



**Kauno technologijos universitetas**

Elektros ir elektronikos fakultetas

# **Transformatoriaus izoliacijos defekto tipo nustatymas pagal dalinių išlydžių charakteristikų klasifikaciją**

Baigiamasis magistro projektas

---

**Ernestas Tarulis**

Projekto autorius

**Prof. Saulius Gudžius**

Vadovas

---

**Kaunas, 2024**



**Kauno technologijos universitetas**

Elektros ir elektronikos inžinerija

# **Transformatoriaus izoliacijos defekto tipo nustatymas pagal dalinių išlydžių charakteristikų klasifikaciją**

Baigiamasis magistro projektas

Elektros energetikos inžinerija (6211EX010)

---

**Ernestas Tarulis**

Projekto autorius

**Prof. Saulius Gudžius**

Vadovas

**Doc. prakt. Kęstutis Jasiūnas**

Recenzentas

---

**Kaunas, 2024**



**Kauno technologijos universitetas**

Elektros ir elektronikos fakultetas

Ernestas Tarulis

## **Transformatoriaus izoliacijos defekto tipo nustatymas pagal dalinių išlydžių charakteristikų klasifikaciją**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) 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 (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Ernestas Tarulis

*Patvirtinta elektroniniu būdu*

Tarulis, Ernestas. Transformatoriaus izoliacijos defekto tipo nustatymas pagal dalinių išlydžių charakteristikų klasifikaciją. Magistro baigiamasis projektas / vadovas prof. dr. Saulius Gudžius; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): studijų kryptis – elektros inžinerija, studijų krypčių grupė – inžinerijos mokslai

Reikšminiai žodžiai: daliniai išlydžiai, transformatoriai, izoliacijos defektas, klasifikacija, konvoliucinis neuroninis tinklas.

Kaunas, 2024. 48 p.

### **Santrauka**

Kiekvieną dieną elektros tinklai yra veikiami elektrinės, mechaninės, šiluminės ir atmosferinės apkrovos, dėl ko ilgainiui juose atsiranda izoliacijos defektų. Esant izoliacijos pablogėjimui pradeda formuotis daliniai išlydžiai, kurie spartina izoliacijos būklės pablogėjimą. Šiame magistro baigiamajame darbe yra nagrinėjami daliniai išlydžiai, jų prigimtis, tipai ir aptikimo metodai. Norint suprasti jų dažnines charakteristikas buvo atliktas eksperimentinis tyrimas, kurio metu pagaminti mėginiai su imituojamais defektais buvo patalpinami į indą su alyva ir prie jų prijungiama bandymo aukšta įtampa. Bandymo metu geto charakteristikos buvo naudojamos konvoliucinio neuroninio tinklo apmokymui norint nustatyti ar jis bus pajėgus atlikti teisingus spėjimus, nustatant izoliacijos defekto tipą pagal išmatuotas dažnines charakteristikas.

Tarulis, Ernestas. Research of Transformer Insulation Defect Type by Classification of Partial Discharge Characteristics. Master's Final Degree Project / supervisor prof. dr. Saulius Gudžius; Faculty of Electrical and Electronics Engineering, Kaunas University of Technology.

Study field and area (study field group): electrical engineering, engineering sciences

Keywords: Partial discharge, transformers, insulation defect, klasifikacija, convolitional neural network

Kaunas, 2024. 48 p.

### **Summary**

Every day, electricity networks are subjected to electrical, mechanical, thermal and atmospheric loads, which eventually lead to insulation defects. As insulation deteriorates, partial discharges begin to form and accelerate the deterioration of the insulation. This master's thesis deals with partial discharges, their nature, types and detection methods. In order to understand their frequency characteristics, an experimental study was carried out in which fabricated samples with simulated defects were placed in a container of oil and subjected to a high test voltage. The acquired characteristics were used to train a convolutional neural network to determine whether it would be able to make correct predictions of the type of insulation defect based on the measured frequency characteristics.

## Turinys

<b>Lentelių sąrašas .....</b>	<b>7</b>
<b>Paveikslų sąrašas .....</b>	<b>8</b>
<b>Įvadas.....</b>	<b>9</b>
<b>1. Literatūros apžvalga .....</b>	<b>10</b>
1.1. Gedimai srovės transformatoriuose.....	10
1.2. Dalinių išlydžių prigimtis .....	11
1.3. Energijos virsmai dalinių išlydžių metu.....	13
1.4. Dalinių išlydžių matavimo metodai. ....	14
1.4.1. Elektrinis dalinio išlydžio aptikimo metodas.....	14
1.4.2. Akustinis dalinio išlydžio aptikimo metodas.....	15
1.4.3. Cheminis dalinio išlydžio aptikimo metodas.....	15
1.5. Mašininio mokymosi panaudojimas duomenų analizėje.....	16
1.6. Apibendrinimas.....	19
<b>2. Eksperimentinė dalis.....</b>	<b>20</b>
2.1. Pasiruošimas bandymui.....	20
2.2. Matavimo įranga.....	23
2.3. Eksperimento atlikimas.....	24
2.3.1 Sveiko bandinio matavimai.....	26
2.3.1. Paviršinių dalinių išlydžių matavimas.....	27
2.3.2. Koronavimo alyvoje bandymas.....	29
2.3.3. Bandymai su 1mm vidiniu defektu.....	31
2.3.4. Rezultatų palyginimas.....	33
2.4. Apibendrinimas.....	33
<b>3. Duomenų paruošimas.....</b>	<b>35</b>
3.1. Duomenų skaitmenizavimas.....	35
3.2. Duomenų filtravimas.....	36
3.3. Matavimų taškų sulyginimas ir etikečių suteikimas.....	37
3.4. Sintetinių duomenų sudarymas.....	38
<b>4. Duomenų klasifikavimas naudojant mašininį mokymąsi .....</b>	<b>40</b>
4.1. Defekto tipo nustatymas naudojant CNN.....	40
4.2. CNN palyginimas su atsitiktinio miško klasifikatoriumi .....	42
4.3. Rezultatų apibendrinimas .....	43
<b>Išvados .....</b>	<b>44</b>
<b>Literatūros sąrašas .....</b>	<b>45</b>
<b>Priedai.....</b>	<b>48</b>
1 priedas. Filtravimo kodas .....	48
2 priedas. Matavimų taškų sulyginimo kodas .....	49

## Lentelių sąrašas

<b>1 lentelė.</b> Defekto tipas pagal DGA[8].....	15
<b>2 lentelė.</b> Eksperimento planas.....	24
<b>3 lentelė.</b> Apibendrinti dalinių išlydžių matavimų rezultatai .....	33
<b>4 lentelė.</b> CNN algoritmo tikslumo vertinimas .....	41
<b>5 lentelė.</b> Atsitiktinio miško algoritmo tikslumo vertinimas.....	43

## Paveikslų sąrašas

<b>1 pav.</b>	Aukštos įtampos srovės transformatoriaus konstrukcija .....	10
<b>2 pav.</b>	Izoliacijoje, dujomis užpildytoje ertmėje, dalinio išlydžio reiškiny[4]. .....	12
<b>3 pav.</b>	Dalinio išlydžio energijos virsmas į kitą ir jos fiksavimas[6]. .....	14
<b>4 pav.</b>	Transformatoriaus skirtingų defektų dalinių išlydžių 3D žemėlapiai [10]. .....	16
<b>5 pav.</b>	Dalinių išlydžių pagal fazę matavimų atvaizdavimas[7]. .....	17
<b>6 pav.</b>	Dalinių išlydžių pagal laiką matavimų atvaizdavimas[7]. .....	17
<b>7 pav.</b>	Tipinio konvoliucinio neuronų tinklo konstrukcija [15]. .....	18
<b>8 pav.</b>	Bandinys imituojantis sveiką izoliaciją. ....	20
<b>9 pav.</b>	Bandinys su 1mm skersmens defektu. ....	21
<b>10 pav.</b>	Bandymo modelis. ....	21
<b>11 pav.</b>	Dalinių išlydžių alyvoje imitavimo bandymas. ....	22
<b>12 pav.</b>	Paviršinių dalinių išlydžių imitavimo bandymas. ....	22
<b>13 pav.</b>	Eksperimentinis modelis. ....	23
<b>14 pav.</b>	Dalinių išlydžių matuoklis su priedais. ....	24
<b>15 pav.</b>	Išmatuotas aplinkos fonas. ....	25
<b>16 pav.</b>	Skaitmenizuotų duomenų atvaizdavimas. ....	26
<b>17 pav.</b>	Sveiko bandinio aukšto dažnio impulsų signalas veikiant 10 kV įtampa. ....	26
<b>18 pav.</b>	Sveiko bandinio aukšto dažnio impulsų signalas veikiant 20 kV įtampa. ....	27
<b>19 pav.</b>	Sveiko bandinio aukšto dažnio impulsų signalas veikiant 30 kV įtampa. ....	27
<b>20 pav.</b>	Paviršinio defekto aukšto dažnio impulsų signalas veikiant 10 kV įtampa. ....	28
<b>21 pav.</b>	Paviršinio defekto aukšto dažnio impulsų signalas veikiant 20 kV įtampa. ....	28
<b>22 pav.</b>	Paviršinio defekto aukšto dažnio impulsų signalas veikiant 30 kV įtampa. ....	29
<b>23 pav.</b>	Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 10 kV įtampa. ....	29
<b>24 pav.</b>	Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 20 kV įtampa. ....	30
<b>25 pav.</b>	Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 30 kV įtampa. ....	30
<b>26 pav.</b>	Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 60 kV įtampa. ....	31
<b>27 pav.</b>	Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 10 kV įtampa. ....	31
<b>28 pav.</b>	Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 20 kV įtampa. ....	32
<b>29 pav.</b>	Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 30 kV įtampa. ....	32
<b>30 pav.</b>	Duomenų skaitmenizavimas įrankiu „WebPlotDigitizer“. ....	35
<b>31 pav.</b>	Matavimo duomenys prieš ir po filtravimo. ....	36
<b>32 pav.</b>	Matavimo taškų suliginimas naudojant interpoliaciją. ....	37
<b>33 pav.</b>	Matavimo taškų suliginimas naudojant interpoliaciją. ....	38
<b>34 pav.</b>	CNN modelio struktūra. ....	40
<b>35 pav.</b>	Modelio mokymosi rezultatai. ....	41
<b>36 pav.</b>	Atsitiktinio miško struktūrinė schema. ....	42

## **Įvadas**

Pastaruoju metu didėjant elektros energijos poreikiui, seni elektros tinklai yra nuolat naujinami, plečiami ir modernizuojami, kad poreikis būtų patenkintas ir užtikrintas elektros sistemos stabilumas bei patikimumas. Srovės transformatorius yra svarbi tinklo dalis, skirta stebėti apkrovos srovės apsaugos ir matavimo tikslais. Eksploatuojamus aukštos įtampos matavimų transformatorius veikia elektrinės, mechaninės, šiluminės ir atmosferinės apkrovos, dėl kurių gali pablogėti įrenginio izoliacijos būklė ir galiausiai privesti prie gedimo. Bet koks gedimas gali lemti didelius kapitalo nuostolius, gamybos prastovas ir elektros energijos tiekimo sutrikimus.

Daugiau nei pusė energetikos įrenginių gedimų įvyksta dėl pablogėjusios izoliacijos būklės, todėl srovės transformatoriaus patikimumui didelę įtaką turi jo izoliacija. Dėl izoliacijos senėjimo jos medžiaga gali tapti trapi, prarasti savo atsparumą elektriniam stresui. Dėl to atsiranda dalinių išlydžių, kurie dar labiau pagreitina izoliacijos irimą ir galiausiai lemia jos ir kartu transformatoriaus gedimą. Todėl dalinių išlydžių matavimas yra visuotinai pripažintas kaip veiksminga diagnostikos priemonė, leidžianti įvertinti ir stebėti izoliacijos sistemų vientisumą gamybos ir eksploatavimo metu, kad būtų užtikrintas patikimas elektros sistemos darbas.

Norint viso to išvengti yra pageidautina dalinių išlydžių matavimus atlikti periodiškai ir pagal turimus duomenis prognozuoti besiformuojančius gedimus. Kadangi vis didėjančiame tinkle informacijos kiekis taip pat didėja yra vis daugiau investuojama į mašininio mokymosi algoritmus, kurie turi didelį potencialą informacijos analizėje.

**Darbo tikslas** – pritaikyti dirbtinį intelektą srovės transformatorių dalinių išlydžių matavimų tyrimui.

### **Darbo uždaviniai:**

1. išsiaiškinti duomenis apie srovės transformatorius;
2. išanalizuoti dalinių išlydžių kilmę, tipus, defektų nustatymo metodus;
3. nustatyti, kuris mašininio mokymosi algoritmo tipas yra efektyviausias dalinių išlydžių matavimų analizei atlikti;
4. atlikti bandymus su pasigamintais mėginiais ir nustatyti kokio tipo defektas generuoja jam būdingą dažninę charakteristiką;
5. sudaryti mašininio mokymosi modelį srovės transformatorių dalinių išlydžių matavimų analizei atlikti.

## 1. Literatūros apžvalga

### 1.1. Gedimai srovės transformatoriuose

Srovės transformatoriai (ST) yra labai svarbi elektros sistemos dalis, atliekanti gyvybiškai svarbų vaidmenį tiksliai matuojant elektros sroves. Jie plačiai naudojami siekiant palengvinti veiksmingą elektros tinklų galios valdymą, apsaugą ir kontrolę.

Srovės transformatoriaus paskirtis – sumažinti dideles pirmines sroves iki išmatuojamų ir valdomų antrinių srovių tokių kaip 5A ir 1A, kurias galima naudoti stebėsenos, apsaugos ir valdymo tikslais. Transformatoriai suprojektuoti taip, kad tiksliai atkartoja pirminės srovės bangos formą ir užtikrina proporcingą antrinę srovę, kuri būtina tiksliems srovės matavimams. Transformuodami dideles sroves į mažesnes vertes, ST leidžia naudoti standartinius matavimo prietaisus ir apsaugos įtaisus, kurie nėra pritaikyti didelėms srovėms ir taip užtikrinti saugią ir tikslią elektros sistemos stebėseną [1].


Pagrindinės srovės transformatorių funkcijos.

**Matavimas.** Srovės transformatoriai naudojami matuoti srovės srautui įvairiose elektros energijos sistemos dalyse, pavyzdžiui, perdavimo linijose, skirstomuosiuose tinkluose ir atskirose apkrovose. Šie matavimai teikia svarbius duomenis sistemos analizei, apkrovų balansavimui, apskaitos registravimui ir energijos valdymui.

**Apsauga.** ST atlieka svarbų vaidmenį elektros energijos sistemos apsaugai, nes tiksliai nustato neįprastas srovės elgsenas, pavyzdžiui, trumpus jungimus ar perkrovas. Kai per pirminę apviją teka per didelė srovė, transformatorius sukuria proporcingą antrinę srovę, kuri įjungia apsauginius įtaisus, izoliuoja sugedusią dalį ir apsaugo įrangą bei personalą nuo žalos.

**Elektros energijos kokybės analizė.** Srovės transformatoriai teikia vertingų duomenų galios kokybės analizei, padeda nustatyti įtampos ir srovės iškreipimus, harmonikų kiekį ir kitus nukrypimus, kurie gali turėti įtakos elektros energijos sistemos ir prijungtų įrenginių veikimui. Ši informacija padeda palaikyti stabilų ir patikimą elektros energijos tiekimą.

Srovės transformatorius (1 pav.) turi tam tikrų panašumų su kitų tipų transformatoriais. Kaip ir kiti transformatoriai, ST veikia elektromagnetinės indukcijos principu bei jame naudojama pirminė ir antrinė apvijos energijai perduoti iš vienos elektros grandinės į kitą [2].



1 pav. Aukštos įtampos srovės transformatoriaus konstrukcija

Aukštos įtampos srovės transformatorių sudaro kelios svarbios sudedamosios dalys, kurios kartu lemia jo funkcionalumą ir patikimumą. Pirminė apvija, skirta didelei pirminei srovei praleisti,

paprastai yra sukonstruota iš vienos ar kelių varinių arba aliuminių vijų. Jai tenka lemiamas vaidmuo tiksliai matuojant per sistemą tekančią pirminę srovę. Antrinę apviją sudaro daugybė plonųjų laidininkų vijų. Ji gamina proporcingą antrinę srovę, kuri priklauso nuo pirminių ir antrinių apvijų vijų santykio, ir yra prijungta prie matavimo prietaisų arba apsaugos relių tolesnei analizei ir valdymui. Antrinės apvijos šerdis, dažniausiai yra pagaminta iš laminuoto silicio plieno, tarnauja kaip magnetinė grandinė, kad pirminės srovės sukurtas magnetinis srautas būtų veiksmingai perduodamas į antrinę apviją. Ji sumažina nuostolius ir padidina srovės matavimo tikslumą.

Izoliacija yra labai svarbi transformatoriaus dalis, užtikrinanti elektros saugą ir užkertanti kelią gedimams. Izoliacijos sistema atskiria apvijas ir užtikrina elektrinę izoliaciją tarp skirtingų apvijų ir šerdis. Ji paprastai sudaryta iš aukštos kokybės medžiagų, pavyzdžiui, alyva impregnuoto popieriaus, dervos arba kompozitinės izoliacijos, sukurtos taip, kad atlaikytų aukštą elektrinį bei terminį stresą[3].

Siekiant apsaugoti vidinius komponentus ir užtikrinti apsaugą nuo mechaninio bei atmosferinio poveikio, transformatoriaus apvijos yra dedamos į talpyklą. Talpykla gaminama iš plieno, kuris yra karštai galvanizuotas. Transformatorius galiausiai papildomas rafinuota izoliacine alyva, kuri naudojama ir kaip izoliacinė terpė, ir kaip aušinimo skystis.

Ekspluatuojami aukštos įtampos srovės transformatoriai yra veikiami elektrinių, šiluminių ir mechaninių apkrovų bei aplinkos sąlygų, dėl kurių gali pablogėti izoliacinės sistemos būklė ir atsirasti dalinių išlydžių, kurie yra pirmoji indikacija, jog yra reikalingas įrenginio stebėjimas ir aptarnavimas.


## 1.2. Dalinių išlydžių prigimtis

Dalinis išlydis (PD) (angl. *Partial Discharge*) – tai elektros iškrova, atsirandanti tam tikroje izoliacijos vietoje tarp dviejų laidininkų, tačiau ji visiškai nenukeliauja nuo vieno iki kito elektrodo. Dalinė iškrova atsiranda įvairiose aukštos įtampos elektros įrangos vietose ir terpėse. Toliau pateiktos priežastys dėl kurių šie išlydžiai gali atsirasti.

- **Gamybos metu.** Kietoji izoliacija suprojektuota taip, kad elektros įtampa tarp laidžiųjų elektrodo pasiskirstytų tolygiai. Tačiau praktikoje gaminant gali atsirasti defektų, dėl kurių izoliacijos masėje atsiranda nedidelių ertmių arba tuštumų, kuriose susidaro daliniai išlydžiai.
- **Įrangos montavimo metu.** Kai elektros įranga surenkama gamykloje arba montuojama vietoje, gali būti padaryta klaidų, dėl kurių izoliacija gali būti pažeista ir susilpninta.
- **Dėl senėjimo ir nusidėvėjimo.** Dauguma izoliacinių medžiagų su amžiumi natūraliai blogėja, nes suyra vidiniai cheminiai ryšiai. Dėl šio proceso izoliacija tampa silpnesnė ir ne tokia patvari, kai atlaiko įprastomis darbo sąlygomis esančią elektros įtampą.
- **Dėl eksploatacijos metu patirtos perkrovos.** Dėl trumpojo jungimo gedimo arba žaibo impulso izoliacija gali būti perkrauta dėl gedimo srovės arba viršįtampio. Nors tokie įvykiai paprastai trunka neilgai, dėl padidėjusios elektros įtampos arba perkaitinimo nuo trumpojo jungimo srovės izoliacija gali būti pažeista visam laikui.
- **Dėl eksploatacinės žalos.** Eksploatuojant elektros įrangą dėl išorinių veiksnių ji gali būti fiziškai pažeista. Požeminiai kabeliai ypač jautrūs trečiųjų šalių žalai, pavyzdžiui, dėl kelių darbų šalia užkastų kabelių arba dėl sunkiasvorių transporto priemonių, važiuojančių per juos.

Viena iš dažnų PD priežasčių yra dėl dielektrike esančios tuštumos ar defekto sumažėjusi dielektriko skvarba, todėl padidėja elektrinio lauko stipris ir per tuštumą įvyksta iškrova, kuri nepažeidžia

laidininkų, tačiau laikui bėgant ji gali sustiprėti dėl ilgalaikės elektrinės įtampos, didinančios fizinių tuštumos dydį (1 pav.). Paprastai tokios iškrovos būna trumpesnės nei 1 mikrosekundės trukmės 1–100 pC impulsai [4].



**2 pav.** Izoliacijoje, dujomis užpildytoje ertmėje, dalinio išlydžio reiškinys[4].

$C_d$  – izoliacijos talpa,  $C_v$  – dujomis užpildytos tuštumos talpa, o  $C_a$  ir  $C_b$  – nuosekliai su tuštuma sujungtos izoliacijos talpos. Tuštumos elektrinė skvarba yra mažesnė nei aplinkinės izoliacijos, nes tuštuma yra linkusi artėti prie oro elektrinės skvarbos, kuri yra mažesnė už izoliacijos elektrinę skvarbą, todėl elektrinio lauko stipris tuštumoje padidėja ir, padidėjus kintamosios srovės potencialui laidininkuose, gali kilti elektros lankas. Susidaręs lankas gali susilpninti aplinkinę izoliaciją ir sukelti medžių susidarymą (angl. *electrical treeing*), dėl kurio galiausiai padidėja tuštumos dydis ir padidėja gedimo rizika.

Paprastai skiriami trys dalinio išlydžio tipai, kiekvienas jų atsiranda dėl skirtingų priežasčių ir kiekvienas iš jų gali sukelti skirtingo lygio žalą.

1. Vidinis dalinis išlydis. Šio tipo išlydis pasireiškia izoliacijos viduje arba defektų, tokių kaip tuštumos ar įtrūkimai, viduje. Paprastai tai susiję su izoliacijos senėjimu ar pažeidimais, dėl kurių atsiranda tuštumų ar kitų defektų, galinčių sukelti lokalius elektrinius laukus ir išlydžio aktyvumą.
2. Paviršinis dalinis išlydis. Šis tipas atsiranda izoliacijos paviršiuje, paprastai ten, kur izoliacija jungiasi su laidininku ar kita izoliacine medžiaga. Paviršinį dalinį išlydį gali sukelti įvairūs veiksniai, įskaitant užterštumą, drėgmę arba izoliacijos paviršiaus pažeidimus. Jį galima lengviau nustatyti nei vidinį PD, tačiau netvarkomas jis vis tiek gali sukelti izoliacijos ir įrangos gedimą.
3. Koronavimas. Šio tipo PD atsiranda dujinėje terpėje, supančioje laidininką, pavyzdžiui, ore aplink aukštos įtampos elektros liniją. Jis paprastai susijęs su dideliais elektriniais laukais ir gali sukelti oro jonizaciją, dėl kurios atsiranda išlydis.

Apskritai dalinis išlydis yra izoliacijos problemos simptomas, o PD nustatymas ir stebėjimas gali padėti diagnozuoti galimas elektros įrangos problemas, kol jos nesukėlė gedimo. Kiekvieno tipo PD priežastys ir poveikis izoliacijai yra skirtingi, o šių skirtumų supratimas gali padėti veiksmingai stebėti ir prižiūrėti elektros sistemas.

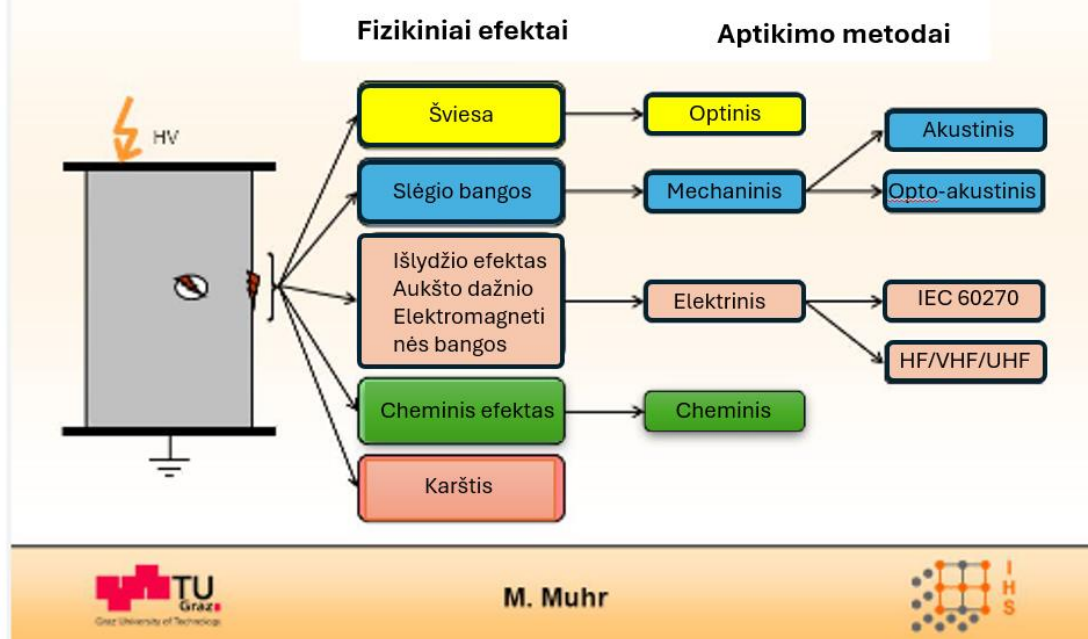
### 1.3. Energijos virsmai dalinių išlydžių metu.

PD aktyvumas rodo prasidedantį vidutinės arba aukštos įtampos elektrinių įrenginių izoliacijos gedimą ir yra laikomas geriausiu ankstyvuoju įspėjimu dėl izoliacijos pablogėjimo. Paprastai PD pasireiškia sistemose, veikiančiose esant 3 kV ir aukštesnei įtampai[5].

Dalinio išlydžio metu izoliacijoje sukaupta elektros energija paverčiama į kitų formų energiją. Energijos konversijos proceso metu gali susidaryti kelių rūšių energija (3 pav.).

1. Elektros energija. Dalis izoliacijos sistemoje sukauptos elektros energijos PD įvykio metu virsta išlydžio srove. Šią išlydžio srovę galima išmatuoti naudojant srovės transformatorių arba Rogovskio ritę. Per PD įvykį susidaranti elektros energijos kiekis priklauso nuo įtampos lygio, izoliacinės medžiagos savybių ir išlydžio charakteristikų.
2. Šiluminė energija. Įvykus PD, nedidelis elektros energijos kiekis dėl izoliacinės medžiagos varžos virsta šilumine energija. Susidariusios šiluminės energijos kiekis priklauso nuo išlydžio stiprumo ir izoliacinės medžiagos savybių. Jei PD įvykis yra pakankamai stiprus, izoliacinės medžiagos temperatūra gali pakilti tiek, kad galimas izoliacijos pažeidimas.
3. Akustinė energija. Išlydžio metu susidaro akustinė energija – garso bangos. Šias garso bangas galima užfiksuoti naudojant mikrofoną arba pjezoelektrinį jutiklį. Garso bangų dažnis priklauso nuo izoliacinės medžiagos savybių ir išlydžio stiprumo. Akustiniai PD nustatymo metodai dažnai naudojami kartu su kitų tipų PD matavimo metodais, siekiant nustatyti išlydžio šaltinį.
4. Elektromagnetinė energija. Dėl staigaus krūvių greitėjimo ir lėtėjimo izoliacijos sistemoje susidaro elektromagnetinė energija. Šią energiją galima aptikti naudojant anteną arba magnetinio lauko jutiklį. Elektromagnetinės spinduliuotės dažnis priklauso nuo izoliacinės medžiagos savybių ir išlydžio charakteristikų. Elektromagnetinio PD nustatymo metodai dažnai naudojami kartu su kitų tipų dalinio išlydžio registravimo metodais, siekiant nustatyti išlydžio tipą ir vietą.
5. Cheminė energija. Kai kuriais atvejais PD įvykis gali sukelti chemines reakcijas izoliacinėje medžiagoje. Dėl šių reakcijų gali išsiskirti cheminė energija šilumos arba šviesos pavidalu. Pavyzdžiui, jei izoliacinėje medžiagoje yra deguonies, iškrova gali sukelti reakciją, kurios metu susidaro ozonas. Dėl šios cheminės reakcijos gali susidaryti šiluma ir šviesa, kurias galima aptikti naudojant atitinkamus jutiklius.

## Dalinių išlydžių matavimas



3 pav. Dalinio išlydžio energijos virsmas į kitą ir jos fiksavimas[6].

Suprasti šių energijos virsmų pobūdį yra svarbu kuriant veiksmingus dalinio išlydžio aktyvumo aptikimo ir stebėjimo metodus aukštos įtampos elektros sistemose. Analizuojant įvairias energijos formas, susidarantiąs PD įvykio metu, galima sukurti išsamias jų aptikimo ir stebėsenos strategijas, kurios gali padėti išvengti įrangos gedimų ir prastovų.

### 1.4. Dalinių išlydžių matavimo metodai.

Dalinių išlydžių matavimas ir stebėjimas yra svarbi prevencinė priemonė, skirta apsaugoti aukštos įtampos įrangą nuo žalos. Skirtingi metodai skirti aptikti PD priklauso nuo to, kokios skirtingos fizikinės savybės lydinės PD atsiradimą yra matuojamos.

#### 1.4.1. Elektrinis dalinio išlydžio aptikimo metodas.

Norint išmatuoti dalinio išlydžio sukurtą elektromagnetinę energiją yra naudojamas aukšto dažnio (HF angl. *High frequency*) metodas. Juo yra matuojamas dalinio išlydžio sukeltas rezonansas. Priklausomai nuo rezonanso matuojamo dažnio, naudojami skirtingi jutikliai, kurie geba matuoti bangas skirtinguose diapazonuose:

- **Aukšto dažnio (HF).** Aukšto dažnio matavimai dažniausiai naudojami dalinių išlydžių aptikimui elektros kabeliuose ir prieduose. HF dažnių diapazonas paprastai yra nuo 3 MHz iki 30 MHz.
- **Labai aukštas dažnis (VHF angl. *very high frequency*).** VHF matavimai paprastai naudojami aukštos įtampos įrangos PD testavimui. Dažnių diapazonas - 30 MHz iki 300 MHz.
- **Ultra aukštas dažnis (UHF angl. *Ultra high frequency*).** UHF, taip pat kaip ir VHF matavimai dažniausiai naudojami aukštos įtampos įrangos dalinių išlydžių stebėjimui. UHF dažnių diapazonas - nuo 300 MHz iki 3 GHz.

### 1.4.2. Akustinis dalinio išlydžio aptikimo metodas.

Akustinis metodas yra pagrįstas reiškiniu, kad PD skleidžia garso bangas. Šis garsas susidaro, kai susiformuoja srovės iškrova ir aplink srautą esanti medžiaga išgaruoja. Šis garavimas sukelia greitą mechaninės energijos išsiskyrimą, kuri sklinda slėgio lauko pavidalu [7].

Akustines aptikimo sistemas galima suskirstyti į dvi kategorijas: išorines ir vidines. Išorinėse akustinio aptikimo sistemose, kurios šiuo metu labiau naudojamos energetikos sistemose, naudojami jutikliai kurie yra montuojami prie elektros įrangos išorės, kad aptiktų PD akustinį signalą. Vidinės sistemos, kita vertus, jutikliai, įrengti elektros energijos įrenginių viduje, naudojami tiesiogiai matuoti akustinį signalo slėgio bangą.

Pagrindinis akustinio aptikimo pranašumas, palyginti su kitais metodais, yra tas, kad padėties nustatymo informaciją galima gauti naudojant keliose vietose esančius jutiklius. Šia padėties informacija galima nustatyti, kurioje įrenginio dalyje vyksta dalinis išlydis, jo tipą ir pagal tai izoliacijos gedimo rimtumą. Kitas privalumas palyginti su elektriniu, yra atsparumas elektromagnetiniams trukdžiams. Tačiau atsparumas EMI nereiškia, kad sistemoje nėra akustinio triukšmo.

### 1.4.3. Cheminis dalinio išlydžio aptikimo metodas.

Dalinius išlydžius galima aptikti cheminiu būdu, nes srovės srautai suardo aplinkines medžiagas į skirtingus cheminius komponentus. Šis metodas vadinamas „Išsiskirusių dujų analizė“ (DGA) (angl. dissolved gas analysis). Verta paminėti, kad šiuos bandymus galima atlikti tik su alyva užpildytais sudedamosiomis dalimis, daugiausia transformatoriais, tai šis metodas yra naudojamas nustatyti dalinių išlydžių buvimo transformatoriuose intensyvumui (4 pav.).

1 lentelė. Defekto tipas pagal DGA[8].

Dujų pavadinimas	Normalios ribos (<)*	Kritinės ribos (>)**	Galimas gedimo tipas
Vandenilis	150	1,000	Kibirkštys, lanko susidarymas
Metanas	25	100	Kibirkštys
Acetilenas	15	70	Lanko susidarymas
Etilenas	20	50	Vietinis perkaitimas
Etanas	10	35	Vietinis perkaitimas
Anglies monoksidas	500	1,000	Smarkus perkaitimas
Anglies dioksidas	10,000	15,000	Smarkus perkaitimas
Bendri degieji elementai	720	4,630	Smarkus perkaitimas

\*Kai dujų koncentracija viršija šią ribą, būtina padidinti mėginių dažnumą, atsižvelgiant į planuojamą artimiausio laikotarpio gedimo įvertinimą.

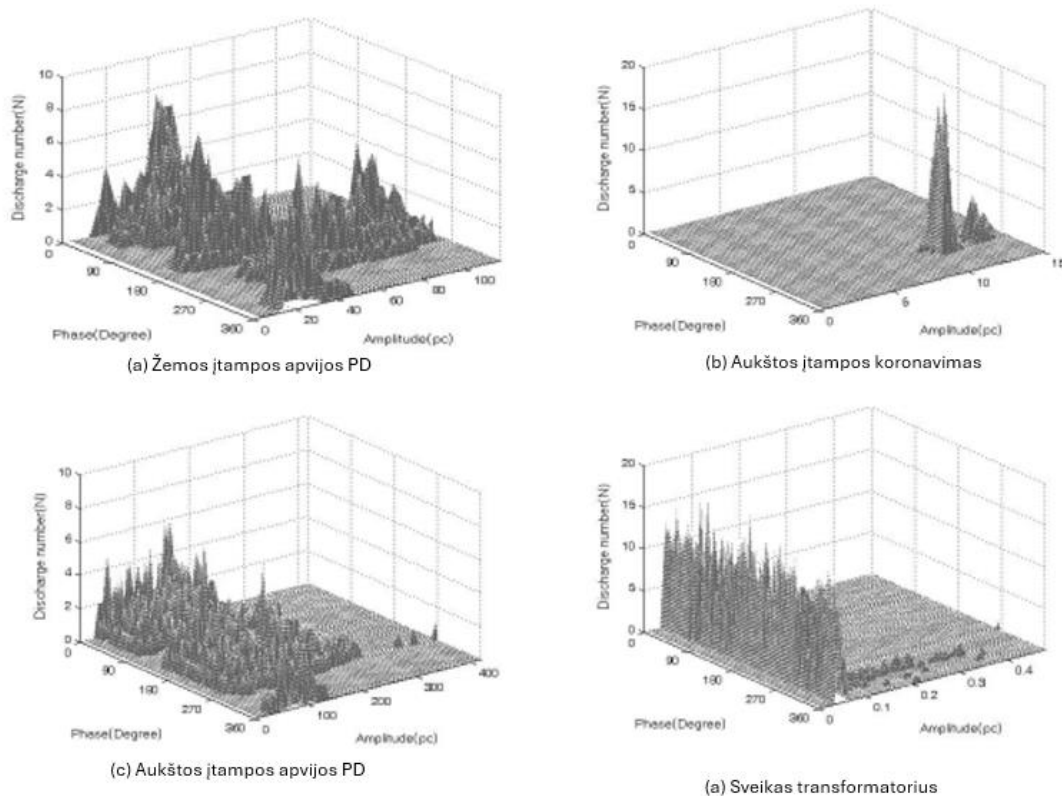
\*\* Jei dujų koncentracija viršija šią ribą, reikėtų svarstyti galimybę išjungti transformatorių iš eksploatacijos.

DGA bandymu nustatomos alyvoje ištirpusios dujos, susidarančios skylant mineralinei alyvai. Bandymas atliekamas paėmus alyvos mėginį ir nustatius įvairių ištirpusių dujų kiekį. Skirtingų dujų pėdsakai ir jų kiekis indikuoja skirtingus galimus reiškinius, kurie pasireiškia ar vyko

transformatoriuje. Cheminių bandymų trūkumai yra tokie, kad šie metodai nesuteikia jokios informacijos apie dalinio išlydžio ir (arba) izoliacijos pažeidimo vietą [9].

### 1.5. Mašininio mokymosi panaudojimas duomenų analizėje.

Kiekvienas defektas turi savo unikalią gedimo charakteristiką (5 pav.). Šią ypatingą savybę galima panaudoti siekiant susieti dalinių išlydžių modelius su defektų tipais.

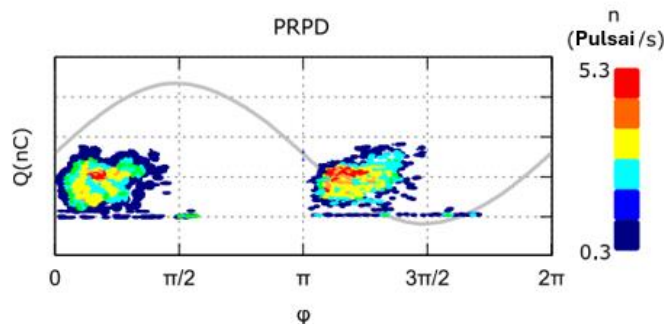


4 pav. Transformatoriaus skirtingų defektų dalinių išlydžių 3D žemėlapis [10].

4 paveiksle yra pateiktas sauso tipo galios transformatoriaus skirtingų izoliacijos defektų dalinių išlydžių pagal fazę 3D žemėlapis. Žemėlapiui sudaryti buvo naudojama:

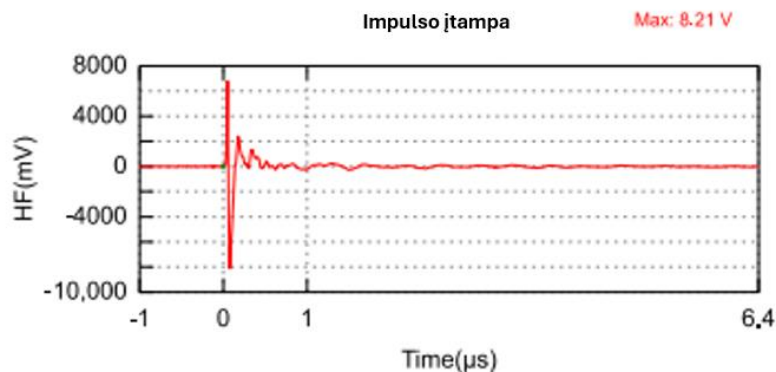
- Išlydžių skaičius  $N$ ;
- Išlydžio stiprumas  $pC$ ;
- Fazės kampas išlydžio metu  $\varphi$ ;

Analizuojant gautus matavimo duomenis ir juos lyginant su jau žinomais dalinių išlydžių vyksmo pasiskirstymo ir intensyvumo žemėlapiais, galima tiksliai nustatyti izoliacijos gedimo tipą [10]. Duomenys taip pat gali būti pateikiami ir 2D dimensijoje (6 pav.).



5 pav. Dalinių išlydžių pagal fazę matavimų atvaizdavimas[7].

Kitas duomenų analizės metodas yra dalinio išlydžio pateikimas pagal laiką (7 pav.). Šis duomenų modelis turi įdomių privalumų, nes galima stebėti atskirų impulsų formą, kuri koreliuoja su izoliacijos defekto pobūdžiu, o tai suteikia informacijos apie izoliacijos sistemos senėjimą. Dalinių išlydžių pagal laiką modelių matavimo procedūrai paprastai reikia pigesnės matavimo sistemos, palyginti su matavimais pagal fazę.



6 pav. Dalinių išlydžių pagal laiką matavimų atvaizdavimas[7].

Tačiau, dalinių išlydžių matavimai pagal fazę yra plačiau naudojami PD klasifikavimo tyrimuose, nes jais galima atvaizduoti fizikinį procesą esantį išlydžių vietoje, nes atskiras PD impulsas turi tvirtą ryšį su išmatuotų duomenų modeliais [9].

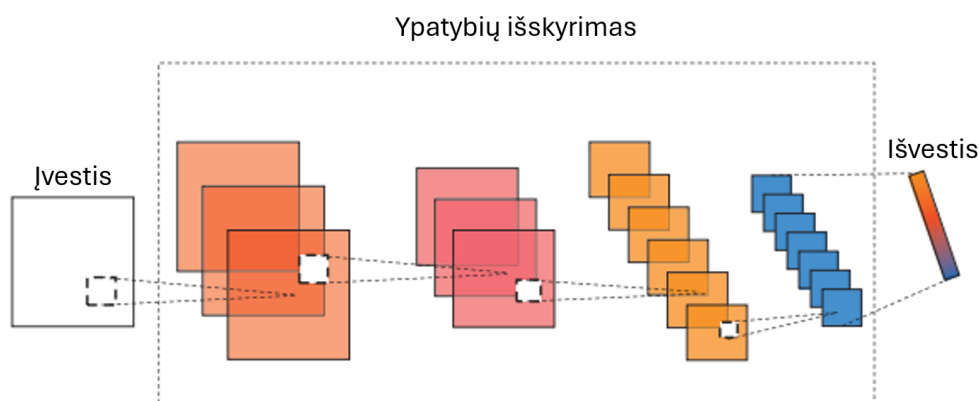
Dalinių išlydžių modelių klasifikavimas yra labai svarbus vertinant izoliacijos būklę naudojant išmatuotą dalinio išlydžio stiprumą. Be to, PD klasifikacija gali būti naudojama prognozuoti bet kokią gresiantį izoliacijos gedimą ir nustatyti, ar reikia keisti esamą izoliacijos sistemą. [11].

Pastaraisiais metais mašininio mokymosi pažanga leido sukurti naujas PD matavimų valdymo priemones ir metodus. Pasitelkus mašininio mokymosi algoritmus ir kitas dirbtiniu intelektu pagrįstas technologijas, dabar galima analizuoti didelius duomenų kiekius, kad būtų galima tiksliai ir efektyviai aptikti ir diagnozuoti PD reiškinius, be žmogaus priežiūros[12].

Per pastaruosius kelerius metus gilusis mokymasis leido pasiekti labai gerų rezultatų sprendžiant įvairias problemas, pavyzdžiui, vaizdo atpažinimo, kalbos atpažinimo ir natūralios kalbos apdorojimo. Iš įvairių giliųjų neuroninių tinklų tipų plačiausiai analizuojami yra konvoliuciniai neuroniniai tinklai. Pasinaudojant sparčiai didėjančiu užvadintų duomenų kiekiu ir labai pagerėjusiais grafikos procesorių pajėgumais, konvoliucinių neuroninių tinklų tyrimai sparčiai vystėsi ir pasiekė aukštų rezultatų sprendžiant įvairius uždavinius, tarp jų ir signalų analizėje[13][14].

Konvoliucinis neuroninis tinklas (KNT) yra daugiasluoksnis neuroninis tinklas įkvėptas smegenų regos žievės, bet nėra apribotas tik vaizdų klasifikavimu. Šio algoritmo pagrindinė užduotis - gauti klasę arba klasių tikimybę, geriausiai apibūdinančią įvesties vaizdą. Kad galėtų atlikti šią užduotį, algoritmas turi gebėti atpažinti požymius (kraštus, kreives, briaunas) ir jų kompozicijas[7].

Tipišką konvoliucinį neuroninį tinklą paprastai sudaro 5 sluoksniai, t. y. įvesties sluoksnis, konvoliucinis sluoksnis, sujungimo sluoksnis, visiškai sujungtas sluoksnis ir išvesties sluoksnis (8 pav.). Konvoliucinį sluoksnį sudaro daugybė paviršių, kurių kiekviename yra daug neuronų. Įvesties stadijoje, kada vaizdas patenka į konvoliucinį sluoksnį, branduolys atlieka įvesties konvoliucinę operaciją, kad išgautų srities požymių rinkinį.



7 pav. Tipinio konvoliucinio neuronų tinklo konstrukcija [15].

Sujungimo sluoksnį taip pat sudaro kelis savosios sritys, kuri atitinka konvoliucinio sluoksnio savąją sritį. Visiškai sujungto sluoksnio neuronai prijungiami prie ankstesnio sluoksnio savųjų sričių, išgaunant informaciją su klasifikavimo požymiais iš ankstesnio sluoksnio savųjų sričių ir įvedant išvestį į išvesties sluoksnį po tiesinių ar netiesinių operacijų. Išvesties sluoksnio vaidmuo - nenormalizuotą visiškai sujungto sluoksnio išvestį atvaizduoti pagal prognozuojamų išvesties kategorijų tikimybinį pasiskirstymą[15].

Pritaikius KNT elektromagnetiniams dalinių išlydžių matavimams buvo gautas aukštas dalinių išlydžių aptikimas ir tikslumas (atitinkamai 95,73% ir 95.58%). Matavimai buvo atlikti aukštos įtampos dujomis izoliuotam jungtuvui naudojant . Algoritmas buvo sudarytas iš 5 sluoksnių ir kiekviename po 500 neuronų, *ReLU* aktyvavimo funkcijos ir *softmax* išvesties funkcijos. Modeliui apmokinti buvo panaudota 3000 matavimų rezultatų atvaizdų iš kurių 500 buvo su daliniais išlydžiais[12].

Kitame eksperimente naudotas modifikuotas, 7 sluoksnių, KNT (lengvo mastelio KNT) parodė dar geresnius rezultatus pasiekdamas 98,13% tikslumą nustatant 1 iš 4 dalinio išlydžio tipą . Matavimo objektas taip pat buvo aukštos įtampos jungtuvas, o matuota UHF metodu, kurio metu buvo sugeneruota 3200 matavimų iš kurių 80% buvo panaudota modelio apmokymui, o likę 20% tikslumo patikrinimui[16].

Buvo atlikta ir vis dar vykdoma daugybė tyrimų, siekiant panaudoti mašininį mokymąsi dalinių išlydžių matavimų analizei palengvinti[12][17].

## **1.6. Apibendrinimas.**

Srovės transformatoriai yra svarbi elektros sistemos dalis, skirta srovių matavimui, apsaugai, sistemos valdymui ir elektros energijos kokybės analizei. Transformatoriaus izoliacija užtikrina elektrinę izoliaciją tarp apvijų ir šerdies, ir tarp pačių apvijų, kuri dėl senėjimo, apkrovų ar defektų gali laikui bėgant pablogėja ir joje atsiranda daliniai išlydžiai.

Daliniai išlydžiai yra elektros iškrovos, atsirandančios izoliacijos viduje ar paviršiuje. Jie yra izoliacijos pablogėjimo pasekmė ir priežastis. Nenustačius dalinių išlydžių laiku, gali neplanuotai sugęsti įrangą, patiriami dideli nuostoliai. Dalinių išlydžių matavimas yra veiksminga diagnostikos priemonė, leidžianti įvertinti izoliacijos būklę ir stebėti transformatoriaus patikimumą. Periodiški matavimai ir duomenų analizė padeda prognozuoti besiformuojančius gedimus


## 2. Eksperimentinė dalis.

### 2.1. Pasiruošimas bandymui.

Iš ankstesnės dalies yra žinoma, jog izoliuojanti medžiaga srovės transformatoriuose yra popierinė izoliacija ir dielektrinė alyva, todėl norint imituoti dalinius išlydžius transformatoriaus izoliacijoje, bandymams turi būti naudojama popierinė izoliacija/elektrotechninis kartonas ir dielektrinė alyva.

Mėginių gaminimui buvo pasirinktas elektrotechninis kartonas. Dielektrinis kartonas yra aukštos kokybės elektros izoliacinė medžiaga, plačiai naudojama įvairiose elektrotechnikos srityse, įskaitant transformatorius, elektros variklius ir kitus įrenginius, kuriuose reikalinga efektyvi elektros izoliacija. Ši medžiaga yra pagaminta iš sulankstytų celuliozės pluoštų, kurie yra slėginio apdorojimo metu suspausti į standžius lakštus. Dielektrinis kartonas pasižymi puikiomis izoliacinėmis savybėmis, kurios apima didelį dielektrinį atsparumą ir mechaninę tvirtumą. Jis taip pat atsparus aukštai temperatūrai ir turi mažą vandens sugėrimo koeficientą, kuris užtikrina, kad medžiagos izoliacinės savybės išliktų stabilios net esant drėgmei. [18]


Kadangi yra tiriama skirtingų defektų skirtingos dalinių išlydžių dažninės charakteristikos, reikia atlikti bandymus, kuriuose yra imituojami skirtingi transformatoriaus defektai. Taip pat buvo padarytas bandinys skirtas imituoti sveiką transformatoriaus izoliaciją. (9 pav)



**8 pav.** Bandinys imituojantis sveiką izoliaciją.


Pirmasis mėginys buvo padarytas iš trijų 150x150x1 mm dydžio kartono lapų, kurie buvo tarpusavyje suklijuoti.

Antrasis mėginys buvo toks pat, kaip ir pirmasis, tik jo viduriniame sluoksnyje buvo padaryta 1mm skersmens skylė (10 pav.). Ertmėje tarp popierinės izoliacijos sluoksnių, veikiant pakankamai dideliame elektriniame laukui, susidaro daliniai išlydžiai. [19]




**9 pav.** Bandinys su 1mm skersmens defektu.

Abu mėginiai buvo patalpinti į įžemintą rezervuarą su seno tipo (GOST standarto) mineraline alyva. Iš viršutinės pusės buvo pridėtas 30cm ilgio ir 10cm skersmens plokščias elektrodas prie kurio buvo prijungtas aukštos įtampos šaltinis (11 pav).




**10 pav.** Bandymo modelis.

Kitas tiriamasis dalinių išlydžių tipas buvo koronavimas alyvoje. Šio tipo išlydžiai įvyksta aštriuose elektrinio lauko taškuose. Šio proceso metu susidaro dujos, kurios vėl yra sugeriamos alyvos taip ją užteršiant, ko pasėkoje atsiranda mažų laidžių dalelių. Dėl to alyvos dielektrinis stipris pamažu mažėja ir galiausiai gali privesti prie transformatoriaus gedimo [20]. Siekiant imituoti vainikinius išlydžius alyvoje, smailus elektrodas buvo panardintas į rezervuarą su alyva ir tarpas tarp elektrodo ir įžeminto korpuso paliktas 30mm (12 pav.) [21][22].



**11 pav.** Dalinių išlydžių alyvoje imitavimo bandymas.

Paskutinis imituojamas dalinių išlydžių šaltinis buvo paviršiniai daliniai išlydžiai. Tam panaudotas jau turimas 3mm storio bandinys be defekto viduje. Panardinus į rezervuarą su alyva prie jo buvo priglaustas aštrus elektrodas (13 pav.).



**12 pav.** Paviršinių dalinių išlydžių imitavimo bandymas.

Realus, paruoštas eksperimentinis modelis pateikiamas 14 paveiksle. Paveiksle matomas įžemintas bandymo rezervuaras. Jame jau yra supilta alyva ir bandinys panardintas į ją. Prie mėginio yra priglaustas elektrodas, o prie jo prijungtas įtampos šaltinis. Bandymo įtampai matuoti prie modelio yra prijungtas kilovoltmetras.



13 pav. Eksperimentinis modelis.

Atliekant šiuos bandymus yra tikimasi, jog elektrodui pasiekus tam tikrą įtampą mėginiuose prasidės daliniai išlydžiai, kuriuos bus galima išmatuoti.

## 2.2. Matavimo įranga.


Matavimai buvo atliekami aukšto dažnio metodu. Šis būdas yra paremtas išlydžio metu susidarantių aukšto dažnio impulsų ir jų galios matavimais. Šis metodas yra pripažįstamas ir dažnai naudojamas dėl savo tikslumo, jautrumo ir gebėjimo fiksuoti dalinius išlydžius be papildomų jutiklių montavimo įrenginyje ar jį atjungiant [9][4].

Eksperimento metu naudota DOBLE DFA300 (15pav.) įranga yra pažangi dalinių išlydžių matavimo sistema, kuri yra ypatingai efektyvi lokalizuojant PD šaltinius įvairiose elektros įrenginiuose. Šiuo įrenginiu galima matuoti 2 būdais:

- 1) radijo dažnių trikdžių (RFI) (angl. *radio frequency interference*);
- 2) akustinės emisijos (AE) (angl. *accustic emission*).

DOBLE DFA300 yra neinvazinis įrenginys, kuris turi patogų, rankinį dizainą su dideliu ekranu, leidžiantį lengvai naudotis ir atlikti matavimus. Įrenginys fiksuoja RFI iš įrangos su izoliacijos

problemomis. Įranga yra veiksminga atvirose skirstyklose, transformatoriuose, matavimo transformatoriuose ir kabelių galuose.[23] [24]



14 pav. Dalinių išlydžių matuoklis su priedais.

Pilnas matavimo įrangos komplektas susidaro iš:

- a) matavimo įranga DOBLE DFA300;
- b) jautrumą padidinančios antenos;
- c) bevielis sinchronizatorius skirtas sinchronizuoti matavimų dažnį su fonu;
- d) sinchronizatoriaus antena.

Prieš pradėdant RFI matavimus naudojant DOBLE DFA300, būtina atlikti aplinkos fono matavimą. Aplinkos fono matavimas leidžia nustatyti ir kompensuoti bet kokius potencialius trikdžius, kurie gali būti klaidingai interpretuojami kaip daliniai išlydžiai. Atliekant šį žingsnį taip pat yra: sukalibruojama įranga, nustatomos matavimo ribos, paklaidos ir mastelis. Taigi, fono matavimas yra būtinas norint užtikrinti teisingą ir patikimą dalinių išlydžių analizę bei išvengti klaidingų išvadų dėl neteisingai identifikuotų signalų.

### 2.3. Eksperimento atlikimas.


Prieš pradėdant matavimus yra sudaromas planas ir matavimų seka, kad išlaikyti sklandžią matavimo eigą ir aiškiai interpretuojamus rezultatus. Eksperimento planas pateikiamas 1 lentelėje.

2 lentelė. Eksperimento planas

Defekto tipas	Matavimo pozicijos	Bandomoji įtampa, kV		
		10	20	30
Paviršiniai daliniai išlydžiai	4	10	20	30
Vidiniai daliniai išlydžiai	4	10	20	30
Koronavimas alyvoje	4	10	20	30
Sveika izoliacija	4	10	20	30

Kadangi matavimo rezultatai turėtų būti skirtingi pagal matavimo poziciją patalpoje buvo pažymėtos 4 matavimo pozicijos su skirtingais atstumais[24].

Susidarius planą atliktas pirmasis matavimas skirtas fono charakteristikai gauti (16 pav.).



**15 pav.** Išmatuotas aplinkos fonas.

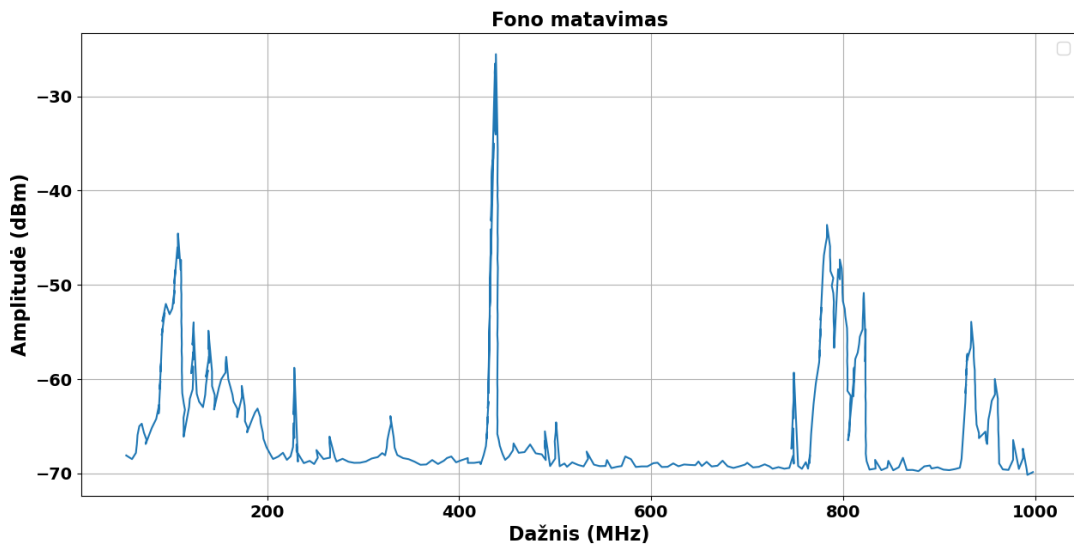
Išmatuotų dalinių išlydžių charakteristikų atvaizdavimui buvo naudojama PDViewer programinė įranga, skirta analizuoti ir tvarkyti duomenis, gautus iš DOBLE DFA300 matavimo įrangos. Ši įranga leidžia efektyviai peržiūrėti, redaguoti ir eksportuoti matavimo duomenis į įvairius ataskaitų formatus.

Iš 16 paveikslo matoma, jog laboratorijos fone fiksuojamas triukšmas. Tam tikruose dažniuose triukšmas yra žinomas:

- Tam tikrus pikus gali sukelti FM radijo stotys, kurios paprastai transliuoja 87,5-108 MHz dažniu.
- Nuo 470 MHz iki 790 MHz diapazone gali būti skaitmeninės antžeminės televizijos (DTT) signalų.
- Mobiliojo ryšio tinklai galėtų būti susiję su 800 MHz dažnių diapazono pikais, kadangi Lietuvoje ir Europoje 4G naudoja 800 MHz .
- Kiti galimi šaltiniai galėtų būti, kad net ir patalpų apšvietimas[25].

Pastebima, jog pateiktas išmatuoto fono paveikslas nėra patogus analizei atlikti, kadangi matuojamų dydžių ašys ir jų reikšmės yra sunkiai įskaitomos. Be to, vėliau darbe atliekamuose duomenų apdorojimo, analizės ir klasifikacijos etapuose yra reikalingi png. ir csv. duomenų formatai, o PDViewer programinės įrangos išeksportuoti matavimų grafikai yra pdf. formato. Dėl šių priežasčių buvo atliktas duomenų skaitmenizavimas.

Šiuo būdu kiekvienas pdf. grafikas buvo pakeičiamas csv. duomenų rinkiniu su grafiko taškų koordinatėmis. Kiekvienas duomenų rinkinys buvo naujai atvaizduojamas Python programine įranga (17 pav.).

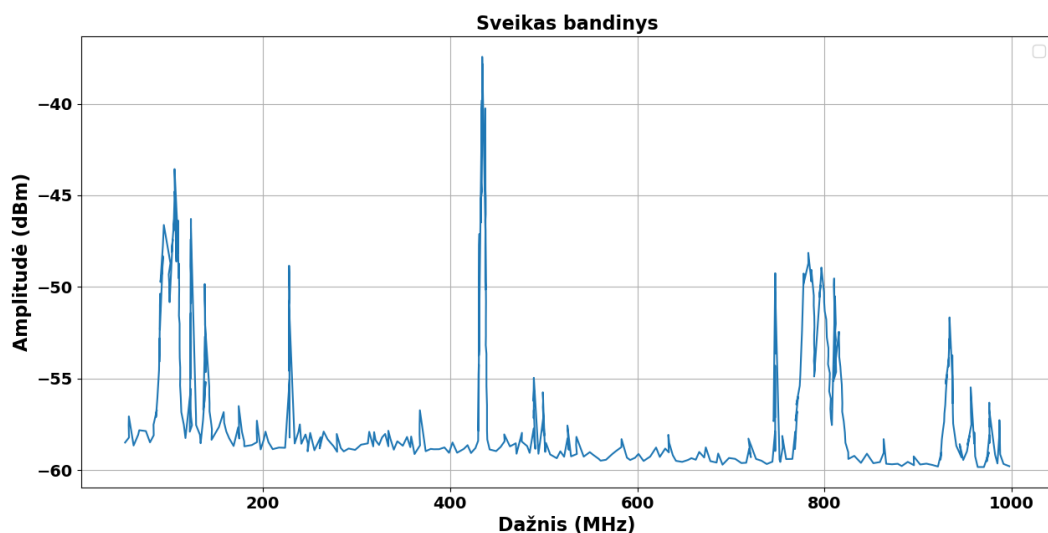


**16 pav.** Skaitmenizuotų duomenų atvaizdavimas.

Palyginus PDVierwer išksporuoto grafiką ir jo skaitmenizuotą atvaizdavimą yra matoma, jog juose didelių skirtumų nėra, todėl tolimesni matavimų rezultatai bus pateikiami šiuo būdu.


### 2.3.1 Sveiko bandinio matavimai.

Pirmiausia bandymai buvo atliekami su sveiku mėginiu. Paruošus schemą ir patalpinus mėginį į mineralinę alyvą į bandymo schemą buvo įjungtas 10 kV įtampos šaltinis ir išmatuotas impulsų signalas (17 pav.)

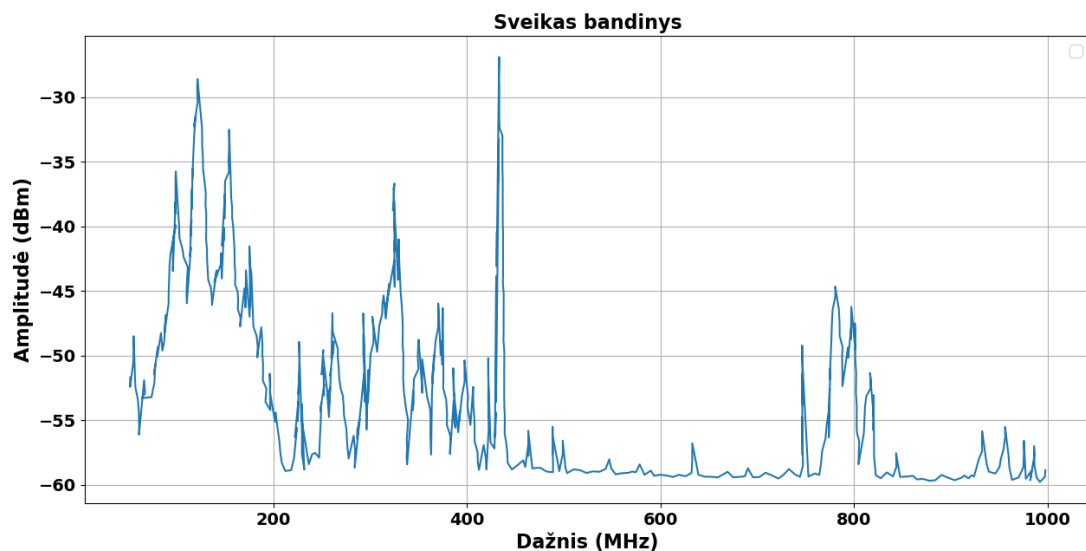


**17 pav.** Sveiko bandinio aukšto dažnio impulsų signalas veikiant 10 kV įtampa.

Iš paveikslo matyti, jog aukšto dažnio impulsų matavimo rezultatas sveiką mėginį veikiant 10 kV įtampa nepakito, kreivė yra lygi fonui.. Analogiški matavimai atliekami su 20 ir 30 kV bandymo įtampomis.



**18 pav.** Sveiko bandinio aukšto dažnio impulsų signalas veikiant 20 kV įtampa.




**19 pav.** Sveiko bandinio aukšto dažnio impulsų signalas veikiant 30 kV įtampa.

Atlikus matavimus, matoma, jog laboratorijos erdvėje atsirado aukšto dažnio impulsų. Jau pasiekus 20 kV įtampą matavimuose pasimatė pikų, o įtampai esant 30 kV jų galia dar labiau padidėjo. Didžiausi skirtumai išvelgiami dažnių juostoje nuo 110 MHz iki 430 MHz. Toliau nuo 430 MHz iki skalės galo kreivės susilygina, impulsai nebefiksuoja.


### 2.3.1. Paviršinių dalinių išlydžių matavimas.

Šiam bandymui taip pat buvo naudojamas sveikas bandinys, tik iš elektrodas plokščiu pagrindu buvo keičiamas į smailų. Smailus galas į izoliacijos paviršių turi iššaukti dalinių išlydžių reiškinį.

Žemiau yra pateikiami visi 3 matavimų grafikai ir jų palyginimas.

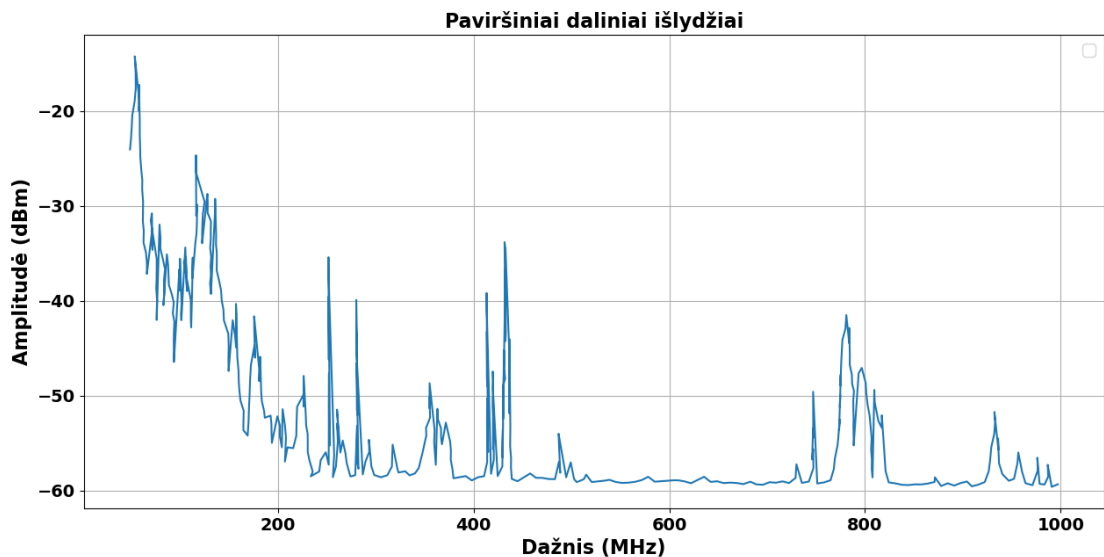


**20 pav.** Paviršinio defekto aukšto dažnio impulsų signalas veikiant 10 kV įtampa.



**21 pav.** Paviršinio defekto aukšto dažnio impulsų signalas veikiant 20 kV įtampa.

Veikiant 10 kV įtampa kaip ir sveiko bandinio su plokščio paviršiaus elektrodu, jokių pakitimu nepastebima. Įtampą pakėlus iki 20 kV, matavimuose pasimato labai aiškus, aštrus pikas 60 MHz dažnyje, o po jo impulsai per visą matuojamą dažninę juostą susilygina su fono matavimu.




**22 pav.** Paviršinio defekto aukšto dažnio impulsų signalas veikiant 30 kV įtampa.

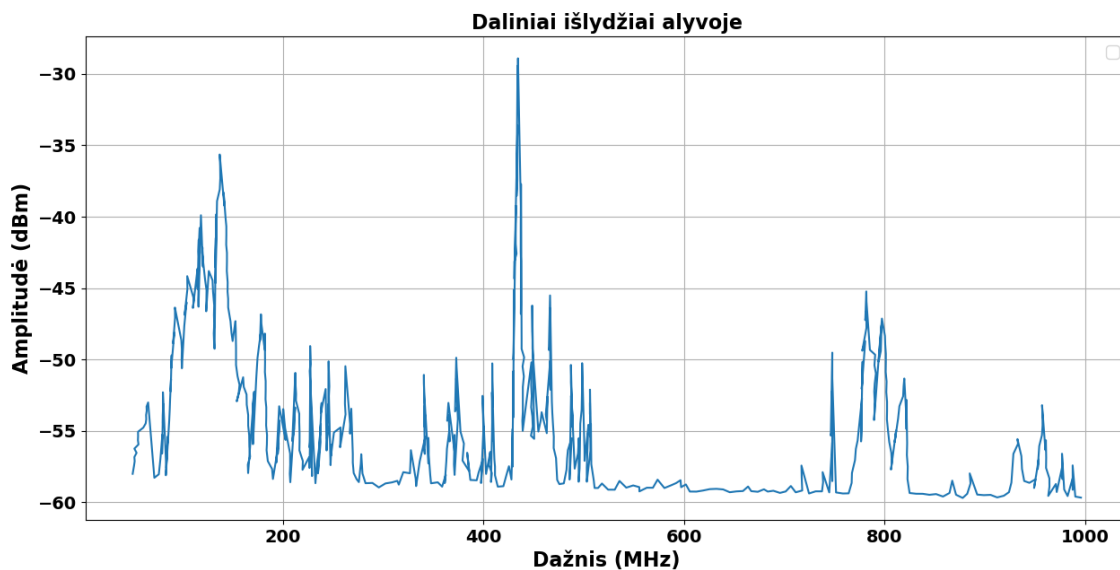
Bandymo įtampą padidinus iki 30 kV dažnių juostoje nuo 50 iki 420 MHz atsiranda stipresnių, silpnesnių impulsų, kur didžiausi pikai ir skirtumai tarp fono matomi 50-70 MHz ir 100–150 MHz dažniuose. Visą kitą didėjant dažniams nusistovi ir susilygina su fono galiomis.

### 2.3.2. Koronavimo alyvoje bandymas.


Pabaigus eksperimentą su mėginiu simuliuojančiu paviršinių dalinių išlydžiu šaltinį, buvo išimtas bandinys iš talpos, elektrodas aštriu galu atitrauktas 30 mm nuo įžeminto korpuso dugno ir veikiamas 3 lygių aukštąją įtampa. Šio tipo bandymų yra tikimasi sukelti dalinių išlydžių alyvoje reiškinį. Gauti rezultatai pateikiami 22 - 24 paveiksluose.



**23 pav.** Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 10 kV įtampa.




24 pav. Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 20 kV įtampa.



25 pav. Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 30 kV įtampa.

Kaip ir su ankstesniais defektais, pasiekus įtampą iki 10 kV jokių pakitimų per visą dažnio juostą nepastebima. Įtampą padidinus iki 20 kV atsiranda pikai, formą panašia į ankstesnių defektų, bet yra vienas skirtumas – taip pat stebimi nedidelės galios pikai 450-470 MHz dažnių diapazone.

Buvo nuspręstą įtampą kelti ir stebėti, kaip keisis impulsų pasiskirstymas ir jų galia. Įtampai esant 40 ir 50 kV jokių esminių pakitimų nebuvo fiksuojama, todėl grafikai nėra pridedami. Bet įtampą padidinus iki 60 kV (26 paveikslas) grafikas pasikeičia stipriai.




**26 pav.** Koronavimo alyvoje aukšto dažnio impulsų signalas veikiant 60 kV įtampa.

Žemesnėse įtampose pasireiškę signalų pikai sustiprėja ir atsiranda akivaizdus pikas, kuris kituose matavimuose žemesnėse įtampose ar su kitais bandiniais nepasireiškia ir yra 600 – 680 MHz diapazone.


### 2.3.3. Bandymai su 1mm vidiniu defektu.

Paskutinis atliekamas buvo plokštelės su 1mm skersmens defektu viduje bandymas. Tam buvo panaudota plokštelė pavaizduota 10 paveiksle ir elektrodas plokščiu pagrindu (11 paveikslas). Šiam bandymui, kaip ir kitiems, buvo naudojama trijų lygių įtampa.

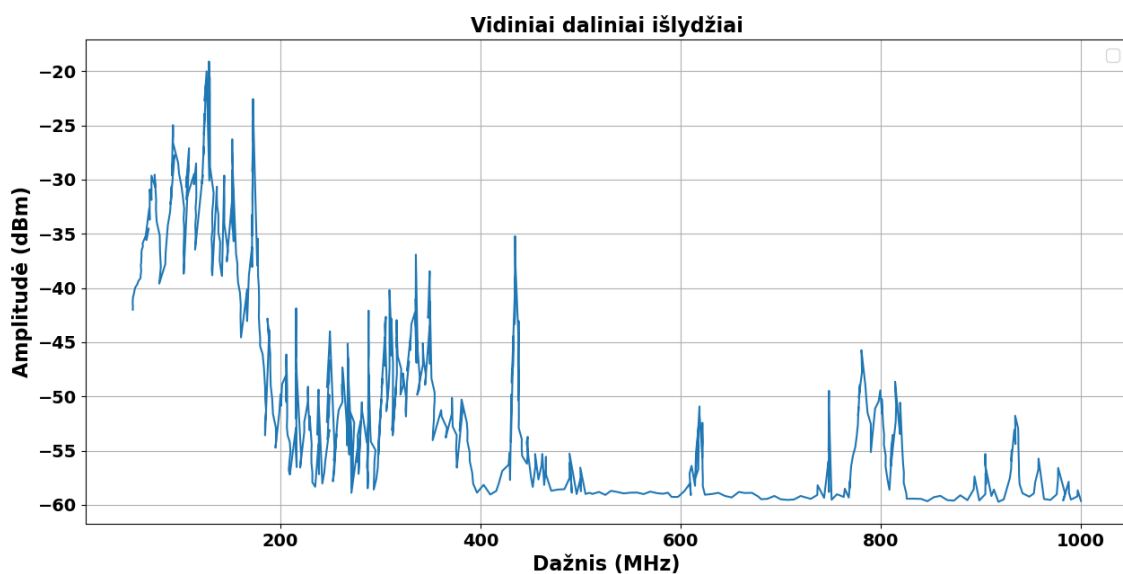


**27 pav.** Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 10 kV įtampa.

Šiame paveikslėlyje, kaip ir kituose bandymuose su 10 kV įtampa pasikeitimai nėra fiksuojami, visas matavimo diapazonas išlieka toks pat kaip ir fonas.



28 pav. Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 20 kV įtampa.



29 pav. Bandinio su 1mm vidiniu defektu aukšto dažnio impulsų signalas veikiant 30 kV įtampa.

Įtampą padidinus iki 20 kV matomi pikai atsiradę nuo 50 iki 430 MHz dažnių diapazone. Taip pat matyti mažos galios impulsai 600-650 ir 900 MHz dažniuose. O įtampai pasiekus 30 kV visi anksčiau registruoti pikai sustiprėja, išskyrus 900 MHz diapazone. Taip pat atsiranda pikai esantys 55-115 MHz dažnių diapazone.

### 2.3.4. Rezultatų palyginimas.

Atlikus grafikų palyginimą matoma, kad:

- Bandymuose labiausiai išsiskyrė koronavimas alyvoje, kuris pasižymėjo pikais esančiais 600-680 MHz dažnių diapazone ir jų pikinė galia siekė -40 dBm. Išlydžių reiškinys prasidėjo įtampai pasiekus 60 kV,
- Atliekant paviršinių dalinių išlydžių eksperimentą didžiausios galios pikas ir turintis didžiausią galių skirtumą su fonu stebimas 50-70 MHz diapazone. Kitų išskirtinimų nebuvo pastebėta.
- Bandinio su 1 mm skersmens defektu viduje dažninė charakteristika iš kitų matavimų išsiskyrė pikais esančiais charakteristikos pradžioje (55-115 MHz diapazone).
- Sveiką bandinį veikiant 30 kV įtampa nebuvo pastebėta išskirtinimų. Jis, taip pat kaip ir kiti bandiniai išskirdavo aukšto dažnio impulsus patenkančius į 110-170 ir 330-400 MHz diapazoną.
- Visų mėginių išskyrus išlydžių alyvoje impulsai po 450 MHz ribos nuslopavo ir susilygindavo su fonu stiprumu.

### 2.4. Apibendrinimas.

Atlikus eksperimentą galima apibendrinti rezultatus ir išskirti kiekvieno defekto impulso bruožą dažninėje charakteristikoje (2 lentelė).

**3 lentelė.** Apibendrinti dalinių išlydžių matavimų rezultatai

Eil. Nr.	Defekto tipas	Impulsų dažnio diapazonas, MHz	Galingiausio impulso dažnis, MHz	Impulso galia, dBm
1.	Koronavimas alyvoje	600-680	640	-40
2.	Paviršiniai daliniai išlydžiai	50-70	55	-13
3.	Vidiniai daliniai išlydžiai	55-115	92	-25

Pagal lentelę matoma, kad:

- 1) Atliekant bandymus su išlydžiais alyvoje buvo pastebėti aiškūs ir unikalūs -40 dBm galios impulsai 600-680 MHz dažniuose. Taip pat Doble instrukcijoje yra rašoma, jog dalinių išlydžių alyvoje reiškinį galima fiksuoti 600-800 MHz diapazonuose [25][26].
- 2) Paviršiniai daliniai išlydžiai pasižymi galingiausiais, -13 dBm galios, impulsais 50-70 MHz dažniuose [25][27].
- 3) Vidiniai daliniai išlydžiai 55-115 MHz dažniuose pasižymi -25 dBm galios impulsais ir negalingais -52 dBm impulsais 410-460, 600-650, 900 MHz dažniuose [28].
- 4) Atliekant eksperimentų duomenų analizę buvo pastebėti pasikartojantys pikai 110-170 ir 330-400 MHz diapazonuose. Daroma išvada, jog tai yra dėl pačio eksperimento susidarantys

triukšmai, kuriuos fiksuoja matavimo įranga ir tolimesniuose darbuose į juos nekreipti dėmesio.

Po atliktos duomenų analizės ir skirtingiems defektams nustatytas dalinių išlydžių dažnines charakteristikas bus atliekamas duomenų paruošimas, mašininio mokymosi algoritmo apmokymas (šiuo atveju pasirinktas CNN algoritmas) atpažinti skirtingus defektus ir jo tikslumo palyginimas su kitu algoritmu. Duomenų paruošimas (kartu su jau atliktais) vyks tokia seka.

- 1. Duomenų skaitmenizavimas.** Šis procesas yra reikalingas norint paversti realius išmatuotus signalus į skaitmeninę formą, kurią vėliau naudojant kompiuterį galima apdoroti ir atlikti tolesnę analizę ir modeliavimą.
- 2. Signalų filtravimas.** Jis yra reikalingas siekiant pašalinti triukšmą ir kitas nepageidaujamas komponentes iš duomenų. Tai padeda pagerinti duomenų kokybę ir užtikrinti, kad mokymo algoritmai galėtų efektyviau atpažinti modelius ir jų ypatybes [29].
- 3. Matavimų taškų sulyginimas.** Sulyginimas reikalingas siekiant užtikrinti, kad visi duomenų taškai būtų vienodo dydžio, kas yra svarbu tinklų mokymui, kad visi įvesties duomenys būtų nuoseklūs [30].
- 4. Etikečių sudarymas.** Jų sudarymas yra kritiškai svarbus algoritmo mokymosi procesui, nes tai apibrėžia tai, ką modelis turėtų mokytis atpažinti. Tai apima kiekvieno duomenų taško priskyrimą prie tam tikros klasės ar kategorijos [30].
- 5. Sintetinių duomenų sudarymas.** Tai daroma siekiant papildyti esamus duomenis, ypač kai originalių duomenų kiekis yra ribotas. Kadangi buvo atlikta 64 matavimai, tai nėra pakankama efektyviam neuroninio tinklo algoritmo apmokymui ir testavimui. Todėl atsiranda poreikis dirbtinai padidinti duomenų skaičių [31].

Kitame skyriuje bus trumpai aptarta kiekvieno metodo panaudojimas paruošiant duomenis algoritmų apmokymui. Pateikiami pakeistų duomenų grafikai ir jų paaishkinimai.

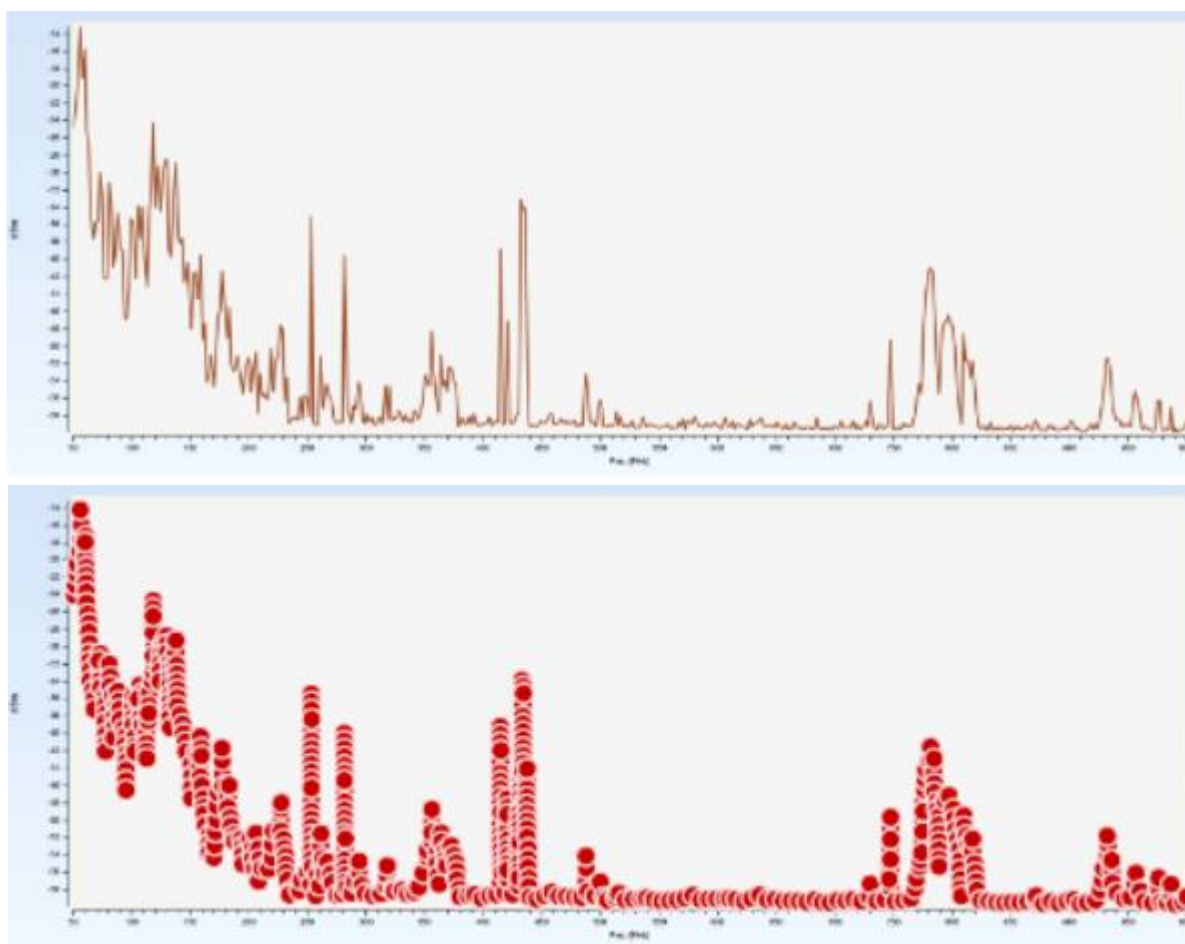
### 3. Duomenų paruošimas.

Duomenų paruošimas yra labai svarbus mašininio mokymosi procese, nes kokybiški duomenys tiesiogiai įtakoja modelio našumą. Netinkamai paruošti duomenys gali sumažinti modelio tikslumą ir padaryti jį neefektyvų, kadangi klaidingą informaciją gali vertinti kaip faktą ir atvirkščiai. Dažnai teigiama, kad iki 80% duomenų analizės laiko yra skiriama būtent duomenų paruošimui. Šis etapas yra būtinas norint pasiekti aukštą modelių našumą ir tikslumą [32].

#### 3.1. Duomenų skaitmenizavimas.

Pirmasis duomenų paruošimo žingsnis buvo jų skaitmenizavimas. Šio žingsnio poreikis atsirado, nes naudojant Doble programinę įrangą PDViewer matavimo duomenis galima išeksportuoti tiktais vaizdinių duomenų formatu. Skaitmenizavimas šiuos duomenis konvertuoja į naudingesnę ir patogesnę formą, kuria galima manipuluoti. Skaitmenizuotus duomenis galima filtruoti, panaikinti ar įterpti reikšmes.

Šiame darbe duomenų skaitmenizavimui buvo naudojamas internetinis įrankis „WebPlotDigitizer“, kuris yra skirtas automatizuotai atpažinti duomenis iš grafikų ar formų (31 pav.).



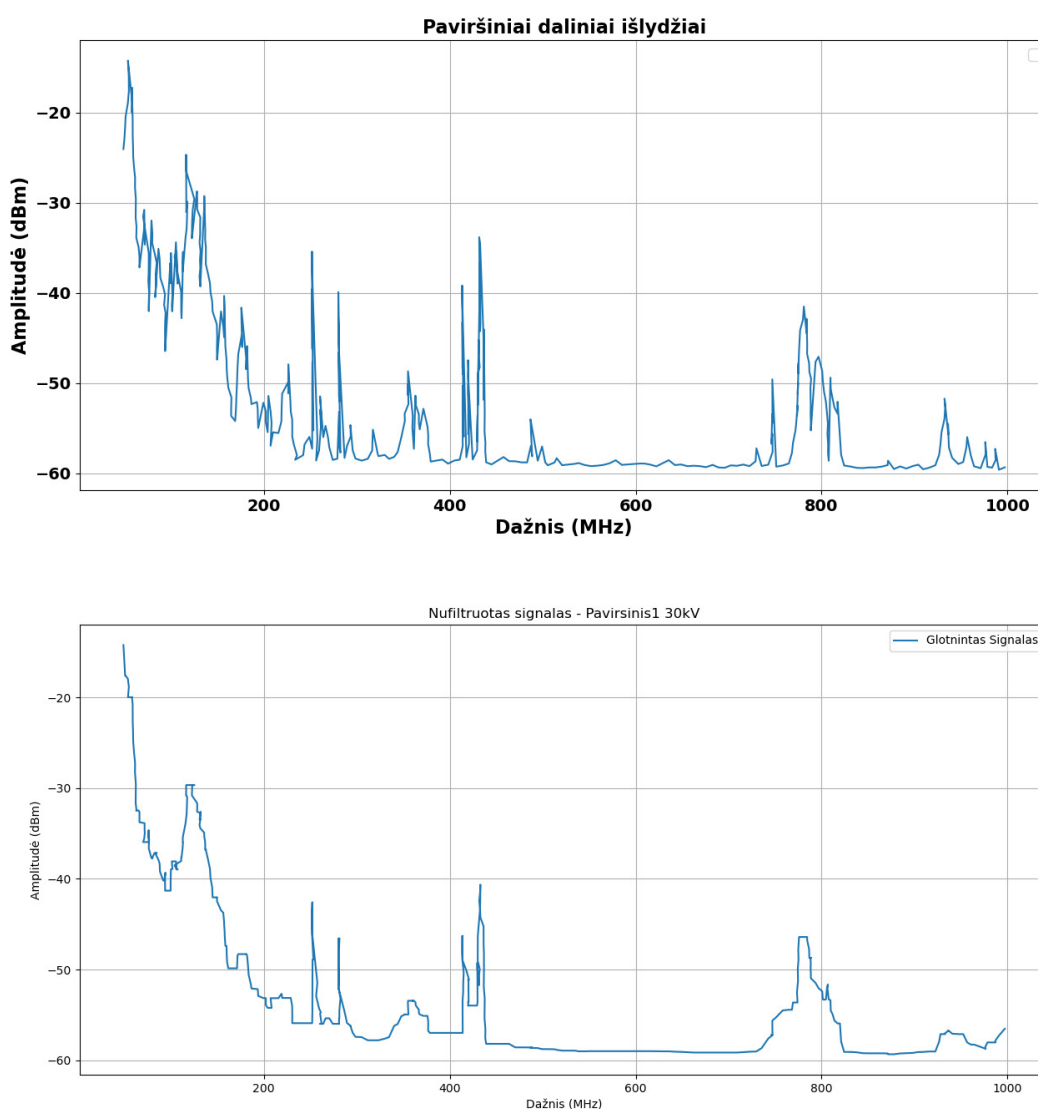
30 pav. Duomenų skaitmenizavimas įrankiu „WebPlotDigitizer“.

Įkėlus duomenų pdf. failą, o programa leidžia nustatyti koordinačių sistemą ir taškus grafike, kuriuos reikia digitalizuoti. Tada WebPlotDigitizer analizuoja grafiką ir ištraukia duomenų taškų koordinates, kurios gali būti eksportuotos į įvairius duomenų formatus tolesniam naudojimui.

### 3.2. Duomenų filtravimas.

Sekantis duomenų paruošimo žingsnis buvo jų filtravimas. Duomenų filtravimas yra svarbus procesas duomenų analizėje, ypač kai dirbama su signalais. Tai leidžia pašalinti nepageidaujamą triukšmą arba duomenų iškraipymus, gerinant duomenų. Tinkamai filtruoti duomenys leidžia efektyviau taikyti tolesnes analizės ir modeliavimo procedūras. Signalų filtravimas buvo atliekamas Python aplinkoje ir pasirinktas metodas – medianos filtras. Filtravimo kodas yra pateikiamas priede nr. 1.

Medianos filtras yra signalų apdorojimo įrankis, skirtas pašalinti triukšmą iš duomenų rinkinių. Šis filtras veikia taip, kad kiekvienam duomenų taškui priskiria medianos reikšmę iš tam tikro langelio, kuris apima šį tašką ir jo kaimynus. Dėl šios savybės medianos filtras yra ypač efektyvus mažinant atsitiktinį triukšmą ir išsaugant signalo briaunas, kas yra svarbu, norint išlaikyti svarbią informaciją duomenyse. 32 paveiksle yra pateiktas skaitmenizuotas matavimo grafikas prieš ir filtravimo.



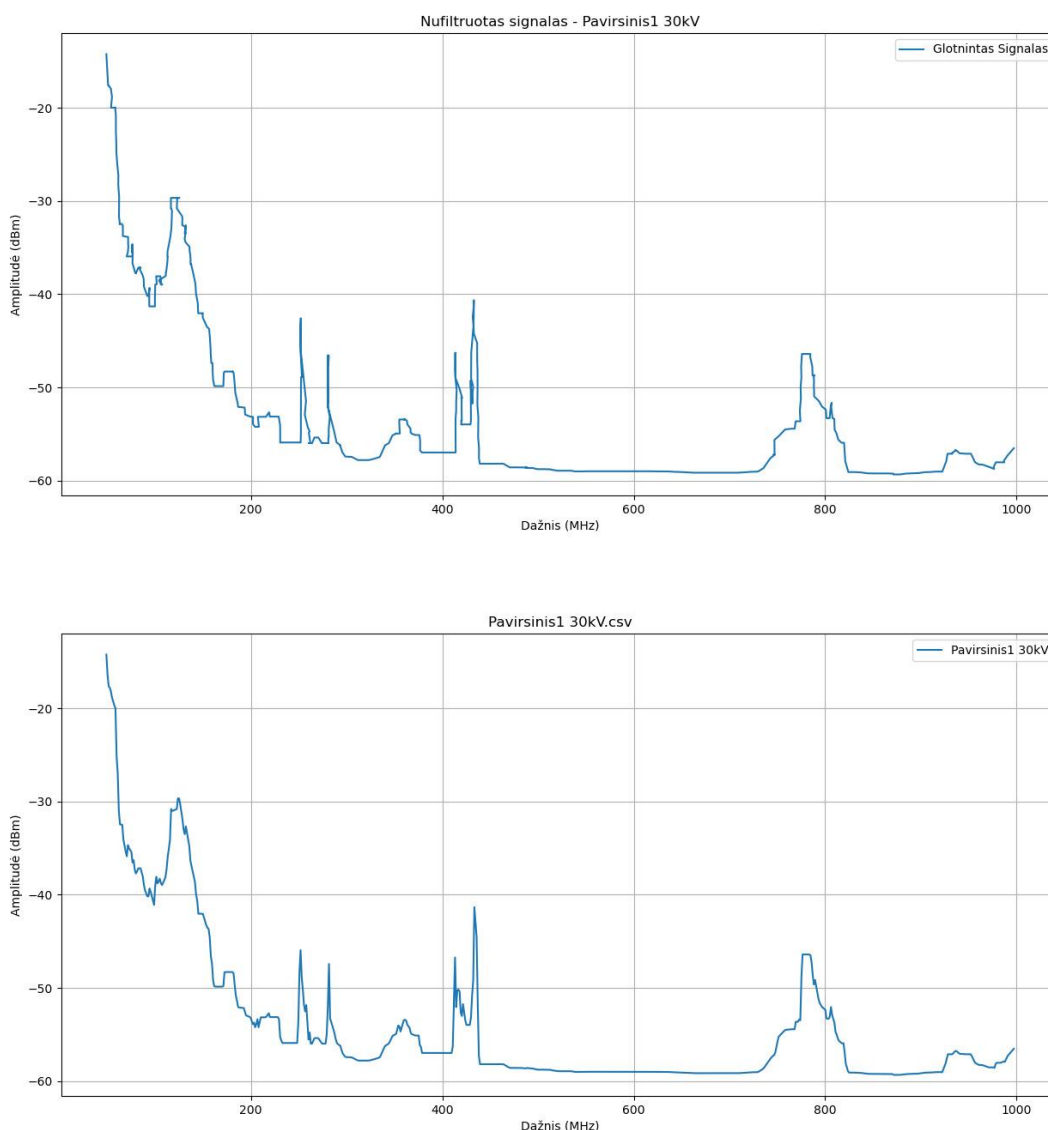
**31 pav.** Matavimo duomenys prieš ir po filtravimo.

32 paveiksle yra matoma, jog matavimo metu susiformavę triukšmai yra eliminuoti, o pagrindiniai bruožai – išsaugoti, paviršinių dalinių išlydžių pikas esantis dažninės charakteristikos pradžioje yra minimaliai pakitęs. Kiti pikai arba visiškai nufiltruoti, arba jų reikšmės sumažėjusios per 3 – 5 dBm.

### 3.3. Matavimų taškų sulyginimas ir etikečių suteikimas.

Dirbant su neuroniniais tinklais ir kitais mokymosi algoritmais yra svarbu aiškūs ir tvarkingi duomenys, jog mokymosi procese į algoritmus neįsiveltų klaidos ir duomenys būtų tinkamai interpretuojami.

Tuo metu esančiuose duomenų rinkiniuose grafikų taškų kiekis buvo įvairus: mažiausiai 409 ir daugiausia – 1261. Tam, kad jie visi būtų vienodi, buvo pasinaudota taškų interpoliacijos metodu, kuris kiekviename duomenų faile bet koki taškų skaičių pakeitė į 800 taškus išlaikant arba minimaliai pakeičiant grafiko formą (33 pav.). Jo kodas yra pateiktas priede nr. 2.



**32 pav.** Matavimo taškų sulyginimas naudojant interpoliaciją.

Po atlikto sulyginimo matomas minimalus grafiko pakitimas, kuris neturės neigiamos įtakos klasifikacijai.

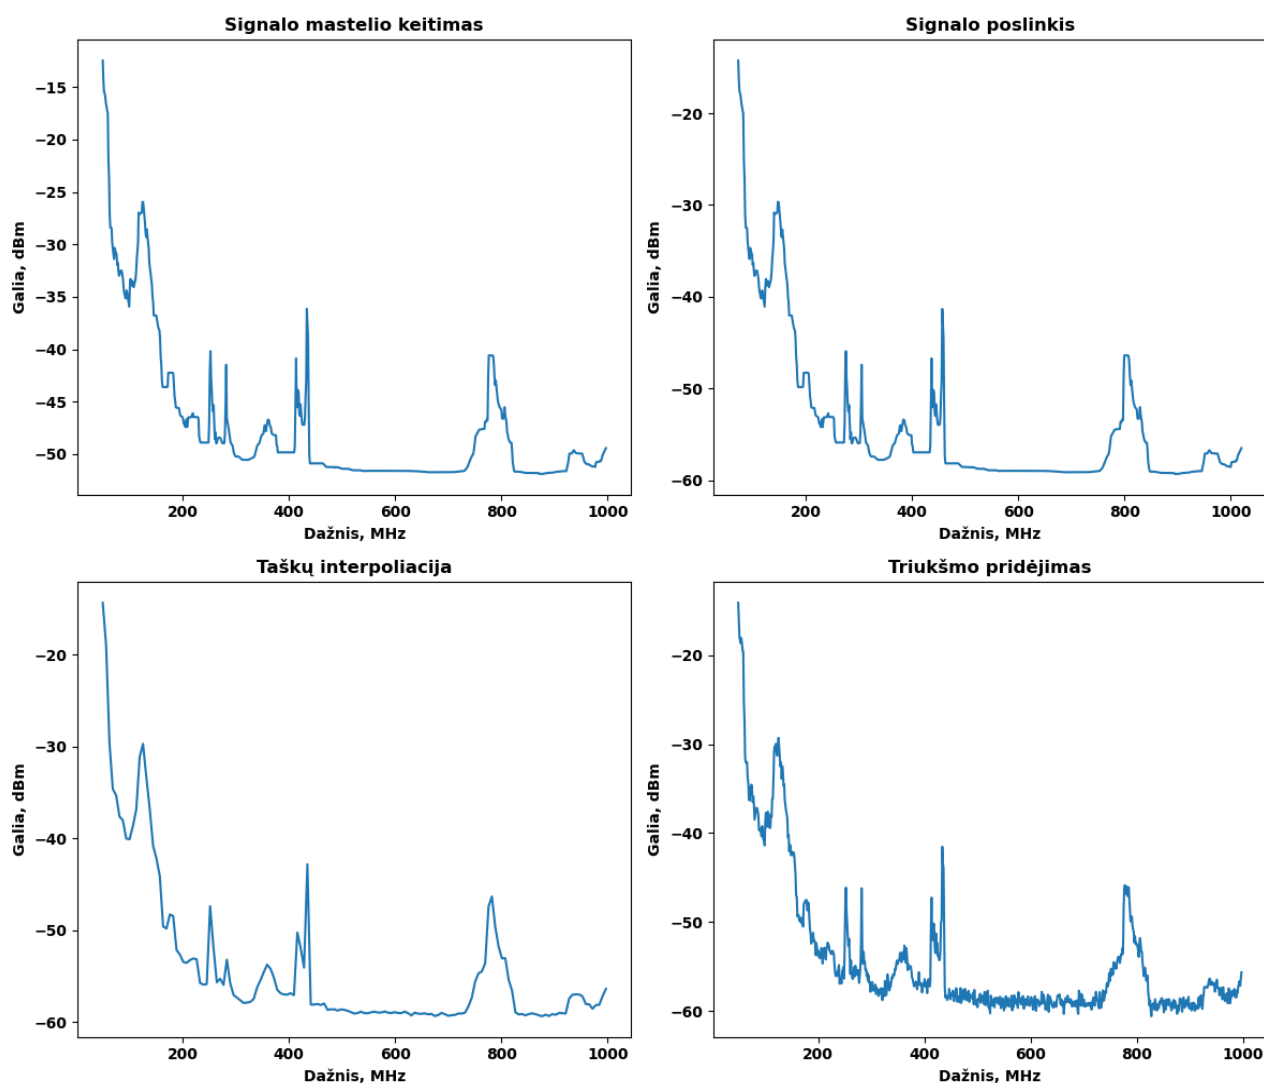
Tuo pačiu naujiems duomenims yra priskiriamos etiketės, kurios klasifikatoriui bus nuoroda, ko yra mokomasi ir ką turėtų turi nuspėti.

### 3.4. Sintetinių duomenų sudarymas.

Kadangi buvo atlikta 64 matavimai ir ne visuose matavimuose pasireiškė dalinių išlydžių reiškinys, buvo nuspręsta naudoti sintetinius duomenis, kurie sugeneruoti naudojant realius matavimus.

Sintetinių duomenų kūrimas yra metodika, kuri padeda pagerinti mašininio mokymosi modelių mokymą ir vertinimą, ypač kuomet trūksta realių duomenų ar jie yra riboti. Šis metodas leidžia išplėsti duomenų rinkinius, pagerinti modelio generalizavimo galimybes ir sumažinti permokymo riziką [34].

Šiame darbe buvo naudoti 4 skirtingi sintetinių duomenų generavimo metodai, kuriais buvo gautą po 50 kiekvieno defekto tipo duomenų. Bendras sintetinių duomenų skaičius yra 600 vnt. 34 paveiksle yra pateikta kiekvieno metodo pagalba sugeneruotas grafiko pavyzdys.



33 pav. Matavimo taškų sulginimas naudojant interpoliaciją.

- **Triukšmo pridėjimas.** Triukšmo pridėjimas yra metodas, skirtas modeliui padėti išmokti atpažinti signalą, nepaisant išorinio triukšmo. Įdedant atsitiktinį triukšmą į Y reikšmes, imituojama tikrovė, kurioje duomenys dažnai būna iškraipyti dėl įvairių veiksnių. Šiuo atveju buvo pridodamas nedidelis triukšmas, kad stipriai nepaveiktų signalo charakteristikos.

- **Signalų poslinkis.** Naudojant signalo poslinkį buvo imituojamas signalo pasikeitimas  $X$  ašies atžvilgiu. Taip signalų poslinkio metodas padeda modeliui išmokti atpažinti svarbias ypatybes nepriklausomai nuo jų pozicijos duomenų rinkinyje.
- **Signalų mastelio keitimas.** Mastelio keitimas yra panašus metodas į signalų poslinkį, tik šiuo atveju yra keičiamos  $Y$  reikšmės. Mastelio keitimą galima įvardinti kaip duomenų generavimo metodą su tokios pat formos bet skirtingų amplitudžių signalais.
- **Duomenų interpoliacija.** Šis metodas jau buvo naudotas ankstesniame duomenų paruošimo etape. Šiuo atveju duomenų interpoliacija buvo naudojama tarpinių taškų pridėjimui, taip nežymiai pakeičiant signalo formą.

Atlikus visus duomenų paruošimo žingsnius bus atliekamas klasifikatoriaus apmokymas ir testavimas naudojant sintetinius duomenis. Kaip buvo minėta anksčiau, šiame darbe pasirinktas gilus mokymo algoritmas CNN.

## 4. Duomenų klasifikavimas naudojant mašininį mokymąsi

Dėl pirmoje dalyje aptarto aukšto tikslumo, šiame darbe, duomenų analizei ir klasifikavimui buvo pasirinktas giluminio mokymosi tinklas, kuris atlieka vaizdų klasifikavimą, naudojant konvoliucinių neuroninių tinklų struktūrą. Taip pat buvo atliktas palyginimas su – atsitiktinis miškas (angl. *random forest*) klasifikatoriumi.

### 4.1. Defekto tipo nustatymas naudojant CNN

Konvoliucinio neuroninio tinklo modelis apima duomenų generavimą, duomenų tikrinimo funkciją, modelio apmokymą ir vertinimą, o pats modelio branduolys, atsakingas už modelio apmokymą, realizuotas naudojant „TensorFlow“ ir „Keras“ bibliotekas, kur pirmosios paskirtis yra modelio aprašymo palengvinimas, o antroji atlieka skaičiavimus ir patį modelio apmokymą. Modeliui apmokyti ir testuoti buvo naudojama 600 paveikslų, kurie buvo padalinti į 480 ir 120 vnt. atitinkamai apmokyti ir testuoti.

```
# CNN modelis su Dropout sluoksniais
model = Sequential([
    Input(shape=(512, 512, 3)),
    Conv2D(32, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),
    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D(2, 2),
    Flatten(),
    Dense(256, activation='relu'),
    Dropout(0.2),
    Dense(len(data['class'].unique()), activation='softmax')
```

34 pav. CNN modelio struktūra.

Pirmasis sluoksnis yra įvesties, kuris nustato įeinančių duomenų formą, kur šiuo atveju yra 512x512 dydžio dalinių išlydžių matavimų paveikslai, o skaičius 3, nurodo, jog tai yra spalvotas paveikslas.

Po įvesties sluoksnio seka trys vienas po kito parašyti konvoliuciniai ir maksimalaus telkimo sluoksniai. Konvoliuciniai sluoksniai pirmasis konvoliucinis tinklas turi 32 filtrus, kur kiekvieno filtro dydis yra 3x3. Šie filtrai slenkasi per paveikslo pikselius taip išgaunant tam tikras ypatybes. Šie sluoksniai naudoja ReLU (angl. *Rectified Linear Unit*) aktyvavimo funkciją, kuri padeda modeliams įvesti nelinearumo, kas yra būtina norint išmokti sudėtingas ir nestandartines funkcijas ir prisideda prie greitesnio ir efektyvesnio tinklų apmokymo.

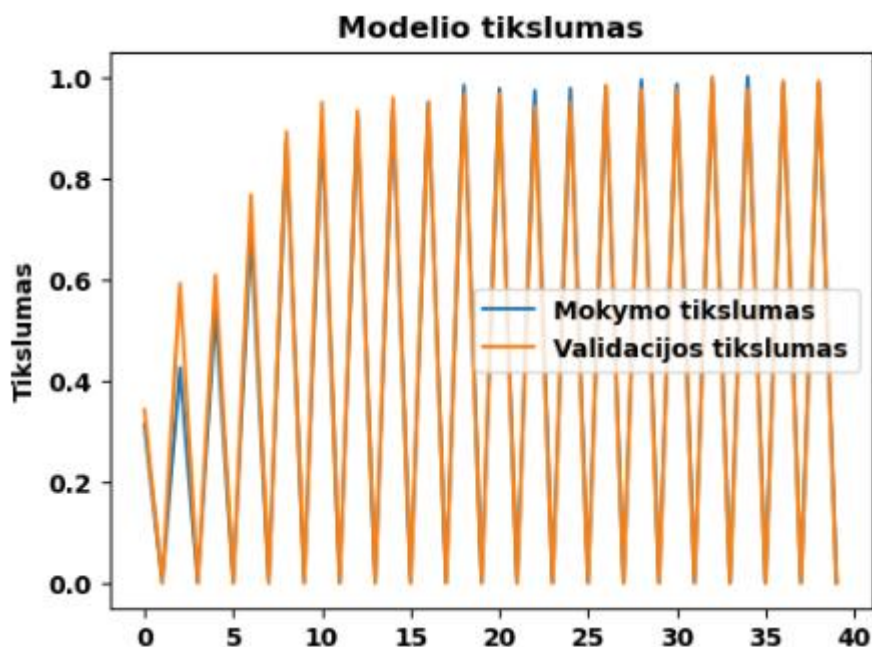
Maksimalaus telkimo sluoksnis sumažina kiekvieno ankstesnio sluoksnio filtro matmenis perimant didžiausią reikšmę. (2, 2) rodo, kad 2x2 langelis bus naudojamas kiekvieno filtro reikšmių sumažinimui. Tai sumažina duomenų matmenis, išlaikant svarbiausias ypatybes.

Gautos savybės išlyginimo sluoksnyje yra paverčiamos į vektorių, kuris gali būti perduotas į sekantį, tankųjį sluoksnį. Tai paprastas sluoksnis su, šiuo atveju 256 neuronais, kuriame kiekvienas neuronas gauna įvestį iš visų ankstesnio sluoksnio neuronų. Ši dalis atlieka vaizdų klasifikaciją pagal konvoliucinių sluoksnių išvestį. Dropout sluoksnis kiekvienos treniruotės metu atsitiktinai "atjungia"

20% neuronų šiame sluoksnyje, padėdamas modelį generalizuoti geriau, taip sumažindamas modelio persimokymo riziką.

Paskutinis, išvesties sluoksnis pateikia galutines klasių tikimybes.

Modelyje buvo naudojama 40 mokymo ir validavimo epochų. Aukštas tikslumas, 0,92 jau buvo pasiektas 11 epochoje (36 pav.).



35 pav. Modelio mokymosi rezultatai

19 epochoje modelio tikslumas buvo 0,98. Sekančiose dalyse modelio tikslumas per 0,015 dalį pamažėdavo ir padidėdavo. Galutinis jo tikslumas pateikiamas 3 lentelėje.

4 lentelė. CNN algoritmo tikslumo vertinimas

Defektas	Tikslumas	Atitiktis	F1-balas	Palaikymas
Alyva	1,00	1,00	1,00	43
Paviršiniai	1,00	0,94	0,97	36
Vidiniai	0,95	1,00	0,98	41
<hr/>				
Tikslumas			0,98	120
Vidurkis per visas klases.	0,98	0,98	0,98	120
Pasvertas vidurkis	0,98	0,98	0,98	120

Bendras tikslumas: 0.9833333333333333

Rezultatai parodo, kad visos prognozės, kuriose modelis prognozavo paviršinius dalinius išlydžius ir koronavimą alyvoje, buvo tesingos. Vidinius dalinius išlydžius nustatė 95% tikslumu. Defektų prognozėms atlikti atitinkamai buvo parinkta po 43, 36 ir 41 charakteristikų paveikslus.

Vidurkis per visas klases parodo bendrą modelio veikimą be atsižvelgimo į klasių dydžius, o pasvertas vidurkis parodo bendrą modelio veikimą atsižvelgiant į klasių dydžius. Abejais atvejais jų dydis yra 0,98.

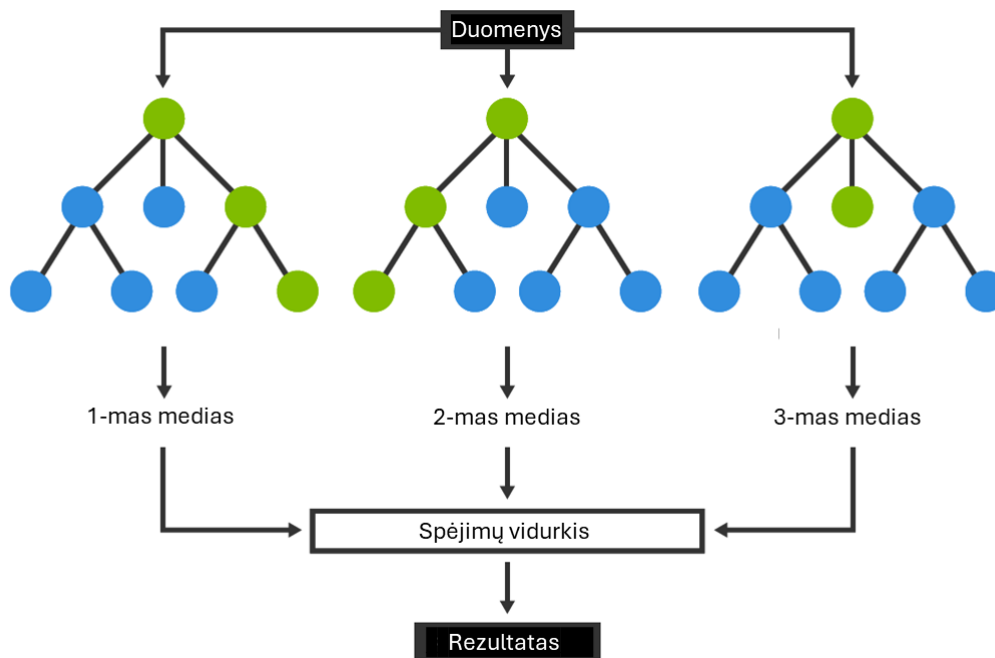
Verta pastebėti, jog atliekant modelio apmokymą, dėl neaiškių priežasčių, praleisdavo kas antrą epochą. Tai puikiai matosi 36 paveiksle. Norint to išvengti buvo atliktas bibliotekų atnaujinimas, perrašoma programinė įranga ir atliekami įvairūs kodo pakeitimai tokie kaip `batch_size`, keitimas. Visos atliktos priemonės norimų rezultatų nedavė.

Neatsižvelgiant į tai, galima teigti, kad:

- modelis labai gerai klasifikuoja vaizdus su aukštu tikslumu ir atgaminimu visoms trimis klasėms;
- didelis F1 balas rodo, kad modelis yra subalansuotas tiek tikslumo, tiek atitikties požiūriu;
- bendras tikslumas, kuris yra 0,98 rodo, kad modelis, šiuo atveju, yra labai patikimas klasifikuojant testinius pavyzdžius.

#### 4.2. CNN palyginimas su atsitiktinio miško klasifikatoriumi

Kaip buvo minėta anksčiau, CNN modelio palyginimas buvo atliekamas su atsitiktinio miško klasifikatoriumi. Tai yra prižiūrimo mokymosi algoritmas, kuris sukuria sprendimų medžių rinkinį, siekdamas pateikti tikslią prognozę. Algoritmo struktūrinė schema pavaizduota 36 paveiksle.



36 pav. Atsitiktinio miško struktūrinė schema

Sprendimų medis yra algoritmas, naudojamas duomenims klasifikuoti. Galima įsivaizduoti jį kaip srautų diagramą, kuri aiškiai nurodo kelią iki sprendimo arba rezultato. Kiekvienas medis prasideda

viename taške ir šakojasi į dvi ar daugiau kryptių, kiekviena šaka siūlo skirtingus galimus rezultatus [35].

Atsitiktinis miškas sukuria kelis sprendimų medžius, kurie sujungiami siekiant tikslesnės prognozės. Logika yra ta, kad keli nesusiję modeliai (individualūs sprendimų medžiai) veikia daug geriau kaip grupė nei vieni. Klasifikacijai kiekvienas medis duoda savo klasifikaciją arba "balsą". Miškas pasirenka klasifikaciją, kuri turi daugiausiai balsų.

Šiame modelyje taip pat buvo naudojama 600 duomenų failų, kurie buvo perskirti į 80 ir 20 procentų atitinkamai mokymui ir testavimui. Klasifikatoriaus rezultatai pateikiami 5 lentelėje.

**5 lentelė.** Atsitiktinio miško algoritmo tikslumo vertinimas

Defektas	Tikslumas	Atitiktis	F1-balas	Palaikymas
Alyva	0,86	0,87	0,87	25531
Paviršiniai	0,83	0,83	0,83	25531
Vidiniai	0,82	0,81	0,81	25531
Tikslumas			0,84	76593
Vidurkis per visas klases.	0,84	0,84	0,84	76593
Pasvertas vidurkis	0,84	0,84	0,84	76593

Bendras tikslumas: 0.8358466178371392

Pagal rezultatus yra matoma, kad atsitiktinio miško tikslumas yra mažesnis nei konvoliucinio neuronų tinklo. Daliniai išlydžiai alyvoje buvo spėjama aukščiausiu, 86% tikslumu, paviršiniai – 83, o vidiniai daliniai išlydžiai – 82% tikslumu. Mokymo ir testavimo palaikymo skaičiai yra žymiai didesni, nei CNN, todėl nes šis algoritmas naudojo csv. failus su grafikų taškų koordinatėmis, kuriuos apdorojo ir pagal tai darė sprendimus.

Bendras modelio tikslumas yra 83,59%.

### 4.3. Rezultatų apibendrinimas

Atlikus defektų klasifikavimo tyrimą naudojant konvoliucinius neuroninius tinklus (CNN) ir atsitiktinio miško klasifikatorių, rezultatai parodė, kad CNN modelis pasiekė aukštesnę tikslumą ir efektyvumą.

CNN modelis, kuris buvo mokytas su 600 dalinių išlydžių matavimų grafikais, pasiekė 98% bendrą tikslumą, lyginant su atsitiktinio miško klasifikatoriaus 84% tikslumu. CNN modelis tiksliai klasifikavo alyvos, paviršinius ir vidinius defektus atitinkamai su 1,00, 0,97 ir 0,98 F1 balais, rodant aukštą modelio subalansuotumą tarp tikslumo ir atgaminimo. Tuo tarpu atsitiktinio miško klasifikatoriaus pasiekė 0,87, 0,83 ir 0,81 F1 balus atitinkamai tiems patiems defektų tipams, rodant žemesnę tikslumą, ypač vidinių defektų nustatyme.

## Išvados

Išanalizavus literatūra nustatyta, kad:

1. Daliniai išlydžiai atsiradę dėl izoliacijos pablogėjimo yra dažna ir rimta problema tiek srovės transformatoriuose, tiek kituose elektros energetikos sistemos įrenginiuose. Pagrindė jų būna 2 tipai - vidiniai ir paviršiniai, kur vidiniai formuojasi izoliacijos viduje, dėl senėjimo, užterštumo, netolygumo, o paviršiniai ant izoliacijos paviršiaus, taip pat dėl pažeidimų, užterštumų ir atmosferinio poveikio.
2. Daliniams išlydžiams matuoti yra sukurtas ne vienas metodas, bet ultra aukšto dažnio metodas yra veiksmingesnis, dėl didelio jautrumo.
3. Dirbtinis intelektas yra efektyvi priemonė vertinant dalinių išlydžių matavimus ir vertinant defekto tipą. Literatūroje ypač gerus rezultatus parodė konvoliucinis neuronų tinklas ir kitų algoritmų kombinacijos su juo.

Atliekant eksperimentinį tyrimą nustatyta, kad skirtingi defektai turi skirtingas išmatuotas dažnines charakteristikas, kuriuose labiausiai išsiskyrė dalinių išlydžių alyvoje reiškinys generuojantis stiprius pikus 600-680 MHz dažnių diapazone. Daliniai išlydžiai taip pat pasireiškė ir mėginuose su vidiniu ir paviršiniu defektu. Jų charakteristikų išskirtinimai atitinkamai buvo fiksuojami 55-155 ir 50-70 MHz dažnių diapazone.

Panaudojus konvoliucinį neuroninį tinklą defektų klasifikavimo užduotyje buvo gauti aukščiausi rezultatai, kur koronavimas alyvoje ir paviršiniai daliniai išlydžiai nustatyti 100% tikslumu, o vidiniai daliniai išlydžiai, kiek mažesniu – 95% tikslumu. To buvo galima tikėtis, nes aukščiausiu balu spėtų defektų charakteristikos labiausiai išsiskyrė iš matavimų.

Palyginus konvoliucinį neuroninį tinklą su atsitiktiniu mišku nustatyta, jog jo klasifikacijos rezultatai buvo prastesni – atitinkamas 86, 83 ir 82 procentų tikslumas, bet panašias tendencijas, kaip CNN modelyje galima išvelgti. Koronavimas alyvoje buvo geriausiai spėjamas, o vidinių dalinių išlydžių klasifikacija pasiekė mažiausią balą.

## Literatūros sąrašas

- 1) V. S. Deolankar, W. Z. Gandhare, „Partial Discharge Analysis in High Voltage Current Transformers“, International Refereed Journal of Engineering and Science (IRJES), vol. 6, pp. 24-30, 2017.
- 2) C. Dan and R. Morar, „Partial discharge measurements on 110kV current transformers. Setting the control value. Case study“, In Innovative Ideas in Science 2016, 2017.
- 3) Tshisikhawe, F., Lencwe, M. J., Chowdhury, S. P., „Design, Manufacturing and Testing of a Standard Current Transformer“. IEEE PES/IAS PowerAfrica pp. 414-419, 2019.
- 4) Upton, D.W., Mistry, K.K., Mather, P.J., Zaharis, Z.D., Atkinson, R.C., Tachtatzis, C., Lazaridis, P.I. A Review of Techniques for RSS-Based Radiometric Partial Discharge Localization. Sensors 2021.
- 5) HVPD, „What is Partial Discharge (PD)?“ [interaktyvus]. [žiūrėta 2023-05-03]. Prieiga per: <https://www.hvpd.co.uk/pd/>
- 6) Partial Discharge Testing Equipment; Comparisons [interaktyvus]. [žiūrėta 2023-05-01]. Prieiga per: <https://www.linkedin.com/pulse/partial-discharge-testing-equipment-comparisons-ryan-mefiardhi>
- 7) Patrick Janus, „Acoustic Emission Properties of Partial Discharges in the time-domain and their applications“, KTH Electrical Engineering, XR-EE-ETK 2012:004, 2012.
- 8) Testguy, Transformer Dissolved Gas Content, Types and Properties [interaktyvus]. [žiūrėta 2023-06-01]. Prieiga per: <https://wiki.testguy.net/t/transformer-dissolved-gas-content-types-and-properties/248>
- 9) Wong, J. K. R., Illias, H. A., Bakar, A. H. A., & Mokhlis, H., „Partial discharge classifications: Review of recent progress. Measurement“, 2015.
- 10) Chen, P.-H., Chen, H.-C., Liu, A., & Chen, L.-M., „Pattern Recognition for Partial Discharge Diagnosis of Power Transformer“. IEEE Transactions on Dielectrics and Electrical Insulation, 20(5), 1675-1682, 2013.
- 11) Bernal-Mor, J. C., & Sánchez-García, J. A. (2017). Wavelet denoising of partial discharge signals and their pattern classification using artificial neural networks and support vector machines. DYNA, 84(203), 240-248. DOI: <https://doi.org/10.15446/dyna.v84n203.63745>.
- 12) Barrios, S., Buldain, D., Comech, M. P., Gilbert, I., & Orue, I. Partial Discharge Classification Using Deep Learning Methods—Survey of Recent Progress. Sensors, 19(13), 2927, 2019.
- 13) Jiuxiang Gu, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai, Tsuhan Chen, „Recent advances in convolutional neural networks, Pattern Recognition“ Volume 77, pp. 354-377, 2018.
- 14) S. Kiranyaz, T. Ince, O. Abdeljaber, O. Avci and M. Gabbouj, "1-D Convolutional Neural Networks for Signal Processing Applications," IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Brighton, UK, 2019, pp. 8360-8364.

- 15) Yu Xi, Li Yu, Bo Chen, Guangqin Chen, and Yimin Chen, "Research on Pattern Recognition Method of Transformer Partial Discharge Based on Artificial Neural Network.", *Security and Communication Networks*, 12 pages, 2022. doi:10.1155/2022/5154649.
- 16) Yanxin Wang, Jing Yan, Zhou Yang, Tingliang Liu, Yiming Zhao, and Junyi Li, "Partial Discharge Pattern Recognition of Gas-Insulated Switchgear via a Light-Scale Convolutional Neural Network.", *Energies*, 2019, doi:10.3390/en12244674 2019.
- 17) Shibo Lu, Hua Chai, Animesh Sahoo, and B. T. Phung, "Condition Monitoring Based on Partial Discharge Diagnostics Using Machine Learning Methods: A Comprehensive State-of-the-Art Review.", *IEEE Transactions on Dielectrics and Electrical Insulation*, Vol. 27, 2020.
- 18) Transformer Insulation Pressboards [interaktyvus]. [žiūrėta 2023-11-24]. Prieiga per: <https://www.hitachienergy.com/products-and-solutions/transformer/insulation-components-and-materials/pressboard>
- 19) M. G. Niasar, R. C. Kiiza, X. Wang, R. Nikjoo and H. Edin, „Aging of oil impregnated paper due to pd activity“, KTH School of Electrical Engineering , Conference Paper, 2013.
- 20) F. Massingue, S. Meijer, P. D. Agoris, J. J. Smit and J. Lopez-Roldan, "Partial discharge pattern analysis of modeled insulation defects in transformer insulation," *Conference Record of the 2006 IEEE International Symposium on Electrical Insulation*, Toronto, ON, Canada, 2006, pp. 542-545, doi: 10.1109/ELINSL.2006.1665376.
- 21) T. Jiang, J. Li, Z. He and P. Wang, "Simulation and experiments of UHF detection for partial discharge in power transformers," *2013 Annual Report Conference on Electrical Insulation and Dielectric Phenomena*, Chenzhen, China, 2013, pp. 1262-1265,
- 22) doi: 10.1109/CEIDP.2013.6748240.
- 23) J. Liang, L. Zhang, J. Li and Y. Li, "Study on partial discharge characteristics of corona discharge in transformer oil under oscillating switching impulse voltage," *2013 Annual Report Conference on Electrical Insulation and Dielectric Phenomena*, Chenzhen, China, 2013, pp. 1173-1176, doi: 10.1109/CEIDP.2013.6747436.
- 24) DFA300 [interaktyvus]. [žiūrėta 2023-12-17]. Prieiga per: <https://www.theprescon.com/dfa300/>
- 25) DFA300 RFI & Acoustic Signal Surveyor [interaktyvus]. [žiūrėta 2023-12-17]. Prieiga per: <https://www.doble.com/product/dfa300/>
- 26) Michal Slodkiewicz „DFA Training Course“. (2015), Doble Engineering Company.
- 27) C. R. Li, Wei Wang, Z. S. Tang and Y. S. Ding, "PD pattern recognition in transformer by using UHF technology," *Conference Record of the 2004 IEEE International Symposium on Electrical Insulation*, Indianapolis, IN, USA, 2004, pp. 46-49, doi: 10.1109/ELINSL.2004.1380441.
- 28) Hai-feng, Y., Yong, Q., Yue, D., Ge-hao, S. and Xiu-chen, J. (2014), Development of multi-band ultra-high-frequency sensor for partial discharge monitoring based on the meandering technique. *IET Sci. Meas. Technol.*, 8: 327-335. <https://doi.org/10.1049/iet-smt.2013.0181>

- 29) Tenbohlen, S.; Beura, C.P.; Sikorski, W.; Albarracín Sánchez, R.; de Castro, B.A.; Beltle, M.; Fehlmann, P.; Judd, M.; Werner, F.; Siegel, M. Frequency Range of UHF PD Measurements in Power Transformers. *Energies* 2023, 16, 1395. <https://doi.org/10.3390/en16031395>.
- 30) Smith, Steven W. 1997. *The scientist and engineer's guide to digital signal processing*. 2nd ed. San Diego, California: California Technical Publishing.
- 31) Goodfellow, Ian, Bengio, Yoshua, Courville, Aaron. 2016. *Deep learning*. Cambridge, Massachusetts: MIT Press.
- 32) Chawla, N.V. et al. 2002. "SMOTE: Synthetic Minority Over-sampling Technique", *Journal of Artificial Intelligence Research*, DOI: <https://doi.org/10.1613/jair.953>.
- 33) Machine Learning Mastery, Why data preparation is so important in machine learning [interaktyvus]. [žiūrėta 2024-04-02]. Prieiga per: <https://machinelearningmastery.com/data-preparation-is-important/>
- 34) Gonzalez, Rafael C., and Woods, Richard E. 2018. *Digital Image Processing*. 4th ed. Global Edition. Harlow: Pearson Education Limited.
- 35) What is Synthetic Data in Machine Learning and How to Generate It [interaktyvus]. [žiūrėta 2024-04-09]. Prieiga per: <https://www.v7labs.com/blog/synthetic-data-guide>
- 36) What Is Random Forest? [interaktyvus]. [žiūrėta 2024-05-03]. Prieiga per: <https://careerfoundry.com/en/blog/data-analytics/what-is-random-forest/>

## Priedai

### 1 priedas. Filtravimo kodas

```
import os
import pandas as pd
import matplotlib.pyplot as plt
from scipy.signal import medfilt

# Skaitymo ir išsaugojimo keliai
read_directory = r'C:\Users\VARTOTOJAS\OneDrive\Documents\Studijos\Magistrinis\Magistro
darbas\Doble bandymai\Sutvarkyti'
save_directory = r'C:\Users\VARTOTOJAS\OneDrive\Documents\Studijos\Magistrinis\Magistro
darbas\Doble bandymai\Po filtravimo'
save_plot_directory =
r'C:\Users\VARTOTOJAS\OneDrive\Documents\Studijos\Magistrinis\Magistro darbas\Doble
bandymai\Po filtravimo grafikai'

# Sukuriamas direktorija, jei ji neegzistuoja
if not os.path.exists(save_directory):
    os.makedirs(save_directory)
if not os.path.exists(save_plot_directory):
    os.makedirs(save_plot_directory)

# Nuskaitomas kiekvienas CSV failas skaitymo direktorijoje
for filename in os.listdir(read_directory):
    if filename.endswith('.csv'):
        file_path = os.path.join(read_directory, filename)
        data = pd.read_csv(file_path)

        # Taikomas medianos filtrą
        data['Po filtravimo'] = medfilt(data['Y'], kernel_size=15)

        # Išsaugomas filtruotas duomenų rinkinį naujame CSV faile
        output_file_path = os.path.join(save_directory, f'{filename}')
        data.to_csv(output_file_path, index=False)

        # Sukuriamas grafikas
        plt.figure(figsize=(15, 7))
        plt.plot(data['X'], data['Po filtravimo'], label='Glotnintas Signalas')
        plt.xlabel('Dažnis (MHz)')
        plt.ylabel('Amplitudė (dBm)')
        plt.title(f'Nufiltruotas signalas - {filename[:-4]}')
        plt.legend()
        plt.grid(True)

        # Išsaugome grafiką
        plot_path = os.path.join(save_plot_directory, f'{filename.split(".")[0]}.png')

        # Išsaugomas grafikas nurodytoje direktorijoje
        plt.savefig(plot_path)
        plt.close()
```

## 2 priedas. Matavimų taškų sulyginimo kodas

```
import pandas as pd
import numpy as np
import os
from scipy.interpolate import interp1d

# Duomenų nuskaitymas
directory = 'C:/Users/VARTOTOJAS/OneDrive/Documents/Studijos/Magistrinis/Magistro
darbas/Doble bandymai/Po filtravimo'

# Naujų duomenų saugojimas
output_directory = 'C:/Users/VARTOTOJAS/OneDrive/Documents/Studijos/Magistrinis/Magistro
darbas/Doble bandymai/Sulyginti'
if not os.path.exists(output_directory):
    os.makedirs(output_directory)

# Nuskaitomi visi CSV failai iš nurodyto katalogo
for filename in os.listdir(directory):
    if filename.endswith('.csv'):
        file_path = os.path.join(directory, filename)
        df = pd.read_csv(file_path)

        # Išmetamas antrasis stulpelis
        df = df.drop(df.columns[1], axis=1)

        # Sukuriama interpolavimo funkcija naudojant 'X' ir 'Smoothed' stulpelius
        interpolation_function = interp1d(df.iloc[:, 0], df.iloc[:, 1], kind='linear')

        # Sukuriama nauja X ašis su norimu taškų skaičiumi
        new_x = np.linspace(df.iloc[:, 0].min(), df.iloc[:, 0].max(), num=800)
        new_y = interpolation_function(new_x)

        # Sukuriamas naujas duomenų rinkinys su vienodais taškais
        new_df = pd.DataFrame({'X': new_x, 'Y': new_y})

        # Naujo failo pavadinimas
        new_file_path = os.path.join(output_directory, f'{filename}')

        # Naujas duomenų rinkinys išsaugomas
        new_df.to_csv(new_file_path, index=False)
```