti sukaupią informaciją. Tyrimai rodo, kad nuosekli testavimo duomenų stebėseną leidžia greitai identifikuoti nuokrypius nuo įprastų procesų, tokiais atvejais kaip matavimo instrumentų dreifas, netikslus trigeriavimas ar padidėjęs gedimų dažnis tam tikrose testavimo sekcijose. Kelių autorių teigimu, efektyvi analizės sistema gali aptikti tendencijas ar pasikartojančius gedimų modelius, kurie kitaip būtų nepastebimi kasdieninėje gamybos praktikoje. Be to, pažangi testavimo stebėseną dažnai integruojama su automatizuotomis signalų analizės, kokybės kontrolės ar priežiūros sistemomis. Tai leidžia įgyvendinti prevencinius veiksmus realiu laiku, sumažinti nereikalingų testų kiekį bei optimizuoti testavimo eigą. Tokie metodai taip pat padeda kurti prognozių modelius, kurių pagrindu galima prognozuoti būsimas nesėkmes ir taip dar labiau sumažinti nereikalingų pakartotinių testų skaičių ar galutinio produkto broką [27, 28, 29].

1.5. Literatūros apžvalgos išvados


1. Funkcinis testavimas yra esminis veiksnys, siekiant užtikrinti galutinio elektronikos gaminio kokybę ir patikimumą, o naudojamos testavimo technologijos – adatų lova, skraidančio zondo

ir šoninės prieigos – pasižymi skirtingais privalumais, kurie leidžia prisitaikyti prie įvairių testavimo poreikių.

2. Didžiųjų duomenų analizė, mašininis mokymasis ir neuroniniai tinklai turi didelį potencialą padidinti testavimo efektyvumą, sumažinant klaidingų gedimų identifikavimą ir optimizuojant testavimo laiką bei resursų panaudojimą.
3. Efektyvus funkcinis testavimas glaudžiai siejasi su matavimo sistemos stabilumu, FPY rodiklio stebėseną ir testavimo procesų automatizacija. Šių veiksmų kontrolė yra būtina, norint užtikrinti testavimo įrangos efektyvumą praktikoje.

2. Testavimo rezultatų kaupimo sistema

Duomenims rinkti naudojama prieigos programa, leidžianti analizuoti testavimo įrangų efektyvumą elektronikos gamyklos duomenų bazėje. Programa susideda iš atskirų sekcijų, skirtų įvairių testavimo parametrų vertinimui. Duomenų bazės panaudojimas priklauso nuo tyrimo architektūros dalių, kurios apibrėžia informacijos srautą ir analizės struktūrą. Struktūrinė tyrimo schema atvaizduota 11 paveiksle.




11 pav. Struktūrinė duomenų analizės schema

Remiantis struktūrine schema, analizė bus vykdoma analizuojant gamybos testavimo procesą, naudojant matavimo rezultatus efektyvumo įvertinimui ir prastų rezultatų priežasčių nustatymui. Tokia analizė leis įvertinti, kaip galima tobulinti testavimą ir didinti funkcinio testavimo efektyvumą. Šiame skyriuje pristatoma naudojama duomenų struktūra ir pateikiama informacija apie vidinės duomenų bazės galimybes. Toliau aprašomos pagrindinės funkcijos, kurios bus taikomos tyrime.

2.1. FPY rodiklio pokyčio analizė

FPY rodiklis jau buvo apibrėžtas literatūros apžvalgos skyriuje. Duomenų bazė leidžia nustatyti, kiek įrenginių buvo pratestuota, ir kiek iš jų tenkino testavimo sąlygas iš pirmo, antro, trečio ar paskesnių kartų. Šis rodiklis glaudžiai susijęs ir su gamybos procesais. Pavyzdžiui, SMT surinkimo linijoje dėl neteisingai įdėto diodo įrenginys tampa nefunkcionalus. Visgi, FPY rodiklis taip pat atspindi ir pačios testavimo įrangos efektyvumą. Pavyzdžiui, įrenginys netenkino testavimo sąlygų iš pirmo karto,

tačiau tenkino iš antro, nors jokių aparatinės dalies pakeitimų nebuvo atlikta. Tokiais atvejais galima įtarti pirmojo tipo klaidą, kai teisingas gaminys klaidingai atmetamas kaip brokuotas. Tai laikoma „False Fail“ atveju ir turi neigiamą poveikį gamybos procesui, nes sukelia papildomą pakartotinį testavimą ar nereikalingas intervencijas (12 pav.).



12 pav. FPY ir panašių rodiklių stebėjimas

Pateiktame pavyzdyje testuoti 10 832 įrenginiai, iš kurių 10 756 atitiko testavimo sąlygas iš pirmo karto. Tai rodo, kad testavimo įranga pasižymi aukštu efektyvumu. Visgi, elektronikos gamyboje įprasta praktika kartoti testą bent du kartus, siekiant užtikrinti, kad gaminys nėra defektuotas. Todėl galima identifikuoti atvejus, kai įranga sukėlė pirmojo tipo klaidą ir teisingas gaminys buvo klaidingai atmestas. Tokios situacijos pastebimos tarp tų gaminių, kurie testavimo sąlygas tenkina tik po antro ar trečio testavimo. Įrenginiai, kurie testavimo sąlygas tenkina tik paskutiniu bandymu, tikėtina, buvo remontuoti ir patyrė aparatinės dalies pakeitimus, todėl jų rezultatai nėra tinkami vertinant testavimo įrangos efektyvumą. Apibendrinant, pateiktos 3 bei 4 formulės leidžia abstrakčiai įvertinti testavimo sistemos našumą:

$$\eta_{FPY} = \frac{FPY}{FPY+SPY+TPY} * 100 \%;$$
(3)

čia: FPY – gaminių skaičius praėjusius testą iš pirmo karto; SPY – gaminių skaičius praėjusius testą iš antro karto; TPY – gaminių skaičius praėjusius testą iš trečio karto; η_{FPY} – įrangos efektyvumas, remiantis FPY.

$$\xi_{FPY} = \frac{SPY+TPY}{FPY+SPY+TPY} * 100 \%;$$
(4)


čia: ξ_{FPY} – įrangos neefektyvumas, remiantis FPY.

Apskaičiavimai:

$$\eta_{FPY} = \frac{10\,756}{10\,756+44+13} * 100 \% = 99,47 \%;$$

$$\xi_{FPY} = 100 - 99,47 = 0,53 \%$$

Tai rodo, kad įranga dar gali būti tobulinama. Be to, stebint FPY ir kitų parametų pokyčius laike, galima įvertinti įrangos stabilumą bei efektyvumo gerinimo veiksmų rezultata. 13 paveiksle pavaizduotas FPY pokytis laike, naudojant tą pačią įrangą.



13 pav. FPY rodiklio kitimas per skirtingus mėnesius

Vertinant FPY rodiklius kiekvieną mėnesį, pastebima, kad testavimo įranga veikia nepakankamai stabiliai ir gali būti tobulinama, siekiant didesnio efektyvumo.

2.2. Charakteringų testavimo rezultatų apžvalga ir analizės gairės


Testavimo sistemos nuolat generuoja rezultatų ataskaitas, kurios gali būti analizuojamos siekiant įvertinti įrangos stabilumą. Analogiškai kaip FPY rodiklio stebėsena leidžia vertinti įrangos efektyvumą, panašus principas gali būti taikomas ir matavimo nuokrypių analizei. Literatūroje pabrėžiama, kad testavimo tikslumui užtikrinti būtina naudoti stabilius, kalibruotus ir tiksliai veikiančius matavimo instrumentus. 14 paveiksle pateikti „National Instruments“ PXI-4065 multimetromatavimai, atlikti testavimo įrangoje.



14 pav. Multimetromatavimo išsibarstymas

Atvaizduoti testavimo rezultatai yra tik vienos savaitės, nes įrenginių testavimas vyksta pakankamai intensyviai, o duomenų srautas gali būti ypatingai didelis. Vis dėlto, suprantant šios funkcijos galimybes, galima stebėti, kaip keičiasi matavimų vidurkis bėgant laikui. Tai galima pritaikyti ir išankstinei kalibravimo datai, jei matoma, kad matavimas dreifuoja. 15 paveiksle matoma, kad matuojama 3,3 V mikrovaldiklio maitinimo įtampa, kurios matavimų vidurkis atvaizduojamas mėlyna linija per dienas. Matoma, kad matavimų išsibarstymas logiškas ir kinta priimtinosiose režiuose. Toks minimalus rezultatų kitimas gali priklausyti nuo komponentų tolerancijos ar kitų priežasčių.

Kaip ir buvo pastebėta literatūros apžvalgoje, matavimo sistemos analizė yra kritiškai svarbi, projektuojant funkcinio testavimo įrangą. Matavimo sistemos analizė remiamasi atitinkamais parametrais, apskaičiuojamais pagal rezultatų pasiskirstymą Gauso skirstinyje.



15 pav. Mikrovaldiklio maitinimo įtampų matavimų pasiskirstymas Gauso skirstinyje

Galima pastebėti, kad testo rezultatai nėra centre tarp specifikacijos ribų, o šiek tiek pasislinkę į kairę – tai reiškia, kad rezultatas nėra idealiai suderintas pagal matavimo sistemos analizės principus. Visgi, matavimas sėkmingai telpa į testo specifikacijoje apibrėžtus rėžius, kurie atvaizduoti raudonomis linijomis skirstinyje. Toks duomenų atvaizdavimas leidžia išskirti parametrus, susijusius su matavimo sistemos analize, kurie įrangos paleidimo metu privalėjo būti suderinti, tačiau praktikoje kartais yra nestabilūs. 3 lentelė atvaizduoja skaičiavimus, apibūdinančius matavimus 14 ir 15 paveiksluose.

3 lentelė. Pagrindiniai rodikliai, apskaičiuoti pagal Gauso skirstinį

Vidutinė reikšmė, μ	3.303 V
Proceso pajėgumo indeksas, C_{pk}	1.562
Standartinis nuokrypis, σ	0.012
Matavimo dispersija, σ^2	~ 0

Pagal apskaičiuotus matavimo sistemos analizės parametrus, galima pastebėti, jog proceso pajėgumo indeksas žymi, kad ateityje gali pasireikšti nestabilumas. Tokia grėsmė atsispindi indekso vertėje, kuri yra ypatingai arti reikšmės, nuo kurios literatūroje apibūdinamas stabilus testavimo procesas. Tai buvo galima pastebėti žvelgiant į Gauso skirstinį, kuris rodo, kad didžiausias matavimų kiekis yra pasislinkęs nuo tikėtinios reikšmės, esančios viduryje tarp testo specifikacijos ribų. Dabartinė elektronikos gamykla jau turi pakankamai stiprias priemones, leidžiančias sekti konkrečius matavimus, jų kitimą bei nuokrypį. Vis dėlto, norint geriau ir giliau įvertinti parametrus, turinčius įtakos funkcinio testavimo efektyvumui, būtinas lygiagretus kelių matavimų analizavimas. Testavimo įranga yra matavimo sistema, apjungianti daugelį glaudžiai susijusių matavimų su testuojamu įrenginiu. Naudojant „Matlab“ programinę aplinką, galima gautus duomenis iš vidinės duomenų bazės apdoroti, siekiant geriau įvertinti matavimo priklausomybes. Kaip pavyzdys, tai gali būti ypač naudinga galios elektronikos įrenginiams, kur dažnai matuojama temperatūra bei galios rodikliai. Šie parametrai glaudžiai susiję ir daro vienas kitam tiesioginę įtaką. Atliekant temperatūros ir galios matavimus tuo pačiu metu, galima juos palyginti laiko ašyje ir, tuo remiantis, formuluoti išvadas,


padedančias optimizuoti tolimesnį testavimą. Taip pat, „Matlab“ aplinka pasižymi lankstumu dirbant su statistiniais modeliais, signalo apdorojimu ir mašininio mokymosi modelių taikymu.

2.3. Testavimo rezultatų kaupimo sistemos išvados

1. Esama duomenų rinkimo sistema užtikrina galimybę rinkti išsamius testavimo duomenis, apimančius tiek įprastus testų rezultatus, tiek papildomus parametrus, tokius kaip programavimo trukmė, aplinkos temperatūra ir individualūs matavimo laikai.
2. Duomenų rinkimo architektūra leidžia efektyviai analizuoti procesų kokybę ir identifikuoti anomalias situacijas, galinčias turėti įtakos testavimo efektyvumui.
3. Esamos sistemos struktūra leidžia integruoti sukurtus mašininio mokymosi modelius, nesukeliant didelių sistemos pertvarkymų, ir suteikia galimybes automatizuoti analizės funkcijas bei sumažinti operatoriaus įsikišimo poreikį.


3. Siūloma testavimo įranga efektyvumui didinti

Tolimesniam tyrimui pasirenkamas elektronikos įrenginys bei atitinkami matavimai, pagal kuriuos projektuojama testavimo įranga. Pasirinktas įrenginys turi būti gaminamas dideliais metiniais kiekiais, jog būtų galima analizuoti sukauptus duomenis gamybinėje aplinkoje. Tokiu būdu galima remtis realiais matavimais, esančiais duomenų bazėje. Tyrimui pasirinktas žoliapjovės variklio valdiklis, kurio gamyba vykdoma dideliu pajėgumu (16 pav.). Šiam įrenginiui buvo suprojektuota specializuota funkcinio testavimo sistema, pritaikyta konkreitiems produkto testavimo taškams ir testavimo poreikiams. Kaip matyti, prieiga prie testavimo taškų įmanoma tik vienoje pusėje, nes kita pusė uždengta plastikiniu dangteliu. Taip pat pateikiama ir jungčių, komponentų bei testavimo taškų schema plokštėje. Šie taškai apibraukti raudona spalva – jie naudojami tiek matavimams, tiek simuliacijoms testavimo metu.



16 pav. Tiriamas objektas tyrime

Testavimo įrangoje naudojama adatų lova, kuri prisijungia prie testavimo taškų bei J108 ir J107 jungčių (17 pav.). Kitos jungtys: J101, J102, J103, J104 bei J105 – aukštos galios, kur bus simuliuojamas srovės tekėjimas iki 250 A vertės, pasirinktos atitinkamos adatos tokiai srovei (17 pav.).



17 pav. Testavimo adatų lova, fikstūra

Adatų lovos fikstūra prijungiama prie testavimo stoties, kur sudėti visi pagrindiniai instrumentai. Prie stoties prisijungiama PXI sąsaja. Toliau aprašomi naudojami prietaisai:

- „Rohde&Schwarz“ HMP4040 maitinimo šaltinis – susideda iš 4 kanalų, 32V/10A/384W;
- „National Instruments“ PXI – 4065 skaitmeninis multimetras, turintis 6.5 skaitmenų rezoliuciją, matuoja nuo -300 iki 300 V įtampą;
- „Pickering“ 40-612-002 multiplekseris – susideda iš 104 rėlių, naudojamas skirtingiems srovės keliams prijungti prie multimetro ar kito įrenginio;
- „Mac Panel“ 561801 komunikacijų sąsajų spausdintinė montažo plokštė. Susidaro iš 4x USB; 4x RJ45 ir daugiau;
- „Pickering“ 40-160-003 didelės srovės rėlės bei „Pickering“ 40-139-101 mažos srovės rėlės;
- 24 V „Traco Power“ pastovios srovės maitinimo šaltinis.

Projektuojant testavimo sistemą, atsižvelgta į poreikį atlikti platų spektrą matavimų – nuo signalų apdorojimo ir programavimo iki „1-wire“ komunikacijos, temperatūros bei didelės galios testų. Įrenginio testavimo specifikacijoje reikalaujama ne tik pagrindinių elektros parametrų matavimo, bet ir papildomų funkcijų. Sistemai pritaikyti įrankiai apibūrėti 4 lentelėje.

4 lentelė. Instrumentai, naudojami fikstūros viduje ar prijungiami per išorinę jungtį

Instrumentas	Gamintojas bei modelis	Techniniai parametrai
Kompiuterinis osciloskopas	„Picoscope“ 2206B	2x kanalai, 50MHz, 500MSPS
Maitinimo šaltinis	„ITECH“ IT3900D	10V/340A/3400W
Diferenciniai zondai	„Picoscope“ Active differential probe	700 V, 25 MHz
„1-wire“ komunikacijos modulis	Pagaminta vietoje	-
Programatorius	„Segger“ 8.08.28	Naudojamas programuoti ARM architektūros procesoriams

Pasirenkami matavimai, kurie bus naudojami efektyvumo stebėjimui ir jo gerinimui. Toliau pateikiamas apibendrintas matavimų sąrašas, kuriems bus atliekamas detalesnis efektyvumo įvertinimas bei jo tobulinimas.

- Įtampos matavimai – testuojant gaminį atliekama daugybė įtampos matavimų. Pagrindiniai matavimai atliekami maitinimo grandinėse, įtampos keitikliuose.
- Srovės matavimai – įrenginys turi kelis skirtingus darbo režimus, nuo to atitinkamai priklauso ir srovės suvartojimas, skirtinguose režimuose fiksuojamas srovės testavimas.
- Signalų matavimai – vieni iš pradinių testo žingsnių, užtikrinant komunikaciją, signalo išsiuntimo patikrinimas oscilografu bei bitų atpažinimas. Taip pat, tikrinama išlydžio srovė, kai įrenginys komutuojamas į pagrindinę darbo būseną.
- Srovės kalibravimas – įrenginiui ypač svarbus srovės suvartojimo kiekis, jog būtų galima apsisaugoti nuo įrenginio perkaitimo ar kitų gedimų. Įrenginyje naudojamos ypatingai mažos vertės šunto varžos, kurių paklaida išauga dėl gamybinių procesų. Dėl šios priežasties testavimo metu simuliuojama srovė iki 200 A bei fiksuojama įrenginio mikroprocesoriuje.
- Kiti matavimai – susideda iš tokių matavimų, kaip TVS diodo patikra, EEPROM atminties įrenginyje patikrinimas, programavimas, serijinio numerio surašymas bei kt.

Pateiktas sąrašas yra apibendrintas, tačiau apžvelgia pagrindines funkcijas, kurioms projektuota testavimo įranga. Numatoma, jog efektyvumo gerinimui tikslingi metodai galėtų būti: mašininis mokymasis, didžiųjų duomenų analizė bei pastovi matavimo sistemos analizė. Lygiagrečiai pasirenkami ir matavimai, kurie būtų labiausiai tinkami šiems metodams pritaikyti. Pagrindiniai matavimai identifikuojami vėlesniuose skyriuose, numatoma, jog jie bus pagrindiniai tiriamieji objektai darbe.

3.1. Reikšmingų testavimo rezultatų identifikavimas

Apibrėžta testavimo įranga bei įrenginys jau yra įdiegta gamyboje, todėl įmanoma pateikti išvadas ir išsikelti stebėsenos bei tobulinimo tikslus. Pagrindinis matavimų filtravimo įrankis – atlikta matavimo sistemos analizė. Nuspręsta matavimus rinktis pagal užduotus reikalavimus, nurodytus toliau.

- Testavimas, kuris vertinamas mažu pajėgumo indeksu ($CPK < 1.33$), tačiau toks rezultatas yra gautas ne dėl specifikacijos ribų, o aukšto standartinio nuokrypio, kur įmanomas klaidos variantas yra testavimo įrangos klaida arba brokuotas gaminys.
- Testavimas, kuris pasižymi vidutiniu pajėgumo indeksu ($1.33 < CPK < 1.67$), tačiau užfiksuotas reikšmingas kiekis neatitikimų.

Toliau atliekama matavimo sistemos analizė, kuriai iškelti reikalavimai leis identifikuoti testavimo žingsnius, potencialius našumo gerinimui.


3.1.1. Atlikta matavimo sistemos analizė

Testavimo įranga atlieka aibę skirtingų matavimų, todėl identifikuojant charakteringus matavimus, pasitelkimas pajėgumo indeksas. Testavimo žingsniai, kur CPK yra didesnės vertės nei 1,67 toliau

neanalizuojami ir laikomi stabiliais. Toliau pateikiami pagrindiniai reikalavimai, kurie išsikelti atliekant sistemos analizę.

- Analizuojama 1000 testavimo ataskaitų.
- Kiekviena testavimo ataskaita yra vertinama, kai įrenginys buvo testuojamas pirmąjį kartą, ypač koncentruojantis į galimus testavimo įrangos efektyvumo nestabilumus.
- Pritaikomas filtras, kur atskiriama tik aktuali matavimų žingsnių aibė. Testo metu matuojamos ne tik skaitinės vertinės, bet ir tikrinamos komunikacijos, nuskaitomos išsaugomos atminties reikšmės ir kt.
- Siekiant išlaikyti elektronikos gamybos įmonės konfidencialumą, kiekvienas matavimo testo žingsnis buvo pervadintas į chronologišką matavimo numerį.

Apskaičiuotos matavimų standartinių nuokrypių, vidurkių bei dispersijos reikšmės įvertinamos pagal duotus testavimo specifikacijos ribų režius. 18 paveiksle matomos gautos pajėgumo indekso vertės kiekvienam matavimui. Grafike matavimai, kurių pajėgumo indeksai siekė mažesnę reikšmę nei 1, pažymėti raudona spalva, jų yra 5. Testavimo eigos žingsniai buvo sunumeruoti chronologiškai, kai pirmasis testavimo žingsnis yra testo pradžia, o 466 žingsnis testo pabaiga, pastebima, jog 4 iš nestabilių matavimų pasireiškia dar neįpusėjus testui, o paskutinis atsitinka vėliau.



18 pav. Gauti pajėgumo indeksai, kiekvienam testavimo žingsniui

Toliau pateikiami charakteringi matavimai, kurių pajėgumo indeksas pasižymi mažiausiomis reikšmėmis.


- 19 testavimas – atliekamas matuojant įtampą ant šunto varžos ir vėliau ji apskaičiuojama bei paverčiama į srovę.
- 144 testavimas – atliekamas baterijos įtampos matavimas komutacijos metu.
- 148 testavimas – atliekamas baterijos įtampos matavimas po komutacijos.

- 158 testavimas – atliekamas srovės matavimas pasitelkiant įtampos matavimą ant šunto varžos.
- 276 testavimas – atliekamas CAN komunikacijos žemo lygio impulso matavimas.

Įvertinus matavimus, nustatoma, ar testavimo įranga netikslumus sukelia dėl ne centrinio matavimo pasiskirstymo, o dėl didelės dispersijos, kuri rodo sistemos nestabilumą ir atsitiktinius blogus rezultatus.

3.1.2. Testavimo metu fiksuotų neatitikčių analizė

Toliau analizuojamas nesutapčių kiekis, naudojant tuos pačius duomenis, kaip ir ankstesnėje matavimo sistemos analizėje. Nesutaptis yra vienas svarbiausių rodiklių elektronikos gamybos industrijoje, nes tiesiogiai veikia įmonės kaštus ir FPY, kuris rodo gamybos kokybę ir turi įtakos įmonės įvaizdžiui. FPY rodiklis dažnai yra pirmasis, į kurį atsižvelgiama vertinant bendrą kokybę testavimo metu. 19 paveiksle atvaizduoti ketvirčio analizuojamos testavimo įrangos FPY rezultatai, naudojant standartinius testavimo metodus.



19 pav. Testavimo įrangos ketvirčio FPY rezultatai

Rezultatas nėra tenkinamas, todėl, vertinant kiekvieno testo žingsnio neatitikčių kiekį, nustatomi potencialūs probleminiai matavimai. Svarbu pastebėti, kad yra reikšmingas skirtumas tarp gaminių, kurie tenkino testo sąlygas iš pirmo karto ir iš antro karto, tai indikuoja, jog, nevertinant gamybos defektų, testavimo įrangos efektyvumas bei stabilumas nėra tenkinantys. Apskaičiuojamas įrangos apytikslis efektyvumas:


$$\eta_{FPY} = \frac{FPY}{FPY+SPY+TPY} * 100 \% = \frac{3516}{3516+195+39} * 100 \% = 93,76 \%$$

Apskaičiavus preliminarų efektyvumą, suprantama, kad įranga gali būti tobulinama daugiau nei 5 %, tai – ypač reikšmingas veiksnys elektronikos gamyboje. Toliau įvertinami testavimo žingsniai, kurie sukelia daugiausiai neatitikčių. Testavimo žingsniai atvaizduojami vertinant tūkstantį paskutinių testavimo ataskaitų. Kartu su nustatytų neatitikčių skaičiumi lygiagrečiai atvaizduojamos CPK vertės. Įvertinant pajėgumo indeksą kartu su klaidų skaičiumi, galima įvertinti, ar testavimas yra iš tiesų atliekamas ne tikslingai, ar tik nėra idealiai centruotas. Gauti rezultatai atvaizduoti 5 lentelėje.

5 lentelė. Sukeltas klaidų skaičius, priklausomai nuo žingsnių

Testavimo žingsnio numeris bei aprašymas	Sukeltas klaidų skaičius	Pajėgumo indeksas CPK
7 – Įtampos testavimas ant šunto	7	1,33
16 – Įtampos testavimas ant šunto	1	2,35
87 – Baterijos įtampos testavimas	1	2,49
144 – Baterijos įtampos testavimas po komutacijos	6	0,87
158 – Paleidimo srovės testavimas	14	0,80
276 – CAN komunikacijos žemo lygio įtampos testavimas	5	0,66
277 – CAN komunikacijos aukšto lygio įtampos testavimas	1	1,72

Matoma, jog pajėgumo indeksas ne visada yra aktualiausias parametras ir galima atmesti kai kuriuos matavimus, kurie buvo apibrėžti 18 paveiksle. Vis dėlto, kai kurie matavimai patenka į abi grupes, todėl jie tampa pagrindinėmis priežastimis, kodėl testavimo įrangos efektyvumas nėra patenkinamas. Pakankamai akivaizdžiai išsiskiria paleidimo srovės testavimas bei CAN komunikacijos matavimai. Matavimai atvaizduojami stulpelinėje charakteristikoje (20 pav.).



20 pav. Neatitikčių skaičiaus pasiskirstymas testo žingsniuose

Charakteristikoje matoma ir projekcinė kreivė, kuri nurodo procentinę dalį visų kilusių klaidų per testo įrangos gyvavimo laiką. Galima pastebėti, kad sutvarkius dažniausią klaidą, kaip žinoma, paleidimo srovės matavimą, tai leistų sumažinti visą klaidų skaičių apie 20 %.

3.1.3. Galutiniai pasirinkti testavimo žingsniai

Atlikus matavimo sistemos analizę bei įvertinus testo žingsnių sukeltą klaidų kiekį, galima įvertinti, kurie testo žingsniai yra kritiniai - turintys neigiamą įtaką testo efektyvumui. Atitinkamai,

labiausiai atkreipiamas dėmesys į matavimus, kurie išsiskyrė atliekant tiek matavimo sistemos analizę, tiek vertinant sukeltą klaidų kiekį, tai atvaizduoja 6 lentelė.


6 lentelė. Visi pastebėti matavimai ir jų atitikmuo pasirinkimo rodikliuose

Testavimo žingsnio numeris bei aprašymas	Žemas pajėgumo indeksas	Didelis klaidų kiekis
7 – Įtampos testavimas ant šunto	NE	TAIP
16 – Įtampos testavimas ant šunto	NE	TAIP
19 – Įtampos testavimas ant šunto	TAIP	NE
87 – Baterijos įtampos testavimas	NE	TAIP
144 – Baterijos įtampos testavimas komutacijos metu	TAIP	TAIP
148 – Baterijos įtampos testavimas po komutacijos	TAIP	NE
158 – Paleidimo srovės testavimas	TAIP	TAIP
276 – CAN komunikacijos žemo lygio įtampos testavimas	TAIP	TAIP
277 – CAN komunikacijos aukšto lygio įtampos testavimas	NE	TAIP

Įvertinus matavimų atitikmenis vertinimo kriterijuose, pastebima, kad identifikuojami 3 matavimai. Vis dėlto, 2 matavimai išsiskiria labiau, jie apibrėžti toliau.

- **Paleidimo srovės testavimas** – matavimas turėjo didžiausią kiekį klaidų bei pasižymėjo ypatingai žemu pajėgumo indeksu, todėl šio matavimo nesklaidumo priežasčių atradimas turėtų didžiausią įtaką testavimo įrangos efektyvumui.
- **CAN komunikacijos žemo lygio įtampos testavimas** – pasižymi prastu, tačiau ne prasčiausiu pajėgumo indeksu. Vis dėlto, klaidų skaičius yra pakankamai didelis ir išskirtinis, tai lemia klaidas ir kitame, po jo atliekamame testo žingsnyje. Dėl šios priežasties analizuojama CAN komunikacija gali turėti reikšmingos įtakos, siekiant nustatyti testavimo įrangos efektyvumo dėsningumus.

Svarbu pabrėžti, jog baterijos įtampos testavimas yra reikšmingas, nes matavimas pasirodė nestabilus tiek vertinant pajėgumo indeksą, tiek klaidų verčių skaičių. Dėl šios priežasties, stebima, kokios matavimų vertės buvo gautos paskutiniu laikotarpiu (21 pav.). Vaizduojami rezultatai yra paskutiniai tūkstantis matavimų.



21 pav. Gauti testavimo rezultatai, po baterijos įtampos komutacijos

Galima matyti, kad čia klaidos atsiranda retai, tačiau matavimo kitimo režiai yra pakankamai stabilūs. Neatitikimai atsiranda dėl galimų momentinių gedimų, kaip kontakto nebuvimo dėl gamybos proceso. Taip pat, galima pastebėti priežastį, kodėl pajėgumo indeksas yra mažos vertės. Taip atsitinka, nes matavimai yra pakankamai šalia apatinės užduotos testo ribos.

Apibendrinant, pasirinkti testavimo žingsniai pavaizduoti toliau. Būtent šie matavimai pasižymėjo didžiausiu nestabilumu, vertinant CPK bei didžiausią neatitikimų skaičių.


1. Paleidimo srovės testavimas.
2. CAN komunikacijos impulso testavimas.

3.2. Charakteringų testavimų analizė


Pasirinkus prieš tai apibrėžtus matavimus, suprantama, jog reikalinga pakankamai detali jų analizė, tai yra svarbu, jog būtų galima nustatyti šių žingsnių efektyvumą ir numatyti, kaip tai pagerinti. Šiame skyriuje pristatoma kiekvieno matavimo analizė, jo įtaka testavimo įrangai bei pasirinkta metodologija, siekiant išgauti geresnį efektyvumą.

3.2.1. Paleidimo srovės testavimo analizė

Apibrėžta, jog įranga atlieka srovės matavimą bei signalų apdorojimą. Srovės matavimas ir signalų apdorojimas apima paleidimo srovės testavimą, kur matuojama įtampa ant šunto varžos, naudojant 4 lentelėje apibrėžtus kompiuterio oscilografą bei diferencinius zondus. Analizuojant testavimo rezultatus, žinoma, jog srovės vertė turėtų stabiliai mažėti po komutacijos (22 pav.). Vis dėlto, ne retai matavimas atitinka specifikacijos nurodytą maksimalią vertės reikšmę, bet generuoja probleminį signalą, kuris sukelia gedimus tolimesniuose testavimo žingsniuose (23 pav.).




22 pav. Tikslingas paleidimo srovės testo signalas



23 pav. Probleminis palaiedimo srovės testo signalas

Nors 23 paveiksle pavaizduotas probleminis signalas, tačiau matomas rezultatas atitinka specifikacijoje reikalaujamą maksimalų srovės dydį. Toks srovės kitimas trikdo tolesnius testus, dėl šios priežasties eikvojamas testavimo laikas ir didėja gamybos sąnaudos. Be to, šis žingsnis dažnai sukelia ribinius matavimus, kaip matyti analizuojant paskutinius tūkstantį rezultatų (24 pav.).




24 pav. Paleidimo srovės matavimo rezultatai

Matoma, kad matavimai yra stipriai išsibarstę ir pasižymi didele variacija. Paleidimo srovė yra kritinis testavimo žingsnis, turintis reikšmingą įtaką bendram įrenginio funkcionalumui. Remiantis 23 paveiksle užfiksuotu signalu, galima daryti prielaidą, kad po juo slypi gilesnės gamybinės kilmės klaidos. Dėl šios priežasties, šiam srovės matavimui planuojama taikyti mašininio mokymosi modelį, pagrįstą neuroniniu tinklu. Paslėptajame tinklo sluoksnyje planuojama įtraukti kintamuosius, tokius kaip impulso trukmė, įtampos reikšmė ir įtampos atskaitų skirtumai, siekiant, kad modelis būtų apmokytas pagal šiuos duomenis.


3.2.2. CAN komunikacijos įtampos impulso testavimas

Svarbu atsižvelgti, kad CAN komunikacijos matavimas nėra toks nestabilus ar kritinis, kaip srovės matavimas. Vis dėlto, nustatytas žemo pajėgumo indeksas bei keletas klaidų indikuoja, kad šis matavimas yra reprezentatyvus, analizuojant testavimo efektyvumo iššūkius, kylančius dėl ilgalaikio įrangos naudojimo. Atvaizduojami 1000 gautų matavimų, kai naudojamos standartinės testavimo technologijos (pav. 25).



25 pav. Paskutiniai gauti CAN komunikacijos žemo lygio įtampos matavimai

Pagal gautus matavimus, pastebima, kad matavimo vidurkis nėra centre tarp testavimo specifikacijos ribų, tačiau turi pakilimų įtampos vertėse. Gauti rezultatai testavimo įrangoje nėra logiški, nes naudojama įranga išlieka ta pati ir gaminiai pasižymi didelio tikslumo komponentais, kas nėra pastebima kituose matavimuose, todėl svarbu įvertinti matavimo pasiskirstymą Gauso skirstinyje (26 pav.).



26 pav. Gauti rezultatai Gauso skirstinyje

Analizuojant matavimų skirstinį rezultatai nėra idealiai centruoti – reikšmės pasislinkusios link apatinės specifikacijos ribos, kur fiksuojamos klaidos. Skirstinys pasižymi dviem pasikartojančiais pasiskirstymo centrais, kas siejama su tuo, jog testavimas atliekamas dviejose skirtingose stotyse. Dėl to matavimų nuokrypiai šiek tiek skiriasi, priklausomai nuo konkrečios įrangos ar aplinkos sąlygų. Siekiant įvertinti šiuos skirtumus ir prognozuoti galimą nestabilumą, planuojama pritaikyti mašininio mokymosi modelį. Modelis padės identifikuoti dreifo tendencijas bei įvertinti matavimų artėjimą prie leistinų ribų, taip užtikrinant didesnę testavimo patikimumą.

3.3. Siūlomos testavimo įrangos efektyvumui didinti išvados

1. Nors bendras FPY rodiklis yra priimtinas, tam tikri matavimo žingsniai ženkliai mažina testavimo efektyvumą ir didina klaidingų gedimų tikimybę.

2. Trys konkretūs matavimai – įtampos prieš impulsą, įtampos impulso metu bei srovės įėjimo amplitudė – pasižymi žemu pajėgumo įvertinimu ir dažnais neatitikimais, todėl turi būti vertinami kaip kritiniai analizės taškai.
3. Identifikuotos matavimo problemos, tokios kaip instrumentų nuokrypis ar osciliografo netikslumai, sudaro pagrindą siūlyti automatizuotus sprendimus, paremtus matavimų analize bei mašininio mokymosi metodais.

4. Eksperimentiniai tyrimai ir testavimo efektyvumo įvertinimas

Apžvelgus literatūros apžvalgoje apibrėžtus metodus buvo numatyta, kad modernios technologijos: mašininis mokymasis, automatizavimas ar kitos technologijos ženkliai prisideda prie pramonės pažangos. Reikia paminėti, jog dauguma šių metodų nebuvo tiesiogiai pritaikyta elektronikos gamybos testavimo srityje. Šiame skyriuje bus pristatomos potencialios metodologijos, kurios leidžia išsamiau pažvelgti į probleminius matavimus ir būdus, kurie pagerintų efektyvumą elektronikos testavimo pramonėje.

4.1. CAN komunikacijos testavimo efektyvumo gerinimo metodologija


Praeitame skyriuje CAN komunikacijos impulso įtampos matavimas buvo vienas iš dominuojančių, kai kalbama apie problemas keliančius testavimo etapus. Pagal 26 paveiksle pateiktus matavimus, galima matyti, kad matavimas pasiskirsto į dvi grupes. Antroji yra ypač arti ir kartais net peržengianti apatinę testo specifikacijos ribą. Dėl šios priežasties, šiam matavimui bus siekiama atspėti tolimesnes vertes, įvertinant atitinkamas dedamąsias. Norint pasiekti užsibrėžtus tikslus buvo išsikeltos trys pagrindinės technologijos.

- Didžiųjų duomenų analitika – naudoja didelius duomenių kiekius tam, kad būtų nustatyta tendencija, įžvalgos ar įvairios sąsajos. Tinkamas, kai naudojamas ypač didelis kiekis duomenų.
- **Mašininis mokymasis** – naudoja adaptyvius algoritmus, kurie mokinasi iš duomenų bei atliktų prognozių. Ypač efektyvus, kai susiduriama su netiesiškumu, sąveikomis ar didesnės dimensijos duomenimis.
- Statistinis modeliavimas – naudoja fiksuotus matematinius modelius, kaip regresijos ar panašiai. Daroma prielaida, kad tarp kintamųjų yra nustatyti ryšiai.

Testavimo neatitikimų problemos bus sprendžiamos naudojant mašininį mokymąsi. Pagrindinės priežastys pateiktos toliau:


- mašininis mokymasis geba atrasti paslėptus ryšius tarp kintamųjų, kurių tradiciniai statistiniai modeliai gali nepastebėti;
- korektiškai apmokintas modelis gali sėkmingai prisitaikyti prie naujų duomenų, nenustatant naujų lygčių rankiniu būdu.
- gebėjimas modeliuoti sudėtingas, netiesines priklausomybes, skirtingai nei statistiniai modeliai, kurie daugiausia numato tiesiškumą;
- metinis gaminių kiekis nėra ypatingai didelis, todėl mašininis mokymasis tinka geriau nei didieji duomenys, kurie remiasi dideliu kiekiu duomenų tendencijomis, kurios kinta laiko ašyje;
- siekiant geresnio efektyvumo, mašininis mokymasis yra idealiai tinkamas, kadangi sprendimų priėmimas yra automatizuojamas;

Atitinkamai išsirinkus metodologiją bei siekiant pagerinti testavimo efektyvumą, toliau pateikiama numatoma suprojektuota MM modelio struktūrinė schema, kuri leis suprojektuoti sėkmingą, efektyvumą gerinantį modelį.




27 pav. Testavimo metodologijos plėtros planas, CAN komunikacijos patikrai

Pavaizduotoje struktūrinėje diagramoje galima pamatyti, kad pirmas žingsnis – duomenų surinkimas, kaip pristatyta prieš tai, ši analizė iš dalies jau buvo atlikta praeitame skyriuje. Pasirinktoje testavimo įrangoje atliekamas keletas jau minėtos CAN komunikacijos matavimų, vis dėlto, įdomu, kad nuosekliai atliekamas ir stabilios būsenos įtampos matavimas, o po to įtampos matavimas impulso metu. Dėl šios priežasties, fiksuojama maždaug 1000 paskutinių įtampos matavimų prieš ir impulso metu. Kartu fiksuojama ir temperatūros reikšmės, kurios taip pat matuojamos testavimo metu. Atvaizduoti įtampos matavimai prieš bei impulso metu, matomi toliau pateiktame paveiksle (28 pav.).




28 pav. CAN komunikacijos įtampos rezultatai

Atitinkamai, gavus įtampos matavimus, papildomai išsaugomas ir temperatūros kitimas bei matavimo trukmė. Iš gautų matavimų aiškėja, kad impulso metu matuojamoje įtampoje matomi šuoliai, kur įtampos išsilygina, tai yra neteisingi matavimai, kai, pavyzdžiui, oscilografas neužfiksuoja impulso ir išmatuojama įtampos reikšmė praktiškai lygi įtampai užfiksuotai prieš impulsą. Norimo įtampos impulso matavimai pateikti 29 paveiksle. Jame matomi du signalai: vienas invertuotas – geltonas, kitas neinvertuotas – mėlynas. Šiuo atveju aktualus yra geltonas signalas, kuris atitinka invertuotą CAN žemo lygio signalą, o mėlynas signalas atitinka CAN aukšto lygio signalą.




29 pav. CAN komunikacijos impulso signalais

Toliau atliekamas duomenų filtravimas bei normavimas. Pagrindinė filtravimo priežastis – pasiekti kuo tikslesnius statistinius parametrus bei sulygiuoti gautus duomenis, kad jie sutaptų su tais pačiais gaminiais. Duomenys buvo filtruojami pritaikant tarpkvartilinį diapazoną (IQR) bei taip nustatomos įtampos prieš ir impulso metu ribos, o visi išskirtiniai taškai, kur invertuoto signalo įtampa nebuvo užfiksuota, iš analizės buvo pašalinti. Tokiu būdu, užtikrinama, kad duomenys yra patikimi. Įtampos matavimo rezultatai po filtravimo atvaizduoti 30 paveiksle.




30 pav. Filtruotos CAN komunikacijos įtampos

Siekiant įsivertinti filtravimo svarbumą, apskaičiuojama tiesinė Pirsono koreleacija tarp skirtingų parametrų, kaip temperatūra, įtampa prieš impulsą bei įtampa impulso metu, tai atvaizduojama 31 paveiksle.



31 pav. Gauti Pirsono koreliacijos ryšio koeficientai tarp parametrų prieš filtravimą (a) bei po filtravimo (b)

Vertinant Pearsono korelaciją, suprantama, kad čia vertinama, kiek parametrai vienas su kitu siejasi tiesiškai. Matoma, kad atlikus duomenų filtravimą, atsirado maždaug vidutinė korelacija tarp įtampų, tai – logiška, kadangi iškilusios įtampos reikšmės, greičiausiai neigiamai paveikė skaičiavimus. Įdomu, kad temperatūros korelacija, kad ir ne didelė, tačiau sumažėjo atlikus filtravimą. Gauti rezultatai leidžia manyti, kad temperatūra gali būti vienas iš veiksnių, lemiančių padidėjusias įtampos reikšmes. Toliau atliekamas ir Spirmano koreliacijos ryšių apskaičiavimas, kur labiau siekiama įžvelgti netiesines parametų priklausomybes (32 pav.).



32 pav. Apskaičiuota Spirmano korelacijos matrica tarp parametų prieš (a) ir po filtravimo (b)

Apskaičiavus Spirmano korelacijos koeficientus tarp parametų, matoma, kad jau prieš duomenų filtravimą tarp įtampų vyrauja vidutinis ryšys, jis nežymiai padidėjo po filtravimo. Visgi, taip pat, kaip ir Pearsono korelacioje, čia temperatūros ryšis atlikus filtravimą sumažėjo. Toks pasikeitimas yra įdomus ir įvertinama, kad naudojant daugiau parametų anomalijų, kur įvyksta įtampos šuoliai yra įmanomas. Toliau dirbama ties mašininio mokymosi modelio sukūrimu. Numatoma suprojektuoti du modelius – vieną, kuris aptiktų instrumentų dreifą, kai matavimo duomenų vidurkis per tam tikrą laiką pakyla ar nusileidžia, o kitą, kuris gebėtų rasti anomalijas, kurios buvo matomos įtampų matavimų charakteristikoje.

4.2. Mašininio mokymosi modelio kūrimas testavimo nuokrypiams atpažinti

Iš atliktos analizės, matoma, kad naudojant vos kelis papildomus parametrus, matomas ryšis tarp kitų parametų, o ypač tarp įtampų. Atsižvelgiant į gautus koreliacijų koeficientus ir bus pasirenkamas mašininio mokymosi modelis. Modelis projektuojamas siekiant prognozuoti įtampą prieš impulsą, nes analizuojant matavimą, būtent čia buvo pastebėtas testavimo nuokrypis. Įvertinus, jog abiem koreliacijos metodais nustatytas sąryšis, šis aspektas buvo svarbus renkant tinkamą MM modelį. Atsižvelgiant į gautus Pearsono koreliacijos rezultatus, MM taikymui bus išbandomi šie statistiniai modeliai:

- tiesinio pritaikymo modelis – tai vienas paprasčiausių modelių, kuris dažnai naudojamas, kai numatoma, kad tarp parametų yra tiesinis ryšys;
- kvadratinio pritaikymo modelis – tai modelis, kai numatoma, kad duomenys rodo parabolinį elgesį, tai yra krenta ar kyla;
- tiesinės regresijos modelis – tai modelis, kuris geriausiai nustato tiesinį ryšį tarp parametų, atitinkamai atliekantis pagal tai prognozes;
- daugybinė tiesinė regresija – tai linijinės regresijos plėtinys, kur rezultatui turi įtakos keli parametrai;

- polinominio pritaikymo modelis – statistinis modelis, kuris dažnai pritaikomas, kai norima aptikti nelineinį ryšį ir pagal tai prognozuoti vertes.

Vis dėlto, nors minėti modeliai yra statistiniai, jie gali būti taikomi ir MM kontekste. Tačiau, norint atlikti sudėtingesnes prognozes, gali prireikti ir pažangesnių MM modelių. Pasirinkti modeliai aprašomi toliau:

- „Support Vector Machine“ (SVN) modelis – metodas, taikomas klasifikacijai ir regresijai. Jo esmė – surasti optimalų hiperpaviršių, atskiriančių duomenis į skirtingas klases. Dažniausiai naudojamas klasifikavimo užduotyse, pavyzdžiui, skirstant duomenis į dvi ar daugiau klasių;
- „Random Forest“ modelis – metodas, paremtas daugybės sprendimų medžių naudojimu. Kiekvienas medis kuriamas atsitiktinai, parenkant duomenų imtis ir kintamuosius, o galutinė prognozė gaunama sujungiant visų medžių rezultatus. Šis metodas pasižymi atsparumu pertreniravimui (angl. *overfitting*), todėl yra ypač tinkamas dirbant su triukšmingais ar dideliais duomenų rinkiniais.

Preliminariai bus išbandyti abu modeliai, siekiant įvertinti, kuris geriau atlieka užduotį. Šie modeliai gali būti efektyvesni, lyginant su statistiniais, nes, kaip ir buvo minėta, matuojant įtampą prieš impulsą, jie yra vyraujantys pakankamai stipriai, nes duomenys yra imami matuojant su dviem instrumentais. Tikėtina, kad kompleksiškesnis modelis su užduotimi susitvarkys geriau. Vienas iš svarbių parametrų vertinant prognozių tikslumą bei naudojant modelius yra determinacijos koeficientas, jo formulė aprašyta žemiau.

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2}; \quad (5)$$


čia: y_i – realios išmatuotos vertės; $\hat{y}_i$ – prognozuojamos modelio vertės; $\bar{y}$ – realių išmatuotų verčių vidurkis.

Tolimesnis modelis būtent ir bus pasirenkamas, naudojant šio parametro įvertį. Koeficiento reikšmė nurodo, kiek galima nusakyti duomenų kitimą pagal pateiktus parametrus, jei reikšmė žemesnė už nulį, tai parodo, kad prognozė prasta ir geresnis tikslumas būtų pasiekiamas naudojant vidurkinimą. Ideliausia parametro reikšmė yra 1, tai parodo, jog visus 100 % duomenų kitimą galima paaiškinti pagal išorinius duomenis, šiuo atveju temperatūrą, įtampą impulso metu. Visi statistiniai bei mašininio mokymosi modeliai buvo paviršutiniškai išbandyti ir gautos determinacijos koeficientų reikšmės surašytos toliau pateiktoje 5 lentelėje.

5 lentelė. Gautos determinacijos koeficiento reikšmės prie skirtingų modelių


	Taikomas modelis	Apskaičiuota R^2 vertė
Statistiniai Modeliai	Tiesinio pritaikymo	0,2278
	Kvadratinio pritaikymo	0,2486
	Tiesinės regresijos	0,2670
	Daugybinės tiesinės regresijos	0,2674
	Polinominio pritaikymo	0,0671
MM Modeliai	„Random forest“	0,8955
	„Support Vector Machine“	0,2107

Suprantama, kad siekiant išpildyti kiekvieną modelį, reiktų juos pakankamai apmokyti ir derinti. Tomis pačiomis sąlygomis testuojant modelius, pagal 5 lentelę, matoma, kad labiausiai pasiteisinęs modelis yra „Random Forest“. Modeliui buvo suteikiamos vidinės testavimo įrangos temperatūros bei įtampos impulso metu vertės, kurios buvo naudojamos kaip požymiai gauti įtampos prieš impulsą prognozėms. Toliau atvaizduotos realios įtampos reikšmės kartu su prognozėmis, taip pat pridėtos apatinės bei viršutinės testo specifikacijos ribos, kurios leidžia geriau įsivaizduoti matavimo režius (33 pav.).



33 pav. Gautos prognozuotos reikšmės, naudojant treniravimo duomenis, kai naudojamas „Random Forest“ modelis


Gauti rezultatai parodo, jog prognozių reikšmės yra logiškos bei pakankamai tikslios, bet vertinant tai, jog modelis turi gebėti aptikti ankstyvus instrumentų nuokrypių požymius, realios vertės nėra tiksliai indikuojančios matavimo nuokrypį. Dėl šios priežasties, ateityje gali prireikti modelį apmokyti su didesniu įtampos kitimo diapazonu. Suprojektavus pradinį modelio variantą, toliau įvertinamas parametrų svarbumas (34 pav.). Parametrų svarbumas nurodo, kokie įverčiai yra esminiai, vertinant sukurtą MM modelį.



34 pav. Parametrų svarbumas, dreifo aptikimų MM modelyje

Matoma, kad didžioji dalis prognozuojamų rezultatų priklauso nuo įtampos reikšmės išmatuotos prieš impulsą. Tokia svarbumo reikšmė – logiška, sprendžiant pagal prieš tai apskaičiuotas koreliacijas.

Atitinkamai, pakankamai svarbi ir parametų priklausomybė nuo prognozuojamos įtampos reikšmės (35 pav.).



35 pav. Gautos parametų priklausomybės nuo prognozuojamos įtampos

Gauti rezultatai yra neįprasti, nes, žvelgiant į įtampų priklausomybę, gauta charakteristika panaši į sudėtinio sinuso formą, o žvelgiant į temperatūros priklausomybę, matoma, kad ji įtampos reikšmei turi įtakos tik prie konkrečių reikšmių. Tokie rezultatai parodo, kad MM modelis gali būti permokintas arba atranda nišines priklausomybes tarp parametų. Rezultatus bus galima daugiau analizuoti juos testuojant su naujais duomenimis, nes modelis prognozuoja tik duomenis, pagal kuriuos buvo apmokintas.

4.3. Mašininio mokymosi modelio kūrimas testavimo anomalijoms atpažinti


Pradėjus CAN komunikacijos analizę buvo pastebėta, kad koreleacija tarp temperatūros ir įtampos impulso metu sumažėja, kai atliekamas staigių įtampos šuolių verčių filtravimas. Tai parodo, kad šių anomalijų, kai oscilografo paleidiklio funkcija nesuveikia, aptikimas statistiškai įmanomas. Projektuojant šį modelį, skirtingai nei prieš tai, remiamasi 28 paveiksle pateiktais matavimais. Skirtingai nei praeitame modelyje, išbandomos dvi skirtingos „Random Forest“ MM modelio apmokymo metodikos, jos aprašytos žemiau.

- „Bagging“ mokymosi metodas – keli modeliai, sprendimo medžiai, mokomi naudojant skirtingus duomenų pogrupius. Galutinė prognozė nustatoma išvedant visų modelių vidurkį

(regresijos atveju) arba balsų daugumą (klasifikavimo atveju). Tai padeda sumažinti dispersiją ir padidina modelio atsparumą persimokymui.

- „LSBoost“ mokymosi metodas – modeliai kuriami nuosekliai, o kiekvienas naujas modelis ištaiso ankstesnių modelių likutines klaidas. Metodas optimizuoja regresijos mažiausių kvadratų nuostolių funkciją, pagerindamas tikslumą. Sumažinami nuokrypiai, tačiau yra rizika, jog modelis bus permokintas, jei nėra gerai suderintas.

Modelis buvo išbandytas su abejomis mokymosi metodikomis, svarbu paminėti, kad skirtingai nei prieš tai, į įverčių aibę buvo įtrauktas ir matavimo laikas, per kurį išmatuojama įtampos vertė prieš impulsą. Suderinus modelius, geriausi gauti rezultatai pavaizduoti 36 paveiksle, o 6 lentelėje pateikti apskaičiuoti determinacijos koeficientai.




36 pav. Gauti prognozių rezultatai anomalijų aptikimui. Viršuje – „LSBoost“ mokymo technologija, žemiau „Bagging“

6 lentelė. Gauti determinacijos koeficientai, lyginant skirtingas mokymo technologijas

Apmokymo technologija	Apskaičiuota R^2 vertė
„Bagging“	0.3844
„LSBoost“	0.9569


Matoma, kad rezultatai ženkliai skiriasi tarp pasiūlytų MM mokymo technologijų. „LSBoost“ tikslumas indikuoja, jog modelis gali būti permokintas, todėl testuojant modelį su nauju duomenų paketu gali būti neefektyvus. Svarbu suprasti, kad pagrindinis modelio tikslas yra aptikti tikslų anomalijų skaičių, o ne išmatuotą įtampos reikšmę, todėl atliekant papildomus derinimus, „Bagging“

apmokymas ateityje gali būti efektyvesnis. 37 paveiksle atvaizduoti parametų svarbumai, kai naudojama „LSBoost“ technologija.




37 pav. Parametų svarbumas, anomalijų aptikimo MM modelyje

Skirtingai nei prieš tai sukurtame modelyje, matoma, kad šiame MM modelyje ypač svarbus kiekvienas paduodamas įvertis, tai – gera indikacija, jog modelis efektyviai apsimokina. Pastebima, kad kai kurie išvestiniai parametrai neturi reikšmės, todėl privalo būti pašalinti. Pateikiama prognozuojamos įtampos reikšmės priklausomybė nuo naujo įverčio – matavimo trukmės (38 pav.) bei apibendrinta priklausomybė nuo temperatūros bei įtampos išmatuotos prieš impulsą (39 pav.).



38 pav. Įtampos impulse prognozės priklausomybė nuo matavimo trukmės




39 pav. Įtampos impulso metu spėjimų priklausomybė nuo temperatūros bei įtampos prieš impulsą

Galima pastebėti, kad tarp įtampų priklausomybė yra charakteringa. Vis dėlto, temperatūros rezultatai panašūs, kaip ir praeitame MM modelyje. Matavimo laikas parodo, jog esant didesnei matavimo trukmei, įtampos anomalijos tikimybė yra didesnė, tai – logiškas rezultatas, kuris argumentuoja, kad anomalijos gali būti atrastos ir modelio testavime.

4.4. Sukurtų modelių testavimas bei derinimas

MM modeliai buvo pakankamai išvystyti, jog funkcionuotų bei aptiktų problemines situacijas, kai pateikiami realūs duomenys. Modelių funkcionavimas parodo, kad naudojant atitinkamus įėjimo požymius, instrumentų dreifo bei anomalijų aptikimas yra įmanomas. Sėkmingas modelio implementavimas leistų pranešti apie galimas problemas, naudojant instrumentų nuokrypio MM modelį arba identifikuoti būsimas klaidas, kurios būtų prognozės, pagal gautus kitų žingsnių matavimo rezultatus dar nepasiekus probleminio matavimo. Vis dėlto, modeliai nebūtų pritaikomi, jei negebėtų adaptuotis prie naujo duomenų paketo. Kaip žinoma, modeliai buvo mokyti pagal 1000 pateiktų matavimų, atitinkamai modeliai bus testuojami pagal sekančius 1000 matavimų, kur minėtų problemų skaičius dar didesnis (40 pav.).




40 pav. Teikiamų duomenų pasiskirstymas, kurie buvo naudojami apmokymui bei testavimui

Galima pastebėti, kad duomenys, kurie bus naudojami testavimui, skiriasi nuo duomenų, kurie buvo naudojami apmokymui. Didelė tikimybė, jog abu modeliai elgsis neįprastai, nes paduodamos įverčių vertės jiems bus nežinomos, neapmokytos. Vis dėlto, pirminei analizei šis duomenų pasirinkimas – logiškas, kadangi esant blogam rezultatui, bus įgyvendinamas modelių atnaujinimas su didesniu duomenų kiekiu. Numatoma, jog ateityje modeliai realiu laiku mokintųsi iš praeityje buvusių įverčių.

4.4.1. Nuokrypio aptikimo modelio testavimas

Aptinkant ankstyvą instrumentų nuokrypį naujame duomenų masyve, taip pat reikalingas filtravimas, kuris panaikintų anomalijas esančias charakteristikoje. Testuojant modelį su nauju duomenų paketu, gauti rezultatai atvaizduoti 41 paveiksle.




41 pav. Realios ir prognozuojamos vertės, kai dreifo aptikimo modeliui pateikiamas naujas duomenų paketas

Pagal gautus pradinio rezultatus matoma, kad modelis nefunkcionuoja, kaip turėtų ir turi didelę paklaidą su realiais duomenimis. Tikrinant modelio efektyvumą, apskaičiuojamas $R^2 = 0.05$. Rezultatai parodo, kad modelis silpnai prognozuoja vertes ir gali paaiškinti tik 5% kitimo variacijos. Visgi, ši vertė aukštesnė už 0, tai reiškia, kad prognozės yra geresnės nei pasitelkiant vidurkio sekimą. Tai paaiškina, kad papildomai suderinus modelį ar apmokinus jį naujais duomenimis, modelis tobules ir gebės aptikti reikiamas vertes.

4.4.2. Anomalijų aptikimo modelio testavimas

Testuojant anomalijų aptikimo modelį ir pateikus naujus duomenis, numatoma daugiau kaip 30 anomalijų atvejų. Pirminiai testavimo rezultatai pavaizduoti toliau 42 paveiksle.



42 pav. Gauti testavimo rezultatai, testuojant anomalijų aptikimo MM modelį

Pritaikius MM modelį aptikti anomalijas, apskaičiuotas determinacijos koeficientas, $R^2 = -1.2$. Tai parodo, kad modelio prognozės yra klaidingos. Vis dėlto, pagal naujus pateiktus duomenis matoma, kad anomalijų skaičius žymiai didesnis, taip pat, pagal 40 paveiksle pateiktus duomenis, matoma, kad duomenys yra pasistūmėję, lyginant su apmokymo duomenimis. Dėl šios priežasties, MM modeliai dažnai būna testuojami kryžmine validacija (angl. *Cross Validation*), kuri parodo MM modelio efektyvumą vidinėje patikroje. Duomenys yra išskaidomi į nurodytą kiekį duomenų ir testuojami atskirai (6 formulė).

$$CV = \frac{1}{K} \sum_{i=1}^K R^2_i; \quad (6)$$

čia: K – duomenų sulenkimų skaičius, R^2 – determinacijos koeficientas, i – iteracija, CV – kryžminės validacijos įvertis.

Suprantant, kad projektuotas „LSBoost“ MM modelis funkcionavo neefektyviai su naujais duomenimis, kryžminė validacija įvertinama ir „Bagging“ modeliui, kurio treniravimas aprašytas anksčiau, gauti rezultatai pateikti 7 lentelėje.

7 lentelė. Determinacijos koeficiento bei vidutinės kvadratinės paklaidos reikšmės, pasitelkus kryžminę validaciją


Metodas	Determinacijos koeficientas	Vidutinė kvadratinė paklaida
„LSBoost“	-0.3686	0.0222
„Bagging“	-0.0248	0.0166

Gauti rezultatai pavaizduoja, jog abu modeliai pasižymi ženkliai prastesniais determinacijos koeficientais, lyginant su reikšmėmis, kurios buvo gautos analizuojant treniruojamą duomenų išsidėstymą. Vis dėlto, matoma, kad „LSBoost“ modelis funkcionuoja prasčiau, lyginant su „Bagging“. Dėl paminėtų priežasčių, toliau atliekamas abiejų modelių modifikavimas. Įtraukiami papildomi parametrai, kurie gaunami iš testavimo dar neatlikus CAN komunikacijos matavimų, jie aprašomi toliau.

- Programavimo laikas – tiriama komunikacijos įtampa, kurios yra neatsiejamų nuo procesoriaus, o programavimo laikas dažnai gali identifikuoti sutrikusią procesoriaus veiklą.

- Ankstesnis instrumento matavimas – baterijos įtampos matavimas, kuris matuojamas, naudojant tą patį instrumentą, kaip ir analizuojamas įtampas, gali atskleisti matavimo instrumento sutrikimus.
- Papildomi aritmetiniai įverčiai – skirti sklandesniam MM modelio prognozavimui, nes kartais sąsaja tarp skirtingų įverčių taip pat gali nusakyti naudingos informacijos.

Įtraukus šiuos įverčius, įvertinamas jų svarbumas, tokiu būdu numatant ar jie prideda reikšmės MM modelio prognozėms, identiški pakeitimai atliekami abiem modeliams (43 pav.).




43 pav. Parametrų svarbumas MM modeliuose.

Suprantant, kad „LSBoost“ modelis buvo permokintas, abu MM modeliai sujungiami į vieną, naudojant „Bagging“ technologiją. Atlikus pakeitimus, įvertinamas determinacijos koeficientas bei vidutinė kvadratinė paklaida. Procesas atliekamas testuojant duomenis normalia eiga bei pritaikant kryžminę validaciją, kai duomenys lankstomi 5 kartus, gauti rezultatai 8 lentelėje.

8 lentelė. Gauti rezultatai, kai MM modeliai sujungti, naudojant „Bagging“ technologiją

Taikoma kryžminė validacija	Determinacijos koeficientas, R^2	Vidutinė kvadratinė paklaida, MSE
NE	0.87	0.0121
TAIP	0.73	0.0143

Pagal gautus rezultatus matoma, kad modelis geriau funkcionuoja, kai duomenys paduodami iš eilės, tai – logiška, kadangi „LSBoost“ persimokinimas yra reikšmingas, tačiau skirtumas tarp gautų reikšmių, nepriklausomai ar kryžminė validacija yra taikoma, pakankamai mažas. Toks rodiklis įrodo, kad suprojektuotas MM modelis funkcionuoja efektyviai ir gali sėkmingai aptikti anomalijas, jei nėra didesnių nuokrypių nuo duomenų paketų. Toliau – MM modelis išbandomas su prieš tai pateiktais testavimo duomenimis (44 pav.).



44 pav. Kombinuoto MM modelio prognozės su naujais testavimo duomenimis

Pastebima, jog modelis aptinka mažą kiekį anomalijų. Daug prognozių yra nepasiteisinusių ir determinacijos koeficientas mažesnės vertės. Papildomai buvo įvertintos ir tokios klasifikavimo metrikos kaip „Precision“, „Recall“ ir „F1“. Įvertinimo parametrai pasirinkti atsižvelgiant į tai, jog determinacijos koeficientas tinkamas prognozės tikslumo vertinimui ties kiekviena reikšme, vis dėlto ne visuomet tinkamai atspindi anomalijų aptikimo efektyvumą. Atlikta modelio klasifikacija, anomalijomis laikant įtampos reikšmes, viršijančias 1,25 V, gauti rezultatai pateikti 9 lentelėje.


9 lentelė. Apskaičiuoti „Precision“, „Recall“ bei „F1“ parametru įvertinimai

Testavimo metodas	„Precision“	„Recall“	„F1“
Taikoma kryžminė validacija	1	1	1
Testuojama su naujais duomenimis	0.09	0.11	0.10

Gauti rezultatai rodo, jog kryžminės validacijos metu buvo aptiktos visos anomalijos, o metrikos pasiekė maksimalias reikšmes, todėl galima teigti, kad modelio struktūra yra tinkama. Visgi, testuojant su naujais duomenimis pastebėta, kad modelis generuoja perteklinius perspėjimus, o tai rodo padidintą modelio jautrumą bei pasislinkusių testavimo duomenų reikšmių įtaką. Siekiant geresnių rezultatų, tolimesni veiksmai būtų integruoti didesnę kiekį testavimo duomenų ar įgyvendinti MM modelio apmokymą realiu laiku.

4.5. Neurotinklo metodologijos metodo pritaikymas paleidimo srovės matavimo kontrolei

Atsižvelgiant į paleidimo srovės testavimo potencialą grandinės gedimams lokalizuoti, siūloma neuroninių tinklų taikymo struktūra. Pradinė fazė sėkmingam metodologijos įgyvendinimui apima požymių identifikavimą, tokių kaip amplitudė ar signalo trukmė. Tolimesnis neuroninio tinklo vystymo planas pateikiamas 45 paveiksle, kuriame aprašomi pagrindiniai žingsniai nuo problemos apibrėžimo iki modelio integracijos į testavimo sistemą gamyboje.



45 pav. Neurotinklo metodologijos pritaikymas paleidimo srovės testavimo žingsniui

Siekiant maksimaliai išnaudoti signalų apdorojimo galimybes, šiam tyrimui pasirinkta konvoliucinio neuroninio tinklo architektūra, kuri yra efektyvi kitose mašininio mokymosi srityse.

Vykdomi tolimesni tyrimai, skirti modelio tikslumo tobulinimui ir efektyvumo patikrinimui, naudojant realius gamybinius duomenis. Ateities darbai orientuoti į diagnostinės sistemos integraciją, leidžiančią praktikoje taikyti neuroninių tinklų pagrindu sukurtus gedimų atpažinimo sprendimus.

4.6. Eksperimentinių tyrimų išvados

1. Pradiniai modeliai, vertinti taikant kryžminę validaciją, pasižymėjo ribotu prognozių tikslumu, tačiau pritaikius modelių apjungimo metodą, prognozių tikslumas reikšmingai pagerėjo ir pasiekė $R^2 \approx 0.73$. Tai rodo, kad sudėtiniai metodai leidžia geriau išnaudoti skirtingų modelių stipriąsias puses, padidinant sistemos stabilumą ir gebėjimą aptikti tiek nuokrypius, tiek anomalijas, remiantis gamybiniais duomenimis.
2. Testuojant su naujais duomenimis, modelių našumas sumažėjo dėl pasikeitusių požymių pasiskirstymų. Tai rodo, kad modeliai jautrūs duomenų nuokrypiui, todėl būtina taikyti adaptacinius metodus ar periodiškai pertreniruoti modelius, kad būtų užtikrintas ilgalaikis tikslumas realiomis sąlygomis.
3. Atsižvelgiant į tai, kad modeliai nėra stabilūs realiuose gamybos scenarijuose, rekomenduojama pradiniam etape diegti sistemą kaip įspėjimo funkciją, kuri padeda operatoriams identifikuoti galimas problemas. Tik po nuoseklaus rezultatų įvertinimo ir adaptacijos, būtų galima taikyti visiškai automatizuotus sprendimus.
4. Rezultatai leidžia daryti prielaidą, kad renkant duomenis ilgesniu laikotarpiu ir taikant nuolatinę modelių adaptaciją, galima pasiekti reikšmingą patobulėjimą tiek tikslumo, tiek stabilumo požiūriu, o tai būtina norint realizuoti patikimą prognozių sistemą gamybiniame aplinkoje.

Išvados

1. Darbo metu įvertinta, kad funkcinio testavimo efektyvumą galima pagrįstai analizuoti remiantis CPK indeksu, testavimo metu registruojamų gedimų skaičiumi bei, iš dalies, FPY rodikliu. Nustatyta, kad kai kurie matavimo parametrai ypač susiję su įtampos matavimu prieš ir impulso metu bei srovės įėjimo piku yra pagrindiniai efektyvumo mažėjimo šaltiniai, kuriuos galima analizuoti tobulinant testavimo stabilumą bei valdymo tikslumą.
2. Statistinių metodų derinimas su mašininio mokymosi sprendimais atveria perspektyvias galimybes optimizuoti testavimo laiką ir pagerinti našumą. Naudojant mašininio mokymosi modelius nuokrypio bei anomalijų prognozėms, FPY galėtų padidėti nuo 93% iki maždaug 94,8%, efektyviai sprendžiant apie 24,5% visų fiksuotų problemų per pusės metų gamybos laikotarpį.
3. Atlikus modelių testavimą nustatyta, kad taikant kryžminę validaciją buvo pasiekti aukšti efektyvumo rezultatai, kas rodo, jog modelio struktūra yra tinkama. Vis dėlto, naudojant naujus testavimo duomenis, tikslumas nebuvo tenkinamas dėl duomenų pasiskirstymo skirtumo. Tai rodo, jog praktiniam naudojimui būtina nuolatinė modelio adaptacija ir mokymas su platesne požymių baze.
4. Remiantis atliktais eksperimentais, galima teigti, kad mašininio mokymosi modeliai gali būti lengvai integruojami į esamą testavimo sistemą, mokantis iš gyvai renkamų duomenų ir nepaveikiant pačio testavimo trukmės. Pasiūlyta dviejų etapų implementacijos strategija: pirmuoju etapu modeliai galėtų veikti kaip perspėjimo sistema, o pasiteisinus – būti automatizuojami ir įtraukiami į gamybinį sprendimų priėmimo procesą.

Literatūros sąrašas

1. Design for Testability (DFT) to Overcome Functional Board Test Complexities in Manufacturing Test.
2. Automated Test Fixture for In-production Functional Testing of Electronic Devices
3. Buckroyd, A. (2015). In-Circuit Testing. Butterworth-Heinemann.
4. Mourad, S., & Zorian, Y. (2000). Principles of testing electronic systems. John Wiley & Sons.
5. Heiming, B., & Haupt, H. (2005). Hardware-in-the-loop testing of networked electronics at Ford (No. 2005-01-1658). SAE Technical Paper.
6. Automated Test Fixture for In-production Functional Testing of Electronic Devices
7. Shorten development time of Functional Testing (FCT) in electronic manufacturing with smart instruments.
8. Real-Time Defect Detection in Electronic Components during Assembly through Deep Learning
9. A. Cay, H. Kocabiyik, B. Karaaslan, S. May, M. Khurelbaatar *Development of an opto-electronic measurement system for planter laboratory tests* Canakkale, ScienceDirect, 2017, pp. 90–95.
10. A. Pruunsild, *Module Tester First Pass Yield Improvement*, Metropolia University of Applied Sciences.
11. D. S. Steiberg, *Test equipment, test methods, test fixtures, and test sensors for evaluating electronic equipment* (book style) California: Structural Dynamics of Electronic and Photonic Systems, 2011.
12. M. Oettmeier, R. Bartelt, C. Heising, V. Staudt, A. Steimel, St. Tietmeyer, B. Bock, Ch. Doerlemann. *Machine Emulator: PowerElectronics Based Test Equipment for Testing High-Power Drive Converters* : IEEE, Ruhr-University Bochum and Scienlab electronic systems, 2010.
13. M. G. Pecht, F. R. Nash, *Predicting the Reliability of Electronic Equipment*, IEEE, 1994.
14. Chen, X., Wu, Y., He, X., & Ming, W. (2023). A comprehensive review of deep learning-based PCB defect detection. *IEEE Access*.
15. Xu, Y., Yang, G., Luo, J., & He, J. (2020). An electronic component recognition algorithm based on deep learning with a faster SqueezeNet. *Mathematical Problems in Engineering*, 2020(1), 2940286.
16. Anusuya, M., Kavitha, P., Bathrinath, S., Vundrajavarapu, P., Kumar, R. B., & Sakthivel, M. (2024, April). Automation of Test and Measurement in Electronics Manufacturing Through AI. In 2024 International Conference on Science Technology Engineering and Management (ICSTEM) (pp. 1-6). IEEE.
17. Keysight E2230C testavimo įrangos aprašymas. Prieiga per internetą: <https://www.keysight.com/us/en/product/E2230C/compact-functional-test-system.html>
18. Pickering rėlyno techniniai duomenų lapai. Prieiga per internetą: <https://www.pickeringtest.com/en-us/kb/hardware-topics/switching-platform-selection/understanding-lxi-and-pxi-for-switching>
19. Dey, M., Mia, S. M., Sarkar, N., Bhattacharya, A., Roy, S., Malakar, S., & Sarkar, R. (2021). A two-stage CNN-based hand-drawn electrical and electronic circuit component recognition system. *Neural Computing and Applications*, 33, 13367-13390.
20. Kazemi, A., Haleh, H., & Hajipour, V. (2010). Developing a Method for increasing accuracy and precision in measurement system analysis: a fuzzy approach.

21. Mihok, E., Ecsedi, E., Silaghi, H., Coroiu, L., & Gergely, E. (2021, June). The development of an automated testing machine for test fixtures. In 2021 16th International Conference on Engineering of Modern Electric Systems (EMES) (pp. 1-4). IEEE.
22. Johansson, C., Larsson, T., & Tatipala, S. (2017). Product-Service Systems for functional offering of automotive fixtures: Using design automation as enabler. *Procedia CIRP*, 64, 411-416.
23. Neumann, W. P., Kihlberg, S., Medbo, P., Mathiassen, S. E., & Winkel, J. (2002). A case study evaluating the ergonomic and productivity impacts of partial automation strategies in the electronics industry. *International journal of production research*, 40(16), 4059-4075.
24. Wollschlaeger, M., Sauter, T., & Jasperneite, J. (2017). The future of industrial communication: Automation networks in the era of the internet of things and industry 4.0. *IEEE industrial electronics magazine*, 11(1), 17-27.
25. Dey, C., & Sen, S. K. (2020). *Industrial automation technologies*. CRC Press.
26. Abd Al Rahman, M., & Mousavi, A. (2020). A review and analysis of automatic optical inspection and quality monitoring methods in electronics industry. *Ieee Access*, 8, 183192-183271.
27. Lv, S., Kim, H., Zheng, B., & Jin, H. (2018). A review of data mining with big data towards its applications in the electronics industry. *Applied Sciences*, 8(4), 582.
28. Stoyanov, S., Ahsan, M., Bailey, C., Wotherspoon, T., & Hunt, C. (2019). Predictive analytics methodology for smart qualification testing of electronic components. *Journal of Intelligent Manufacturing*, 30(3), 1497-1514.
29. Reis, M. S., & Gins, G. (2017). Industrial process monitoring in the big data/industry 4.0 era: From detection, to diagnosis, to prognosis. *Processes*, 5(3), 35.
30. Brainerd, S. . *Statistical Process Control and Design of Experiments – Class 2: Cpk* . OHSU OGI. Prieiga per internetą: https://myplace.frontier.com/~stevebrainerd1/STATISTICS/ECE-580-DOE%20WEEK%203_files/Class2_cpk.pdf

1 priedas. „Matlab“ programos kodas

```
clear all;
clc;
data1 = readtable('TestID260_100_ Measure CANL voltage_Export_25-Mar-25, 11_18.xlsx');
data2 = readtable('TestID260_500_ Measure value on CANL during pulse_Export_25-Mar-25, 11_18.xlsx');
data3 = readtable('TestID330_100_ Verify TMPC=2_Export_25-Mar-25, 11_18.xlsx');
data4 = readtable('TestID260_100_ Measure CANL voltage_Export_25-Mar-27, 13_04.xlsx');
data8 = readtable('TestID220_100_ Program board with SW_DEC.xlsx');
data9 = readtable('TestID250_400_ Measure BAT_IF high level voltage. BCOM=1,255_DEC.xlsx');
data10 = readtable('TestID250_400_ Measure BAT_IF low level voltage. BCOM=1,255_DEC.xlsx');
SN1 = data1.SerialNumber;
SN2 = data2.SerialNumber;
SN3 = data3.SerialNumber;
SN4 = data4.SerialNumber;
SN8 = data8.SerialNumber;
SN9 = data9.SerialNumber;
SN10 = data10.SerialNumber;
H1 = data1.NumericValue;
H2 = data2.NumericValue;
H3 = data3.NumericValue;
StepExecutionTime = data4.StepExecutionTime;
StepTime8 = data8.StepExecutionTime;
H9 = data9.NumericValue;
H10 = data10.NumericValue;
if iscell(SN1), SN1 = string(SN1); end
if iscell(SN2), SN2 = string(SN2); end
if iscell(SN3), SN3 = string(SN3); end
if iscell(SN4), SN4 = string(SN4); end
if iscell(SN8), SN8 = string(SN8); end
if iscell(SN9), SN9 = string(SN9); end
if iscell(SN10), SN10 = string(SN10); end
commonSN = intersect(SN1, SN2);
commonSN = intersect(commonSN, SN3);
commonSN = intersect(commonSN, SN4);
commonSN = intersect(commonSN, SN8);
commonSN = intersect(commonSN, SN9);
commonSN = intersect(commonSN, SN10);
temperature = [];
voltage_before = [];
voltage_during = [];
step_time = [];
program_time = [];
bat_if_high = [];
bat_if_low = [];
for i = 1:length(commonSN)
    idx1 = find(strcmp(SN1, commonSN(i)), 1);
    idx2 = find(strcmp(SN2, commonSN(i)), 1);
    idx3 = find(strcmp(SN3, commonSN(i)), 1);
    idx4 = find(strcmp(SN4, commonSN(i)), 1);
    idx8 = find(strcmp(SN8, commonSN(i)), 1);
    idx9 = find(strcmp(SN9, commonSN(i)), 1);
    idx10 = find(strcmp(SN10, commonSN(i)), 1);

    voltage_before(end+1) = H1(idx1);
    voltage_during(end+1) = H2(idx2);
    temperature(end+1) = H3(idx3);
    step_time(end+1) = StepExecutionTime(idx4);
    program_time(end+1) = StepTime8(idx8);
    bat_if_high(end+1) = H9(idx9);
    bat_if_low(end+1) = H10(idx10);
end
disp('Temperaturos:');
disp(temperature);
disp('Itampa pries:');
disp(voltage_before);
disp('Itampa impulse:');
disp(voltage_during);
disp('Matavimo zingsnio laikas:');
disp(step_time);
disp('Programavimo laikas:');
disp(program_time);
disp('BAT_IF aukstas lygis:');
disp(bat_if_high);
disp('BAT_IF žemas lygis:');
disp(bat_if_low);
data5 = readtable('TestID260_100_ Measure CANL voltage_TEST.xlsx');
data6 = readtable('TestID260_500_ Measure value on CANL during pulse_TEST.xlsx');
data7 = readtable('TestID330_100_ Verify TMPC=2_TEST.xlsx');
SN5 = data5.SerialNumber;
SN6 = data6.SerialNumber;
SN7 = data7.SerialNumber;
H5 = data5.NumericValue;
H6 = data6.NumericValue;
H7 = data7.NumericValue;
```

```

if iscell(SN5), SN5 = string(SN5); end
if iscell(SN6), SN6 = string(SN6); end
if iscell(SN7), SN7 = string(SN7); end
data11 = readtable('TestID220_100_ Program board with SW_NOV.xlsx');
data12 = readtable('TestID250_400_ Measure BAT_IF high level voltage. BCOM=1,255_NOV.xlsx');
data13 = readtable('TestID250_400_ Measure BAT_IF low level voltage. BCOM=1,255_NOV.xlsx');
SN11 = data11.SerialNumber;
SN12 = data12.SerialNumber;
SN13 = data13.SerialNumber;
ProgramTime = data11.StepExecutionTime;
BAT_IF_High = data12.NumericValue;
BAT_IF_Low = data13.NumericValue;
if iscell(SN11), SN11 = string(SN11); end
if iscell(SN12), SN12 = string(SN12); end
if iscell(SN13), SN13 = string(SN13); end
commonSN_NEW = intersect(intersect(intersect(SN5, SN6), SN7), ...
                           intersect(SN11, intersect(SN12, SN13)));

new_temperature = [];
new_voltage_before = [];
new_voltage_during = [];
new_step_time = [];
new_program_time = [];
new_bat_if_high = [];
new_bat_if_low = [];
for i = 1:length(commonSN_NEW)
    idx5 = find(strcmp(SN5, commonSN_NEW(i)), 1);
    idx6 = find(strcmp(SN6, commonSN_NEW(i)), 1);
    idx7 = find(strcmp(SN7, commonSN_NEW(i)), 1);
    idx11 = find(strcmp(SN11, commonSN_NEW(i)), 1);
    idx12 = find(strcmp(SN12, commonSN_NEW(i)), 1);
    idx13 = find(strcmp(SN13, commonSN_NEW(i)), 1);
    if all([idx5, idx6, idx7, idx11, idx12, idx13] > 0)
        new_voltage_before(end+1) = H5(idx5);
        new_voltage_during(end+1) = H6(idx6);
        new_temperature(end+1) = H7(idx7);
        new_step_time(end+1) = data5.StepExecutionTime(idx5);
        new_program_time(end+1) = ProgramTime(idx11);
        new_bat_if_high(end+1) = BAT_IF_High(idx12);
        new_bat_if_low(end+1) = BAT_IF_Low(idx13);
    else
        new_voltage_before(end+1) = NaN;
        new_voltage_during(end+1) = NaN;
        new_temperature(end+1) = NaN;
        new_step_time(end+1) = NaN;
        new_program_time(end+1) = NaN;
        new_bat_if_high(end+1) = NaN;
        new_bat_if_low(end+1) = NaN;
    end
end
disp('New Temperaturos:'); disp(new_temperature);
disp('New Itampa pries:'); disp(new_voltage_before);
disp('New Itampa impulse:'); disp(new_voltage_during);
disp('New Matavimo zingsnio laikas:'); disp(new_step_time);
disp('New Programavimo laikas:'); disp(new_program_time);
disp('New BAT_IF aukstas:'); disp(new_bat_if_high);
disp('New BAT_IF zemas:'); disp(new_bat_if_low);
figure;
plot(1:length(voltage_before), voltage_before, 'Linewidth', 1.5);
hold on;
plot(1:length(voltage_during), voltage_during, 'Linewidth', 1.5);
hold off;
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
title('CAN komunikacijos itampos');
legend('Itampa pries impulsa', 'Itampa impulso metu', 'Location', 'Best');
grid on;
set(gca, 'FontSize', 12);
temperature = temperature + 23;
new_temperature = new_temperature + 23;
Q1_voltage_before = prctile(voltage_before, 25); % 1st quartile
Q3_voltage_before = prctile(voltage_before, 75); % 3rd quartile
IQR_voltage_before = Q3_voltage_before - Q1_voltage_before;
Q1_voltage_during = prctile(voltage_during, 25);
Q3_voltage_during = prctile(voltage_during, 75);
IQR_voltage_during = Q3_voltage_during - Q1_voltage_during;
lower_bound_voltage_before = Q1_voltage_before - 1.5 * IQR_voltage_before;
upper_bound_voltage_before = Q3_voltage_before + 1.5 * IQR_voltage_before;
lower_bound_voltage_during = Q1_voltage_during - 1.5 * IQR_voltage_during;
upper_bound_voltage_during = Q3_voltage_during + 1.5 * IQR_voltage_during;
valid_indices = (voltage_before >= lower_bound_voltage_before & voltage_before <=
upper_bound_voltage_before) & ...
(voltage_during >= lower_bound_voltage_during & voltage_during <=
upper_bound_voltage_during);
voltage_before_filtered = voltage_before(valid_indices);
voltage_during_filtered = voltage_during(valid_indices);
temperature_filtered = temperature(valid_indices);
figure;
plot(1:length(voltage_before_filtered), voltage_before_filtered, 'Linewidth', 1.5);
hold on;
plot(1:length(voltage_during_filtered), voltage_during_filtered, 'Linewidth', 1.5);
hold off;

```

```

xlabel('Matavimo iteracija');
ylabel('Itampa, V');
title('Filtruotos CAN komunikacijos itamos');
legend('Itampa prieš impulsą', 'Itampa impulso metu', 'Location', 'Best');
grid on;
set(gca, 'FontSize', 12);
Q1_new_voltage_before = prctile(new_voltage_before, 25);
Q3_new_voltage_before = prctile(new_voltage_before, 75);
IQR_new_voltage_before = Q3_new_voltage_before - Q1_new_voltage_before;
Q1_new_voltage_during = prctile(new_voltage_during, 25);
Q3_new_voltage_during = prctile(new_voltage_during, 75);
IQR_new_voltage_during = Q3_new_voltage_during - Q1_new_voltage_during;
Q1_new_temperature = prctile(new_temperature, 25); % 1st quartile
Q3_new_temperature = prctile(new_temperature, 75); % 3rd quartile
IQR_new_temperature = Q3_new_temperature - Q1_new_temperature;
lower_bound_new_voltage_before = Q1_new_voltage_before - 1.5 * IQR_new_voltage_before;
upper_bound_new_voltage_before = Q3_new_voltage_before + 1.5 * IQR_new_voltage_before;
lower_bound_new_voltage_during = Q1_new_voltage_during - 1.5 * IQR_new_voltage_during;
upper_bound_new_voltage_during = Q3_new_voltage_during + 1.5 * IQR_new_voltage_during;
lower_bound_new_temperature = Q1_new_temperature - 1.5 * IQR_new_temperature;
upper_bound_new_temperature = Q3_new_temperature + 1.5 * IQR_new_temperature;
valid_indices = (new_voltage_before >= lower_bound_new_voltage_before & new_voltage_before <=
upper_bound_new_voltage_before) & ...
(new_voltage_during >= lower_bound_new_voltage_during & new_voltage_during <=
upper_bound_new_voltage_during) & ...
(new_temperature >= lower_bound_new_temperature & new_temperature <=
upper_bound_new_temperature);
new_voltage_before_filtered = new_voltage_before(valid_indices);
new_voltage_during_filtered = new_voltage_during(valid_indices);
new_temperature_filtered = new_temperature(valid_indices);
figure;
subplot(3,1,1); histogram(temperature, 'Normalization', 'probability'); hold on;
                histogram(new_temperature, 'Normalization', 'probability'); hold off;
legend('Apmokymo', 'Testavimo'); title('Temperatūros pasiskirstymas');

subplot(3,1,2); histogram(voltage_before, 'Normalization', 'probability'); hold on;
                histogram(new_voltage_before, 'Normalization', 'probability'); hold off;
legend('Apmokymo', 'Testavimo'); title('Itamos prieš pasiskirstymas');

subplot(3,1,3); histogram(step_time, 'Normalization', 'probability'); hold on;
                histogram(new_step_time, 'Normalization', 'probability'); hold off;
legend('Apmokymo', 'Testavimo'); title('Matavimo laiko pasiskirstymas');
log_step_time = log(step_time + 1);
interaction_term = (voltage_before' .* step_time') ./ max(step_time');
ratio_bat_if = bat_if_high' ./ (bat_if_low' + eps);
ratio_voltage = voltage_before' ./ (step_time' + eps);
ratio_program_vs_step = program_time' ./ (step_time' + eps);
X_features = [temperature', voltage_before', log_step_time, ...
                interaction_term, program_time', bat_if_high', bat_if_low', ...
                ratio_bat_if, ratio_voltage, ratio_program_vs_step];
mu = mean(X_features);
sigma = std(X_features);
X_features_norm = (X_features - mu) ./ sigma;
t = templateTree('MaxNumSplits', 10);
mdl_rf = fitensemble(X_features, voltage_during', ...
    'Method', 'LSBoost', 'NumLearningCycles', 600, 'LearnRate', 0.05);
predicted_rf_train = predict(mdl_rf, X_features);
R2_rf = 1 - sum((voltage_during' - predicted_rf_train).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
fprintf('R² (Train, LSBoost): %.4f\n', R2_rf);
mdl_rf_bag = fitensemble(X_features, voltage_during', ...
    'Method', 'Bag', 'NumLearningCycles', 600, 'Learners', t);
predicted_rf_bag = predict(mdl_rf_bag, X_features);
R2_rf_bag = 1 - sum((voltage_during' - predicted_rf_bag).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
fprintf('R² (Train, Bag): %.4f\n', R2_rf_bag);
mdl_svm = fitsvm(X_features, voltage_during', ...
    'KernelFunction', 'gaussian', ...
    'KernelScale', 'auto', ...
    'BoxConstraint', 10, ...
    'Standardize', true);
pred_svm = predict(mdl_svm, X_features);
R2_rf_SVM = 1 - sum((voltage_during' - pred_svm).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
X_stacked = [predicted_rf_train, predicted_rf_bag];
meta_model = fitensemble(X_stacked, voltage_during', 'Method', 'LSBoost', 'NumLearningCycles',
100);
predicted_stacked = predict(meta_model, X_stacked);
R2_stacked = 1 - sum((voltage_during' - predicted_stacked).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
fprintf('R² (Train, Stacked): %.4f\n', R2_stacked);
residuals_stacked = abs(voltage_during' - predicted_stacked);
threshold = 1;
anomalies_stacked = residuals_stacked > threshold;
importance_rf = predictorImportance(mdl_rf);
importance_bag = predictorImportance(mdl_rf_bag);
figure;
bar(importance_rf);
xticklabels({'Temperatura', 'Itampa prieš', 'Matavimo laikas (log)', ...
    'Saveika', 'Programavimo laikas', 'BAT_IF aukštas', 'BAT_IF žemas', ...

```

```

        'BAT_IF aukštas / BAT_IF žemas', 'Itampa prieš / Matavimo laikas', 'Programavimo
laikas / Matavimo laikas'}));
xlabel('Parametras');
ylabel('Svarbumas, S.V. ');
title('Parametru svarbumas modelyje (LSBoost)');
figure;
bar(importance_bag);
xticklabels({'Temperatura', 'Itampa prieš', 'Matavimo laikas (log)', ...
            'Saveika', 'Programavimo laikas', 'BAT_IF aukštas', 'BAT_IF žemas', ...
            'BAT_IF aukštas / BAT_IF žemas', 'Itampa prieš / Matavimo laikas', 'Programavimo
laikas / Matavimo laikas'}));
xlabel('Parametras');
ylabel('Svarbumas, S.V. ');
title('Parametru svarbumas modelyje (Bagging)');
figure;
hold on;
plot(voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_rf_train, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5); % LSL
yline(1.25, 'k--', 'Linewidth', 1.5); % USL
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes (LSBoost)');
hold off;
figure;
hold on;
plot(voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_rf_bag, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5); % LSL
yline(1.25, 'k--', 'Linewidth', 1.5); % USL
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes (Bagging)');
hold off;
figure;
hold on;
plot(voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_stacked, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5); % LSL
yline(1.25, 'k--', 'Linewidth', 1.5); % USL
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes (Stacked)');
hold off;
cvmodel = fitrensemble(X_features, voltage_during, ...
    'Method', 'LSBoost', 'KFold', 5, 'NumLearningCycles', 600, 'LearnRate', 0.05);
cv_loss = kfoldLoss(cvmodel);
fprintf('CV Loss (MSE, LSBoost): %.4f\n', cv_loss);
cv_preds = kfoldPredict(cvmodel);
R2_cv = 1 - sum((voltage_during' - cv_preds).^2) / sum((voltage_during' -
mean(voltage_during')).^2);
fprintf('R² on CV (LSBoost): %.4f\n', R2_cv);
cvmodel_bag = fitrensemble(X_features, voltage_during, ...
    'Method', 'Bag', 'KFold', 5, 'NumLearningCycles', 300);
cv_loss_bag = kfoldLoss(cvmodel_bag);
fprintf('CV Loss (MSE, Bag): %.4f\n', cv_loss_bag);
cv_preds_bag = kfoldPredict(cvmodel_bag);
R2_cv_bag = 1 - sum((voltage_during' - cv_preds_bag).^2) / sum((voltage_during' -
mean(voltage_during')).^2);
fprintf('R² on CV (Bag): %.4f\n', R2_cv_bag);
cvmodel_stacked = fitrlinear(X_stacked, voltage_during, 'KFold', 5);
cv_loss_stacked = kfoldLoss(cvmodel_stacked);
fprintf('CV Loss (MSE, Stacked): %.4f\n', cv_loss_stacked);
cv_preds_stacked = kfoldPredict(cvmodel_stacked);
R2_cv_stacked = 1 - sum((voltage_during' - cv_preds_stacked).^2) / sum((voltage_during' -
mean(voltage_during')).^2);
fprintf('R² on CV (Stacked): %.4f\n', R2_cv_stacked);
X_stacked_svm = [pred_svm, predicted_rf_bag];
meta_model_bag = fitrensemble(X_stacked_svm, voltage_during, ...
    'Method', 'Bag', 'NumLearningCycles', 100);
predicted_stacked_bag = predict(meta_model_bag, X_stacked_svm);
R2_stacked_bag = 1 - sum((voltage_during' - predicted_stacked_bag).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
fprintf('R² (Train, Stacked + Bagging): %.4f\n', R2_stacked_bag);
figure;
hold on;
plot(voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_stacked_bag, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5); % LSL
yline(1.25, 'k--', 'Linewidth', 1.5); % USL
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes (Stacked + Bagging)');
hold off;
cvmodel_stacked_bag = fitrensemble(X_stacked, voltage_during, ...
    'Method', 'Bag', 'KFold', 5, 'NumLearningCycles', 100);
cv_loss_stacked_bag = kfoldLoss(cvmodel_stacked_bag);

```

```

fprintf('CV Loss (MSE, Stacked + Bagging): %.4f\n', cv_loss_stacked_bag);
cv_preds_stacked_bag = kfoldPredict(cvmodel_stacked_bag);
R2_cv_stacked_bag = 1 - sum((voltage_during' - cv_preds_stacked_bag).^2) / ...
    sum((voltage_during' - mean(voltage_during')).^2);
fprintf('R² on CV (Stacked + Bagging): %.4f\n', R2_cv_stacked_bag);
new_log_step_time = log(new_step_time' + 1);
new_interaction_term = (new_voltage_before' .* new_step_time') ./ max(new_step_time');
ratio_bat_if = new_bat_if_high' ./ (new_bat_if_low' + eps);
ratio_voltage = new_voltage_before' ./ (new_step_time' + eps);
ratio_program_vs_step = new_program_time' ./ (new_step_time' + eps);
X_features_new = [new_temperature', new_voltage_before', ...
    new_log_step_time, new_interaction_term, ...
    new_program_time', new_bat_if_high', new_bat_if_low', ratio_bat_if, ...
    ratio_voltage, ratio_program_vs_step];
predicted_rf_test = predict mdl_rf, X_features_new;
R2_rf = 1 - sum((new_voltage_during' - predicted_rf_test).^2) / ...
    sum((new_voltage_during' - mean(new_voltage_during')).^2);
fprintf('R²: %.4f\n', R2_rf);
residuals = abs(new_voltage_during' - predicted_rf_test);
threshold = 1;
anomalies = residuals > threshold;
importance = predictorImportance mdl_rf;
bar(importance);
xticklabels({'Temperatura', 'Itampa prieš', 'Matavimo laikas (log)', ...
    'Saveika', 'Programavimo laikas', 'BAT_IF aukštas', 'BAT_IF žemas'});
xlabel('Parametras');
ylabel('Svarbumas S.V. ');
title('Parametru svarbumas modelyje');
figure;
hold on;
plot(new_voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_rf_test, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5);
yline(1.25, 'k--', 'Linewidth', 1.5);
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes');
hold off;
residuals_train = abs(voltage_during' - predicted_rf_train);
residuals_test = abs(new_voltage_during' - predicted_rf_test);
new_log_step_time = log(new_step_time' + 1);
new_interaction_term = (new_voltage_before' .* new_step_time') ./ max(new_step_time');
new_ratio_bat_if = new_bat_if_high' ./ (new_bat_if_low' + eps);
new_ratio_voltage = new_voltage_before' ./ (new_step_time' + eps);
new_ratio_program_vs_step = new_program_time' ./ (new_step_time' + eps);
X_features_new = [new_temperature', new_voltage_before', ...
    new_log_step_time, new_interaction_term, ...
    new_program_time', new_bat_if_high', new_bat_if_low', ...
    new_ratio_bat_if, new_ratio_voltage, new_ratio_program_vs_step];

predicted_rf_test = predict mdl_rf, X_features_new;
predicted_bag_test = predict mdl_rf_bag, X_features_new;
predicted_svm_test = predict mdl_svm, X_features_new;
X_stacked_test = [predicted_rf_test, predicted_bag_test];
predicted_stacked_bag_test = predict(meta_model_bag, X_stacked_test);
R2_stacked_bag_test = 1 - sum((new_voltage_during' - predicted_stacked_bag_test).^2) / ...
    sum((new_voltage_during' - mean(new_voltage_during')).^2);
fprintf('R² (Stacked + Bagging Model on NEW data): %.4f\n', R2_stacked_bag_test);
residuals_bag_test = abs(new_voltage_during' - predicted_stacked_bag_test);
threshold = 1;
anomalies_bag = residuals_bag_test > threshold;
figure;
hold on;
plot(new_voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_stacked_bag_test, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5);
yline(1.25, 'k--', 'Linewidth', 1.5);
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos (Stacked + Bagging)', 'LSL', 'USL');
title('Stacked + Bagging modelio prognozes ant nauju duomenu');
hold off;
residuals_train_stacked_bag = abs(voltage_during' - predicted_stacked_bag);
figure;
subplot(2,1,1);
plot(residuals_train);
title('Training Residuals');
xlabel('Matavimo iteracija');
ylabel('Absoliuti paklaida');
subplot(2,1,2);
plot(residuals_test);
title('Test Residuals');
xlabel('Matavimo iteracija');
ylabel('Absoliuti paklaida');
predicted_rf_test_bag = predict mdl_rf_bag, X_features_new;
R2_rf_bag_test = 1 - sum((new_voltage_during' - predicted_rf_test_bag).^2) / ...
    sum((new_voltage_during' - mean(new_voltage_during')).^2);
fprintf('R² (Test, Bagging): %.4f\n', R2_rf_bag_test);
residuals_bag_test = abs(new_voltage_during' - predicted_rf_test_bag);
anomalies_bag_test = residuals_bag_test > 1;

```

```

importance_bag = predictorImportance mdl_rf_bag);
figure;
bar(importance_bag);
xticklabels({'Temperatura', 'Itampa prieš', 'Matavimo laikas (log)', ...
            'Saveika', 'Programavimo laikas', 'BAT-IF aukštas', 'BAT-IF žemas'});
xlabel('Parametras');
ylabel('Svarbumas S.V. ');
title('Parametru svarbumas modelyje (Bagging)');
figure;
hold on;
plot(new_voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_rf_test_bag, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5);
yline(1.25, 'k--', 'Linewidth', 1.5);
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes (Bagging)');
hold off;
residuals_train_bag = abs(voltage_during - predicted_rf_bag);
figure;
subplot(2,1,1);
plot(residuals_train_bag);
title('Training Residuals (Bagging)');
xlabel('Matavimo iteracija');
ylabel('Absoliuti paklaida');
subplot(2,1,2);
plot(residuals_bag_test);
title('Test Residuals (Bagging)');
xlabel('Matavimo iteracija');
ylabel('Absoliuti paklaida');
y_true = voltage_during;
y_pred = cv_preds_stacked_bag;
anomaly_threshold = 1.25;
true_labels = y_true > anomaly_threshold;
predicted_labels = y_pred > anomaly_threshold;
confmat = confusionmat(true_labels, predicted_labels);
if numel(confmat) < 4
    confmat(2,2) = 0;
end
TP = confmat(2,2);
FP = confmat(1,2);
FN = confmat(2,1);
precision = TP / (TP + FP);
recall = TP / (TP + FN);
f1 = 2 * (precision * recall) / (precision + recall);
fprintf('Confusion Matrix:\n');
disp(confmat);
fprintf('TP: %d | FP: %d | FN: %d\n', TP, FP, FN);
fprintf('Precision: %.2f\n', precision);
fprintf('Recall: %.2f\n', recall);
fprintf('F1 Score: %.2f\n', f1);
new_log_step_time = log(new_step_time + 1);
new_interaction_term = (new_voltage_before .* new_step_time) ./ max(new_step_time);
ratio_bat_if = new_bat_if_high ./ (new_bat_if_low + eps);
ratio_voltage = new_voltage_before ./ (new_step_time + eps);
ratio_program_vs_step = new_program_time ./ (new_step_time + eps);
X_features_new = [new_temperature, new_voltage_before, ...
                  new_log_step_time, new_interaction_term, ...
                  new_program_time, new_bat_if_high, new_bat_if_low, ratio_bat_if, ...
                  ratio_voltage, ratio_program_vs_step];
predicted_rf_test = predict(mdl_rf, X_features_new);
R2_rf = 1 - sum((new_voltage_during - predicted_rf_test).^2) / ...
        sum((new_voltage_during - mean(new_voltage_during)).^2);
fprintf('R²: %.4f\n', R2_rf);
residuals = abs(new_voltage_during - predicted_rf_test);
threshold = 1;
anomalies = residuals > threshold;
importance = predictorImportance(mdl_rf);
bar(importance);
xticklabels({'Temperatura', 'Itampa prieš', 'Matavimo laikas (log)', ...
            'Saveika', 'Programavimo laikas', 'BAT-IF aukštas', 'BAT-IF žemas'});
xlabel('Parametras');
ylabel('Svarbumas S.V. ');
title('Parametru svarbumas modelyje');
figure;
hold on;
plot(new_voltage_during, 'b', 'Linewidth', 1.5);
plot(predicted_rf_test, 'r', 'Linewidth', 1.5);
yline(0.5, 'g--', 'Linewidth', 1.5);
yline(1.25, 'k--', 'Linewidth', 1.5);
xlabel('Matavimo iteracija');
ylabel('Itampa, V');
legend('Realios vertes', 'Prognozuotos vertes', 'LSL', 'USL');
title('Realios ir prognozuotos vertes');
hold off;
residuals_train = abs(voltage_during - predicted_rf_train);
residuals_test = abs(new_voltage_during - predicted_rf_test);
new_log_step_time = log(new_step_time + 1);
new_interaction_term = (new_voltage_before .* new_step_time) ./ max(new_step_time);

```

```

new_ratio_bat_if = new_bat_if_high' ./ (new_bat_if_low' + eps);
new_ratio_voltage = new_voltage_before' ./ (new_step_time' + eps);
new_ratio_program_vs_step = new_program_time' ./ (new_step_time' + eps);

X_features_new = [new_temperature', new_voltage_before', ...
                  new_log_step_time, new_interaction_term, ...
                  new_program_time', new_bat_if_high', new_bat_if_low', ...
                  new_ratio_bat_if, new_ratio_voltage, new_ratio_program_vs_step];

predicted_rf_test = predict mdl_rf, X_features_new;
predicted_bag_test = predict mdl_rf_bag, X_features_new;
predicted_svm_test = predict mdl_svm, X_features_new;
X_stacked_test = [predicted_rf_test, predicted_bag_test];
predicted_stacked_bag_test = predict meta_model_bag, X_stacked_test;

pred_filtered = medfilt1(predicted_stacked_bag_test, 5);
plot
plot(new_voltage_during, 'b', 'Linewidth', 1.5);
plot(pred_filtered, 'r', 'Linewidth', 1.5);
true_labels = new_voltage_during' > 1.25;
predicted_labels = pred_filtered > 1.25;
confmat = confusionmat(true_labels, predicted_labels);
if size(confmat,1) < 2 || size(confmat,2) < 2
    confmat(2,2) = 0;
end
TP = confmat(2,2);
FP = confmat(1,2);
FN = confmat(2,1);
precision = TP / (TP + FP);
recall = TP / (TP + FN);
f1 = 2 * (precision * recall) / (precision + recall);
fprintf("Confusion Matrix (NEW DATA, filtered):\n");
disp(confmat);
fprintf("Precision: %.2f | Recall: %.2f | F1 Score: %.2f\n", precision, recall, f1);

```