



Kauno technologijos universitetas

Informatikos fakultetas

**Dirbtinio intelekto metodais pagrįstas kompozitinių
konstrukcijų defektų identifikavimas iš deformacijų laukų,
naudojant skaitmeninių vaizdų koreliacijos ir baigtinių
elementų duomenis**

Baigiamasis magistro projektas

Justas Griškevičius

Projekto autorius

prof. Agnė Paulauskaitė-Tarasevičienė

Vadovė

Kaunas, 2026



Kauno technologijos universitetas

Informatikos fakultetas

**Dirbtinio intelekto metodais pagrįstas kompozitinių
konstrukcijų defektų identifikavimas iš deformacijų laukų,
naudojant skaitmeninių vaizdų koreliacijos ir baigtinių
elementų duomenis**

Baigiamasis magistro projektas

Dirbtinio intelekto informatika (6211BX007)

Justas Griškevičius

Projekto autorius

**prof. Agnė Paulauskaitė-
Tarasevičienė**

Vadovė

doc. Alfonsas Misevičius

Recenzentas

Kaunas, 2026



Kauno technologijos universitetas

Informatikos fakultetas

Justas Griškevičius

**Dirbtinio intelekto metodais pagrįstas kompozitinių
konstrukcijų defektų identifikavimas iš deformacijų laukų,
naudojant skaitmeninių vaizdų koreliacijos ir baigtinių
elementų duomenis**

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. rengiant baigiamąjį projektą dirbtinio intelekto (toliau – DI) įrankiai buvo naudoti teksto kalbiniam ir stilistiniam koregavimui, formuluočių tikslinimui ir atskirų programinio kodo fragmentų redagavimui, laikantis Universitete nustatytos tvarkos, nepažeidžiant akademinio sąžiningumo principų. DI įrankiai nebuvo naudojami tyrimo duomenims ar rezultatams generuoti, paveikslams kurti ar savarankiškai formuluoti galutines rezultatų interpretacijas;

5. 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.

Justas Griškevičius

Patvirtinta elektroniniu būdu

Griškevičius, Justas. Dirbtinio intelekto metodais pagrįstas kompozitinių konstrukcijų defektų identifikavimas iš deformacijų laukų, naudojant skaitmeninių vaizdų koreliacijos ir baigtinių elementų duomenis. Magistro baigiamasis projektas / vadovė prof. Agnė Paulauskaitė-Tarasevičienė; Kauno technologijos universitetas, informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatikos mokslai, Informatika (B01).

Reikšminiai žodžiai: kompozitinės medžiagos; defektų identifikacija; mašininis mokymasis; skaitmeninė vaizdų koreliacija; baigtinių elementų metodas.

Kaunas, 2026. 81 p.

Santrauka

Kompozitinės medžiagos plačiai naudojamos lengvose ir saugai svarbiose konstrukcijose, tačiau dėl sluoksniuotos sandaros jos yra jautrios įvairiems pažeidimams. Tokie defektai kaip įtrūkimai ar tarp sluoksniinis atsisluoksniavimas gali keisti deformacijų lauką ir mažinti konstrukcijos patikimumą, todėl svarbu ne tik aptikti pažeidimą, bet ir kiekybiškai įvertinti jo parametrus.

Šio darbo tikslas – sukurti ir iširti mašininio mokymosi metodiką, skirtą kompozitinės plokštelės defektams aptikti, klasifikuoti ir įvertinti, naudojant baigtinių elementų metodu sugeneruotus ir eksperimentinius skaitmeninio vaizdo koreliacijos deformacijų laukus. Darbe nagrinėjami du defektų tipai – įpjova ir atsisluoksniavimas. Sprendžiamos penkios užduotys: įpjovos ir atsisluoksniavimo aptikimas, įpjovos gylis, įpjovos kampo ir atsisluoksniavimo ilgio prognozavimas.

Kadangi eksperimentinių duomenų su žinomais defektų parametrais kiekis yra ribotas, modelių apmokymui naudoti sintetiniai duomenys, sugeneruoti taikant parametrizuotą baigtinių elementų modelį. Defektų parametrų kombinacijos sudarytos naudojant eksperimentų planavimo metodiką. Sugeneruoti deformacijų laukai buvo interpoliuojami į reguliarias gardeles, segmentuojami ir transformuojami į statistinių požymių vektorius, kurie naudoti klasikiniams prižiūravimo mašininio mokymosi modeliams.

Rezultatai parodė, kad didesnis 328 skaitinių atvejų duomenų rinkinys, lyginant su 113 atvejų rinkiniu, reikšmingai pagerino regresijos modelių tikslumą: geriausių nepriklausomo validavimo rezultatų vidutinė absoliutinė paklaida (MAE) sumažėjo 48,3 % įpjovos gylis, 54,7 % įpjovos kampo ir 46,0 % atsisluoksniavimo ilgio prognozavimo uždaviniuose. Taip pat nustatyta, kad regresijos uždaviniuose segmentuoti požymiai buvo informatyvesni už globalius požymius – geriausiu atveju pasiektas 82,6 % MAE sumažėjimas.

Modelių ir hiperparametrų analizė parodė, kad skirtingoms regresijos užduotims reikalingi skirtingo sudėtingumo modeliai, o tikslumo pagerėjimas turi būti vertinamas kartu su skaičiavimo sąnaudomis. Sukurta metodika buvo patikrinta naudojant eksperimentinius DIC deformacijų laukus: modeliai teisingai identifikavo įpjovą, o jos kampas ir gylis prognozuoti atitinkamai 94,7 % ir 89,8 % tikslumu.

Griškevičius, Justas. AI-Based Damage Identification in Composite Structures from Strain Fields Using Digital Image Correlation and Finite Element Data. Master's Final Degree Project / supervisor prof. Agnė Paulauskaitė-Tarasevičienė; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Computer science, Informatics (B01).

Keywords: composite materials; damage identification; machine learning; digital image correlation; finite element method.

Kaunas, 2026. 81 pages.

Summary

Composite materials are widely used in lightweight and safety-critical structures; however, due to their layered architecture, they are sensitive to various types of damage. Defects such as notches or interlaminar delamination can alter the strain field and reduce structural reliability. Therefore, it is important not only to detect damage, but also to quantitatively evaluate its parameters.

The aim of this work is to develop and investigate a machine learning methodology for detecting, classifying and evaluating defects in a composite plate using finite element model-generated synthetic data and experimental Digital Image Correlation strain fields. Two defect types are analysed: a notch and delamination. Five tasks are formulated: notch detection, delamination detection, notch depth prediction, notch angle prediction and delamination length prediction.

Since the amount of experimental data with known defect parameters is limited, synthetic data generated using a parametrized finite element model were used for model training. Defect parameter combinations were defined using a Design of Experiments approach. The generated strain fields were interpolated into regular grids, segmented and transformed into statistical feature vectors, which were then used for classical supervised machine learning models.

The results showed that the larger dataset of 328 numerical cases significantly improved regression accuracy compared with the 113-case dataset. Based on the best independent validation results, mean absolute error (MAE) decreased by 48.3% for notch depth prediction, 54.7% for notch angle prediction and 46.0% for delamination length prediction. It was also found that segmented features were more informative than global features in regression tasks, with the best case showing an 82.6% reduction in MAE.

The analysis of models and hyperparameters showed that different regression tasks require models of different complexity, and that accuracy improvements must be evaluated together with computational cost. The developed methodology was tested using experimental DIC strain fields. The models correctly identified the notch, while its angle and depth were predicted with accuracies of 94.7% and 89.8%, respectively.

Turinys

Paveikslų sąrašas	10
Lentelių sąrašas	12
Santrumpų ir terminų sąrašas	13
Įvadas.....	14
1. Kompozitinių konstrukcijų pažeidimų identifikavimo ir dirbtinio intelekto metodų taikymo analizė	17
1.1. Kompozitinių medžiagų defektai	17
1.2. Neardomųjų bandymų metodai	19
1.3. Skaitmeninės vaizdų koreliacijos (DIC) taikymas pažeidimų identifikavimui	20
1.4. Sintetinių duomenų ir BE modelių taikymas SHM uždaviniuose.....	21
1.5. Mašininio mokymosi metodai konstrukcijų būklės stebėsenos uždaviniuose	22
1.5.1. Giliojo mokymosi metodai SHM uždaviniuose	22
1.5.2. Skirtingų ML metodų palyginimas SHM uždaviniuose.....	23
1.5.3. Klasikiniai mašininio mokymosi metodai SHM uždaviniuose	25
1.6. Analizės apibendrinimas	26
2. Sintetinių duomenų rinkinių generavimo ir ML taikymo defektų identifikavimui metodika	27
2.1. Testuojamos medžiagos, naudojami dirbtiniai pažeidimai	27
2.2. Duomenų gavimo metodai	28
2.2.1. Skaitmeninio vaizdo koreliacija (DIC).....	28
2.2.2. Baigtinių elementų modeliavimas (BEM).....	29
2.3. Duomenų rinkinio sudarymas.....	31
2.3.1. DOE struktūra.....	31
2.3.2. Treniravimo duomenų rinkinio sudarymas	31
2.3.3. Validavimo duomenų rinkinio sudarymas.....	33
2.4. Duomenų apdorojimas ir požymių formavimas	34
2.4.1. Tiriamosios srities išskyrimas ir deformacijų laukų interpoliavimas.....	34
2.4.2. Laukų segmentavimas	35
2.4.3. Požymių rinkinių struktūra	35
2.4.4. Įvesties ir išvesties kintamieji.....	36
2.5. Mašininio mokymosi metodika	36
2.5.1. Mašininio mokymosi užduočių formulavimas	36
2.5.2. Naudoti ML modeliai ir hiperparametrų tyrimo logika.....	37
2.5.3. Modelių apmokymas, validavimas ir vertinimo rodikliai	38
2.5.4. Eksperimentinių DIC duomenų taikymas modelių patikrinimui.....	39
2.6. Naudojamos technologijos, įranga	40
2.7. Tyrimo įgyvendinimo eiga	41
3. ML modelių skirtų defektų identifikavimui rezultatų analizė	43
3.1. Duomenų generavimo ir ML eksperimentų įgyvendinimas	43
3.2. Interpoliacijos gardelės ir segmentų dydžio įtakos tyrimas	44
3.2.1. Eksperimentinė schema	44
3.2.2. Klasifikacijos užduočių įvertinimas	44

3.2.3. Įpjovos gylio regresijos rezultatai	47
3.2.4. Įpjovos kampo regresijos rezultatai	50
3.2.5. Atsisluoksniavimo ilgio regresijos rezultatai	54
3.2.6. Modelių mokymo laiko analizė ir tikslumo–skaičiavimo kainos kompromisas	57
3.2.7. Interpoliacijos ir segmentavimo parametrų įtakos apibendrinimas	63
3.3. ML modelių ir hiperparametrų įtakos tyrimas.....	64
3.3.1. Eksperimentinė schema	64
3.3.2. Ridge parametrų analizė įpjovos kampo regresijos uždavinyje	64
3.3.3. Gradient Boosting parametrų analizė atsisluoksniavimo ilgio regresijos uždavinyje.....	66
3.3.4. Gradient Boosting ir SVR modelių palyginimas įpjovos gylio regresijos uždavinyje.....	70
3.3.5. ML modelių ir hiperparametrų įtakos apibendrinimas	73
3.4. Patikrinimas naudojant eksperimentinius DIC duomenis	73
3.5. Skyriaus apibendrinimas	77
Išvados	79
Literatūros sąrašas	80

Paveikslų sąrašas

1.1 pav. NDT metodai, kompozitinių konstrukcijų pažeidimų aptikimui [2].....	18
1.2 pav. SHM sistemos komponentai [3].....	19
1.3 pav. DeepLabv3+ architektūra paveikslėlių semantiniam segmentavimui [5].....	22
1.4 pav. ResNet-50 pagrindo modelio struktūra [5].....	23
1.5 pav. Skirtingų DI metodų rezultatų palyginimas [15].....	24
2.1 pav. CFRP bandinys. kairėje - dirbtiniai defektai, dešinėje - DIC matavimų modelis.....	28
2.2 pav. DIC matavimo įranga [17]	29
2.3 pav. BE modelio ir defektų vietos vaizdas [17].....	30
3.1 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 328 bandinių treniravimo rinkinį, CV.....	45
3.2 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE	46
3.3 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 113 bandinių treniravimo rinkinį, CV.....	46
3.4 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE	47
3.5 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV.....	48
3.6 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE.....	48
3.7 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE.....	49
3.8 pav. Segmentuotų požymių įtaka įpjovos gylio regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328.....	50
3.9 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE.....	51
3.10 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV	51
3.11 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, CV	52
3.12 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE.....	53
3.13 pav. Segmentuotų požymių įtaka įpjovos kampo regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328.....	54
3.14 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV.....	55
3.15 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE	55
3.16 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE	56
3.17 pav. Segmentuotų požymių įtaka atsisluoksniavimo ilgio regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328	57
3.18 pav. Vidutinio ML modelių mokymo laiko priklausomybė nuo segmentų dydžio, n = 328	58
3.19 pav. Vidutinio ML modelių mokymo laiko priklausomybė nuo segmentų dydžio, n = 113	58
3.20 pav. Įpjovos gylio regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 328	59

3.21 pav. Įpjovos gylio regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 113	60
3.22 pav. Įpjovos kampo regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 328 ...	61
3.23 pav. Įpjovos kampo regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 113 ...	61
3.24 pav. Atsisluoksniavimo ilgio regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 328	62
3.25 pav. Atsisluoksniavimo ilgio regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 113	63
3.26 pav. Ridge alpha parametro įtaka įpjovos kampo regresijos MAE, n = 328	65
3.27 pav. Ridge alpha parametro įtaka įpjovos kampo regresijos MAE, n = 113	66
3.28 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 328, CV.....	67
3.29 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 328, validavimo DOE.....	67
3.30 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 113, CV.....	68
3.31 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 113, validavimo DOE.....	68
3.32 pav. Gradient Boosting hiperparametrų įtaka apmokymo laikui, n = 328, CV	69
3.33 pav. Gradient Boosting hiperparametrų įtaka apmokymo laikui, n = 113, CV	69
3.34 pav. 10 geriausių Gradient Boosting hiperparametrų kombinacijų, pagal validavimo MAE, vidutinės paklaidos ir apmokymo laikai, atsisluoksniavimo ilgio regresijos uždavinyje, n = 328 ...	70
3.35 pav. SVR hiperparametrų įtaka įpjovos gylio regresijos MAE, n = 328, validavimo DOE	71
3.36 pav. Gradient Boosting hiperparametrų įtaka įpjovos gylio regresijos MAE, n = 328, validavimo DOE	71
3.37 pav. 5 geriausių SVR ir GB hiperparametrų kombinacijų, pagal validavimo MAE, vidutinės paklaidos ir apmokymo laikai, įpjovos gylio regresijos uždavinyje, n = 328	72
3.38 pav. 5 geriausių SVR ir GB hiperparametrų kombinacijų pagal MAE spėjimų laikai, n = 328, validavimo DOE.....	72
3.39 pav. ML modelio patikrinimui naudojamos tiriamosios srities (ROI) apibrėžimas, pagrįstas eksperimentiniais DIC deformacijos laukais: ROI (juodas kontūras) ir atitinkama FE modelio sritis (raudonas kontūras)	74
3.40 pav. ML modelių ir segmentų dydžio įtaka įpjovos gylio regresijai	75
3.41 pav. ML modelių ir segmentų dydžio įtaka įpjovos kampo regresijai.....	75
3.42 pav. ML modelių ir segmentų dydžio įtaka atsisluoksniavimo ilgio regresijai	76

Lentelių sąrašas

1.1 lentelė. Skirtingų DI metodų privalumai ir trūkumai.....	24
2.1 lentelė. Bazinės ML modelių hiperparametrų konfigūracijos.....	37
3.1 lentelė. Defektų identifikavimo ir parametrų prognozavimo iš eksperimentinių DIC duomenų rezultatai	76

Santrumpų ir terminų sąrašas

Santrumpos:

DI, AI – Dirbtinis intelektas (angl. Artificial Intelligence)

CNN – Konvoliucinis neuroninis tinklas (angl. Convolutional Neural Network)

SHM – Struktūrinė sveikatos stebėseną (angl. Structural Health Monitoring)

CFRP – Anglies pluoštu sustiprintas plastikas (angl. Carbon Fiber-Reinforced Plastic)

SVK, DIC – Skaitmeninio vaizdo koreliacija (angl. Digital Image Correlation)

BEM, FEM – Baigtinių elementų modelis (angl. Finite Element Model)

BE – Baigtinis elementas

ROI – Tiriamoji sritis (angl. Region of Interest)

DOE – Eksperimento planavimas (angl. Design of Experiments)

CV – Kryžminė validacija (angl. Cross-validation)

MAE – Vidutinė absoliutinė paklaida (angl. Mean Absolute Error)

MIOU – Vidutinė sankirta virš sąjungos (angl. Mean Intersection over Union)

BPNN – Atgalinio sklaidimo neuroninis tinklas (angl. Backpropagation Neural Network)

LS-SVM – Mažiausių kvadratų paramos vektorių mašina (angl. Least Squares Support Vector Machine)

ANFIS – Pristaikanti neuronų-miglotos logikos išvados sistema (angl. Adaptive Neuro-Fuzzy Inference System)

RBFFN – Radialinės bazės funkcijų neuroninis tinklas (angl. Radial Basis Function Neural Network)

LMNN – Didelio atstumo artimiausio kaimyno klasifikacija (angl. Large Margin Nearest Neighbor Classification)

ELM – Ekstremaliojo mokymosi mašina (angl. Extreme Learning Machine)

GP – Gauso procesas (angl. Gaussian Process)

Ivadas

Kompozitinės medžiagos dėl didelio stiprumo ir mažos masės santykio plačiai taikomos konstrukcijose, kurioms keliami aukšti mechaninio patikimumo ir svorio mažinimo reikalavimai. Tokios medžiagos naudojamos aviacijos, transporto, energetikos, sporto įrangos ir kitose inžinerinėse srityse, kur konstrukcijos turi atlaikyti sudėtingas apkrovos sąlygas ir kartu išlikti lengvos. Vis dėlto sluoksniuotos kompozitinės konstrukcijos pasižymi sudėtinga vidine sandara, todėl jų pažeidimų atsiradimo ir vystymosi mechanizmai dažnai yra sudėtingesni nei vienalyčių metalinių konstrukcijų.

Kompozitinėse medžiagose pažeidimai gali atsirasti tiek gamybos ar mechaninio apdirbimo metu, tiek eksploatacijos sąlygomis. Išoriniai pažeidimai, tokie kaip įpjovos ar paviršiniai defektai, gali būti identifikuojami tiesiogiai, tačiau vidiniai pažeidimai, pavyzdžiui, tarp sluoksnių atsiskyrimas, dažnai nėra aiškiai matomi iš išorės. Nepaisant to, tokie defektai gali keisti konstrukcijos deformacijų ir įtempių pasiskirstymą, mažinti laikomąją gebą ir sudaryti sąlygas tolesniam pažeidimo augimui. Todėl kompozitinių konstrukcijų būklės stebėsenoje svarbu ne tik nustatyti pažeidimo buvimą, bet ir įvertinti jo pobūdį bei kiekybinius parametrus.

Neardomųjų bandymų metodai suteikia galimybę tirti konstrukcijų būklę nepažeidžiant tiriamo objekto. Tarp tokių metodų svarbią vietą užima skaitmeninio vaizdo koreliacija, leidžianti gauti viso lauko paviršiaus poslinkių ir deformacijų duomenis. Skirtingai nei taškiniai jutikliai, šis metodas leidžia analizuoti erdvinę deformacijų pasiskirstymą visoje pasirinktoje tiriamojame srityje. Tai ypač svarbu kompozitinių konstrukcijų atveju, nes defekto poveikis gali pasireikšti ne tik lokaliu deformacijų padidėjimu, bet ir platesniu deformacijų lauko persiskirstymu.

Vis dėlto viso lauko deformacijų duomenų interpretavimas nėra paprastas uždavinys. Defekto požymiai gali būti silpnai išreikšti, priklausyti nuo defekto geometrijos, padėties, apkrovos sąlygų ir tiriamosios srities pasirinkimo. Be to, praktiniuose tyrimuose dažnai susiduriama su ribotu eksperimentinių duomenų kiekiu, nes kiekvienas bandymas reikalauja laiko, įrangos ir tiksliai apibrėžtų pažeidimo parametrų. Dėl šios priežasties vien eksperimentiniais duomenimis grįstas mašininio mokymosi modelių apmokymas dažnai yra ribotas.

Vienas iš būdų spręsti šią problemą yra sintetinių duomenų generavimas taikant baigtinių elementų modeliavimą. Parametruotas skaitinis modelis leidžia sistemingai keisti defektų parametrus ir gauti deformacijų laukus, kuriems tikslinės reikšmės yra žinomos iš anksto. Tokiu būdu galima sudaryti anotuotą duomenų rinkinį, tinkamą mašininio mokymosi modeliams apmokyti ir vertinti. Ši strategija ypač naudinga tada, kai eksperimentinių duomenų nepakanka plačiai defektų parametrų erdvei padengti, tačiau yra galimybė sudaryti fiziškai pagrįstą skaitinį modelį.

Šiame darbe nagrinėjama kompozitinė plokštelė su dviem pažeidimų tipais: įpjova ir tarp sluoksnių atsiskyrimas. Pagal baigtinių elementų modelio rezultatus suformuoti sintetiniai deformacijų laukai naudojami mašininio mokymosi modeliams apmokyti. Modelių įvestis sudaroma iš interpoliuotų ir segmentuotų deformacijų laukų, o išvestys apima tiek klasifikavimo, tiek regresijos užduotis. Tokiu būdu siekiama ne tik aptikti defektų buvimą, bet ir kiekybiškai prognozuoti įpjovos gylį, įpjovos kampą bei atsiskyrimo ilgį. Darbe taip pat vertinama, kaip rezultatams įtaką daro duomenų paruošimo parametrai, modelių tipas ir hiperparametrų pasirinkimas.

Projekto naujumas ir aktualumas

Šio darbo aktualumas siejamas su kompozitinių konstrukcijų būklės stebėsenos poreikiu ir ribotu eksperimentinių duomenų prieinamumu. Praktikoje sudėtinga surinkti didelį kiekį eksperimentinių duomenų, apimančių skirtingas defektų konfigūracijas, todėl vien matavimais grįstas mašininio mokymosi modelių kūrimas tampa ribotas. Sintetinių baigtinių elementų duomenų naudojimas leidžia sistemingai padengti pasirinktą defektų parametrų erdvę ir suformuoti kontroliuojamą apmokymo duomenų rinkinį.

Darbo naujumas siejamas su deformacijų laukų, gautų taikant baigtinių elementų modeliavimą ir skaitmeninio vaizdo koreliaciją, integravimu į mašininio mokymosi metodiką. Darbe nagrinėjamas ne tik defekto buvimo nustatymas, bet ir kiekybinis jo parametrų įvertinimas. Be to, analizuojama, kaip interpoliacijos gardelės dydis, segmentų skaičius, apmokymo duomenų kiekis, modelio tipas ir hiperparametrai veikia skirtingas klasifikavimo bei regresijos užduotis.

Šio darbo tikslas – sukurti ir iširti mašininio mokymosi metodiką, skirtą kompozitinės plokštelės defektams aptikti, klasifikuoti ir kiekybiškai įvertinti, naudojant baigtinių elementų metodu sugeneruotus ir eksperimentinius skaitmeninio vaizdo koreliacijos deformacijų laukus.

Darbo tikslui pasiekti suformuoti tokie uždaviniai:

1. Atlikti literatūros analizę apie kompozitinių konstrukcijų defektų identifikavimo metodus, skaitmeninio vaizdo koreliacijos taikymą ir mašininio mokymosi algoritmų panaudojimą struktūrinės būklės stebėsenos uždaviniuose;
2. Taikant kompozitinės plokštelės baigtinių elementų modelį, sugeneruoti sintetinį duomenų rinkinį, apimančią skirtingas įpjovos ir atsisluoksniavimo defektų parametrų kombinacijas;
3. Parengti deformacijų laukų apdorojimo eigą, apimančią duomenų interpoliavimą, segmentavimą ir požymių vektorių sudarymą mašininio mokymosi modeliams;
4. Iširti interpoliacijos gardelės, segmentų dydžio, mašininio mokymosi modelių ir jų hiperparametrų įtaką defektų aptikimo, klasifikavimo ir parametrų regresijos tikslumui;
5. Patikrinti sukurtos metodikos pritaikomumą eksperimentiniams DIC deformacijų laukams.

Dokumento struktūra:

1. Pirmajame skyriuje pateikiama kompozitinių konstrukcijų pažeidimų identifikavimo ir dirbtinio intelekto metodų taikymo analizė. Šiame skyriuje aptariami kompozitinių medžiagų defektai, neardomųjų bandymų metodai, skaitmeninio vaizdo koreliacijos taikymas pažeidimų identifikavimui, sintetinių duomenų ir baigtinių elementų modelių naudojimas struktūrinės būklės stebėsenos uždaviniuose bei mašininio mokymosi metodų taikymas defektų aptikimui ir jų parametrų prognozavimui.
2. Antrajame skyriuje aprašoma sintetinių duomenų rinkinių generavimo ir mašininio mokymosi taikymo defektų identifikavimui metodika. Jame pateikiama tiriamos kompozitinės plokštelės ir dirbtinių pažeidimų charakteristika, duomenų gavimo metodai, baigtinių elementų

modeliavimas, duomenų rinkinio sudarymo logika ir DOE struktūra. Taip pat aprašomas deformacijų laukų apdorojimas, interpoliavimas, segmentavimas, požymių formavimas, mašininio mokymosi užduočių formulavimas, naudoti modeliai, vertinimo rodikliai, taikyta programinė ir eksperimentinė įranga bei bendra tyrimo įgyvendinimo eiga.

3. Trečiajame skyriuje pateikiama defektų identifikavimui skirtų mašininio mokymosi modelių rezultatų analizė. Šiame skyriuje aprašomas duomenų generavimo ir mašininio mokymosi eksperimentų įgyvendinimas, tiriama interpoliacijos gardelės ir segmentų dydžio įtaka klasifikavimo bei regresijos užduotims, analizuojamas modelių mokymo laikas ir tikslumo–skaičiavimo kainos kompromisas. Toliau nagrinėjama mašininio mokymosi modelių ir hiperparametrų įtaka rezultatams bei atliekamas sukurtos metodikos patikrinimas naudojant eksperimentinius DIC deformacijų laukus.

1. Kompozitinių konstrukcijų pažeidimų identifikavimo ir dirbtinio intelekto metodų taikymo analizė

Šiame skyriuje analizuojami dažniausiai kompozitinėse medžiagose pasitaikantys pažeidimai, jų aptikimui taikomi neardomieji bandymo metodai bei struktūrinės būklės stebėsenos (angl. Structural Health Monitoring, SHM) principai. Taip pat apžvelgiami egzistuojantys dirbtinio intelekto ir mašininio mokymosi metodų taikymo sprendimai kompozitinių konstrukcijų pažeidimų identifikavimo uždaviniuose.

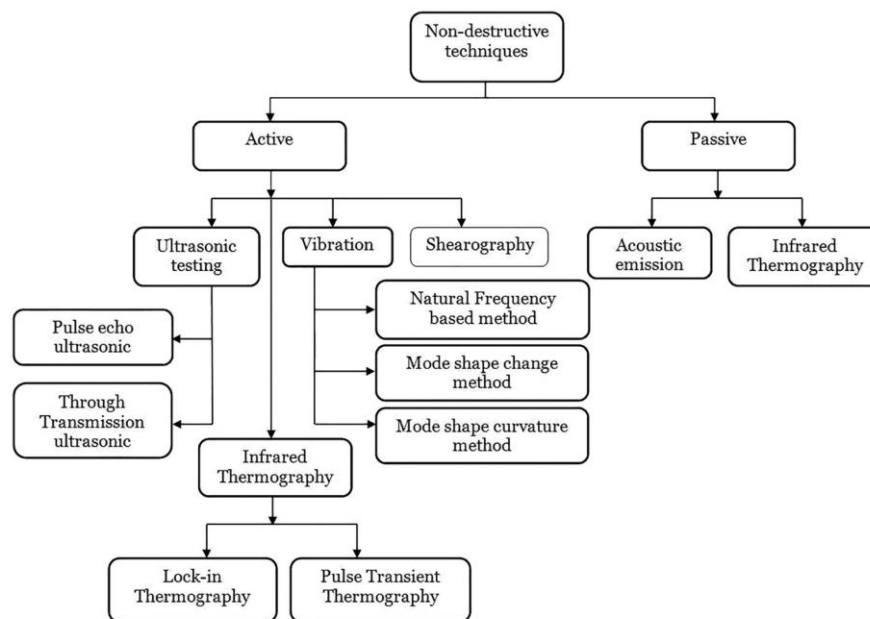
1.1. Kompozitinių medžiagų defektai

Kompozitinės medžiagos plačiai naudojamos aviacijos, transporto, energetikos ir kitose aukštos atsakomybės srityse dėl didelio stiprio ir masės santykio, atsparumo korozijai bei galimybės formuoti sudėtingas konstrukcijas. Tačiau kompozitinės medžiagos pasižymi sudėtingais pažeidimų mechanizmais, kurie dažnai vystosi sluoksnių viduje ir gali būti sunkiai identifikuojami vizualinės apžiūros metu [1]

Literatūroje dažniausiai išskiriami šie kompozitinių medžiagų pažeidimų tipai: poringumas, atsisluoksniavimas (angl. Delamination), matricos įtrūkimai, pluošto lūžiai bei pluošto–matricos atsiskyrimas [1]. Poringumas dažniausiai susiformuoja gamybos proceso metu dėl netinkamų technologinių parametrų arba nepakankamo dervos įsotinimo. Tuo tarpu atsisluoksniavimas dažniausiai atsiranda eksploatacijos metu dėl smūginių apkrovų, nuovargio reiškinių arba lokalių įtempių koncentracijų. Šio tipo pažeidimai yra ypač pavojingi, nes reikšmingai mažina konstrukcijos standumą ir laikomąją gebą, tačiau ilgą laiką gali išlikti vizualiai nepastebimi.

Matricos įtrūkimai bei pluošto lūžiai dažniausiai siejami su mechaninėmis apkrovomis arba cikliniu apkrovimu. Tokie pažeidimai gali inicijuoti tolimesnį defektų vystymąsi, pavyzdžiui, atsisluoksniavimą tarp sluoksnių arba lokalius konstrukcijos nestabilumus. Dėl daugiasluoksnės kompozitų struktūros vidiniai pažeidimai dažnai nėra tiesiogiai matomi paviršiuje, todėl jų identifikavimui būtini pažangūs neardomieji bandymo metodai [1], [2].

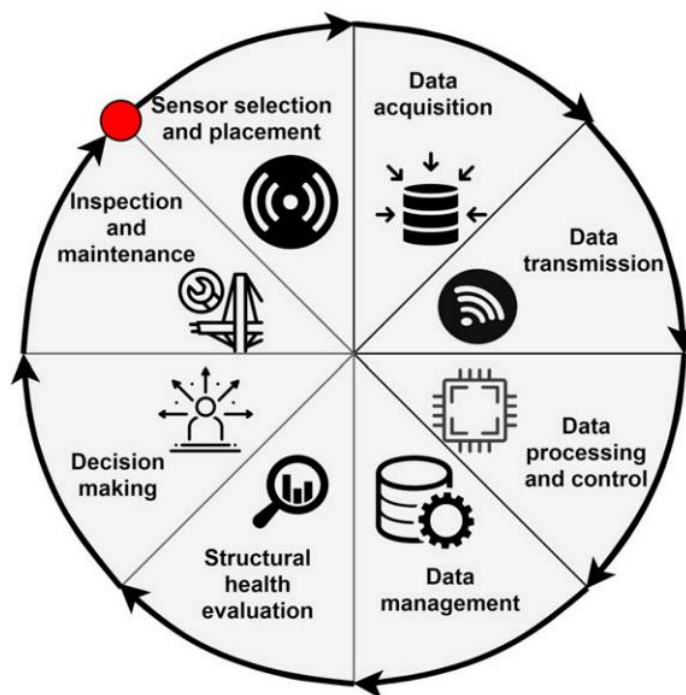
Kompozitinių konstrukcijų pažeidimų aptikimui ir lokalizavimui naudojami įvairūs neardomieji bandymo metodai (angl. Non-Destructive Testing, NDT), kurių pagrindiniai tipai pateikti **1.1 pav.**



1.1 pav. NDT metodai, kompozitinių konstrukcijų pažeidimų aptikimui [2]

Siekiant ne tik identifikuoti jau egzistuojančius pažeidimus, bet ir realiu laiku stebėti konstrukcijos būklę bei prognozuoti pažeidimų vystymąsi, taikomos struktūrinės būklės stebėsenos sistemos (SHM). Tokios sistemos leidžia nuolat rinkti duomenis iš konstrukcijos bei vertinti jos būklės pokyčius eksploatacijos metu [3]. Vieni plačiausiai taikomų SHM metodų yra valdomų bangų metodai (angl. Guided Waves), paremti „Lamb“ bangų sklidimu konstrukcijoje. Šie metodai pasižymi dideliu jautrumu nedideliems pažeidimams, galimybe stebėti didelį plotą bei santykinai mažu signalų slopinimu [2], [3].

Be valdomų bangų metodų, SHM sistemose taip pat naudojami ultragarsiniai bandymai, termografija, rentgeno radiografija bei akustinės emisijos metodai. Pagrindiniai SHM sistemos komponentai pateikti **1.2 pav.**



1.2 pav. SHM sistemos komponentai [3]

1.2. Neardomųjų bandymų metodai

Neardomieji bandymo metodai (NDT) yra vieni svarbiausių kompozitinių konstrukcijų vertinimo įrankių, leidžiantys aptikti vidinius ir paviršinius pažeidimus nepažeidžiant pačios konstrukcijos. Tokie metodai ypač svarbūs aviacijos, energetikos ir transporto srityse, kur konstrukcijų patikimumas ir eksploatacinis saugumas yra kritiškai svarbūs [4].

Literatūroje dažniausiai išskiriami šie NDT metodai: vizualinė kontrolė (VT), ultragarsiniai bandymai (UT), rentgeno radiografija (RT), infraraudonųjų spindulių termografija, elektromagnetiniai metodai (ET), akustinės emisijos metodai (AE), deformacijų matavimo metodai bei šearografija (angl. Shearography) [4]. Kiekvienas metodas pasižymi skirtingu jautrumu tam tikro tipo pažeidimams, skirtinga matavimo trukme, įrangos sudėtingumu bei taikymo apribojimais.

Ultragarsiniai metodai yra vieni plačiausiai naudojamų kompozitinių konstrukcijų diagnostikoje, nes leidžia efektyviai identifikuoti vidinius defektus, tokius kaip atsisluoksniavimas ar poringumas. Termografiniai metodai dažniausiai taikomi paviršinių bei netoli paviršiaus esančių defektų aptikimui, tuo tarpu rentgeno radiografija leidžia vizualizuoti vidinę konstrukcijos struktūrą ir aptikti tūrinio pobūdžio pažeidimus [4].

Akustinės emisijos metodai dažniausiai naudojami konstrukcijų būklės stebėsenai apkrovimo metu, registruojant medžiagoje vykstančių pažeidimų generuojamas elastines bangas. Fotogrametrijos būdu pagrįsti deformacijų matavimo metodai leidžia nustatyti lokalius deformacijų netolygumus, susijusius su vidiniais pažeidimais ar atsisluoksniavimu. Pastaraisiais metais vis didesnis dėmesys skiriamas pilno lauko matavimo metodams bei jų integravimui su dirbtinio intelekto algoritmais [2], [3].

NDT metodo pasirinkimas priklauso nuo daugelio veiksnių: tikėtino pažeidimo tipo, konstrukcijos geometrijos, reikiamo jautrumo, bandymo trukmės, ekonominių aspektų bei eksploatacinių sąlygų.

Dėl šios priežasties praktikoje dažnai taikoma kelių metodų kombinacija, leidžianti patikimiau identifikuoti skirtingų tipų pažeidimus [4].

1.3. Skaitmeninės vaizdų koreliacijos (DIC) taikymas pažeidimų identifikavimui

Skaitmeninė vaizdų koreliacija (angl. Digital Image Correlation, DIC) yra optinis bekontaktis deformacijų ir poslinkių matavimo metodas, leidžiantis nustatyti pilno lauko deformacijų pasiskirstymą tiriamos konstrukcijos paviršiuje. DIC metodas laikomas perspektyvia neardomosios diagnostikos technologija, nes suteikia galimybę dideliu tikslumu registruoti lokalius deformacijų pokyčius bei stebėti pažeidimų vystymąsi realiu laiku [5].

DIC metodas paremtas nuosekliai užfiksuotų bandinio paviršiaus vaizdų palyginimu. Tiriamo paviršiaus deformacijos nustatomos sekant kontrastingo atsitiktinio taškinio rašto poslinkius apkrovimo metu. Tokiu būdu apskaičiuojami pilno lauko poslinkių ir deformacijų laukai, kurie leidžia identifikuoti lokalias deformacijų koncentracijos zonas bei galimus pažeidimų iniciacijos taškus. Skirtingai nei tradiciniai kontaktiniai jutikliai, DIC suteikia galimybę vienu metu analizuoti didelį paviršiaus plotą ir gauti erdvinę informaciją apie visos konstrukcijos deformacinę būseną.

Apžvalginiame straipsnyje „A Digital Image Correlation Technique for Laboratory Structural Tests and Applications: A Systematic Literature Review“ pažymima, kad DIC metodas plačiai taikomas konstrukcijų mechanikos, įtrūkių plitimo, vibracijų analizės, nuovargio bei kompozitinių medžiagų tyrimuose [6]. DIC technologija naudojama tiek 2D, tiek 3D deformacijų matavimams, o pastaraisiais metais vis daugiau dėmesio skiriama pilno lauko deformacijų analizei kompozitinėse konstrukcijose bei struktūrinės būklės stebėsenos sistemose [6].

Kompozitinių medžiagų tyrimuose DIC metodas dažniausiai naudojamas atsisluoksniavimo, įtrūkių iniciacijos, sluoksnių atsisluoksniavimo bei lokalių standumo pokyčių stebėsenai. Kadangi kompozitinėse konstrukcijose pažeidimai dažnai vystosi sluoksnių viduje ir ilgą laiką gali būti nepastebimi vizualinės apžiūros metu, pilno lauko deformacijų analizė leidžia netiesiogiai identifikuoti vidinius defektus pagal jų sukeltus deformacijų laukų netolygumus.

Pastaraisiais metais vis didesnis dėmesys skiriamas DIC duomenų integravimui su mašininio mokymosi metodais. Straipsnyje „Digital image correlation (DIC) based damage detection for CFRP laminates by using machine learning based image semantic segmentation“ pateikiamas metodas, kuriame CFRP kompozitų deformacijų laukai naudojami automatizuotam pažeidimų identifikavimui taikant konvoliucinius neuroninius tinklus ir semantinės segmentacijos algoritmus [5]. Autoriai pažymi, kad tradiciniai vizualiniai metodai gali būti jautrūs paviršiaus tekstūrai, apšvietimui bei triukšmui, tuo tarpu DIC deformacijų laukų analizė leidžia tiesiogiai stebėti deformacijų pasiskirstymo pokyčius, susijusius su pažeidimų formavimusi [5].

Minėtame tyrime mašininio mokymosi modelių apmokymui buvo naudojami baigtinių elementų modeliais sugeneruoti deformacijų laukų duomenys, o modelių validacijai - eksperimentiniai 2D-DIC matavimai [5]. Toks metodas parodo, kad skaitiniai modeliai gali būti efektyviai naudojami sintetinių duomenų generavimui, kai eksperimentinių matavimų kiekis yra ribotas. Ši idėja ypač aktuali struktūrinės būklės stebėsenos uždaviniuose, kuriuose eksperimentinių pažeidimų scenarijų sudarymas dažnai yra sudėtingas ir brangus.

Nors naujausiuose tyrimuose DIC duomenų analizei dažniausiai taikomi giliojo mokymosi metodai, tokie kaip CNN architektūros bei semantinės segmentacijos tinklai [5], šie metodai įprastai reikalauja didelių anotuotų duomenų rinkinių bei reikšmingų skaičiavimo resursų. Dėl šios priežasties vis daugiau dėmesio skiriama alternatyviems metodams, kuriuose pilno lauko deformacijų duomenys transformuojami į požymių rinkinius ir analizuojami taikant klasikinius mašininio mokymosi algoritmus. Tokia metodika leidžia sumažinti modelių sudėtingumą bei efektyviau dirbti su riboto dydžio duomenų rinkiniais.

Remiantis apžvelgtais tyrimais, šiame darbe pasirinkta naudoti DIC metodą naudojamas eksperimentinių deformacijų laukų matavimui ir baigtinių elementų modelio validacijai. Gauti pilno lauko deformacijų duomenys bus naudojami mašininio mokymosi modelių apmokymui bei kompozitinių konstrukcijų pažeidimų parametrų prognozavimui.

1.4. Sintetinių duomenų ir BE modelių taikymas SHM uždaviniuose

Struktūrinės būklės stebėsenos uždaviniuose vienas iš pagrindinių iššūkių yra pakankamo kiekio paženklintų duomenų gavimas. Realiose konstrukcijose kontroliuojamai sukurti skirtingų tipų ir lygių pažeidimus dažnai yra sudėtinga, brangu arba nepraktiška, o eksperimentinių duomenų kiekis dažniausiai būna ribotas. Dėl šios priežasties vis dažniau taikomi skaitiniai modeliai, leidžiantys generuoti sintetinius duomenis skirtingiems konstrukcijos būsenos scenarijams [7], [8]. FE simuliacijomis galima sistemingai keisti pažeidimo vietą, dydį, mechanines savybes ar apkrovimo sąlygas, todėl toks metodas yra tinkamas mašininio mokymosi modelių apmokymo duomenų rinkiniams sudaryti.

Straipsnyje „Structural Health Monitoring using deep learning with optimal finite element model generated data“ pateikiama metodika, kurioje SHM klasifikavimo modelis apmokomas vien tik baigtinių elementų modeliu sugeneruotais duomenimis [7]. Autoriai pabrėžia, kad tokia strategija gali būti taikoma tais atvejais, kai tikėtini pažeidimų tipai yra pakankamai aiškiai apibrėžti ir gali būti imituojami skaitiniame modelyje. Vis dėlto svarbi sąlyga yra patikimas pradinio modelio suderinimas su eksperimentine konstrukcijos būsena, nes nominalus, nevaliduotas BE modelis gali generuoti duomenis, kurie nepakankamai atitinka realų konstrukcijos atsaką [7].

Sintetinių duomenų taikymas plačiai aptariamas ir duomenimis grįstos SHM analizės apžvalgose. Jose pažymima, kad dirbtinio intelekto modelių tikslumas priklauso nuo apmokymo duomenų reprezentatyvumo, o realių pažeidimų duomenų rinkimas ne visada įmanomas. Vienas iš sprendimų yra BE modeliais generuoti duomenis, kurie vėliau gali būti naudojami modelių išankstiniam apmokymui arba papildyti eksperimentinius duomenis [8]. Tačiau tokie duomenys skiriasi nuo realių matavimų dėl modelio supaprastinimų, triukšmo ir neapibrėžtumų, todėl jų taikymas turi būti siejamas su eksperimentine validacija.

BEM ir ML integracija yra aktuali ne tik SHM, bet ir platesniame skaitinės mechanikos kontekste. Apžvalginiam straipsnyje „Application of Machine Learning and Deep Learning in Finite Element Analysis: A Comprehensive Review“ nurodoma, kad mašininis mokymasis gali būti taikomas įvairiuose FEA etapuose: priešprocesoriuje, sprendimo pagreitinimui, pakaitinių modelių sudarymui, parametrų identifikavimui ir rezultatų interpretavimui [9]. Tai rodo, kad ML gali būti naudojamas ne kaip BEM pakaitalas, bet kaip papildomas įrankis, leidžiantis efektyviau analizuoti didelius skaitinių rezultatų kiekius ir kurti greitesnes prognozavimo sistemas.

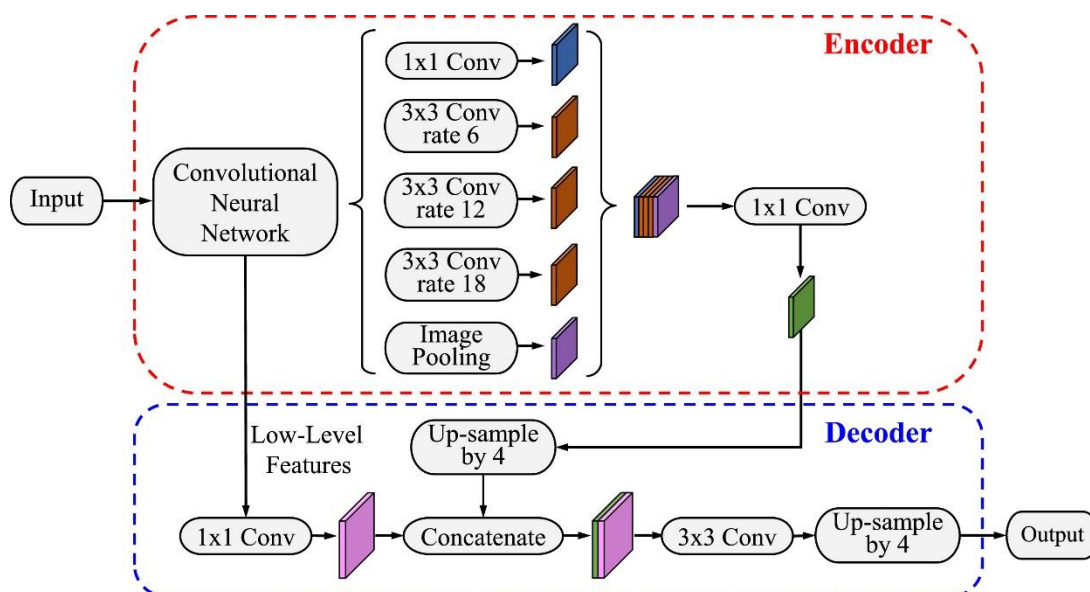
Šiame darbe pasirinkta taikyti panašią hibridinę logiką: BEM naudojamas kontroliuojamam sintetinių deformacijų laukų generavimui, o mašininio mokymosi modeliai – pažeidimų buvimui, tipui ir parametrams prognozuoti. Toks sprendimas yra tinkamas riboto eksperimentinių duomenų kiekio sąlygomis, nes leidžia sistemingai padengti pažeidimų parametų erdvę ir vėliau modelių veikimą tikrinti naudojant eksperimentinius DIC duomenis. Todėl BEM pagrindu sugeneruoti sintetiniai duomenys šiame tyrime sudaro tarpinę grandį tarp fizikinio modelio ir duomenimis grįsto pažeidimų identifikavimo metodo.

1.5. Mašininio mokymosi metodai konstrukcijų būklės stebėsenos uždaviniuose

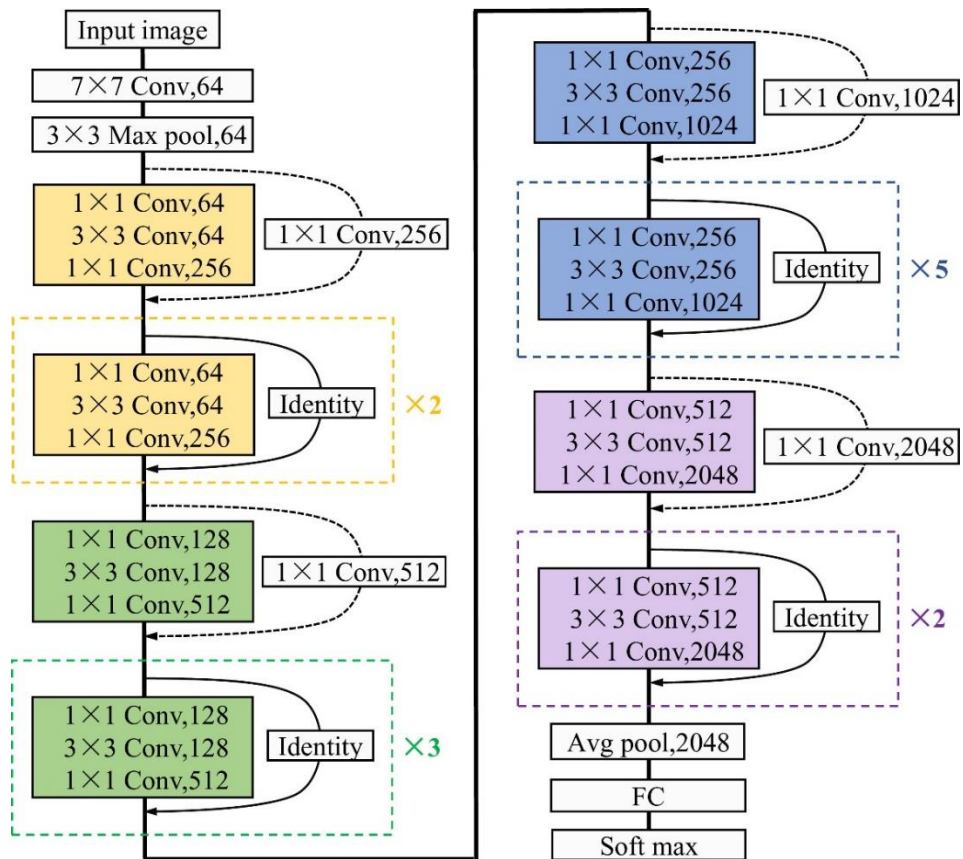
1.5.1. Giliojo mokymosi metodai SHM uždaviniuose

Pastaruosiu metu struktūrinės būklės stebėsenos (SHM) uždaviniuose vis dažniau taikomi giliojo mokymosi (angl. Deep Learning) metodai, leidžiantys automatiškai išgauti sudėtingus požymius iš didelės apimties eksperimentinių duomenų. Didžiausias dėmesys skiriamas konvoliuciniams neuroniniams tinklams (CNN), kurie plačiai naudojami deformacijų laukų, vibracinių signalų bei kitų pilno lauko matavimų analizei [5], [10], [11].

Straipsnyje „Digital image correlation (DIC) based damage detection for CFRP laminates by using machine learning based image semantic segmentation“ [5] buvo nagrinėjamas DIC deformacijų laukų taikymas CFRP kompozitų pažeidimų identifikavimui naudojant CNN pagrindu veikiančią semantinio segmentavimo architektūrą DeepLabv3+ (žr. 1.3 pav.). Tyrime buvo lyginami keli skirtingi CNN pagrindo modeliai, tarp jų ResNet-50, ResNet-18 [12], MobileNetv2 [13] bei Xception-71 [14]. Autoriai nustatė, kad geriausius rezultatus pasiekė ResNet-50 pagrindu sudarytas modelis (žr. 1.4 pav.), kuris efektyviai identifikavo pažeistas zonas iš deformacijų laukų vaizdų [5]. Šio tyrimo rezultatai parodė, kad pilno lauko deformacijų duomenys gali būti tiesiogiai naudojami automatizuotam kompozitinių konstrukcijų pažeidimų aptikimui.



1.3 pav. DeepLabv3+ architektūra paveikslėlių semantiniam segmentavimui [5]



1.4 pav. ResNet-50 pagrindo modelio struktūra [5]

Kitame tyrime „Digital image correlation-based structural state detection through deep learning“ [10] CNN modelis buvo taikomas plieninių konstrukcijų būsenų klasifikavimui naudojant DIC metodu išmatuotus vibracinius atsakus. Autoriai lygino CNN ir klasikinio atgalinio sklidimo neuroninio tinklo (BPNN) rezultatus bei nustatė, kad CNN modelis pasiekė ženkliai didesnę tikslumą. Tyrimo metu klasifikavimo tikslumas viršijo 99 %, o modelis išlaikė gerą gebėjimą identifikuoti pažeidimus net naudojant nepilnus duomenis [10].

Dirbtinio intelekto metodų taikymas SHM uždaviniuose analizuotas ir straipsnyje „Artificial intelligence-based damage localization method for building structures using correlation of measured structural responses“ [11]. Tyrime buvo naudojami konstrukcijų poslinkių, deformacijų ir vibracijos matavimų duomenys, iš kurių apskaičiuoti koreliaciniai požymiai buvo perduodami CNN modeliui. Autoriai parodė, kad CNN metodai gali būti efektyviai taikomi pažeidimų lokalizavimui tiek skaitiniuose, tiek eksperimentiniuose tyrimuose [11].

Nors CNN ir kiti giliojo mokymosi metodai pasižymi aukštu tikslumu, jų taikymas dažniausiai reikalauja didelių duomenų kiekių bei reikšmingų skaičiavimo resursų. Dėl šios priežasties šiame darbe pagrindinis dėmesys skiriamas klasikiniams mašininio mokymosi metodams, kurie leidžia efektyviau dirbti su ribotos apimties sintetiniais duomenų rinkiniais bei suteikia galimybę paprasčiau interpretuoti modelių veikimą.

1.5.2. Skirtingų ML metodų palyginimas SHM uždaviniuose

Straipsnyje „Comparison of Seven Artificial Intelligence Methods for Damage Detection of Structures“ [15] pateikta skirtingų dirbtinio intelekto metodų, taikomų konstrukcijų pažeidimų identifikavimui, palyginamoji analizė. Tyrime buvo nagrinėjami septyni metodai: atgalinio sklidimo

neuroniniai tinklai (BPNN), mažiausių kvadratų atraminių vektorių mašinos (LS-SVM), adaptyvios neuronų–fuzzy išvados sistemos (ANFIS), radialinių bazinių funkcijų neuroniniai tinklai (RBFNN), didelio atstumo artimiausių kaimynų klasifikavimas (LMNN), ekstremaliojo mokymosi mašinos (ELM) bei Gauso procesai (GP).

Tyrime modeliai buvo apmokyti naudojant konstrukcijos savųjų virpesių parametrus, o jų užduotis buvo nustatyti pažeidimo vietą bei pažeidimo lygį. Autoriai analizavo ne tik modelių tikslumą, bet ir jų stabilumą, mokymo laiką bei jautrumą mažesniems duomenų kiekiams [15].

Rezultatai, kurie matomi **1.5 pav.**, parodė, kad geriausius rezultatus pasiekė LS-SVM ir ELM metodai, kurie pasižymėjo geru prognozavimo tikslumu bei santykinai nedidelėmis skaičiavimo sąnaudomis. Tuo tarpu BPNN modeliai reikalavo ilgesnio mokymo laiko bei buvo jautresni persimokymui, o LMNN metodas regresijos uždaviniuose demonstravo mažesnę tikslumą ir didesnes skaičiavimo sąnaudas [15].

AI method	Number Of Training Data	Number Of Testing Data	MSE	Time (S)
LS-SVM	8137	3488	0.00051	300
RBFNN	9300	2325	0.00678	440
ANFIS	10000	1625	0.048	700
LMNN	10000	1625	0.1	1200
BPNN	9300	2325	0.00981	680
ELM	8137	3488	0.00031	350
GP	10000	1625	0.048	910

1.5 pav. Skirtingų DI metodų rezultatų palyginimas [15]

Autoriai taip pat pažymi, kad skirtingi metodai pasižymi skirtingomis savybėmis priklausomai nuo uždavinio pobūdžio. Pavyzdžiui, LS-SVM metodai efektyviai dirba aukštos dimensijos duomenų erdvėse ir yra mažiau linkę į persimokymą, tačiau jų veikimas stipriai priklauso nuo branduolio funkcijos parinkimo. RBFNN ir ELM metodai pasižymi greitu mokymu, tačiau gali būti jautrūs tinklo parametrų. Gauso procesų modeliai leidžia įvertinti prognozės neapibrėžtumą, tačiau jų taikymas didesniems duomenų rinkiniams reikalauja reikšmingų skaičiavimo resursų [15]. Apibendrinus autorių pastebėjimus, buvo sudaryta šių modelių privalumų ir trūkumų **1.1 lentelė**.

1.1 lentelė. Skirtingų DI metodų privalumai ir trūkumai

Metodas	Privalumai	Trūkumai
LS-SVM (Least Squares Support Vector Machine)	Veiksmingas aukštamatėje erdvėje. Mažiau linkęs į permokymą.	Reikalingas atidus branduolio pasirinkimas. Reikalauja daug skaičiavimo resursų.
RBFNN (Radial Basis Function Neural Network)	Greitas apsimokymas. Efektyvus artinimo problemoms.	Jautrus radialinės bazės funkcijos pasirinkimui.
ANFIS (Adaptive Neuro-fuzzy Inference Systems)	Sujungia neuroninių tinklų mokymą su neaiškios logikos aiškinamumu.	Sudėtinga modelio struktūra. Sunku apmokyti.
LMNN (Large Margin Nearest Neighbor Classification)	Atsparus išskirtinėms reikšmėms. Gerina KNN klasifikavimo tikslumą.	Reikalauja daug skaičiavimo resursų.

BPNN (Back-Propagation Neural Networks)	Tinkamas netiesinių struktūrų aptikimui.	Linkęs į persimokymą. Lėtas konvergavimas.
ELM (Extreme Learning Machines)	Greitas mokymasis. Efektyvus didelės apimties problemoms.	Atsitiktiniai paslėpti mazgai gali sukelti nestabilumą rezultatuose.
GP (Gaussian Processes)	Pateikia tikimybinę išvestį. Tinkamas neapibrėžtumo modeliavimui.	Reikalauja daug skaičiavimo resursų. Jautrus branduolio pasirinkimui.

Tyrimo rezultatai rodo, kad SHM uždaviniuose nėra vieno universaliai geriausio metodo, todėl modelio pasirinkimas priklauso nuo turimų duomenų kiekio, uždavinio sudėtingumo bei reikalaujamo skaičiavimo efektyvumo. Dėl šios priežasties praktiniuose SHM taikymuose dažnai atliekamas kelių skirtingų mašininio mokymosi metodų palyginimas, siekiant nustatyti tinkamiausią modelį konkrečiam uždaviniui.

1.5.3. Klasikiniai mašininio mokymosi metodai SHM uždaviniuose

Nors pastaraisiais metais struktūrinės būklės stebėsenos (SHM) uždaviniuose sparčiai populiarėja giliojo mokymosi metodai, klasikiniai mašininio mokymosi algoritmai išlieka plačiai taikomi dėl mažesnių skaičiavimo resursų poreikio, paprastesnio modelių interpretavimo bei gero veikimo su ribotos apimties duomenų rinkiniais [16].

Apžvalginiame straipsnyje „Machine learning for structural engineering: A state-of-the-art review“ [16] pažymima, kad konstrukcijų inžinerijoje dažniausiai taikomi klasikiniai metodai apima logistinės regresijos (Logistic Regression), atraminių vektorių mašinų (SVM), atsitiktinių miškų (Random Forest), gradientinio stiprinimo (Gradient Boosting) bei dirbtinių neuroninių tinklų metodus. Šie algoritmai naudojami pažeidimų klasifikavimo, defektų lokalizavimo, parametru regresijos bei konstrukcijų būsenos prognozavimo uždaviniuose [16]

SVM metodai dažnai taikomi dėl gebėjimo efektyviai dirbti su mažesnės apimties duomenimis bei netiesinėmis priklausomybėmis. Tuo tarpu Random Forest ir Gradient Boosting modeliai pasižymi geru atsparumu triukšmui, gebėjimu modeliuoti sudėtingas požymių sąveikas bei galimybe įvertinti skirtingų požymių svarbą [16]. Tokie metodai ypač tinkami SHM uždaviniams, kuriuose naudojami didelės dimensijos eksperimentiniai ar skaitiniai deformacijų laukų duomenys.

Literatūroje taip pat pabrėžiama, kad klasikiniai metodai dažnai naudojami kaip baziniai modeliai vertinant naujų metodikų efektyvumą. Dėl santykinai nedidelės modelių sudėtingumo klasikiniai algoritmai leidžia greitai atlikti hiperparametru optimizavimą, skirtingų požymių rinkinių analizę bei jautrumo tyrimus [16].

Šiame darbe pagrindinis dėmesys skiriamas klasikiniams mašininio mokymosi metodams, kadangi tyrime naudojami sintetiniai duomenų rinkiniai yra ribotos apimties, o vieno BEM sprendinio generavimas reikalauja reikšmingų skaičiavimo resursų. Tyrime naudojami logistinės regresijos, Random Forest, Support Vector Machine (SVM), Gradient Boosting, Ridge regresijos bei Support Vector Regression (SVR) modeliai, kurie taikomi tiek klasifikavimo, tiek regresijos uždaviniams spręsti.

1.6. Analizės apibendrinimas

Atlikta literatūros analizė parodė, kad kompozitinėse konstrukcijose susidarantys pažeidimai dažnai yra sunkiai aptinkami įprastais vizualinės kontrolės metodais. Tokie defektai kaip atsiskuoksnivimas, matricos įtrūkimai, pluošto lūžiai ar pluošto–matricos atsiskyrimas gali vystytis konstrukcijos viduje ir ilgą laiką neturėti aiškių išorinių požymių. Dėl šios priežasties kompozitinių medžiagų būklės vertinimui reikalingi neardomieji bandymo metodai ir struktūrinės būklės stebėsenos sistemos, leidžiančios aptikti ne tik pažeidimo buvimą, bet ir įvertinti jo vietą, tipą bei sunkumo lygį.

Neardomųjų bandymų metodų analizė parodė, kad skirtingi metodai pasižymi skirtingomis taikymo galimybėmis ir apribojimais. Ultragaršiniai, termografiniai, radiografiniai ar akustinės emisijos metodai gali būti efektyvūs tam tikriems pažeidimų tipams, tačiau jų taikymas priklauso nuo konstrukcijos geometrijos, defekto pobūdžio, įrangos prieinamumo ir matavimo sąlygų. Šiame kontekste skaitmeninė vaizdų koreliacija (DIC) yra aktuali dėl galimybės bekontakčiu būdu matuoti pilno lauko poslinkius ir deformacijas. Tokie duomenys suteikia ne tik lokalią, bet ir erdvinę informaciją apie konstrukcijos atsaką, todėl gali būti naudojami defektų sukeltų deformacijų netolygumų analizei.

Literatūroje taip pat išryškėja tendencija DIC ir kitų SHM duomenų analizę derinti su dirbtinio intelekto metodais. Giliojo mokymosi metodai, ypač CNN architektūros, leidžia tiesiogiai apdoroti vaizdinio pobūdžio duomenis ir pasiekti aukštą pažeidimų aptikimo ar lokalizavimo tikslumą. Vis dėlto tokie metodai paprastai reikalauja didelių anotuotų duomenų rinkinių ir didesnių skaičiavimo resursų. Kadangi kompozitinių konstrukcijų pažeidimų eksperimentiniai duomenys dažnai yra riboti, vien tik eksperimentiniais duomenimis paremta giliojo mokymosi metodika ne visada yra praktiška.

Sintetinių duomenų generavimas taikant baigtinių elementų metodą yra vienas iš būdų sumažinti šį apribojimą. BE modeliai leidžia kontroliuojamai keisti pažeidimų parametrus, apkrovimo sąlygas ir konstrukcijos atsaką, todėl gali būti naudojami mašininio mokymosi modelių apmokymo duomenų rinkiniams sudaryti. Kartu literatūroje pabrėžiama, kad tokie duomenys turi būti siejami su eksperimentine validacija, nes skaitiniai modeliai neišvengiamai supaprastina realios konstrukcijos elgseną. Dėl šios priežasties BE ir DIC duomenų derinimas yra tinkama kryptis, leidžianti sujungti kontroliuojamą parametrinį modeliavimą su eksperimentiniais pilno lauko deformacijų matavimais.

Atsižvelgiant į analizėje aptartus metodus, šiame darbe pasirinkta ne tiesioginė CNN pagrindu veikianti vaizdų analizė, o požymių formavimu paremta klasikinio mašininio mokymosi metodika. Tokia strategija yra tinkama riboto dydžio duomenų rinkiniams, leidžia aiškiau kontroliuoti naudojamų fizinių laukų ir požymių įtaką, taip pat suteikia galimybę lyginti skirtingus modelius, požymių rinkinius ir duomenų reprezentavimo būdus. Todėl projektuojamas sprendimas grindžiamas sintetiniais BEM deformacijų laukais, DIC eksperimentiniais matavimais, segmentuotų požymių formavimu ir klasikinių mašininio mokymosi modelių taikymu defektų aptikimo, klasifikavimo ir parametrų regresijos uždaviniams spręsti.

2. Sintetinių duomenų rinkinių generavimo ir ML taikymo defektų identifikavimui metodika

2.1. Testuojamos medžiagos, naudojami dirbtiniai pažeidimai


Šiame darbe atlikti tyrimai naudojantis Mechanikos inžinerijos ir dizaino fakulteto tyrėjų gautais eksperimentiniais duomenimis vykdant projektą „Quantitative Damage Detection and Evolution in Composite Structures Using Digital Image Correlation, Machine Learning, and Peridynamics“ [17]. Tyrime naudoti anglies pluoštu sustiprinti polimeriniai (angl. Carbon Fiber-Reinforced Plastic) kompozitai. Šie kompozitai pasižymi mažu svoriu, dideliu atsparumu deformacijoms bei tempimui, todėl yra plačiai naudojami įvairiose saugai svarbiose konstrukcijose (pvz., aviacijoje, vėjo jėgainėse). Kompozitinėse konstrukcijose pasitaiko pažeidimai, kurie sunkiai pastebimi vizualiai, tačiau turi esminę įtaką konstrukcijų saugumui.

Tyrimų objektu pasirinkta serijiniu būdu (www.r-g.de) gaminama anglies pluoštu armuota kompozitinė plokštė (laminatas), kurios matmenys 350 x 150 x 2.0 mm. Plokštės buvo naudojamos bandinių su pažaida paruošimui. Plokštės gamybos procesas grindžiamas aukšto slėgio terminiu konsolidavimu (presiniu formavimu), naudojant HT-3-K anglies pluošto prepregus su epoksidine derva. Pagal gamintojo pateiktus duomenis, plokštės medžiagos savybės yra tokios: pluošto tūrinė dalis: 60 – 65 %, tankis: 1500 – 1600 kg/m³, efektyvusis tamprumo modulis: 50 – 70 GPa, stiprumo riba: 600–775 MPa.

Plokštę sudaro iš viso 6 sluoksniai, kurių klojimo seka yra [(0/90)^o/90^o/0^o]_s. Pirmiausia iš plokštės buvo paruošti tempimo bandiniai, siekiant nustatyti efektyviausias medžiagos savybes ir sukaliuoti skaitinius modelius. Bandiniai išpjauti naudojant diskinį stalinį pjūklą 0° ir 45° kryptimis CFRP plokštės atžvilgiu, kaip parodyta **2.1 pav.**. Kompozitinį laminatą sudaro du išoriniai audiniu armuoto anglies pluošto sluoksniai ir keturi vidiniai vienakrypčio pluošto, orientuoto 0–90 laipsnių kryptimis sluoksniai [(0/90)^o/90^o/0^o]_s.

Tempimo bandinių matmenys parinkti pagal ASTM D3039 standartą: plotis – 25 mm; nors tiesioginio reikalavimo bandinio ilgiui nėra, šiame darbe jis buvo pasirinktas lygus plokštės matmeniui – 150 mm. Siekiant išvengti bandinių suirimo ties spaustuvais, prie abiejų bandinio galų iš abiejų pusių priklijuotos 25 × 30 mm matmenų plokštelės (tabs), pagamintos iš 1,5 mm storio aliuminio lakšto. Dėl aukštos kokybės ir būdingo aukšto slėgio būdu suformuoto OKE laminato homogeniškumo kiekvienai pasirinktai sluoksnių orientacijai pakako trijų tempimo bandinių, kad būtų gauti reprezentatyvūs rezultatai.

Tokių pačių matmenų pagaminti bandiniai ir pažaidos stebėsenai, išfrezuojant dvi vienodo pločio (1 mm) ir 10 mm ilgio įpjovas. Įpjovos orientuotos 45° kampu tempimo krypties atžvilgiu, o jų gyliai parinkti skirtingi: 1 mm ir 1,5 mm, tai atvaizduota **2.1 pav.**. Atstumas tarp įpjovų buvo parinktas 21 mm, siekiant išvengti jų tarpusavio sąveikos. Šie įpjovimai naudojami kaip dirbtiniai pažeidimai, siekiant įvertinti metodų gebėjimą aptikti ir charakterizuoti pažeidimus.



2.1 pav. CFRP bandinys. kairėje - dirbtiniai defektai, dešinėje - DIC matavimų modelis

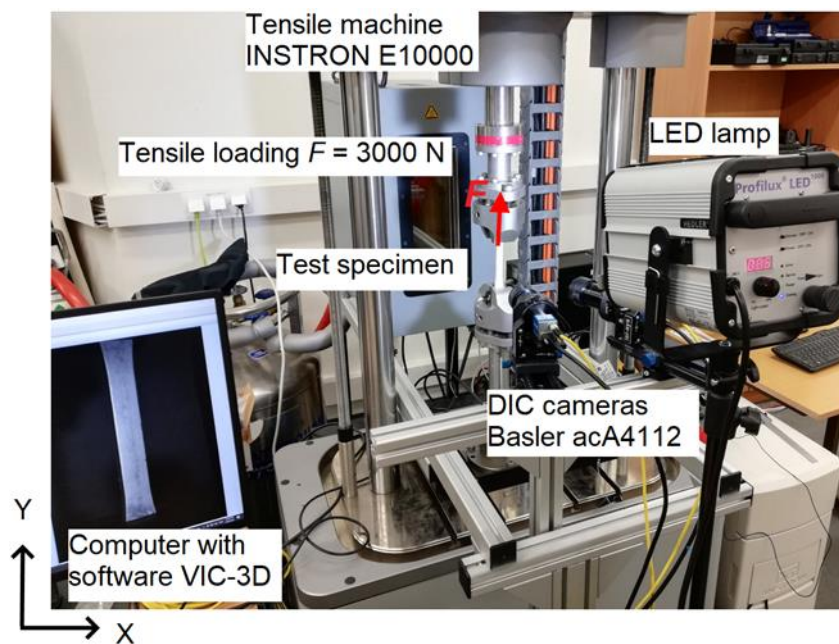
2.2. Duomenų gavimo metodai

2.2.1. Skaitmeninio vaizdo koreliacija (DIC)

Skaitmeninio vaizdo koreliacijos (DIC) metodas naudojamas CFRP bandinių paviršiaus deformacijų laukui nustatyti. Bandinio paviršius paruošiamas padengiant jį atsitiktiniu didelio kontrasto taškų raštu, purškiant juodus dažus ant balto pagrindo.

Bandymo metu bandinys veikiamas statine tempiamąja apkrova naudojant INSTRON E10000 bandymo mašiną, o jo paviršius nuolat fotografuojamas aukštos raiškos kameromis. Remiantis nuosekliai užfiksuotais vaizdais, DIC sistema apskaičiuoja poslinkių ir deformacijų laukus, analizuodama taškų rašto poslinkius tarp pradinės ir deformuotos būsenų (žr. 2.2 pav.).

DIC kalibravimo plokštė su žinomu raštu ir matmenimis naudojama sistemai kalibruoti, užtikrinant tikslių poslinkių ir deformacijų matavimą.



2.2 pav. DIC matavimo įranga [17]

Pagal eksperimentinius deformacijų matavimus sudarytas ir validuotas baigtinių elementų modelis, kuris vėliau buvo naudojamas sintetiniam duomenų rinkiniui generuoti, keičiant pažeidimo parametrus.

2.2.2. Baigtinių elementų modeliavimas (BEM)


Trimatis CFRP bandinio baigtinių elementų modelis buvo sukurtas naudojant ANSYS APDL aplinką/programavimo kalbą. Modelio matmenys ($40 \times 20 \times 2$ mm) buvo parinkti taip, kad atitiktų deformacijų laukų analizei naudojamą dominančią sritį (Region Of Interest (ROI)). Laminatas buvo modeliuojamas kaip šeši atskiri sluoksniai, kurių klojimo seka $[(0/90)^\circ/90^\circ/0^\circ]$ s. Tiek austiniams, tiek vienkrypčiams sluoksniams buvo priskirtos ortotropinės tampriosios savybės bei atitinkamos lokaliai medžiagos koordinatinių sistemų [17].

Eksperimentinėje schemoje viename bandinyje buvo suformuotos dvi įpjovos, siekiant vienu metu stebėti pažaidos evoliuciją. Tačiau, siekiant skaičiavimo efektyvumo ir modelio paprastumo, BE modelyje buvo nagrinėjama tik viena įpjova (žr. 2.3 pav.). Ši prielaida pagrįsta papildomais palyginimais tarp dviejų įpjovų ir atitinkamų vienos įpjovos FE modelių, kurie parodė, kad deformacijų lokalizacija kiekvienos įpjovos aplinkoje daugiausia priklauso nuo lokaliai geometrijos, o įpjovų tarpusavio sąveika esant nagrinėtam atstumui yra nereikšminga. Todėl ši supaprastinta schema neturi įtakos lokaliai įtempimų–deformacijų būsenai įpjovos srityje ir, atitinkamai, nedaro įtakos ML modelių mokymo duomenims.

BE modelio validacija buvo atlikta lyginant skaitiniu būdu gautus ir eksperimentiškai (3D DIC metodu) išmatuotus deformacijų laukus apkrovimo metu. Nustatytas geras sutapimas tiek deformacijų lokalizacijos, tiek jų pasiskirstymo pobūdžio atžvilgiu įpjovos srityje. Įpjova buvo modeliuojama kaip pasukta pailga išpjova (angl. obround slot), kurios geometrija apibrėžta trimis pagrindiniais parametrais: įpjovos gyliu (NOT_D), orientacijos kampu (NOT_ANG), bei fiksuotais ilgio ir pločio matmenimis.

Vidinis atsiskuoksniaivimas buvo įvestas po įpjova, apibrėžiant lokalų tarpsluoksninį kontaktą. Pirminiame etape, atsiskuoksniaivimas buvo tik tarp 4 ir 5 sluoksnių, vėliau BE modelis pakoreguotas ir atsiskuoksniaivimo tarpsluoksnio vieta buvo parenkama automatiškai pagal defekto gylio reikšmę. Atsiskuoksniaivimo sąsajos vieta parinkta remiantis ultragarsinių tyrimų rezultatais. Defekto gylis buvo generuojamas diskretiškai, t. y. arba gylis sutampa su laminato tarpsluoksniu arba su sluoksnio vidurio padėtimi. Tokiu būdu atsiskuoksniaivimo tarpsluoksnis buvo parenkamas taip kad sutaptų su įpjovos gyliu arba būtų artimiausiame tarpsluoksnyje keliaujant nuo įpjovos gylio. Atsiskuoksniaivimo srityje buvo taikytas paviršius ir “nonpenetration” paviršiaus kontakto tipas. Likusi nepažeista tarpsluoksnų vieta modeliuota kaip sukibusi (angl. bonded contact). Toks modeliavimas leido parametrizuotai valdyti defekto vietą ir plotą. Atsiskuoksniaivimas buvo centruotas su įpjova ir apibūdinama pirmiausia jos ilgiu plokštumoje (DEL_L), o plotis apibrėžtas santykiu $DEL_W = DEL_L/2$.

Bandinys buvo veikiamas tempimo apkrova, užduodant tolygų ašinį poslinkį, atitinkantį eksperimentinę apkrovos amplitudę $F = 6$ kN. Priešingas bandinio galas buvo papildomai apribotas, siekiant išvengti standaus kūno poslinkių, tačiau leidžiant laisvą skersinį medžiagos deformavimąsi (susitraukimą) (žr. **2.3 pav.**). Buvo atliekama netiesinė statinė analizė. Kiekvieno skaičiavimo metu iš viršutinio paviršiaus ROI, atitinkančio DIC matavimo sritį, buvo išgauti tampriųjų deformacijų laukai. Siekiant sumažinti kraštinių sąlygų įtaką, ROI (38×18 mm) buvo parinkta šiek tiek mažesnė nei visas BE modelio domenai.



2.3 pav. BE modelio ir defektų vietos vaizdas [17]

Eksperimentiniai duomenys, gauti taikant DIC metodą, naudoti baigtinių elementų modelio validacijai, o vėliau ML modelių patvirtinimui. Visas sintetinių duomenų rinkinys sugeneruotas taikant baigtinių elementų metodą (BEM) buvo naudojamas matematinių modelių apmokymui.

Validuotas baigtinių elementų modelis naudojamas generuoti deformacijų laukus, atitinkančius skirtingas defektų konfigūracijas. Keičiant modelio parametrus, tokius kaip įpjovos gylis, kampas ar atsiskuoksniaivimo ilgis, sudaromas įvairus ir kontroliuojamas mokymo duomenų rinkinys. Skirtingai nei eksperimentiniuose duomenyse, sintetiniuose duomenyse visi defektų parametrai yra žinomi tiksliai, todėl anotavimas atliekamas automatiškai.

Eksperimentiniai duomenys, t. y. DIC deformacijų laukai, šiame darbe naudojami galutiniam apmokytų modelių patikrinimui su realiais matavimo duomenimis. Eksperimento metu buvo žinomi pagrindiniai įpjovos parametrai – įpjovos gylis ir kampas.

2.3. Duomenų rinkinio sudarymas

Šiame tyrime ML modelių apmokymui ir vertinimui buvo naudojami sintetiniai duomenys, sugeneruoti taikant baigtinių elementų metodą (BEM). Atsižvelgiant į sąlyginai didelius vieno skaitinio eksperimento skaičiavimo laiko resursus (apie 8 min. vienam sprendiniui), duomenų rinkinio sudarymas buvo formuluojamas kaip optimizavimo uždavinys, kuriame siekiama maksimaliai efektyviai padengti parametų erdvę ribotu skaičiavimų skaičiumi.

Tam tikslui buvo pasirinktas mišrus eksperimentų planavimo metodas (Design of Experiments, DOE), derinantis sisteminę parametų diskretizavimą su daline atsitiktine atranka. Tokia strategija leidžia išlaikyti struktūrinę parametų erdvės padengimą, kartu užtikrinant pakankamą duomenų įvairovę, reikalingą modelių generalizacijai.

Taikant šią metodiką buvo sudaryti trys atskiri duomenų rinkiniai: du treniravimo rinkiniai (113 ir 328 atvejų), skirti modelių apmokymui ir parametų parinkimui, bei nepriklausomas validavimo rinkinys (100 atvejų), skirtas modelių veikimo įvertinimui nematytuose duomenyse. Validavimo rinkinys buvo taikomas kaip papildoma vertinimo priemonė greta kryžminės validacijos (angl. Cross-validation), siekiant sumažinti galimą rezultatų priklausomybę nuo konkretaus duomenų padalijimo.

2.3.1. DOE struktūra

Tyrime nagrinėjami du pagrindiniai defektų tipai: įpjova (angl. Notch) ir tarp sluoksnių atsisluoksniavimas (angl. Delamination). Jų aprašymui naudojami šie parametrai:

- įpjovos gylis: $NOT_D \in \{0.8, 1.0, 1.2, 1.4, 1.5, 1.66\} \text{ mm}$
- įpjovos kampas: $NOT_ANG \in [0^\circ, 90^\circ]$
- atsisluoksniavimo ilgis: $DEL_L \in [0, 30] \text{ mm}$

Papildomai, atsisluoksniavimo plotis apibrėžiamas deterministiškai:

$$DEL_W = \frac{DEL_L}{2} \quad (1)$$

o plotas:

$$A_{del} = DEL_L \times DEL_W \quad (2)$$

Įpjovos gylio reikšmės koreliuoja su sluoksnių storiais t. y. gylis parenkamas, kad sutaptų su tarp sluoksnių pozicija, arba su sluoksnių vidurio padėtimi. Įpjovos gylis dalinai įtakoja BE skaičių, todėl parametų parinkimas buvo derinamas su ANSYS Student licencijoje taikomu baigtinių elementų skaičiaus apribojimu.

2.3.2. Treniravimo duomenų rinkinio sudarymas

Bendra struktūra

Treniravimo duomenų rinkinys buvo formuojamas dviem etapais, pradedant nuo kompaktiško rinkinio su 113 atvejais ir vėliau pereinant prie išplėsto rinkinio, turinčio 328 atvejus, siekiant

įvertinti, kiek tai įtakos ML modelių tikslumą ir stabilumą. Abiem atvejais buvo laikomasi tos pačios bendros logikos – suderinti sisteminių parametrų padengimą su daline atsitiktine atranka, tačiau skyrėsi parametrų diskretizavimo tankis ir bendras atvejų skaičius.

Įpjovos gylis visais atvejais buvo laikomas diskrečiu kintamuoju, turinčiu šešias galimas reikšmes: 0.8 mm, 1.0 mm, 1.2 mm, 1.4 mm, 1.5 mm ir 1.66 mm. Šios reikšmės buvo parinktos taip, kad apimtų skirtingus pažeidimo režimus leistų nuosekliai nustatyti kuriuose sluoksniuose randasi atsisluoksniavimas. Įpjovos kampas buvo nagrinėjamas intervale nuo 0° iki 90°, o atsisluoksniavimo ilgis – intervale nuo 0 iki 30 mm.

Visi treniravimo duomenų rinkiniai, nepriklausomai nuo jų dydžio, buvo sudaromi laikantis vieningos struktūros, apimančios keturis pagrindinius atvejų tipus: medžiaga be defektų, atvejis tik su įpjova (angl. Notch-only), atvejis tik su atsisluoksniavimu (angl. Delamination-only) ir kombinuotus defektus, kuriuose vienu metu egzistuoja tiek įpjova, tiek atsisluoksniavimas. Tokia struktūra pasirinkta siekiant užtikrinti, kad duomenų rinkinys būtų tinkamas tiek klasifikavimo, tiek regresijos uždaviniams.

Vienas defekto neturintis atvejis įtraukiamas kaip atskaitos būseną, leidžianti modeliams išmokti atskirti pažeistą ir nepažeistą struktūrą. Atvejai tik su įpjova naudojami siekiant izoliuotai įvertinti įpjovos įtaką deformacijų laukui, tuo tarpu atvejai tik su atsisluoksniavimu leidžia analogiškai tirti atsisluoksniavimo poveikį. Kombinuoti atvejai yra esminiai, nes realiose konstrukcijose dažniausiai pasitaiko kompleksiniai pažeidimai, todėl modelis turi gebėti vienu metu identifikuoti ir kiekybiškai įvertinti abu defektų tipus.

Kombinuotų defektų grupė papildomai skaidoma į struktūrizuotą ir atsitiktinę dalis. Struktūrizuotoje dalyje naudojamas diskretus parametrų tinklas, užtikrinantis tolygų pagrindinių parametrų erdvės taškų padengimą, o atsitiktinėje dalyje parametrai generuojami iš anksčiau apibrėžtų intervalų. Tokia mišri strategija leidžia išvengti modelio perpratimo tik diskretiems lygiams ir pagerina jo gebėjimą interpoliuoti tarp nematytų parametrų kombinacijų.

Pirminis treniravimo DOE

Pirminis treniravimo duomenų rinkinys buvo sudarytas iš 113 skaitinių eksperimentų ir skirtas metodikos patikrinimui bei preliminariems modelių palyginimams. Šiame etape siekta sumažinti skaičiavimo kaštus, todėl parametrų diskretizavimas buvo sąlyginai retas.

Atvejams tik su įpjova, įpjovos kampas buvo diskretizuotas naudojant keturias reikšmes: 0°, 30°, 60° ir 90°, kurios atitinka pagrindines geometrines orientacijas. Šios reikšmės buvo taikomos tik atvejams be atsisluoksniavimo. Tuo tarpu atvejams tik su atsisluoksniavimu, atsisluoksniavimo ilgis buvo parenkamas iš diskretaus reikšmių rinkinio: 2.5 mm, 5.0 mm, 8.5 mm, 12.5 mm, 14.0 mm, 17.5 mm, 20.0 mm, 22.5 mm, 26.0 mm ir 30.0 mm. Tokiu būdu buvo užtikrintas pakankamas, nors ir netolygus, atsisluoksniavimo ilgių intervalo padengimas.

Kombinuotų defektų atveju buvo taikytas mišrus metodas. Struktūrizuotoje dalyje buvo naudojami trys kampai (15°, 45° ir 75°) ir trys atsisluoksniavimo ilgio reikšmės (5 mm, 15 mm ir 25 mm), sudarant pagrindinį parametrų erdvės karkasą. Papildomai buvo generuojami atsitiktiniai taškai, kuriuose kampas ir atsisluoksniavimo ilgis buvo parenkami iš trijų intervalų (mažų, vidutinių ir didelių reikšmių zonų), taip padidinant duomenų įvairovę ir sumažinant modelių priklausomybę nuo

diskrečių lygių. Tokia kombinacija leido išlaikyti DOE paprastumą, kartu užtikrinant bazinę parametru įvairovę.

Išplėstas treniravimo DOE

Išplėstas treniravimo DOE buvo sudarytas siekiant padidinti parametru diskretizavimo tankį ir užtikrinti tolygesnį parametru erdvės padengimą, ypač kombinuotų defektu atvejais. Šis duomenų rinkinys apima 328 atvejus ir išlaiko tą pačią bendrą struktūrą kaip ir pirminis DOE, tačiau pasižymi didesne parametru įvairove.

Šiame rinkinyje atvejuose tik su įpjova, jos kampas buvo diskretizuotas kas 15°, naudojant reikšmes 0°, 15°, 30°, 45°, 60°, 75° ir 90°, taip padidinant modelio jautrumą orientacijos pokyčiams. Atvejams tik su atsisluoksniavimu, atsisluoksniavimo ilgis buvo apibrėžtas naudojant 15 reikšmių rinkinį: 2.0 mm, 4.0 mm, 6.0 mm, 8.0 mm, 10.0 mm, 12.5 mm, 15.0 mm, 17.5 mm, 20.0 mm, 22.5 mm, 24.0 mm, 26.0 mm, 28.0 mm, 29.0 mm ir 30.0 mm, kas leido geriau aproksimuoti kontinuumą.

Didžiausias pokytis buvo susijęs su kombinuotų defektu dalimi. Struktūrizuotoje dalyje buvo naudojami penki kampai (10°, 25°, 45°, 65° ir 80°) ir penkios atsisluoksniavimo ilgio reikšmės (3 mm, 8 mm, 15 mm, 22 mm ir 28 mm), sudarant tankesnę parametru tinklą. Ši dalis buvo papildyta 120 atsitiktinių atvejų, generuotų iš tų pačių parametru intervalu kaip ir pirminiame DOE. Tokiu būdu buvo sukurtas treniravimo rinkinys, kuris ne tik tolygiau padengia parametru erdvę, bet ir leidžia efektyviau treniruoti modelius, skirtus tiek klasifikavimo, tiek regresijos uždaviniams.

2.3.3. Validavimo duomenų rinkinio sudarymas

Validavimo duomenų rinkinys buvo sudaromas laikantis tos pačios bendros struktūros kaip ir treniravimo duomenys, t. y. apimant keturis pagrindinius atvejų tipus: intaktinę būseną be defektu, atvejus tik su įpjova, atvejus tik su atsisluoksniavimu ir kombinuotus defektus. Tačiau skirtingai nei treniravimo DOE, validavimo rinkinio sudarymo principas buvo orientuotas ne į parametru erdvės padengimą, o į modelių gebėjimo generalizuoti į nematytus atvejus įvertinimą.

Dėl šios priežasties validavimo DOE buvo formuojamas taip, kad jo parametru reikšmės nesutaptų su treniravimo DOE struktūrizuotais taškais. Tai ypač svarbu kombinuotų defektu atvejams, nes būtent šie atvejai yra sudėtingiausi ir labiausiai atspindi realias konstrukcijų pažeidimo situacijas. Kaip ir treniravimo rinkiniuose, atvejai tik su įpjova ir tik su atsisluoksniavimu buvo generuojami nepriklausomai.

Siekiant patikimiau įvertinti modelių veikimą ir sumažinti atsitiktinių variacijų įtaką, buvo sudarytas validavimo duomenų rinkinys, apimantis 100 atvejų. Šiame rinkinyje išlaikyta ta pati struktūra kaip ir ankstesniuose DOE, tačiau ženkliai padidintas parametru variantiškumas ir kombinuotų defektu dalis.

Įpjovos gylis šiame rinkinyje išliko nepakitęs ir įgijo tas pačias šešias reikšmes kaip treniravimo DOE. Atvejuose tik su įpjova, įpjovos kampas buvo parenkamas iš naujo, naudojant keturias reikšmes: 7.5°, 22.5°, 52.5° ir 82.5°, kurios nesutampa nei su treniravimo atvejų tik su įpjova kampais, nei su struktūrizuotų kombinuotų atvejų kampais.

Atvejuose tik su atsisluoksniavimu, atsisluoksniavimo ilgis buvo apibrėžtas naudojant 15 reikšmių rinkinį: 1.5 mm, 3.5 mm, 4.5 mm, 6.5 mm, 7.5 mm, 9.5 mm, 11.5 mm, 13.5 mm, 16.5 mm, 18.5 mm,

19.5 mm, 21.5 mm, 24.5 mm, 27.5 mm ir 29.0 mm. Šios reikšmės buvo parinktos taip, kad nesutaptų su struktūrizuoto treniravimo DOE atsisluoksniavimo ilgio reikšmėmis ir tuo pačiu užtikrintų pakankamą viso intervalo padengimą.

Kombinuotų defektų atveju buvo naudojamas deterministinis kampo ir atsisluoksniavimo ilgio porų rinkinys, sudarytas iš dešimties kombinacijų, tarp kurių buvo tokios poros kaip (7.5°, 4.5 mm), (12.5°, 9.5 mm), (22.5°, 13.5 mm), (27.5°, 18.5 mm), (37.5°, 21.5 mm), (52.5°, 24.5 mm), (57.5°, 27.5 mm), (67.5°, 6.5 mm), (72.5°, 16.5 mm) ir (82.5°, 29.0 mm). Kiekviena šių porų buvo kombinuojama su visais įpjovos gylio lygiais, sudarant pagrindinę validavimo DOE dalį.

Tokiu būdu suformuotas 100 atvejų validavimo rinkinys leidžia ne tik įvertinti modelių tikslumą, bet ir patikimai analizuoti jų stabilumą bei jautrumą parametrų pokyčiams. Dėl sąmoningai parinktų, su treniravimo DOE nesutampančių parametrų, šis rinkinys yra tinkamas objektyviam modelių generalizacijos gebėjimo įvertinimui.

2.4. Duomenų apdorojimas ir požymių formavimas

Šiame darbe mašininio mokymosi modeliams naudojami ne tiesioginiai baigtinių elementų modelio rezultatai, o iš jų suformuoti struktūrizuoti požymių rinkiniai. Kadangi kiekvieno skaitinio eksperimento deformacijų laukai gaunami nereguliarame baigtinių elementų tinkle, prieš taikant ML modelius duomenys turi būti perkelti į vienodą skaitinę struktūrą. Tam buvo taikomi keli duomenų apdorojimo etapai: tiriamosios srities išskyrimas, deformacijų laukų interpoliavimas į reguliarią gardelę, laukų segmentavimas ir statistinių požymių apskaičiavimas.

2.4.1. Tiriamosios srities išskyrimas ir deformacijų laukų interpoliavimas

Kiekvienam skaitiniam eksperimentui buvo eksportuojami tiriamosios srities mazgų duomenys ir atitinkamos deformacijų reikšmės. Tiriamoji sritis buvo apibrėžta stačiakampiu ROI, kuriame tikimasi didžiausios informacijos apie defekto poveikį deformacijų laukui. Tokiu būdu iš viso modelio pašalinamos tolimosios sritys, kuriose deformacijų pasiskirstymas mažiau susijęs su nagrinėjamais pažeidimais.

Kad visi skaitiniai atvejai turėtų vienodą duomenų struktūrą, deformacijų laukai buvo interpoliuojami į reguliarią gardelę. Interpoliacijai naudojamos mazgų koordinatės x, y ir atitinkamos deformacijų reikšmės. Pagrindiniuose tyrimuose naudotos trys plokštuminės deformacijų dedamosios: $\varepsilon_x, \varepsilon_y, \gamma_{xy}$. Šie laukai pasirinkti todėl, kad jie tiesiogiai atitinka DIC metodu gaunamus paviršiaus deformacijų duomenis ir gali būti taikomi tiek sintetiniams BEM rezultatams, tiek eksperimentiniams matavimams.

Interpoliacijos metu nereguliarame BE tinkle esantys deformacijų duomenys buvo perkelti į reguliarią $N_x \times N_y$ gardelę. Tokia reprezentacija leidžia kiekvieną skaitinį atvejį saugoti vienodo formato duomenų faile ir užtikrina, kad vėlesniuose ML eksperimentuose visi bandiniai turėtų tą patį požymių skaičiavimo pagrindą.

Šiame darbe interpoliacijos gardelės dydis buvo laikomas vienu iš tiriamų duomenų reprezentacijos parametrų. Eksperimentinėje dalyje buvo nagrinėjamos keturios gardelės konfigūracijos: 48×24, 64×32, 80×40 ir 96×48. Tokie dydžiai pasirinkti siekiant įvertinti, kaip deformacijų lauko diskretizavimo tankis veikia ML modelių tikslumą. Mažesnės gardelės leidžia sumažinti duomenų

apimtį, tačiau gali prarasti lokalius defekto požymius, o didesnės gardelės išsaugo daugiau erdvinės informacijos, bet nebūtinai užtikrina geresnę modelių generalizaciją.

2.4.2. Laukų segmentavimas

Po interpoliavimo deformacijų laukai buvo skaidomi į stačiakampius segmentus. Segmentavimo tikslas – išsaugoti ne tik bendrą deformacijų lauko informaciją, bet ir lokalius erdvinius pokyčius, kurie gali būti susiję su defekto tipu, dydžiu arba orientacija. Jeigu iš viso lauko būtų skaičiuojami tik globalūs požymiai, dalis lokalsios informacijos būtų prarasta, todėl defektų parametrų regresijos užduotys taptų mažiau informatyvios.

Segmentavimo schema apibrėžiama segmentų skaičiumi $N_{seg,x} \times N_{seg,y}$. Kiekvienas segmentas apima tam tikrą interpoliacijos gardelės taškų dalį, o požymiai skaičiuojami atskirai kiekvienam segmentui ir kiekvienam deformacijų laukui. Tokiu būdu sudaromas požymių vektorius, kuris išlaiko informaciją apie deformacijų pasiskirstymą skirtingose tiriamosios srities vietose.

Segmentų dydis turi tiesioginę įtaką požymių vektoriaus dimensijai. Stambesnis segmentavimas sumažina požymių skaičių ir gali pagerinti modelių stabilumą mažesniame duomenų rinkinyje, tačiau kartu gali prarasti smulkesnius defekto sukeltus deformacijų pokyčius. Smulkesnis segmentavimas suteikia daugiau lokalsios informacijos, bet padidina požymių skaičių ir gali didinti persimokymo riziką bei modelių apmokymo laiką. Dėl šios priežasties segmentų dydžio įtaka vėliau buvo atskirai tiriama eksperimentinėje darbo dalyje.

Segmentų dydžio įtakai įvertinti buvo numatytos keturios segmentavimo konfigūracijos: 8×4 , 16×8 , 24×12 ir 32×16 segmentai. Eksperimentinėje dalyje kiekviena segmentavimo konfigūracija buvo derinama su skirtingomis interpoliacijos gardelėmis, sudarant 4×4 interpoliacijos gardelių ir segmentų kombinacijų matricą.

2.4.3. Požymių rinkinių struktūra

Iš kiekvieno deformacijų lauko ir kiekvieno segmento buvo apskaičiuojami statistiniai požymiai, apibūdinantys deformacijų reikšmių pasiskirstymą. Tokie požymiai leidžia sumažinti pirminių laukų dimensiją ir pateikti ML modeliams kompaktišką, tačiau fiziškai interpretuojamą informacijos rinkinį.

Pagrindinėje analizėje naudota *segments_basic* požymių grupė, kurioje kiekvienam segmentui apskaičiuojami baziniai statistiniai rodikliai. Jie apibūdina deformacijų reikšmių vidutinį lygį, sklaidą ir ekstremalias reikšmes. Bendra požymių formavimo logika gali būti aprašoma taip: kiekvienam laukui $f \in \{\varepsilon_x, \varepsilon_y, \gamma_{xy}\}$ ir kiekvienam segmentui S_i apskaičiuojamas požymių rinkinys, sudarantis vieną bendrą įvesties vektorių:

$$x = [\varphi(S_1^{\varepsilon_x}), \varphi(S_1^{\varepsilon_y}), \varphi(S_1^{\gamma_{xy}}), \dots, \varphi(S_n^{\varepsilon_x}), \varphi(S_n^{\varepsilon_y}), \varphi(S_n^{\gamma_{xy}})]$$

Čia $\varphi(S_i)$ žymi statistinių požymių rinkinį, apskaičiuotą iš segmento S_i reikšmių. Tokiu būdu kiekvienas skaitinis atvejis paverčiamas vienu požymių vektoriumi, kurį galima naudoti klasifikavimo ir regresijos modeliams.

Be segmentuotų požymių, kai kuriuose eksperimentuose buvo naudojami ir globalūs požymiai (*global_all*), apskaičiuojami iš viso deformacijų lauko be segmentavimo. Šie požymiai naudoti kaip palyginamasis atvejis, leidžiantis įvertinti, ar lokali segmentų informacijos įtraukimas pagerina modelių veikimą.

2.4.4. Įvesties ir išvesties kintamieji

Suformuoti požymių vektoriai buvo naudojami kaip ML modelių įvestis. Išvesties kintamieji buvo sudaryti pagal DOE faile nurodytus defektų parametrus. Šiame darbe spęstos dvi klasifikavimo ir trys regresijos užduotys.

Klasifikavimo užduotyse modeliai turėjo nustatyti, ar tiriamame atvejyje yra įpjova ir ar yra atsisluoksniavimas. Regresijos užduotyse buvo prognozuojami kiekybiniai defektų parametrai: įpjovos gylis, įpjovos kampas ir atsisluoksniavimo ilgis. Tokia užduočių struktūra leidžia įvertinti metodiką dviem lygiais: pirma, ar pažeidimas gali būti aptiktas, ir antra, ar jo parametrai gali būti įvertinti kiekybiškai.

Kiekvienam skaitiniam atvejui kartu su požymių vektoriumi buvo saugoma ir papildoma informacija: bandinio identifikatorius, defekto tipas, įpjovos bei atsisluoksniavimo parametrai, ROI ribos, interpoliacijos gardelės dydis ir naudoti fiziniai laukai. Tai leido automatizuotai susieti skaitinius rezultatus su DOE parametrų lentele ir užtikrinti eksperimentų atkuriamumą.

Duomenų apdorojimo ir požymių formavimo eiga buvo svarbi visiems tolimesniems ML eksperimentams. Interpoliacijos gardelės dydis, segmentavimo schema ir naudojami deformacijų laukai tiesiogiai lemia požymių vektoriaus struktūrą, todėl gali paveikti tiek modelio tikslumą, tiek apmokymo laiką.

Ta pati duomenų apdorojimo logika buvo taikoma tiek sintetiniams BEM duomenims, tiek eksperimentiniams DIC duomenims. Eksperimentinių DIC laukų atveju ROI ribos, interpoliacijos gardelė ir naudojami deformacijų komponentai buvo suderinti su atitinkamai pergeneruotu sintetinių duomenų rinkiniu. Taip buvo užtikrinta, kad realių matavimo duomenų įvestis atitiktų modelių apmokymo metu naudotą duomenų reprezentaciją.

2.5. Mašininio mokymosi metodika

2.5.1. Mašininio mokymosi užduočių formulavimas

Šiame darbe mašininio mokymosi modeliai naudojami kompozitinės plokštelės defektams identifikuoti ir jų parametrus prognozuoti pagal iš deformacijų laukų suformuotus požymių vektorius. Modelių įvestį sudaro 2.4 poskyryje aprašyti požymiai, apskaičiuoti iš interpoliuotų ir segmentuotų deformacijų laukų $\varepsilon_x, \varepsilon_y, \gamma_{xy}$. Išvesties kintamieji apibrėžiami pagal DOE faile nurodytus defektų parametrus.

Tyrime sprendžiamos penkios mašininio mokymosi užduotys: dvi klasifikavimo ir trys regresijos. Klasifikavimo užduotys skirtos nustatyti, ar nagrinėjamame atvejyje yra įpjova ir ar yra tarp sluoksninis atsisluoksniavimas. Tokia formuluotė leidžia įvertinti, ar deformacijų laukuose esanti informacija yra pakankama defekto buvimui aptikti, nepriklausomai nuo jo tikslų geometrinių parametrų.

Regresijos užduotys skirtos kiekybiniam defektų parametų įvertinimui. Šiame darbe prognozuojamas įpjovos gylis, įpjovos kampas ir atsiskuoksnavimo ilgis. Šie parametrai pasirinkti todėl, kad jie apibūdina skirtingus pažeidimo aspektus: įpjovos gylis nusako defekto dydį per storį, įpjovos kampas – jo orientaciją apkrovos krypties atžvilgiu, o atsiskuoksnavimo ilgis – vidinio tarpfluoksninio pažeidimo mastą.

Tokia užduočių struktūra leidžia metodiką įvertinti dviem lygiais. Pirmiausia tikrinama, ar modeliai geba atpažinti defekto buvimą, o vėliau vertinama, ar iš tų pačių deformacijų laukų galima gauti kiekybinį pažeidimo parametų įvertinimą. Klasifikavimo ir regresijos užduočių atskyrimas taip pat leidžia aiškiau analizuoti, kurie defektų požymiai deformacijų laukuose yra lengvai aptinkami, o kuriems reikalinga detalesnė erdvinė informacija ir sudėtingesni ML modeliai.

2.5.2. Naudoti ML modeliai ir hiperparametų tyrimo logika

Mašininio mokymosi modeliai buvo parinkti taip, kad būtų galima palyginti skirtingo sudėtingumo algoritmus, veikiančius su struktūrizuotais požymių vektoriais. Kadangi šiame darbe naudojami ne pirminiai vaizdai, o iš deformacijų laukų apskaičiuoti statistiniai požymiai, pasirinkti klasikiniai prižiūravimo mokymosi metodai. Tokia strategija leidžia aiškiau įvertinti požymių formavimo, segmentavimo ir modelio tipo įtaką rezultatams.

Klasifikavimo užduotims buvo taikomi baziniai klasifikavimo modeliai, įskaitant logistinę regresiją, atraminių vektorių klasifikatorių ir medžių ansamblių metodus. Logistinė regresija naudota kaip paprastas ir stabilus bazinis modelis, leidžiantis įvertinti, ar defekto buvimas gali būti nustatomas pagal tiesines požymių kombinacijas. Sudėtingesni klasifikatoriai buvo įtraukti siekiant patikrinti, ar netiesinės sprendimo ribos suteikia papildomos naudos defektų aptikimo užduotyse.

Regresijos užduotims naudoti keli skirtingo pobūdžio modeliai: Ridge regresija, atraminių vektorių regresija su RBF branduoliu (SVR), atsitiktinių miškų regresija (Random Forest) ir gradientinio stiprinimo regresija (Gradient Boosting). Ridge regresija pasirinkta kaip reguliari tiesinė regresija, tinkama tada, kai ryšys tarp požymių ir prognozuojamo parametro gali būti pakankamai gerai aprašomas tiesiniu modeliu. SVR su RBF branduoliu leidžia modeliuoti netiesines priklausomybes ir gali būti veiksmingas riboto dydžio duomenų rinkiniuose. Random Forest ir Gradient Boosting modeliai pasirinkti kaip medžių ansambliai, galintys aprašyti sudėtingesnius ir lokaliai kintančius ryšius tarp deformacijų požymių ir defektų parametų.

Modelių palyginimas buvo atliekamas etapais. Pirmiausia visi pasirinkti modeliai buvo vertinami naudojant numatytasias *scikit-learn* hiperparametų reikšmes (žr. **2.1 lentelė**). Šis etapas buvo skirtas bendroms modelių tendencijoms nustatyti ir parinkti modelius, kuriuos vėliau detaliau tirti konkrečiose regresijos užduotyse. Vėliau hiperparametų analizė buvo atliekama tik tiems modeliams, kurie ankstesniuose bandymuose pasirodė stabiliausi arba tiksliausi.

2.1 lentelė. Bazinės ML modelių hiperparametų konfigūracijos

Užduoties tipas	ML modelis	Scikit-learn klasė	Bazinės hiperparametų reikšmės
Klasifikavimas	Logistinė regresija	LogisticRegression	C=1.0, penalty='l2', solver='lbfgs', max_iter=1000, random_state=42

Klasifikavimas	SVC	SVC	C=1.0, kernel='rbf', gamma='scale', class_weight=None
Klasifikavimas	Random Forest	RandomForestClassifier	n_estimators=100, criterion='gini', max_depth=None, random_state=42
Klasifikavimas	Gradient Boosting	GradientBoostingClassifier	n_estimators=100, learning_rate=0.1, max_depth=3, random_state=42
Regresija	Ridge	Ridge	alpha=1.0, fit_intercept=True, solver='auto'
Regresija	SVR	SVR	C=1.0, kernel='rbf', gamma='scale', epsilon=0.1
Regresija	Random Forest	RandomForestRegressor	n_estimators=100, max_depth=None, random_state=42
Regresija	Gradient Boosting	GradientBoostingRegressor	n_estimators=100, learning_rate=0.1, max_depth=3, random_state=42

Hiperparametrų tyrimas buvo formuluojamas tikslingai, atsižvelgiant į konkrečių regresijos užduočių rezultatus. Įpjovos kampo regresijai buvo analizuojamas Ridge modelio reguliavimo parametras α . Atsisluoksniavimo ilgio regresijai tirti Gradient Boosting modelio parametrai: medžių skaičius, medžių gylis ir mokymosi greitis. Įpjovos gylio regresijos atveju detaliau lyginti Gradient Boosting ir SVR modeliai, nes ankstesni rezultatai parodė, kad abu metodai gali būti tinkami šiai užduočiai, tačiau pasižymi skirtingu tikslumo ir skaičiavimo sąnaudų santykiu.

Toks modelių tyrimo principas leidžia išvengti perteklinio algoritmų skaičiaus didinimo ir išlaikyti aiškia analizės logiką. Šiame darbe modelių parinkimas grindžiamas ne vien siekiu gauti mažiausią paklaidą, bet ir noru įvertinti, kokio sudėtingumo modelio reikia skirtingiems defektų parametrų prognozuoti. Dėl šios priežasties vėlesnėje eksperimentinėje dalyje modelių rezultatai vertinami kartu su apmokymo bei prognozavimo laiku.

2.5.3. Modelių apmokymas, validavimas ir vertinimo rodikliai

Mašininio mokymosi modelių apmokymui buvo naudojami sintetiniai BEM duomenys, sudaryti pagal DOE metodiką. Kiekvienas skaitinis atvejis turėjo žinomus defektų parametrus ir iš deformacijų laukų suformuotą požymių vektorių. Tokia duomenų struktūra leido taikyti prižiūrimojo mokymosi metodus, kai modelis mokomas susieti įvesties požymius su iš anksto žinomais klasifikavimo arba regresijos tikslais. Modelių vertinimui buvo taikomi du lygiai: kryžminė validacija (CV) ir nepriklausomas validavimo duomenų rinkinys. Kryžminė validacija naudota siekiant įvertinti modelio stabilumą treniravimo rinkinio viduje ir sumažinti priklausomybę nuo vieno atsitiktinio duomenų padalijimo. Klasifikavimo užduotims taikytas stratifikavimas, t. y. duomenų padalijimas išlaikant defektų klasių proporcijas skirtingose imtyse. Nepriklausomas validavimo duomenų rinkinys skirtas įvertinti, kaip modeliai veikia su anksčiau nematytomis defektų parametrų kombinacijomis. Toks vertinimas šiame darbe yra svarbus, nes vien kryžminė validacija gali

nepakankamai atskleisti modelio gebėjimo generalizuoti į naujus defektų scenarijus, ypač kai treniravimo duomenų rinkinys yra riboto dydžio.

Klasifikavimo užduotims vertinti naudotas tikslumas (ACC) ir subalansuotas tikslumas (BACC). Tikslumas parodo teisingai klasifikuotų atvejų dalį, o subalansuotas tikslumas leidžia patikimiau įvertinti modelio veikimą, kai klasės nėra visiškai vienodai pasiskirsčiusios.

Regresijos užduotims pagrindine vertinimo metrika pasirinkta vidutinė absoliutinė paklaida (MAE). Ši metrika yra patogi inžinerinei interpretacijai, nes pateikiama tais pačiais vienetais kaip prognozuojamas parametras: įpjovos gylio ir atsisluoksniavimo ilgio atveju – milimetrais, o įpjovos kampo atveju – laipsniais. Papildomai buvo skaičiuojami RMSE ir R^2 rodikliai, tačiau pagrindinė rezultatų analizė grindžiama MAE, nes ji tiesiogiai parodo vidutinį prognozės nuokrypį nuo tikrosios reikšmės.

Be tikslumo rodiklių, buvo vertinamas ir modelių apmokymo bei prognozavimo laikas. Šie rodikliai leidžia įvertinti, ar nedidelis tikslumo pagerėjimas nėra pasiekiamas neproporcingai didelėmis skaičiavimo sąnaudomis. Tai ypač aktualu analizuojant segmentų skaičiaus įtaką ir lyginant skirtingo sudėtingumo modelius, tokius kaip Ridge, SVR, Random Forest ir Gradient Boosting.

2.5.4. Eksperimentinių DIC duomenų taikymas modelių patikrinimui

Nors pagrindinis modelių apmokymas ir vertinimas buvo atliekamas naudojant sintetinius BEM skaičiavimais sugeneruotus duomenis, papildomai buvo atliktas metodikos patikrinimas su eksperimentiniais DIC deformacijų laukais. Šis etapas skirtas įvertinti, ar sintetiniai duomenimis apmokyti modeliai gali būti pritaikomi realiems matavimo duomenims.

Eksperimentiniai DIC duomenys buvo pateikti kaip paviršiaus taškų koordinatės ir trys deformacijų komponentai: $\varepsilon_x, \varepsilon_y, \gamma_{xy}$. Kad šie duomenys būtų suderinami su ML modelių įvesties struktūra, jie buvo apdorojami ta pačia logika kaip ir sintetiniai duomenys: išskiriama tiriamoji sritis, deformacijų laukai interpoliuojami į reguliarią gardelę, segmentuojami ir paverčiami požymių vektoriais.

Eksperimentinių DIC duomenų atveju buvo naudojama tiriamoji sritis, apibrėžta pagal realaus matavimo lauką. Dėl to sintetinis duomenų rinkinys modelių apmokymui buvo pergeneruotas taip, kad ROI ribos ir interpoliacijos gardelė sutaptų su eksperimentinių duomenų paruošimo schema. Tai buvo būtina, nes modeliai yra jautrūs duomenų reprezentacijai: skirtinga tiriamosios srities padėtis arba gardelės struktūra gali pakeisti požymių pasiskirstymą ir pabloginti modelių prognozes.

Eksperimentinis DIC atvejis buvo naudojamas kaip galutinis modelių patikrinimas. Klasifikavimo modeliai turėjo nustatyti, ar bandinyje yra įpjova ir atsisluoksniavimas, o regresijos modeliai – įvertinti įpjovos gylį, įpjovos kampą ir atsisluoksniavimo ilgį. Kadangi eksperimentiniame bandinyje buvo žinomi pagrindiniai įpjovos parametrai, įpjovos gylio ir kampo prognozės galėjo būti tiesiogiai palygintos su realiomis reikšmėmis.

Šis patikrinimas nėra laikomas pilna eksperimentine validacija, nes naudotas vienas eksperimentinis atvejis ir ne visiems defektų parametrams buvo prieinama patikima atskaitinė reikšmė. Vis dėlto jis leidžia įvertinti svarbų metodikos aspektą – ar sintetiniai BEM duomenimis apmokyti modeliai gali būti taikomi realiems DIC deformacijų laukams, kai užtikrinamas vienodas duomenų apdorojimo ir požymių formavimo principas.

2.6. Naudojamos technologijos, įranga

Šio projekto įgyvendinimui buvo naudojama programinė įranga ir eksperimentinė įranga, skirta baigtinių elementų modeliavimui, eksperimentinių deformacijų laukų matavimui, duomenų apdorojimui ir mašininio mokymosi modelių kūrimui. Kadangi tyrimo tikslas buvo sukurti duomenimis grįstą defektų identifikavimo metodiką, pagrindinis dėmesys skirtas automatizuotam sintetinių duomenų generavimui, požymių formavimui ir klasikinių mašininio mokymosi modelių taikymui.

Skaitiniai eksperimentai buvo atliekami naudojant ANSYS Mechanical APDL (MAPDL) aplinką. Joje buvo realizuotas parametrizuotas CFRP plokštelės baigtinių elementų modelis, leidžiantis keisti įpjovos ir atsiskuksniavimo parametrus, generuoti skirtingus pažeidimų scenarijus, tiriamąją kompozitinę plokštelę apkrovus eksperimentui identiškoms apkrovomis. MAPDL aplinka taip pat buvo naudojama deformacijų, poslinkių ir įtempių laukų eksportavimui iš pasirinktos dominančios srities. Skaitinių eksperimentų automatizavimui ir rezultatų apdorojimui buvo naudojama PyMAPDL sąsaja, leidžianti integruoti ANSYS BE modelį ir skaičiavimus su Python pagrindu realizuota duomenų generavimo ir apdorojimo eiga.

Eksperimentiniams duomenims gauti buvo taikoma skaitmeninio vaizdo koreliacijos (DIC) metodika. Bandymų metu CFRP bandiniai buvo apkraunami naudojant INSTRON E10000 bandymo mašiną, o bandinio paviršiaus vaizdai fiksuojami DIC sistema. Iš DIC matavimų gauti paviršiaus deformacijų laukai vėliau buvo naudojami galutiniam apmokytų mašininio mokymosi modelių pritaikymui ir prognozių patikrinimui. Šiame tyrime naudota, MIDFe surinkta kompozitinės ploštelės su defektais eksperimentinių rezultatų duomenų bazė su paviršiaus taškų ID, jų koordinatėmis, poslinkiais (x, y ir z kryptimis), bei jų deformacijų komponentėmis.

Pagrindinė programavimo kalba šiame darbe buvo Python. Ji buvo naudojama DOE lentelių sudarymui, MAPDL rezultatų apdorojimui, deformacijų laukų interpoliacijai, požymių formavimui, mašininio mokymosi modelių apmokymui, validavimui ir rezultatų vizualizavimui. Darbo metu naudotos šios pagrindinės Python bibliotekos: NumPy ir Pandas duomenų struktūroms, lentelėms ir skaitiniams masyvams apdoroti; SciPy deformacijų laukų interpoliacijai ir reguliarią gardelę; Scikit-learn klasifikavimo ir regresijos modeliams, kryžminei validacijai, tikslumo rodiklių skaičiavimui ir modelių išsaugojimui; Matplotlib rezultatų grafikams ir vizualizacijoms sudaryti.

Programavimo ir eksperimentų vykdymo aplinkai buvo naudojami Visual Studio Code ir Jupyter Notebook. Visual Studio Code buvo taikoma pagrindinių Python skriptų kūrimui ir vykdymui, o Jupyter Notebook naudotas rezultatų analizei, lentelių formavimui ir ataskaitoje naudojamų grafikų generavimui. Tarpiniai ir galutiniai duomenys buvo saugomi struktūrizuotais formatais: .csv lentelėse, .npz masyvų rinkiniuose, .json metaduomenų failuose ir .pkl apmokytų modelių failuose.

Mašininio mokymosi dalyje buvo naudojami klasikiniai prižiūrimojo mokymosi metodai: logistinė regresija defektų klasifikavimui, Ridge regresija, Gradient Boosting regresija, atraminių vektorių regresija ir atsitiktinių miškų metodai regresijos uždaviniams. Galutinėje DIC taikymo sistemoje apmokyti modeliai buvo išsaugomi ir vėliau naudojami naujiems eksperimentiniams DIC deformacijų laukams įvertinti.

2.7. Tyrimo įgyvendinimo eiga

Tyrimo įgyvendinimo eiga apima eksperimentinių DIC duomenų, baigtinių elementų modelio, sintetinių duomenų generavimo ir mašininio mokymosi modelių taikymo etapus. Pirmieji metodikos etapai – CFRP bandinio paruošimas, dirbtinių pažeidimų suformavimas, eksperimentinių DIC duomenų gavimas ir pradinio baigtinių elementų modelio sudarymas – buvo atlikti ankstesniame tyrime „Quantitative Damage Detection and Evolution in Composite Structures Using Digital Image Correlation, Machine Learning, and Peridynamics“ [17]. Šiame darbe šie rezultatai naudojami kaip pradinė eksperimentinė ir skaitinė bazė, o pagrindinis dėmesys skiriamas sintetinių duomenų sudarymui, jų apdorojimui, požymių formavimui ir mašininio mokymosi modelių tyrimui.

Tyrimo eiga:

1. CFRP bandinio ir dirbtinių pažeidimų apibrėžimas.

Ankstesniame tyrime [17] buvo apibrėžta CFRP plokštelės geometrija, sluoksnių struktūra ir dirbtinių pažeidimų schema. Tyrime nagrinėti du pagrindiniai defektų tipai – įpjova ir tarp sluoksniinis atsisluoksniavimas. Šiame darbe ši defektų schema naudojama kaip pagrindas tolesniam parametrizuotam duomenų generavimui ir ML užduočių formulavimui.

2. Eksperimentinių DIC deformacijų laukų gavimas.

Straipsnyje [17] atliktų mechaninių bandymų metu buvo gauti eksperimentiniai DIC deformacijų laukai. Šie duomenys šiame darbe naudojami ne kaip pagrindinis modelių apmokymo rinkinys, o kaip realių matavimo duomenų šaltinis galutiniam ML modelių patikrinimui. Tokiu būdu galima įvertinti, ar sintetiniai BEM duomenimis apmokyti modeliai gali būti taikomi eksperimentiniams deformacijų laukams.

3. Baigtinių elementų modelio sudarymas ir parametrizavimas.

Pradinis baigtinių elementų modelis taip pat buvo sudarytas ankstesniame tyrime [17]. Šiame darbe šis modelis naudojamas kaip skaitinis pagrindas sintetiniams duomenims generuoti. Modelis buvo taikomas parametriniams skaičiavimams, kuriuose keičiami įpjovos ir atsisluoksniavimo parametrai, siekiant gauti skirtingus pažeidimų scenarijus ir atitinkamus deformacijų laukus.

4. Defektų parametrų erdvės apibrėžimas ir DOE sudarymas.

Šiame darbe buvo sudarytos DOE lentelės, apibrėžiančios įpjovos gylio, įpjovos kampo ir atsisluoksniavimo ilgio kombinacijas. DOE struktūra parinkta taip, kad ribotu skaitinių eksperimentų skaičiumi būtų padengta kuo platesnė defektų parametrų erdvė. Atskirai sudaryti treniravimo ir nepriklausomo validavimo duomenų rinkiniai.

5. Sintetinių duomenų generavimas naudojant BEM modelį.

Pagal DOE lentelėse apibrėžtas parametrų kombinacijas buvo vykdomi skaitiniai eksperimentai. Kiekvienam atvejui buvo generuojami paviršiaus deformacijų laukai ir saugomos tikrosios defektų parametrų reikšmės. Tokiu būdu sudarytas anotuotas sintetinis duomenų rinkinys, naudojamas ML modeliams apmokyti ir vertinti.

6. Skaitinių rezultatų apdorojimas ir požymių formavimas.

Iš BEM rezultatų eksportuoti tiriamosios srities deformacijų laukai buvo interpoliuojami į reguliarias gardeles, segmentuojami ir paverčiami statistinių požymių vektoriais. Šiame etape užtikrinama, kad visi skaitiniai atvejai turėtų vienodą įvesties struktūrą, tinkamą klasikiniam mašininio mokymosi modeliams.

7. Mašininio mokymosi užduočių formulavimas ir modelių apmokymas.

Paruošti požymių vektoriai buvo naudojami dviem klasifikavimo ir trimis regresijos uždutims spręsti. Klasifikavimo uždutyse modeliai nustatė įpjovos ir atsisluoksniavimo buvimą, o regresijos uždutyse prognozavo įpjovos gylį, įpjovos kampą ir atsisluoksniavimo ilgį.

8. Duomenų reprezentacijos, modelių ir hiperparametrų įtakos tyrimas.

Eksperimentinėje dalyje buvo vertinama interpoliacijos gardelės dydžio, segmentų skaičiaus, ML modelio tipo ir hiperparametrų įtaka modelių tikslumui bei skaičiavimo laikui. Šis etapas leido įvertinti, kurios duomenų reprezentacijos ir modelių konfigūracijos yra tinkamiausios skirtingoms defektų identifikavimo bei parametrų prognozavimo uždutims.

9. Patikrinimas naudojant eksperimentinius DIC duomenis.

Galutiniame etape apmokyti modeliai buvo pritaikyti eksperimentiniams DIC deformacijų laukams iš tyrimo [17]. Kad DIC duomenys būtų suderinami su ML modelių įvestimi, jie buvo apdoroti ta pačia logika kaip ir sintetiniai duomenys: išskirta ROI sritis, deformacijų laukai interpoliuoti į reguliarią gardelę, segmentuoti ir paversti požymių vektoriais. Šis etapas leido įvertinti metodikos pritaikomumą realiems matavimo duomenims.

3. ML modelių skirtų defektų identifikavimui rezultatų analizė

3.1. Duomenų generavimo ir ML eksperimentų įgyvendinimas

Šiame darbe sukurta integruota duomenų generavimo ir mašininio mokymosi eksperimentų vykdymo sistema, apimanti visus etapus nuo skaitinių eksperimentų vykdymo iki modelių apmokymo ir rezultatų vertinimo. Skaitiniai skaičiavimai buvo vykdomi naudojant ANSYS Mechanical APDL (MAPDL), o duomenų apdorojimas, požymių formavimas ir mašininio mokymosi modelių taikymas buvo realizuoti Python programavimo kalba.

Duomenų generavimo etapas buvo automatizuotas naudojant parametrizuotą APDL modelį, kuris leidžia keisti defektų parametrus ir generuoti atitinkamus fizinius laukus. Kiekvienas skaitinis eksperimentas buvo inicijuojamas pagal DOE faile apibrėžtus parametrus, o skaičiavimai vykdomi nuosekliai, generuojant atskirus rezultatų failus kiekvienam bandiniui.

BEM rezultatų eksportavimas buvo realizuotas naudojant PRNSOL komandą, leidžiančią išgauti mazgų lygio fizinius dydžius, tokius kaip poslinkiai, deformacijos ir įtempiai. Šie duomenys buvo saugomi tekstiniuose failuose, kuriuose kiekvienam mazgui priskiriamos koordinatės ir atitinkamos fizinių laukų reikšmės.

Tolimesniame etape Python scenarijai buvo naudojami šių failų apdorojimui. Duomenys buvo sujungiami pagal mazgų identifikatorius ir interpoliuojami į reguliarią gardelę, naudojant iš anksto apibrėžtą dominančią sritį. Interpoliuoti duomenys buvo saugomi struktūrizuotu „.npz“ formatu, kuriame kiekvienas bandinys pateikiamas kaip daugiamatis masyvas kartu su metaduomenimis, apibrėžiančiais defektų parametrus.

Sugeneruoti duomenų rinkiniai buvo naudojami mašininio mokymosi eksperimentuose. Požymių formavimas realizuotas Python aplinkoje: kiekvienam bandiniui buvo skaičiuojami globalūs ir segmentuoti statistiniai požymiai. Šie požymiai sudarė įvesties vektorius mašininio mokymosi modeliams.

Mašininio mokymosi eksperimentai buvo vykdomi naudojant atskirą eksperimentų vykdymo kodo scenarijų, kuris automatizuoja modelių apmokymą, kryžminę validaciją, validaciją su nepriklausomu duomenų rinkiniu ir rezultatų saugojimą. Kodo scenarijus leidžia keisti požymių rinkinius, segmentavimo parametrus ir modelių tipus, todėl buvo galima sistemingai tirti skirtingų konfigūracijų įtaką modelių veikimui.

Rezultatai buvo saugomi struktūrizuotu formatu, įskaitant modelių vertinimo rodiklius, apmokymo ir prognozavimo laikus. Tai leido vėlesniuose etapuose atlikti išsamią rezultatų analizę ir palyginimą tarp skirtingų eksperimentų konfigūracijų.

Papildomai sukurta procedūra, leidžianti apmokytus modelius pritaikyti eksperimentiniams DIC duomenims. Šiuo tikslu buvo išsaugomi geriausi modeliai ir jų naudoti požymiai, o DIC duomenys apdorojami ta pačia seka kaip ir sintetiniai BEM duomenys. Taip užtikrinamas suderinamumas tarp modelių apmokymo ir eksperimentinių duomenų vertinimo etapų.

3.2. Interpoliacijos gardelės ir segmentų dydžio įtakos tyrimas

3.2.1. Eksperimentinė schema

Šio tyrimo etapo tikslas – įvertinti, kaip du pagrindiniai deformacijų laukų reprezentacijos parametrai – interpoliacijos gardelės dydis ir segmentavimo detalumas – veikia mašininio mokymosi modelių tikslumą bei stabilumą. Kadangi šiame darbe modeliai mokomi ne tiesiogiai iš deformacijų laukų, o iš jų pagrindu apskaičiuotų statistinių požymių, galutinis požymių vektorius priklauso nuo to, koku tankiu laukas interpoliuojamas ir koku detalumu jis skaidomas į segmentus.

Interpoliacijos gardelė nusako, kiek erdvinės informacijos išsaugoma iš pradinio BEM deformacijų lauko, o segmentavimas apibrėžia, koku lokalumo lygiu ši informacija apibendrinama požymiais. Per reta gardelė arba per stambūs segmentai gali prarasti lokalius pažeidimų požymius, o per didelis detalumas gali padidinti požymių dimensiją ir pabloginti modelių generalizaciją. Todėl šiame etape abu parametrai nagrinėjami kartu.

Eksperimentuose buvo nagrinėjamos keturios interpoliacijos gardelės konfigūracijos: 48×24 , 64×32 , 80×40 ir 96×48 . Kiekviena jų buvo derinama su keturiais segmentavimo variantais: 8×4 , 16×8 , 24×12 ir 32×16 . Taip kiekvienam uždaviniui buvo sudaryta 4×4 konfigūracijų matrica, leidžianti įvertinti ne tik atskirą kiekvieno parametro poveikį, bet ir galimą jų tarpusavio sąveiką.

Modelių veikimas buvo vertinamas taikant kryžminę validaciją treniravimo duomenų rinkinyje ir nepriklausomą validavimo duomenų rinkinį. Analizė atlikta su dviem treniravimo duomenų rinkiniais: pirminiu 113 bandinių rinkiniu ir išplėstu 328 bandinių rinkiniu. Toks palyginimas leidžia įvertinti, ar gautos tendencijos išlieka stabilios keičiantis treniravimo duomenų kiekiui.

Kiekvienai interpoliacijos gardelės ir segmentavimo kombinacijai buvo atrenkamas geriausias rezultatus pasiekęs ML modelis. Klasifikacijos uždaviniuose vertinimui naudotas subalansuotas tikslumas, o regresijos uždaviniuose pagrindiniu kriterijumi laikyta MAE. Todėl pateikiami rezultatai atspindi ne visų modelių vidurkį, o geriausią konkrečios duomenų reprezentacijos ir modelio kombinacijos rezultatą.

Tolimesniuose poskyriuose pirmiausia trumpai įvertinamos klasifikacijos užduotys, o pagrindinis dėmesys skiriamas regresijos uždaviniams: įpjovos gylio, įpjovos kampo ir atsisluoksniavimo ilgio prognozavimui. Papildomai analizuojamas modelių apmokymo laikas, siekiant įvertinti tikslumo ir skaičiavimo kainos kompromisą.


3.2.2. Klasifikacijos užduočių įvertinimas

Klasifikacijos uždavinių analizė parodė, kad segmentavimo detalumo įtaka priklauso nuo konkretaus klasifikavimo scenarijaus. Įpjovos aptikimo užduotyje visoms nagrinėtoms interpoliacijos gardelės ir segmentavimo konfigūracijoms buvo pasiektas maksimalus tikslumas tiek kryžminės validacijos, tiek nepriklausomo validation DOE atveju. Tai rodo, kad įpjovos buvimas deformacijų laukuose suformuoja pakankamai aiškų požymių atsaką, kurį modeliai geba atskirti nepriklausomai nuo taikomos erdvinės reprezentacijos.


Atsisluoksniavimo aptikimo užduotis buvo sudėtingesnė, todėl jos rezultatai pateikiami atskirai. Gauti rezultatai rodo, kad segmentuoti požymiai yra informatyvesni už globalius požymius, nes leidžia geriau išsaugoti lokalius deformacijų lauko pokyčius, susijusius su atsisluoksniavimo

poveikiu. Vis dėlto skirtumai tarp kelių vidutinio detalumo segmentavimo konfigūracijų nebuvo esminiai, todėl vienareikšmiškai optimali klasifikacijos konfigūracija neišskiriama.

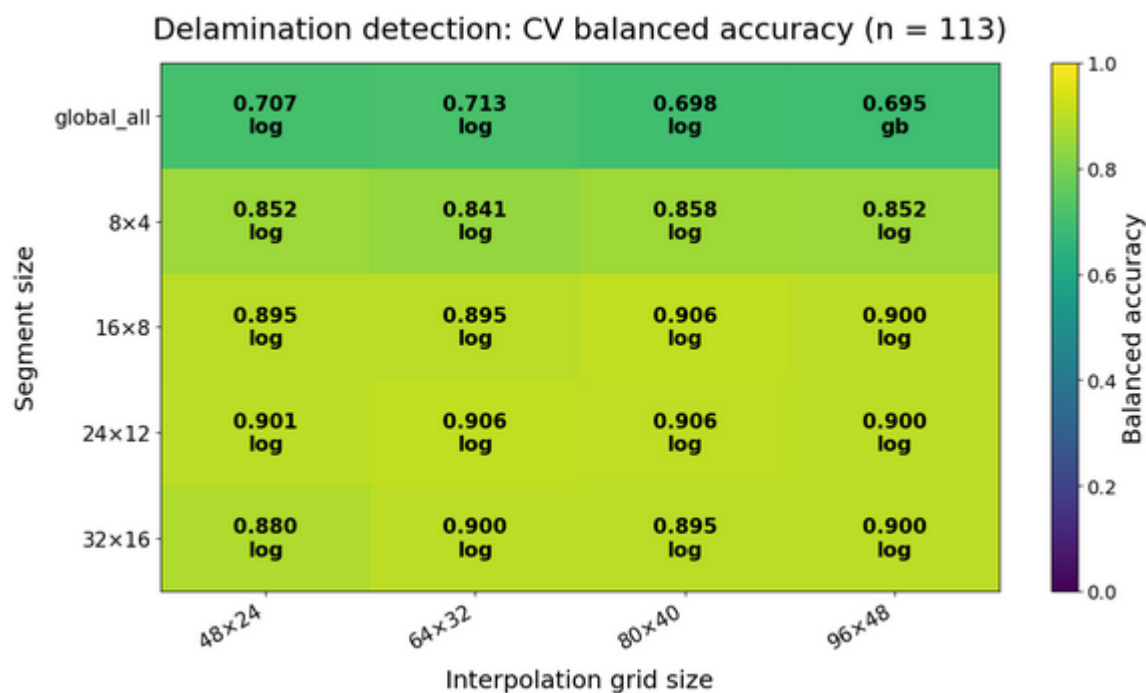
Lyginant 328 ir 113 bandinių treniravimo rinkinius matyti, kad didesnis duomenų kiekis pagerino atsisluoksniavimo aptikimo stabilumą validavimo DOE atveju (žr. **3.1 pav.**, **3.2 pav.**). Mažesniame rinkinyje smulkesnis segmentavimas dažniau gerino CV rezultatus, tačiau toks pagerėjimas ne visada išliko nepriklausomame validavimo rinkinyje (žr. **3.3 pav.**, **3.4 pav.**). Tai rodo, kad klasifikacijos rezultatai yra jautresni duomenų kiekio ir generalizacijos aspektams nei pačiam interpoliacijos ar segmentavimo parametrai.



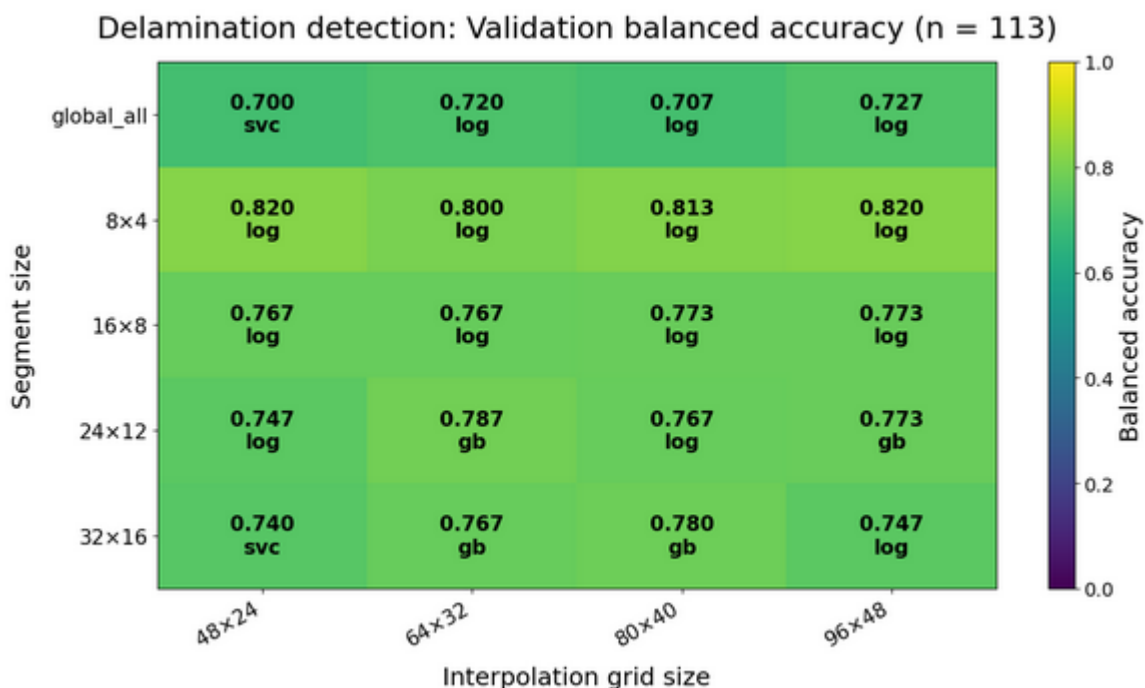
3.1 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 328 bandinių treniravimo rinkinį, CV



3.2 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE



3.3 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 113 bandinių treniravimo rinkinį, CV



3.4 pav. Atsisluoksniavimo klasifikacijos BACC rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE

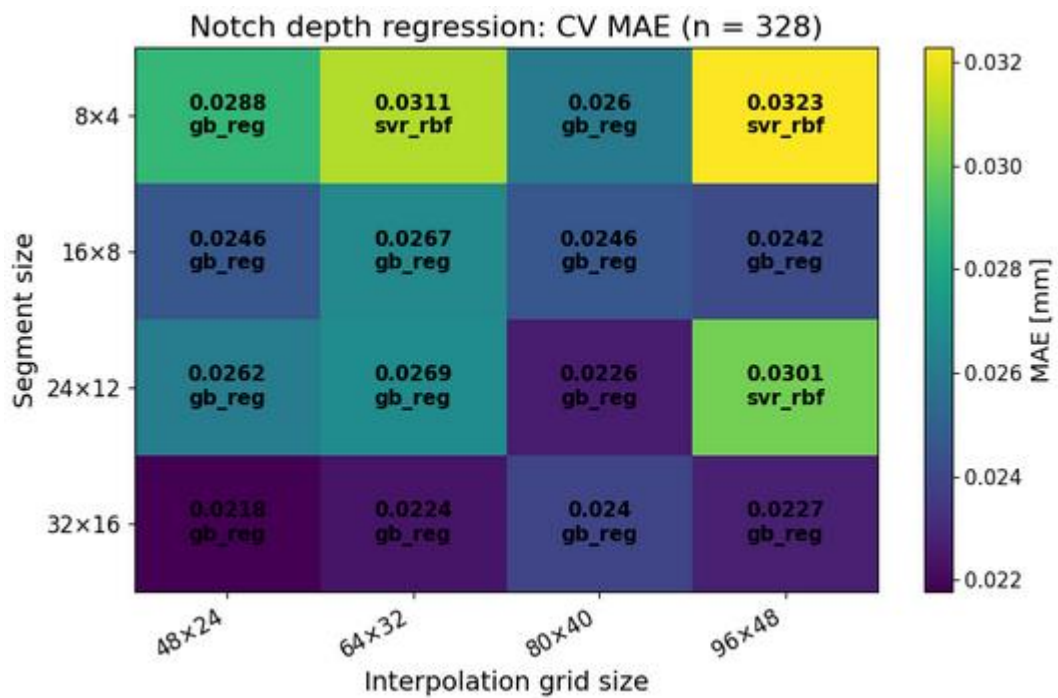
Daugumoje konfigūracijų geriausi rezultatai buvo gauti naudojant logistinę regresiją, o sudėtingesni modeliai (svc_rbf, gb_cls) dominavo tik pavieniais atvejais. Todėl atsisluoksniavimo klasifikacijoje svarbiausias veiksnys yra ne sudėtingesnė klasifikavimo architektūra, o tinkamas lokalių deformacijų požymių išsaugojimas.

Atsižvelgiant į tai, klasifikacijos užduotys šiame skyriuje nėra naudojamos kaip pagrindinis kriterijus pasirenkant interpoliacijos ir segmentavimo konfigūracijas. Tolimesnė analizė orientuojama į regresijos užduotis, kuriose šių parametrų įtaka yra ryškesnė ir svarbesnė kiekybiniam defektų parametrų įvertinimui.

3.2.3. Įpjovos gylio regresijos rezultatai

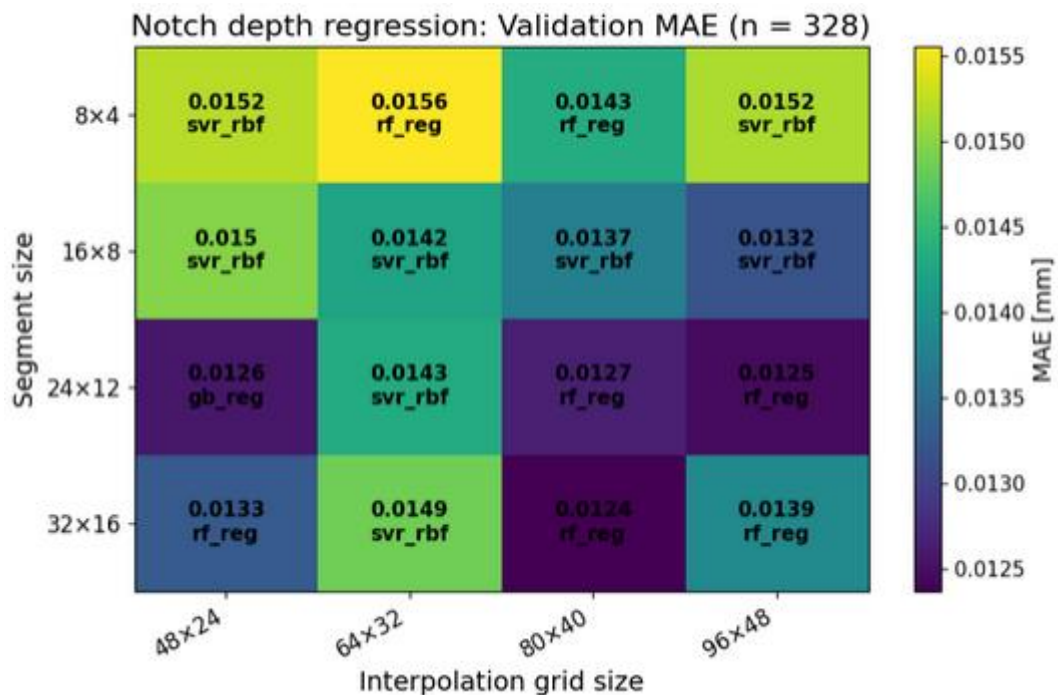
Įpjovos gylio regresijos užduotis šiame tyrime vertinama kaip papildomas regresijos atvejis, nes prognozuojamas parametras turi diskretų reikšmių rinkinį. Dėl šios priežasties absoliučios paklaidos buvo mažos visose nagrinėtose konfigūracijose, o skirtumai tarp atskirų interpoliacijos gardelės ir segmentavimo kombinacijų nėra tokie ryškūs kaip įpjovos kampo ar atsisluoksniavimo ilgio regresijos užduotyse. Vis dėlto šis uždavinys leidžia įvertinti, ar pasirinkta deformacijų laukų reprezentacija yra pakankama mažo mastelio geometriniais pažeidimo parametrams prognozuoti.

Naudojant išplėstą 328 bandinių treniravimo rinkinį, kryžminės validacijos rezultatai parodė, kad daugumoje konfigūracijų geriausias modelis buvo GB (žr. 3.5 pav.). Mažiausios CV MAE reikšmės dažniausiai buvo gaunamos taikant smulkesnį segmentavimą, ypač 32x16 segmentų tinklą. Tai rodo, kad treniravimo rinkinio viduje detalesnė požymių reprezentacija gali padėti tiksliau atskirti skirtingus įpjovos gylio lygius.



3.5 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV

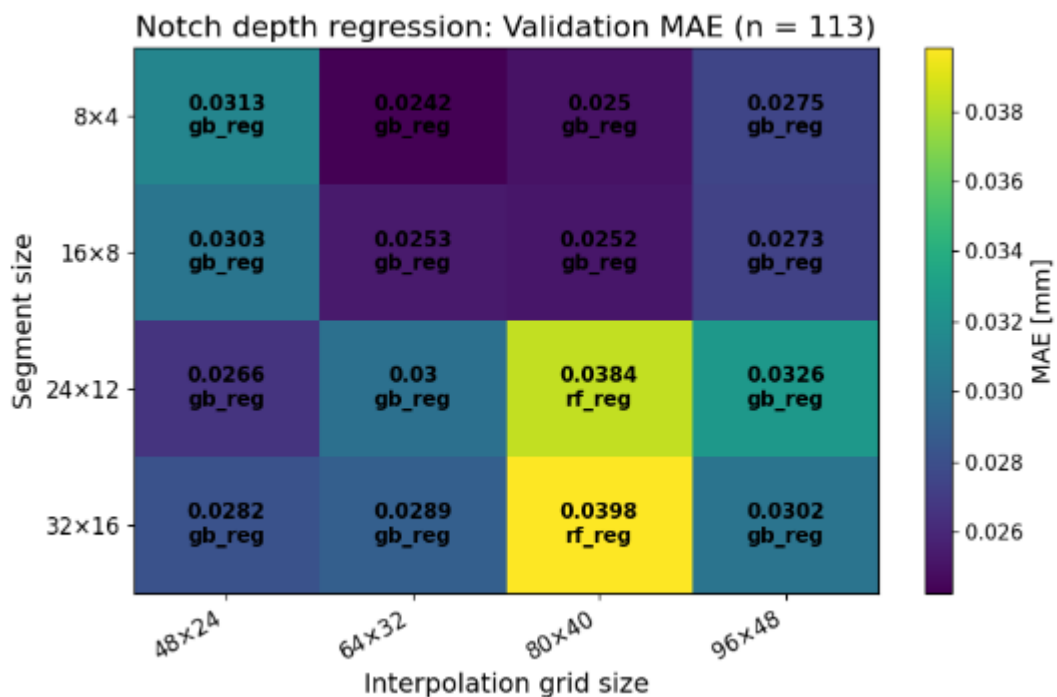
Nepriklausomo validavimo rinkinio rezultatai parodė, kad geriausi rezultatai nebuvo susiję su viena konkrečia interpoliacijos gardelės ir segmentavimo kombinacija (žr. 3.6 pav.). Mažiausios paklaidos buvo gaunamos keliuose vidutinio ir didesnio detalumo deriniuose, tačiau skirtumai tarp jų buvo nedideli. Tai rodo, kad įpjovos gylio prognozei naudinga lokali deformacijų lauko informacija, bet maksimalus gardelės tankis ar smulkiausias segmentavimas nėra būtina sąlyga geriausiam rezultatui pasiekti.



3.6 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE

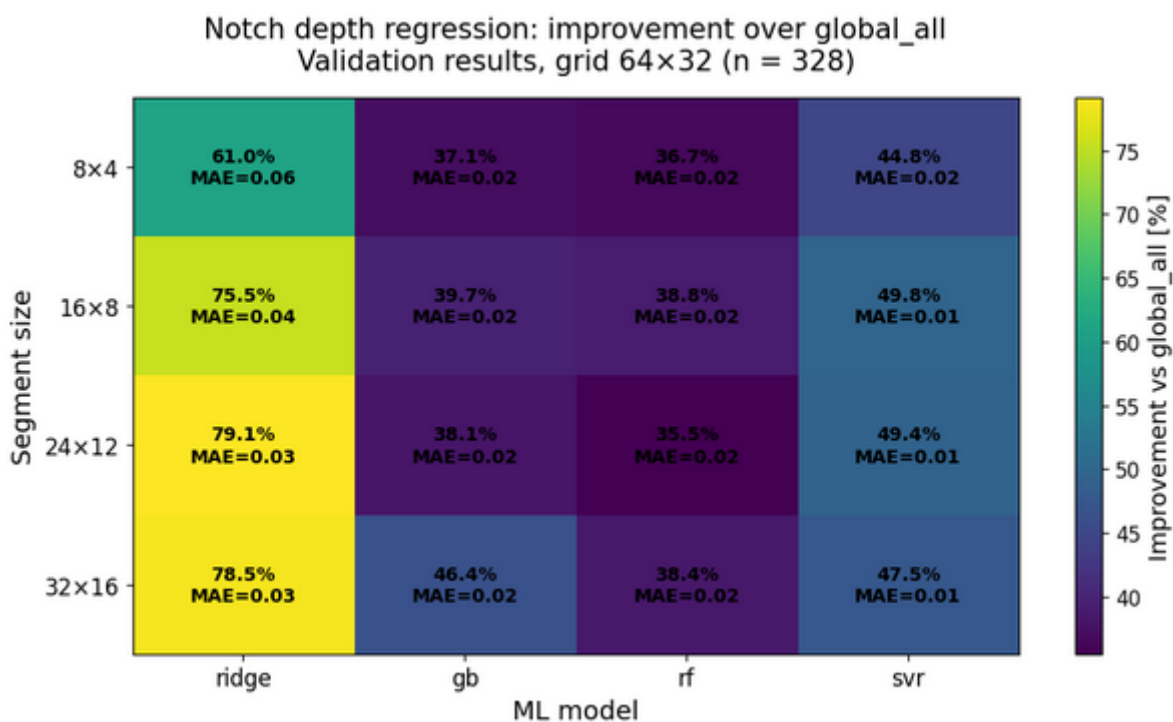
Modelių parinkimas validavimo rinkinyje taip pat skyrėsi nuo CV rezultatų. Nors kryžminės validacijos metu dažniausiai dominavo GB, nepriklausomame validavimo rinkinyje kai kuriais atvejais geriau veikė SVR arba RF. Tai leidžia manyti, kad Gradient Boosting gerai prisitaiko prie treniravimo duomenų struktūros, tačiau įpjovos gylio regresijoje, kur parametro reikšmės yra diskrečios, modelio stabilumas nepriklausomame rinkinyje tampa ne mažiau svarbus nei maža CV paklaida.

Naudojant mažesnę 113 bandinių treniravimo rinkinį, paklaidos nepriklausomame validavimo rinkinyje buvo didesnės (žr. **3.7 pav.**). Šiuo atveju geresni rezultatai dažniau buvo gaunami naudojant paprastesnes arba vidutinio detalumo segmentavimo konfigūracijas, o smulkesnės segmentacijos nebuvo nuosekliai pranašesnės. Tai rodo, kad mažesniame treniravimo rinkinyje perteklinis požymių skaičius gali pabloginti generalizaciją.



3.7 pav. Įpjovos gylio regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE

Papildomas globalių ir segmentuotų požymių palyginimas, atliktas naudojant 64×32 interpoliacijos gardelę ir nepriklausomo validavimo DOE rezultatus, parodė, kad segmentavimas pagerino įpjovos gylio regresijos tikslumą visais nagrinėtais ML modeliais (žr. **3.8 pav.**). Nors absoliučios MAE reikšmės šiame uždavinyje buvo mažos dėl diskretaus prognozuojamo parametro pobūdžio, segmentuotų požymių naudojimas sumažino paklaidas, lyginant su globaliais požymiais. Didžiausias santykinis pagerėjimas buvo stebimas Ridge modelio atveju, tačiau mažiausios absoliučios paklaidos buvo gaunamos taikant SVR, RF ir GB modelius. Tai rodo, kad lokali deformacijų lauko informacija yra naudinga net ir santykinai paprastesniam įpjovos gylio regresijos uždaviniui.




3.8 pav. Segmentuotų požymių įtaka įpjovos gylio regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328

Bendrai, įpjovos gylio regresijos rezultatai rodo, kad šiam uždaviniui nėra būtina naudoti labai tankios interpoliacijos gardelės ar smulkiausios segmentacijos. Išplėsto 328 bandinių rinkinio atveju geriausi rezultatai pasiekti naudojant vidutinio ir didesnio detalumo reprezentacijas, tačiau skirtumai tarp geriausių konfigūracijų išlieka maži. Mažesnis 113 bandinių rinkinys parodė didesnę jautrumą požymių dimensijai, todėl šiuo atveju paprastesnės segmentavimo konfigūracijos buvo stabilesnės. Globalių ir segmentuotų požymių palyginimas papildomai patvirtino, kad lokali deformacijų lauko informacija sumažina prognozavimo paklaidą, tačiau šio uždavinio atveju absoliutus pagerėjimas yra mažesnis nei sudėtingesnėse regresijos užduotyse.

3.2.4. Įpjovos kampo regresijos rezultatai

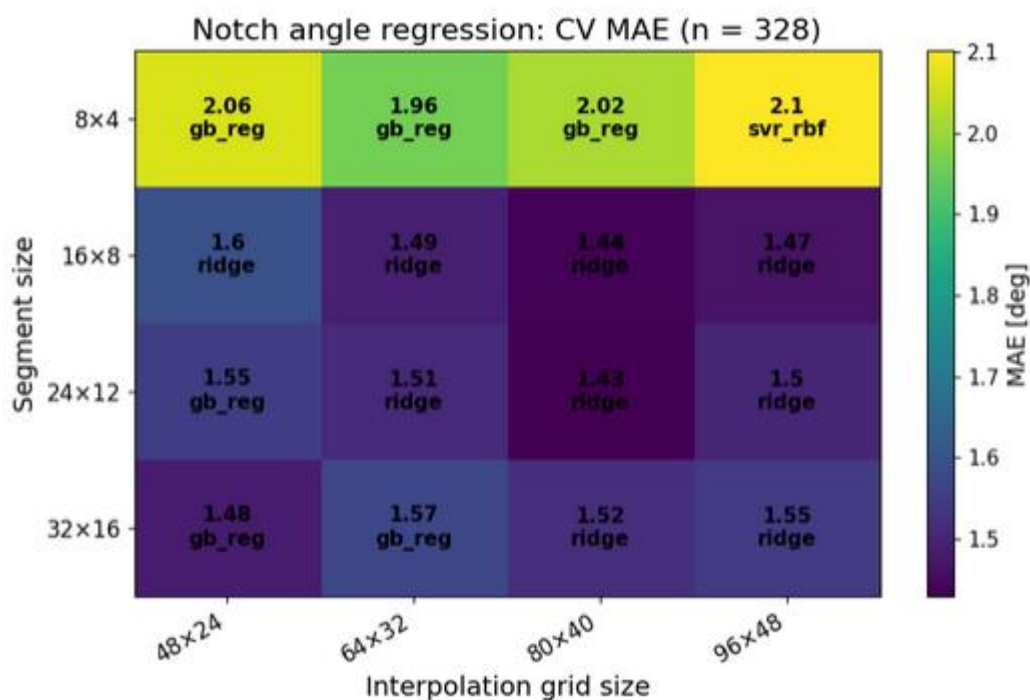
Įpjovos kampo regresija yra jautresnė erdvinei deformacijų lauko reprezentacijai nei įpjovos gylio regresija. Skirtingai nuo gylio parametro, kuris šiame darbe apibrėžtas diskrečiomis reikšmėmis, įpjovos kampas kinta platesniame intervale, todėl modelis turi tiksliau įvertinti deformacijų lauko formos ir orientacijos pokyčius. Dėl šios priežasties interpoliacijos gardelės ir segmentavimo kombinacijos šiame uždavinyje turi aiškesnę įtaką prognozavimo paklaidai.

Naudojant išplėstą 328 bandinių treniravimo rinkinį, nepriklausomo validavimo rinkinio rezultatai parodė, kad geriausios konfigūracijos buvo susijusios su vidutinio detalumo segmentavimu (žr. **3.9 pav.**). Mažiausios MAE reikšmės gautos naudojant 16×8 segmentaciją kartu su 64×32 arba 80×40 interpoliacijos gardelėmis. Tai rodo, kad kampo regresijai svarbus pakankamas deformacijų lauko detalumas, tačiau maksimali gardelės ar segmentų raiška nėra būtina.



3.9 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE

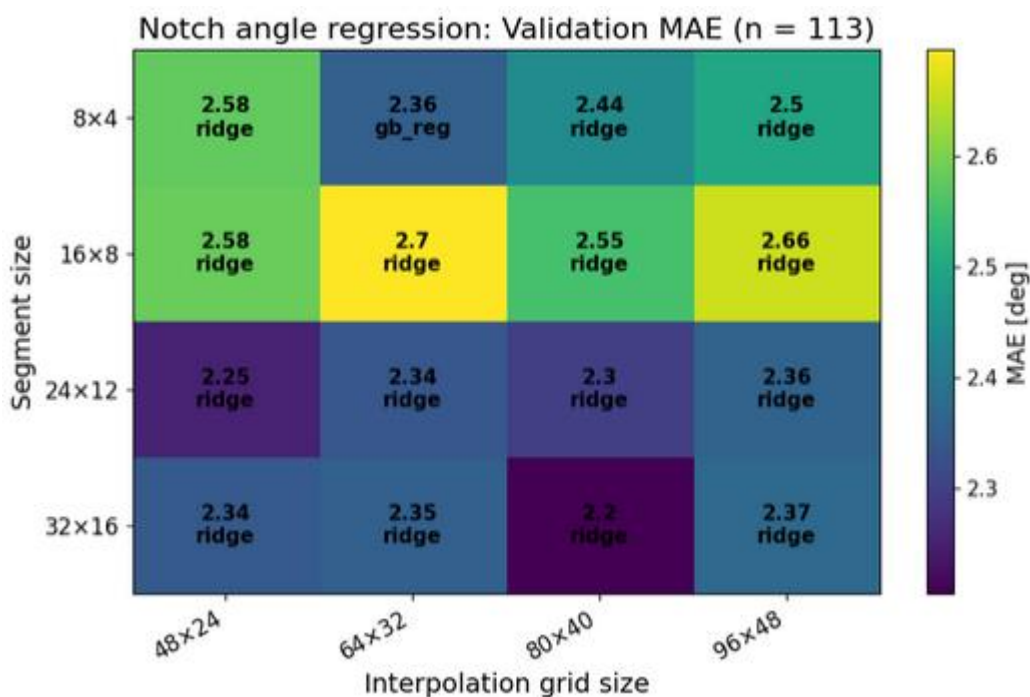
Kryžminės validacijos rezultatuose matoma panaši tendencija: geriausi rezultatai dažniausiai pasiekti naudojant 16×8 arba 24×12 segmentaciją, o 8×4 segmentacija buvo silpnesnė daugumoje interpoliacijos gardelių (žr. **3.10 pav.**). Tai leidžia teigti, kad pernelyg stambus segmentavimas praranda dalį kampui svarbios erdvinės informacijos. Kita vertus, smulkiausia 32×16 segmentacija nepranoko vidutinio detalumo konfigūracijų nepriklausomame validavimo rinkinyje, todėl papildomas požymių skaičiaus didinimas nedavė aiškios naudos generalizacijai.



3.10 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV


Modelių parinkimo požiūriu ši užduotis išsiskyrė tuo, kad daugumoje konfigūracijų geriausiai veikė Ridge regresija. Ši tendencija ypač ryški nepriklausomo validavimo rinkinyje. Tik stambiausioje 8×4 segmentacijoje dažniau buvo parenkami GB arba SVR modeliai. Tai rodo, kad tinkamai suformuoti segmentuoti požymiai leidžia įpjovos kampo priklausomybę aprašyti santykinai paprastu reguliariu linijiniu modeliu. Sudėtingesni modeliai tampa naudingesni tada, kai požymių reprezentacija yra mažiau informatyvi arba per daug apibendrinta..

Naudojant 113 bandinių treniravimo rinkinį, nepriklausomo validavimo rinkinio paklaidos buvo didesnės ir mažiau stabilios (žr. **3.11 pav.**). Geresni rezultatai buvo gaunami naudojant didesnio detalumo segmentavimo konfigūracijas, tačiau vienos aiškiai dominuojančios kombinacijos neišryškėjo. Šiuo atveju 16×8 segmentacija nebuvo nuosekliai geriausia, o tai rodo, kad mažesnis treniravimo rinkinis neleidžia taip patikimai įvertinti optimalios erdvinės reprezentacijos.




3.11 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, CV

Mažesnio rinkinio validavimo rezultatuose taip pat dažniausiai dominavo Ridge modelis. Net tais atvejais, kai CV metu geriausiu modeliu buvo GB arba RF, nepriklausomame validavimo rinkinyje dažniausiai geriau veikė Ridge regresija (žr. **3.12 pav.**). Tai sustiprina išvadą, kad įpjovos kampo regresijoje paprastesnis modelis gali generalizuoti stabiliau nei sudėtingesni ansambliniai metodai, ypač kai treniravimo duomenų kiekis ribotas.



3.12 pav. Įpjovos kampo regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE

Papildomas globalių ir segmentuotų požymių palyginimas, atliktas naudojant 64×32 interpoliacijos gardelę ir nepriklausomo validavimo DOE rezultatus, patvirtino, kad įpjovos kampo regresijai erdvinė deformacijų lauko informacija yra ypač svarbi. Visais nagrinėtais ML modeliais segmentuoti požymiai sumažino MAE reikšmes, lyginant su globaliais požymiais, o didžiausias santykinis pagerėjimas buvo gautas taikant Ridge ir SVR modelius (žr. **3.13 pav.**). Tai rodo, kad globalūs požymiai nepakankamai aprašo deformacijų lauko orientacinius pokyčius, o segmentavimas leidžia modeliams geriau išnaudoti lokalią informaciją, susijusią su įpjovos kampo kitimu.




3.13 pav. Segmentuotų požymių įtaka įpjovos kampo regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328

Apibendrinant, įpjovos kampo regresijos rezultatai rodo, kad optimaliausia reprezentacija nėra susijusi su maksimaliu interpoliacijos ar segmentavimo detalumu. Išplėsto 328 bandinių rinkinio rezultatai išskiria 16×8 segmentaciją kartu su 64×32 arba 80×40 interpoliacijos gardele kaip stabiliausias konfigūracijas. Mažesnio 113 bandinių rinkinio atveju rezultatai yra labiau kintantys, tačiau juose taip pat matyti, kad globaliai stambios reprezentacijos nėra pakankamos, o didesnio detalumo segmentacija gali kompensuoti ribotą treniravimo duomenų kiekį.

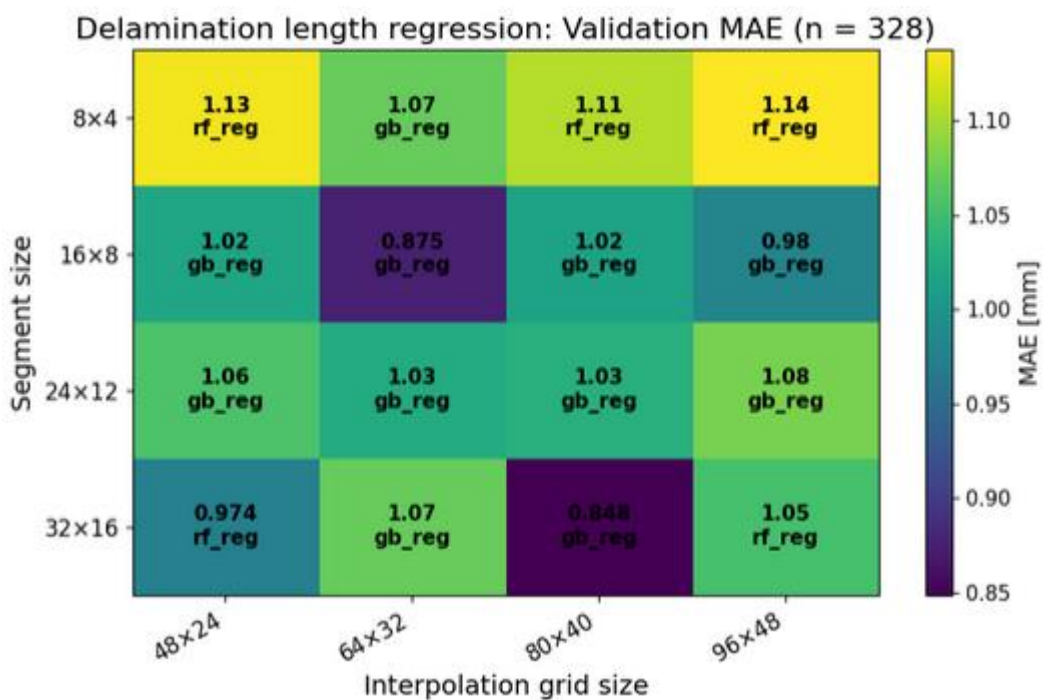
3.2.5. Atsisluoksniavimo ilgio regresijos rezultatai

Atsisluoksniavimo ilgio regresija yra vienas svarbiausių šio tyrimo uždavinių, nes šis parametras apibūdina vidinį pažeidimą, kurio poveikis paviršiaus deformacijų laukui nėra toks tiesioginis kaip įpjovos atveju. Dėl šios priežasties, ši užduotis yra jautresnė tiek interpoliacijos gardelės, tiek segmentavimo pasirinkimui, o gauti rezultatai yra ypač svarbūs vertinant visos požymių formavimo metodikos tinkamumą.

Naudojant išplėstą 328 bandinių treniravimo rinkinį, visose konfigūracijose CV rezultatuose dominavo GB modelis (žr. **3.14 pav.**). Tai rodo, kad atsisluoksniavimo ilgio regresijai reikalingas modelis, gebantis aprašyti netiesines priklausomybes tarp lokalių deformacijų požymių ir defekto parametro. Skirtingai nei įpjovos kampo regresijoje, kur dažnai pakako Ridge modelio, šiuo atveju linijiniai ryšiai nėra pakankami.



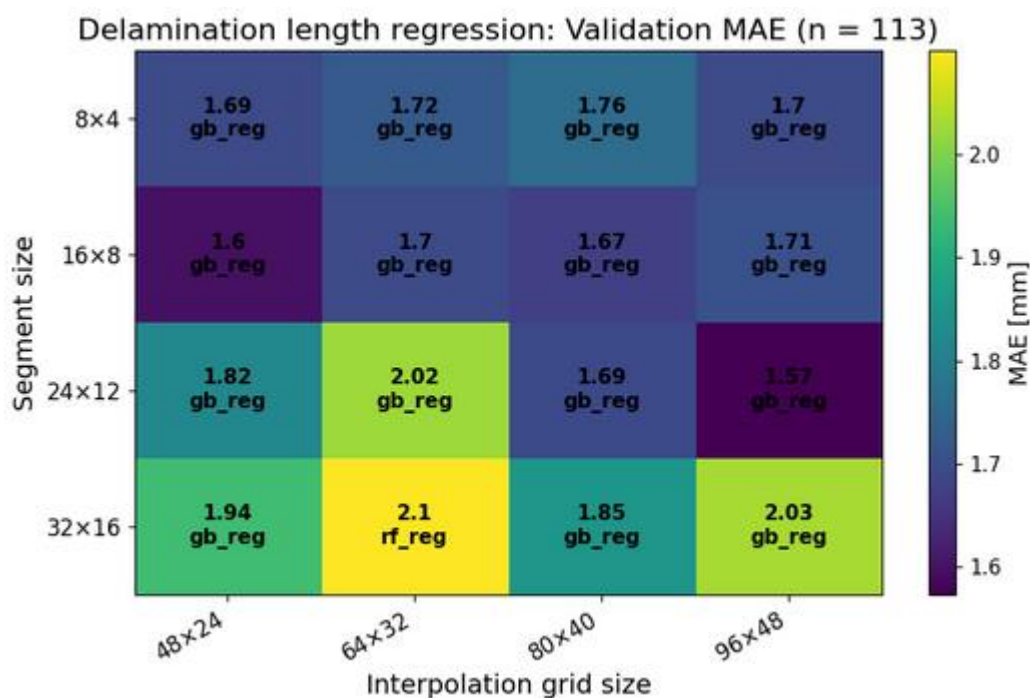
3.14 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, CV Nepriklausomo validavimo rinkinio rezultatai parodė, kad mažiausios paklaidos buvo gautos taikant vidutinio arba didesnio detalumo reprezentacijas. Geriausi rezultatai pasiekti naudojant 64×32–80×40 interpoliacijos gardses kartu su 16×8 arba 32×16 segmentavimu (žr. **3.15 pav.**). Tai rodo, kad atsisluoksniavimo ilgio prognozei svarbi lokali deformacijų lauko informacija, tačiau maksimalus gardselės tankis ar didžiausias segmentų skaičius nebūtinai užtikrina geriausią generalizaciją.



3.15 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 328 bandinių treniravimo rinkinį, validavimo DOE

Kryžminės validacijos ir nepriklausomo validavimo rinkinio tendencijos buvo panašios, tačiau ne visiškai sutapo. Kai kurios smulkesnės reprezentacijos gerai veikė CV atveju, bet nepriklausomame rinkinyje nebuvo stabiliai geresnės. Todėl šioje užduotyje vien kryžminės validacijos rezultatų nepakanka – nepriklausomas validavimo rinkinys yra būtinas modelių generalizacijai įvertinti.

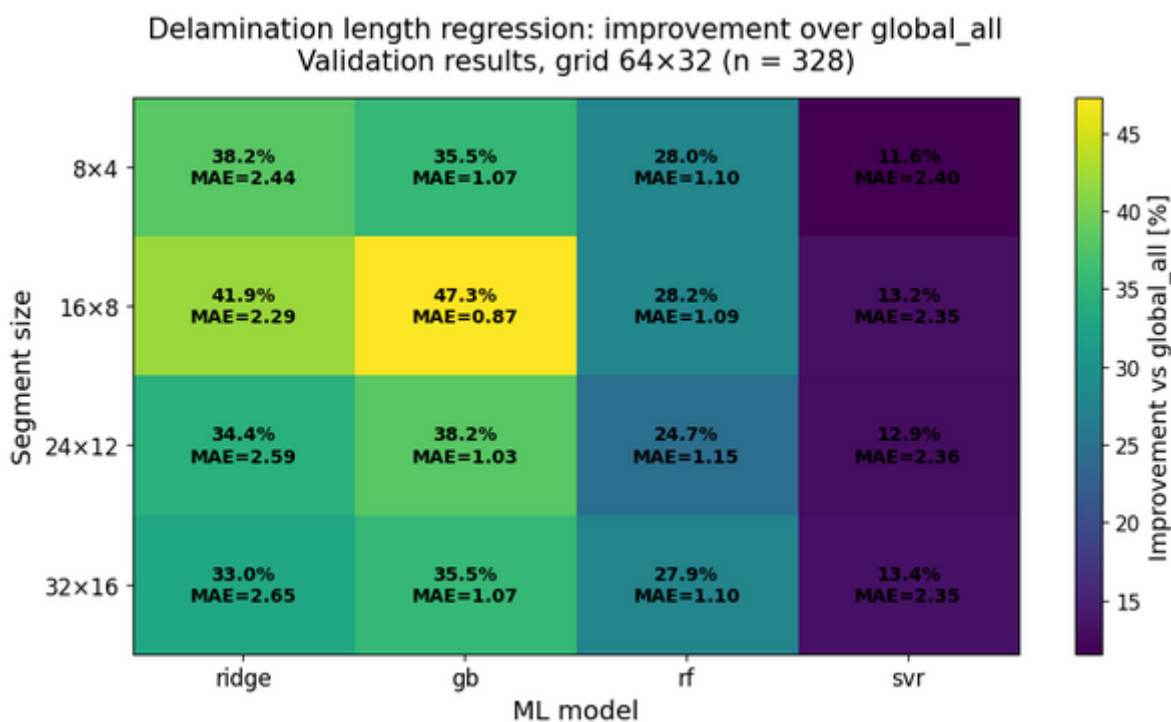
Naudojant mažesnę 113 bandinių treniravimo rinkinį, bendras paklaidų lygis buvo didesnis. Šiuo atveju taip pat buvo pastebimos kelios gerai veikiančios vidutinio detalumo konfigūracijos, tačiau smulkiausia 32×16 segmentacija dažniausiai nepagerino rezultatų (žr. **3.16 pav.**). Tai rodo, kad kai treniravimo duomenų kiekis ribotas, didesnė požymių dimensija gali būti nepakankamai efektyviai išnaudojama ir nebūtinai pagerina generalizaciją.



3.16 pav. Atsisluoksniavimo ilgio regresijos MAE rezultatai naudojant 113 bandinių treniravimo rinkinį, validavimo DOE

Svarbu pažymėti, kad 113 bandinių rinkinyje taip pat beveik visose konfigūracijose geriausias modelis buvo GB. Tik vienu validavimo rinkinio atveju, geriausiu modeliu tapo RF, tačiau ši konfigūracija nepasižymėjo geriausiu rezultatu. Tai patvirtina, kad atsisluoksniavimo ilgio regresijai gradientinio stiprinimo modelis yra stabiliausias iš nagrinėtų metodų, nepriklausomai nuo treniravimo rinkinio dydžio.

Papildomas globalių ir segmentuotų požymių palyginimas, atliktas naudojant 64×32 interpoliacijos gardelę ir nepriklausomo validavimo DOE rezultatus, patvirtino segmentavimo svarbą atsisluoksniavimo ilgio regresijai. Visais nagrinėtais ML modeliais segmentuoti požymiai sumažino prognozavimo paklaidą, lyginant su globaliais požymiais, o didžiausias pagerėjimas buvo matomas taikant vidutinio detalumo 16×8 segmentavimą, kai buvo pasiektas net 47.3% pagerėjimas (žr. **3.17 pav.**). Tačiau, šiame uždavinyje pagerėjimas yra mažesnis nei ankstesniuose regresijos uždaviniuose.



3.17 pav. Segmentuotų požymių įtaka atsisluoksniavimo ilgio regresijos tikslumui, lyginant su globaliais požymiais, kai naudojama 64×32 interpoliacijos gardelė, validavimo DOE, n = 328

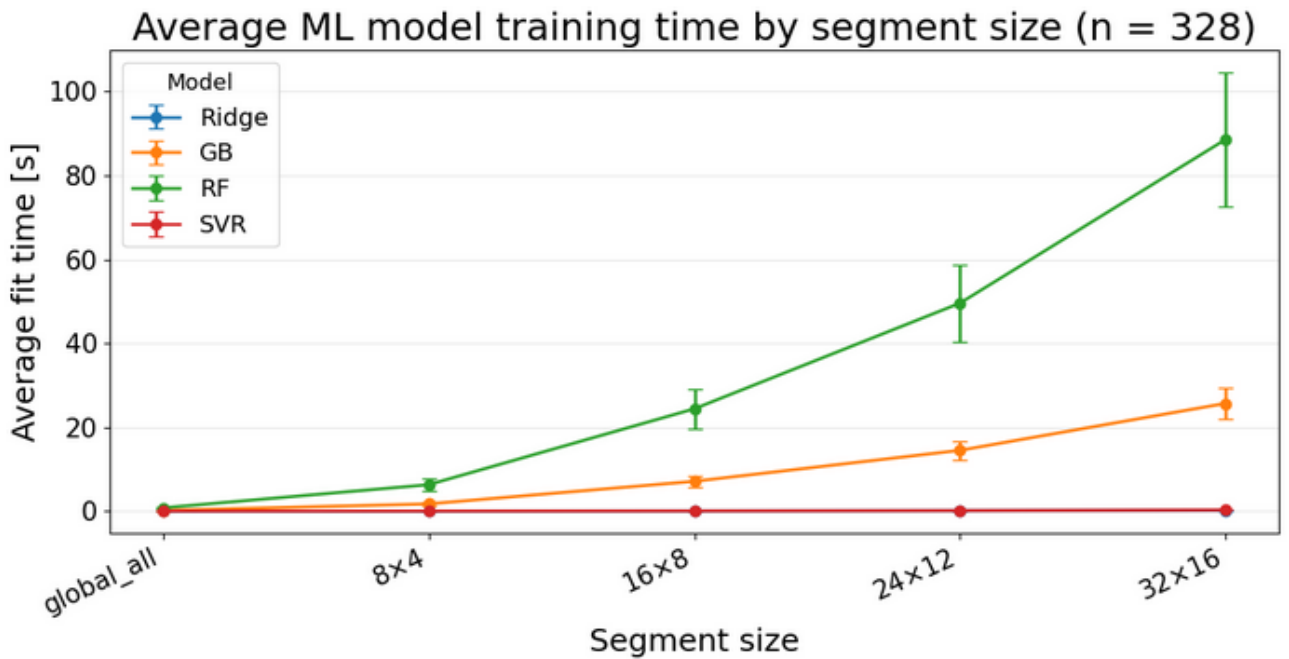
Apibendrinant galima teigti, kad atsisluoksniavimo ilgio regresijai būtina išlaikyti pakankamą lokalią deformacijų lauko informaciją. Geriausi rezultatai buvo gaunami ne su viena konkrečia konfigūracija, bet su vidutinio arba didesnio detalumo reprezentacijomis. Vis dėlto rezultatai nepatvirtina, kad maksimalus interpoliacijos ar segmentavimo detalumas visada yra optimalus. Todėl šiam uždaviniui svarbu vertinti ne tik mažiausią MAE reikšmę, bet ir rezultatų stabilumą tarp kryžminės validacijos bei nepriklausomo validavimo rinkinio.

3.2.6. Modelių mokymo laiko analizė ir tikslumo–skaičiavimo kainos kompromisas

Didinant segmentų skaičių didėja požymių vektoriaus dimensija, todėl kartu keičiasi ir mašininio mokymosi modelių apmokymo trukmė. Šis aspektas yra svarbus, nes ankstesniuose poskyriuose nustatyta, kad didesnis segmentavimo detalumas ne visada lemia mažesnę prognozavimo paklaidą. Todėl optimalios konfigūracijos pasirinkimas turi būti siejamas ne tik su MAE reikšmėmis, bet ir su skaičiavimo kaina.


Pirmiausia buvo įvertinta vidutinė modelių apmokymo trukmė, apskaičiuota apibendrinant regresijos uždavinius skirtingiems segmentų dydžiams. Šioje analizėje lyginti keturi modeliai: Gradient Boosting (GB), Random Forest (RF), Ridge regresija ir SVR. Rezultatai pateikti atskirai 328 ir 113 bandinių treniravimo rinkiniams.

Naudojant 328 bandinių rinkinį, modelių apmokymo laikas didėjo kartu su segmentų skaičiumi. Ši priklausomybė buvo ypač ryški ansambliniams modeliams. GB modelio mokymo laikas didėjo nuo kelių sekundžių iki kelių dešimčių sekundžių, o RF modelio atveju augimas buvo dar didesnis. Tuo tarpu Ridge ir SVR modelių apmokymo laikai išliko gerokai mažesni: net ir 32×16 segmentacijos atveju Ridge vidutiniškai buvo apmokomas per 0.17 s, o SVR – per 0.27 s (žr. **3.18 pav.**).



3.18 pav. Vidutinio ML modelių mokymo laiko priklausomybė nuo segmentų dydžio, $n = 328$

Panaši tendencija gauta ir naudojant 113 bandinių rinkinį, tačiau absoliutūs apmokymo laikai buvo mažesni (žr. 3.19 pav.). Tai rodo, kad skaičiavimo laiką lemia ne tik požymių skaičius, bet ir treniravimo duomenų kiekis bei modelio struktūra. Globalių požymių atvejis buvo skaičiavimo požiūriu pigiausias, tačiau ankstesni rezultatai parodė, kad toks požymių rinkinys praranda dalį lokalių informacijos ir regresijos uždaviniuose paprastai nusileidžia segmentuotoms reprezentacijoms.




3.19 pav. Vidutinio ML modelių mokymo laiko priklausomybė nuo segmentų dydžio, $n = 113$

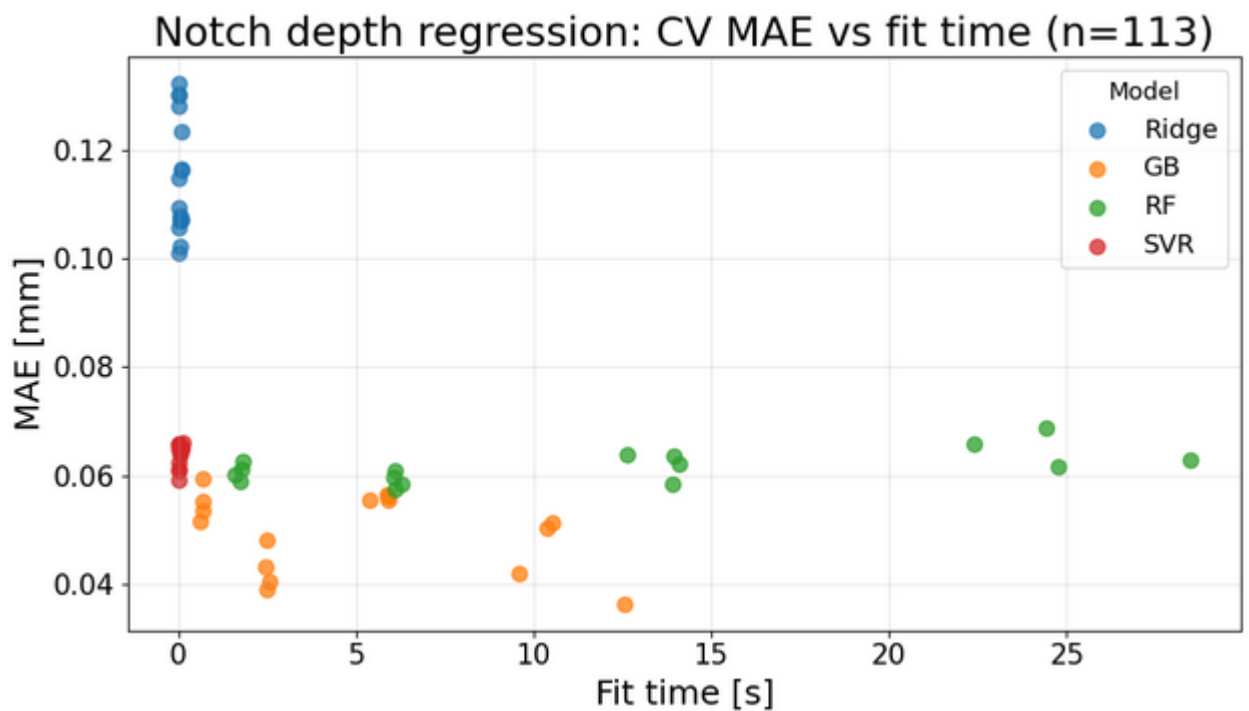
Toliau buvo analizuojamas regresijos tikslumo ir modelių mokymo laiko santykis kiekvienam regresijos uždaviniui. Šiai analizei naudoti CV rezultatai, gauti su visomis interpoliacijos gardelės ir segmentų dydžio kombinacijomis.

Įpjovos gylio regresijos atveju geriausios MAE reikšmės daugiausia buvo pasiektos naudojant GB modelį, tačiau šio modelio taškai išsidėstė plačiame mokymo laiko intervale, ypač naudojant didesnę 328 bandinių rinkinį (žr. **3.20 pav.**). Tai rodo, kad GB gali būti tiksliausias, tačiau jo skaičiavimo kaina stipriai priklauso nuo duomenų reprezentacijos detalumo. RF modelis šioje užduotyje nepasižymėjo geru kompromisu, nes jo mokymo laikas buvo didžiausias, o MAE reikšmės nebuvo mažesnės už GB.

SVR taškai abiejuose duomenų rinkiniuose išsidėstė gana kompaktiškai – tiek mokymo laiko, tiek MAE atžvilgiu (žr. **3.20 pav.**, **3.21 pav.**). Tai rodo, kad SVR yra stabilus skaičiavimo kainos požiūriu, tačiau jo tikslumas dažniausiai buvo šiek tiek prastesnis nei geriausių GB konfigūracijų. Tuo tarpu Ridge modelis aiškiausiai išsiskyrė didesnėmis MAE reikšmėmis, nors jo mokymo laikas buvo mažiausias. Todėl įpjovos gylio regresijoje Ridge gali būti laikomas greitu, bet nepakankamai tiksliu modeliu, o pagrindinis tikslumo ir skaičiavimo kainos kompromisas formuojasi tarp GB ir SVR.




3.20 pav. Įpjovos gylio regresijos CV MAE ir modelių mokymo laiko kompromisas, $n = 328$




3.21 pav. Įpjovos gylio regresijos CV MAE ir modelių mokymo laiko kompromisas, $n = 113$

Įpjovos kampo regresijos atveju aiškiausiai išsiskiria Ridge modelis. Naudojant 328 bandinių rinkinį, šio modelio taškai grupuojasi mažo mokymo laiko ir mažos paklaidos srityje: geriausios reikšmės siekia apie $1.43\text{--}1.50^\circ$, o mokymo laikas išlieka mažesnis nei sudėtingesnių ansamblinių modelių (žr. **3.22 pav.**). GB kai kuriais atvejais pasiekia panašų tikslumą, tačiau jo mokymo laikas yra gerokai didesnis ir labiau priklauso nuo erdvinės reprezentacijos detalumo. RF šioje užduotyje nėra efektyvus kompromisas, nes pasižymi didžiausiu mokymo laiku, bet nepasiekia geresnių MAE reikšmių nei Ridge. SVR yra skaičiavimo požiūriu greitas, tačiau jo MAE reikšmės aiškiai didesnės, todėl jis netinka kaip pagrindinis modelis kampo regresijai.




3.22 pav. Įpjovos kampo regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 328

Naudojant 113 bandinių rinkinį, bendra modelių tvarka išlieka panaši, tačiau visų modelių MAE reikšmės padidėja (žr. **3.23 pav.**). Ridge išlieka vienu palankiausių pasirinkimų, nes išlaiko mažą mokymo laiką ir konkurencingą tikslumą. GB taip pat gali pasiekti gerus rezultatus, tačiau jo skaičiavimo kaina didesnė, o pranašumas prieš Ridge nėra nuoseklus. Šie rezultatai patvirtina ankstesnę išvadą, kad įpjovos kampo regresija yra gerai aprašoma santykinai paprastu reguliariu linijiniu modeliu, todėl sudėtingesni modeliai šioje užduotyje nėra būtini.




3.23 pav. Įpjovos kampo regresijos CV MAE ir modelių mokymo laiko kompromisas, n = 113

Atsisluoksniavimo ilgio regresijos atveju taškinės diagramos rodo aiškiausią modelių išsiskyrimą pagal tikslumo ir skaičiavimo kainos santykį. Naudojant 328 bandinių rinkinį, geriausios MAE reikšmės buvo pasiektos su GB modeliu. Šio modelio taškai sudaro atskirą grupę mažesnės MAE srityje, tačiau jų mokymo laikas priklauso nuo gardelės ir segmentų kombinacijos ir didėja naudojant detalesnes reprezentacijas. RF šioje užduotyje buvo skaičiavimo požiūriu brangiausias, tačiau MAE reikšmėmis nepralenkė GB, todėl nėra optimalus pasirinkimas. Ridge ir SVR modeliai buvo gerokai greitesni, bet jų paklaidos buvo didesnės, ypač Ridge atveju (žr. **3.24 pav.**).



3.24 pav. Atsisluoksniavimo ilgio regresijos CV MAE ir modelių mokymo laiko kompromisas, $n = 328$

Naudojant 113 bandinių rinkinį, išlieka ta pati bendra tendencija: GB pasiekia mažiausias MAE reikšmes, o Ridge ir SVR yra greitesni, bet mažiau tikslūs. Vis dėlto mažesniame duomenų rinkinyje visų modelių paklaidos padidėja, o GB pranašumas išlieka ryškus (žr. **3.25 pav.**). Tai patvirtina, kad atsisluoksniavimo ilgio regresijai reikalingas netiesinis modelis, gebantis išnaudoti lokalius deformacijų požymius. Šioje užduotyje GB sudaro geriausią tikslumo kompromisą, tačiau jo skaičiavimo kaina turi būti vertinama kartu su pasirinktu segmentavimo detalumu.



3.25 pav. Atsisluoksniavimo ilgio regresijos CV MAE ir modelių mokymo laiko kompromisas, $n = 113$

Apibendrinant galima teigti, kad segmentavimo detalumas turi aiškią skaičiavimo kainą, ypač kai naudojami ansambliniai modeliai. Įpjovos kampo regresijai palankiausias buvo Ridge modelis, nes jis suderino gerą tikslumą ir labai mažą mokymo laiką. Įpjovos gylio regresijoje pagrindinis kompromisas susidarė tarp tikslesnio, bet brangesnio GB ir greitesnio SVR. Atsisluoksniavimo ilgio regresijoje tikslumo požiūriu dominavo GB, tačiau jo taikymas reikalauja atsižvelgti į segmentavimo detalumą ir atitinkamai didėjančias skaičiavimo sąnaudas.

3.2.7. Interpoliacijos ir segmentavimo parametrų įtakos apibendrinimas

Atliktas interpoliacijos gardelės ir segmentų dydžio tyrimas parodė, kad šie parametrai skirtingai veikia atskirus uždavinius. Klasifikacijos uždutyse jų įtaka buvo ribota: įpjovos aptikimo atveju visose konfigūracijose pasiektas maksimalus tikslumas, o atsisluoksniavimo aptikime segmentuoti požymiai pagerino rezultatus, tačiau skirtumai tarp vidutinio detalumo konfigūracijų nebuvo esminiai. Todėl klasifikacijos rezultatai nebuvo laikomi pagrindiniu kriterijumi vertinant optimalią duomenų reprezentaciją.

Regresijos uždutyse interpoliacijos ir segmentavimo įtaka buvo ryškesnė. Tiesioginis globalių ir segmentuotų požymių palyginimas parodė, kad lokali deformacijų lauko informacija ženkliai sumažino prognozavimo paklaidas visose nagrinėtose regresijos uždutyse. Tai patvirtina, kad vien globalių statistinių požymių nepakanka pilnai aprašyti defektų sukeltus deformacijų lauko pokyčius, ypač kai prognozuojamas parametras yra susijęs su pažeidimo orientacija arba vidiniu pažeidimu.

Įpjovos gylio regresijoje visos konfigūracijos davė mažas paklaidas, todėl šis uždavinys nebuvo labai jautrus pasirinktiems erdvinės reprezentacijos parametrams. Įpjovos kampo regresijoje geriausi arba artimi geriausiems rezultatai buvo pasiekti naudojant vidutinio detalumo konfigūracijas, ypač 64×32 ir 80×40 interpoliacijos gardeles ir 16×8 segmentaciją. Šiame uždavinyje dažniausiai pakako Ridge modelio, o tai rodo, kad tinkamai suformuoti požymiai leidžia kampo informaciją aprašyti santykinai paprastu modeliu.

Atsisluoksniavimo ilgio regresija buvo jautriausia duomenų reprezentacijos pasirinkimui. Geriausi rezultatai buvo gaunami naudojant vidutinio arba didesnio detalumo konfigūracijas, tačiau maksimalus interpoliacijos ar segmentavimo detalumas ne visada pagerino generalizaciją. Šiame uždavinyje dažniausiai dominavo GB modelis, o tai patvirtina, kad atsisluoksniavimo ilgio prognozei svarbios netiesinės priklausomybės ir lokali deformacijų lauko informacija.

Skaičiavimo laiko analizė parodė, kad segmentų skaičius turi didesnę įtaką modelių apmokymo trukmei nei interpoliacijos gardelės dydis. Didinant segmentų skaičių, ypač ryškiai augo ansamblinių modelių, tokių kaip GB ir RF, mokymo laikas. Todėl labai smulkios segmentacijos turi būti vertinamos atsargiai, nes jų tikslumo pagerėjimas ne visada pateisina didesnes skaičiavimo sąnaudas.

3.3. ML modelių ir hiperparametrų įtakos tyrimas

3.3.1. Eksperimentinė schema

Šio tyrimo etapo tikslas – įvertinti, kaip pasirinktų mašininio mokymosi modelių hiperparametrai veikia defektų parametrų regresijos tikslumą ir modelių gebėjimą generalizuoti į nepriklausomą validavimo duomenų rinkinį. Ankstesniuose skyriuose buvo nagrinėjama duomenų reprezentacijos įtaka, t. y. interpoliacijos gardelės ir segmentavimo parametrų poveikis modelių rezultatams. Šiame etape dėmesys perkeliamas į pačių ML modelių elgseną: siekiama nustatyti, ar papildomas modelių parametrų derinimas gali pagerinti rezultatus, lyginant su bazinėmis modelių konfigūracijomis.

Tyrimas fokusuojamas į tris regresijos uždavinius, kuriuose ankstesni eksperimentai parodė skirtingą modelių elgseną. Įpjovos kampo regresijoje dažniausiai geriausius rezultatus pasiekė Ridge regresija, todėl šiame uždavinyje analizuojama reguliavimo parametro α , intervale nuo 0.001 iki 1000, įtaka. Atsisluoksniavimo ilgio regresijoje stabiliausiai veikė Gradient Boosting modelis, todėl vertinama medžių skaičiaus (angl. Number of Estimators, $n_{estimators}$), medžių gylio (angl. Max Depth) ir mokymosi greičio (angl. Learning Rate) įtaka. Įpjovos gylio regresijoje ankstesni rezultatai parodė skirtumą tarp CV ir validavimo, su nepriklausomu duomenų rinkiniu, rezultatų: CV atveju dažnai dominavo Gradient Boosting, o nepriklausomame validavimo rinkinyje kai kuriais atvejais geriau generalizavo SVR modelis. Dėl šios priežasties šiame uždavinyje lyginamas Gradient Boosting ir SVR modelių hiperparametrų jautrumas. SVR modelio atveju nagrinėti C , γ ir epsilon parametrai, kurie apibrėžia modelio lankstumą, branduolio jautrumą ir leidžiamą paklaidos zoną. Visais atvejais rezultatai vertinami pagal CV ir nepriklausomo validavimo DOE rezultatus, pagrindine metrika laikant vidutinę absoliučią paklaidą (MAE).


Šis tyrimo etapas leidžia įvertinti, ar ankstesniuose skyriuose nustatytos geriausios modelių tendencijos išlieka ir tikslingai keičiant hiperparametrus, taip pat nustatyti, kurie modeliai yra stabilesni riboto dydžio sintetinių duomenų rinkiniuose.

3.3.2. Ridge parametrų analizė įpjovos kampo regresijos uždavinyje

Ankstesni eksperimentai parodė, kad įpjovos kampo regresijos uždavinyje Ridge regresija dažnai pasiekia geriausius arba artimus geriausiems rezultatus ir išsiskyrė labai mažu apmokymo laiku. Todėl šiame etape buvo tiriama reguliavimo parametro α įtaka modelio tikslumui. Parametras α valdo L2 reguliavimo stiprumą: mažos reikšmės leidžia modeliui labiau prisitaikyti prie duomenų, o didelės reikšmės stipriau riboja koeficientų dydžius ir gali sumažinti persimokymo riziką, tačiau kartu gali suprastinti modelio gebėjimą aprašyti duomenų priklausomybes. Kadangi Ridge

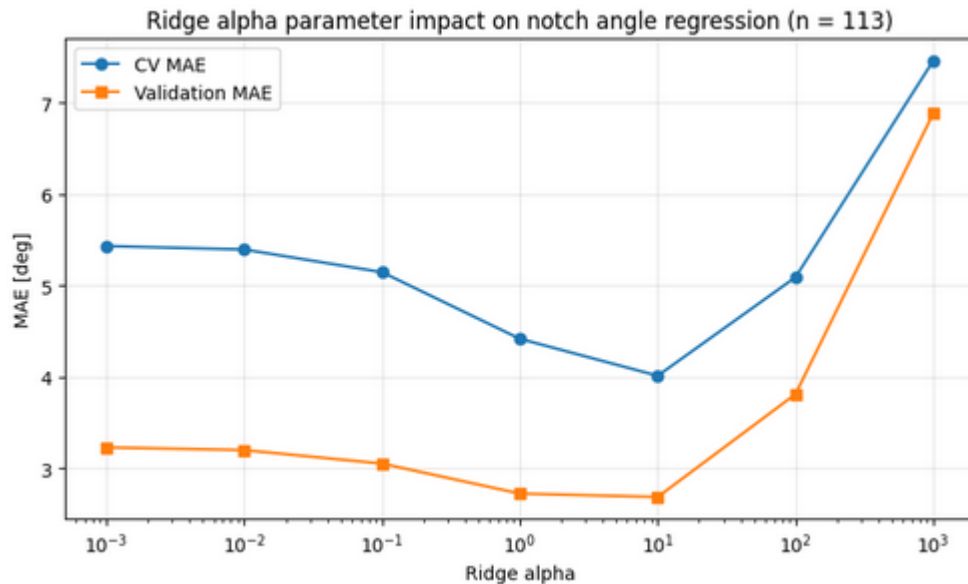
regresija yra skaičiavimo požiūriu paprastas modelis, keičiant alpha reikšmę apmokymo laiko pokyčiai buvo nereikšmingi, todėl pagrindinis vertinimo kriterijus šiame poskyryje yra MAE pokytis CV ir validavimo DOE atvejais.

Naudojant didesnę 328 bandinių treniravimo rinkinį, modelis geriausiai veikė esant mažoms arba silpnai reguliuojančioms alpha reikšmėms [0.001; 1]. Šiame intervale CV ir validavimo DOE kreivės išliko gana stabilios, o tai rodo, kad turint didesnę duomenų kiekį modeliui nereikalingas stiprus koeficientų ribojimas. Didinant alpha iki labai didelių reikšmių, tiek CV, tiek validavimo paklaidos pradėjo ryškiai didėti (žr. **3.26 pav.**). Tai rodo per stipraus reguliavimo poveikį, kai modelis tampa per daug apribotas ir nebegali tinkamai aprašyti įpjovos kampui svarbių požymių priklausomybių.



3.26 pav. Ridge alpha parametro įtaka įpjovos kampo regresijos MAE, n = 328

Naudojant mažesnę 113 bandinių treniravimo rinkinį, optimali reguliavimo zona pasislinko į didesnes alpha reikšmes (1, 10) (žr. **3.27 pav.**). Tai rodo, kad mažesniame duomenų rinkinyje stipresnis reguliavimas padeda sumažinti modelio jautrumą treniravimo duomenų variacijai. Vis dėlto labai didelės alpha reikšmės abiejuose rinkiniuose blogino rezultatus, todėl per stiprus reguliavimas nėra tinkamas sprendimas.




3.27 pav. Ridge alpha parametro įtaka įpjovos kampo regresijos MAE, $n = 113$

Šie rezultatai rodo, kad Ridge modelio reguliavimo parametras turi būti parenkamas atsižvelgiant į treniravimo duomenų kiekį. Didesniame duomenų rinkinyje pakanka silpno reguliavimo, o mažesniame rinkinyje naudingesnis vidutinis reguliavimas. Kadangi apmokymo laikas praktiškai nekinta, alpha parametro pasirinkimas turėtų būti grindžiamas ne skaičiavimo kaina, o modelio generalizacijos kokybe.

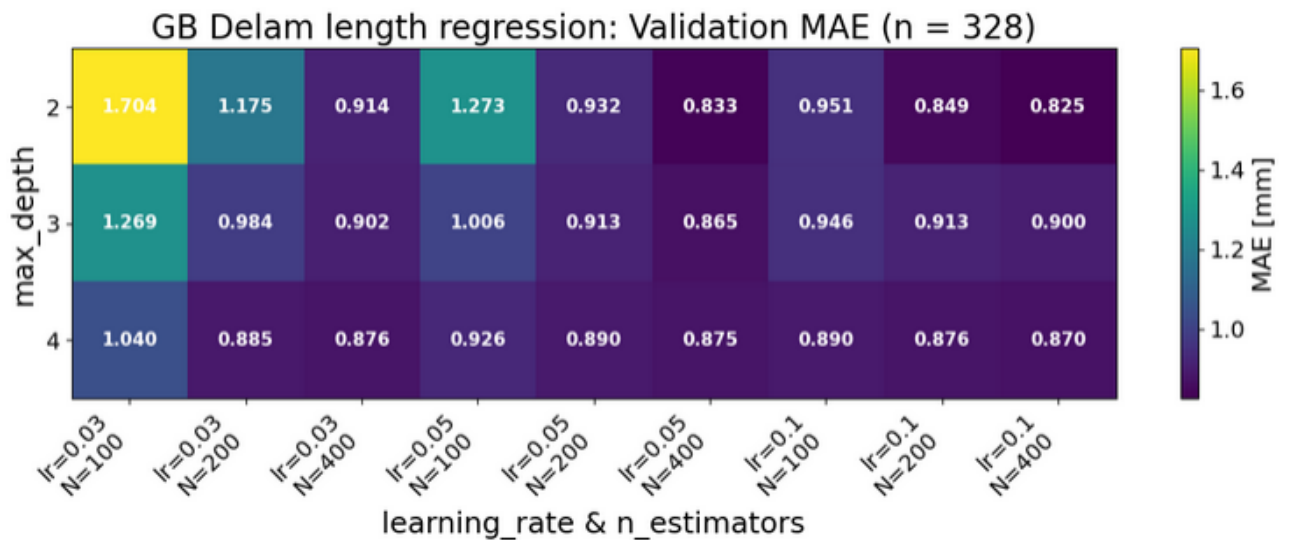
3.3.3. Gradient Boosting parametrų analizė atsisluoksniavimo ilgio regresijos uždavinyje

Atsisluoksniavimo ilgio regresijos uždavinyje ankstesni eksperimentai parodė, kad Gradient Boosting modelis dažniausiai pasiekia geriausius rezultatus, todėl šiame etape buvo tiriama trijų pagrindinių jo hiperparametrų įtaka: medžių skaičiaus ($n_estimators$), medžių gylio (max_depth) ir mokymosi greičio ($learning_rate$). Šių parametrų kombinacijos buvo vertinamos pagal MAE reikšmes, atskirai analizuojant CV ir nepriklausomo validavimo duomenų rinkinio rezultatus.

Naudojant 328 bandinių treniravimo rinkinį, didesnis medžių skaičius daugeliu atvejų mažino vidutinę paklaidą, ypač kai buvo taikomas mažesnis mokymosi greitis. Seklesni medžiai su mažu $n_estimators$ skaičiumi nebuvo pakankami tiksliai aprašyti atsisluoksniavimo ilgio priklausomybei nuo deformacijų požymių. Vidutinio ir didesnio sudėtingumo konfigūracijos pasiekė geresnius rezultatus tiek CV, tiek validavimo DOE atvejais, tačiau didžiausias medžių gylis ne visose kombinacijose suteikė papildomos naudos (žr. **3.28 pav.**, **3.29 pav.**).




3.28 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 328, CV




3.29 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 328, validavimo DOE

Naudojant 113 bandinių treniravimo rinkinį, paklaidos buvo didesnės, o hiperparametrų poveikis mažiau stabilus. Šiuo atveju sudėtingesnės konfigūracijos ne visada davė geresnius validavimo rezultatus, todėl mažesniame duomenų rinkinyje hiperparametrų pasirinkimas tampa jautresnis treniravimo duomenų padengimui (žr. 3.30 pav., 3.31 pav.).




3.30 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 113, CV




3.31 pav. Gradient Boosting hiperparametrų įtaka atsisluoksniavimo ilgio regresijos MAE, n = 113, validavimo DOE

Be modelio tikslumo, buvo įvertinta ir hiperparametrų įtaka apmokymo laikui. Rezultatai rodo aiškia ir nuoseklią priklausomybę nuo dviejų hiperparametrų: n_estimators ir max_depth. Didinant medžių skaičių, apmokymo laikas didėjo beveik proporcingai, o didesnis medžių gylis papildomai didino skaičiavimo sąnaudas. Ši tendencija stebima abiejuose treniravimo rinkiniuose, tačiau naudojant 328 bandinių duomenų rinkinį absoliutūs laikai buvo gerokai didesni nei naudojant 113 bandinių rinkinį (žr. 3.32 pav., 3.33 pav.). Tuo tarpu learning_rate tiesioginės įtakos apmokymo laikui beveik neturėjo.



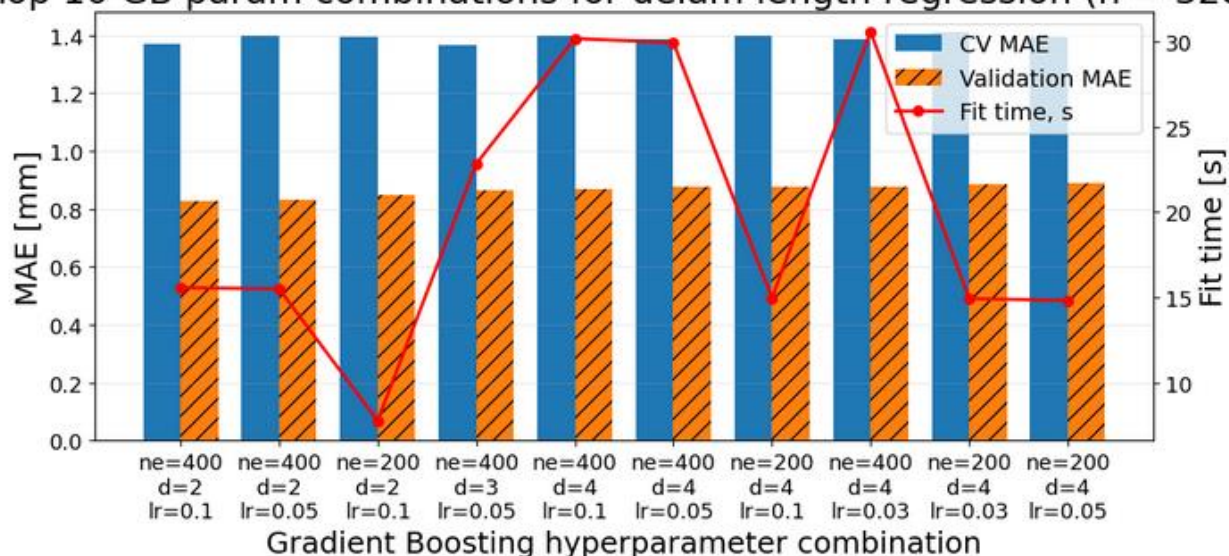
3.32 pav. Gradient Boosting hiperparametrų įtaka apmokymo laikui, n = 328, CV



3.33 pav. Gradient Boosting hiperparametrų įtaka apmokymo laikui, n = 113, CV

Vertinant geriausias validavimo MAE pasiekusias kombinacijas, matyti, kad tarp jų dažniausiai pasitaiko didesnis medžių skaičius ir nedidelis arba vidutinis medžių gylis. Vis dėlto absoliučiai mažiausia MAE reikšmė nėra vienintelis praktiškai svarbus kriterijus. Viena iš geriausiai pasirodžiusių kombinacijų ($n_estimators = 200$, $max_depth = 2$, $learning_rate = 0.1$) pasižymėjo gerokai mažesniu apmokymo laiku nei dauguma 400 medžių konfigūracijų, išlaikydama labai artimą paklaidą (žr. 3.34 pav.). Todėl tokia konfigūracija gali būti laikoma palankesniu tikslumo ir skaičiavimo kainos kompromisu.

Top 10 GB param combinations for delam length regression (n = 328)



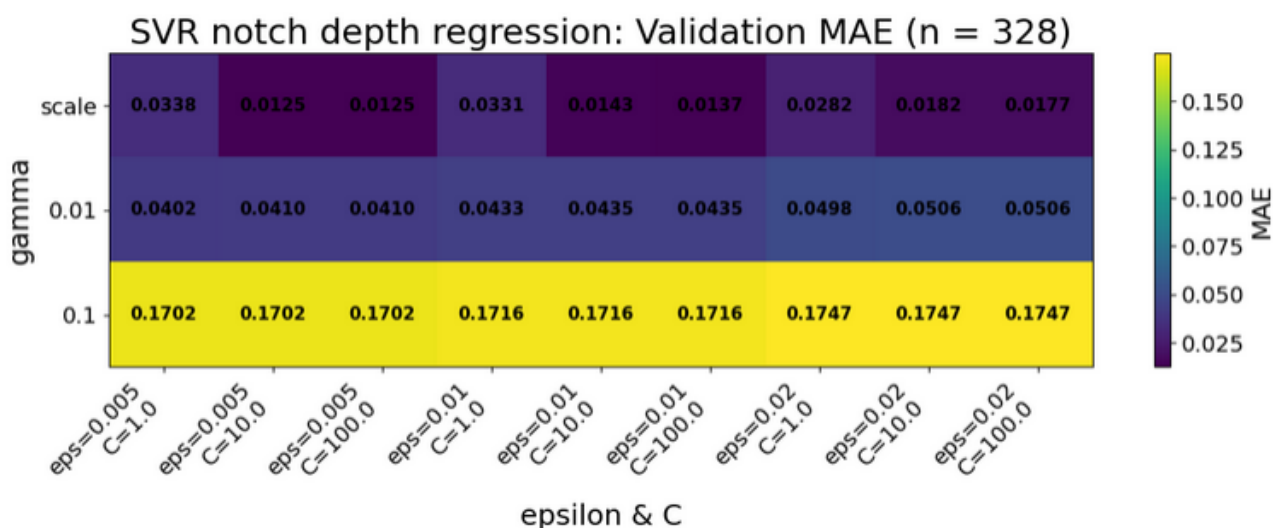
3.34 pav. 10 geriausių Gradient Boosting hiperparametų kombinacijų, pagal validavimo MAE, vidutinės paklaidos ir apmokymo laikai, atsisluoksniavimo ilgio regresijos uždavinyje, n = 328

Apibendrinant galima teigti, kad atsisluoksniavimo ilgio regresijoje Gradient Boosting modelio hiperparametų parinkimas turi reikšmingą įtaką tiek tikslumui, tiek skaičiavimo sąnaudoms. Geriausi rezultatai pasiekiami ne su paprasčiausiomis konfigūracijomis, tačiau maksimalus modelio sudėtingumas taip pat nėra būtinas. Praktiniu požiūriu tikslinga rinktis parametų derinius, kurie pasiekia artimą geriausia validavimo rezultatą, bet nereikalauja neproporcingai didelio apmokymo laiko.

3.3.4. Gradient Boosting ir SVR modelių palyginimas įpjovos gylio regresijos uždavinyje


Įpjovos gylio regresijos uždavinyje ankstesni eksperimentai parodė, kad geriausi rezultatai dažniausiai buvo gaunami naudojant Gradient Boosting arba SVR modelius. Todėl šiame etape šie du metodai buvo nagrinėjami detaliau, siekiant įvertinti jų jautrumą hiperparametų parinkimui ir palyginti ne tik tikslumą, bet ir skaičiavimo sąnaudas. SVR modeliui buvo analizuojami C, gamma ir epsilon parametrai, o Gradient Boosting modeliui – n_estimators, max_depth ir learning_rate.

SVR rezultatų analizė parodė aiškia hiperparametų įtakos struktūrą (žr. 3.35 pav.). Didžiausią reikšmę turėjo gamma parametras: geriausi rezultatai nuosekliai buvo gaunami naudojant gamma = scale, o fiksuotos gamma reikšmės davė ženkliai didesnes paklaidas. C parametro įtaka buvo mažesnė – mažiausios paklaidos buvo pasiekiamos esant C = 10 arba C = 100, o skirtumas tarp šių dviejų reikšmių buvo nedidelis. Epsilon poveikis buvo silpnas, todėl šis parametras labiau veikė kaip modelio reguliavimo detalė, o ne pagrindinis tikslumą lemiantis veiksnys. Taigi, SVR modelio atveju galima teigti, kad svarbiausia yra tinkamai parinkti branduolio mastelį, o kiti du parametrai tikslumą koreguoja daug silpniau.




3.35 pav. SVR hiperparametrų įtaka įpjovos gylio regresijos MAE, n = 328, validavimo DOE

Gradient Boosting modelio rezultatai parodė kitokį pobūdį. Mažiausios paklaidos buvo gaunamos naudojant didesnę medžių skaičių ir didesnę medžių gylį, ypač nepriklausomo validavimo rinkinio atveju. Geriausiai pasirodžiusios konfigūracijos daugiausia telkėsi ties `max_depth = 4`, o `learning_rate` įtaka buvo mažesnė nei `n_estimators` ir `max_depth` (žr. 3.36 pav.). Tai rodo, kad įpjovos gylio regresijoje šiam modeliui naudingesnis didesnis išraiškos lankstumas, leidžiantis tiksliau atkartoti santykinai subtilius deformacijų laukų ir įpjovos gylio ryšius.




3.36 pav. Gradient Boosting hiperparametrų įtaka įpjovos gylio regresijos MAE, n = 328, validavimo DOE

Papildomas dešimties geriausių konfigūracijų palyginimas parodė, kad abu modeliai gali pasiekti labai artimus MAE rezultatus nepriklausomame validavimo rinkinyje (žr. 3.37 pav.). Gradient Boosting konfigūracijos užėmė pačias aukščiausias pozicijas pagal validavimo rinkinio paklaidą, tačiau jų apmokymo laikas buvo ženkliai didesnis. Tuo tarpu geriausios SVR kombinacijos davė tik nežymiai didesnes paklaidas, bet buvo apmokomos per labai trumpą laiką. Tai rodo, kad vien pagal MAE Gradient Boosting gali būti laikomas stipresniu modeliu, tačiau vertinant tikslumo ir skaičiavimo kainos santykį SVR išlieka labai konkurencingas. Tarp Gradient Boosting konfigūracijų išsiskyrė ir tokios kombinacijos, kurios išlaikė labai gerą tikslumą, tačiau reikalavo mažesnio apmokymo laiko nei sudėtingiausi 400 medžių variantai.



3.37 pav. 5 geriausių SVR ir GB hiperparametrų kombinacijų, pagal validavimo MAE, vidutinės paklaidos ir apmokymo laikai, įpjovos gylio regresijos uždavinyje, n = 328

Atskiras spėjimo laiko palyginimas parodė, kad SVR modelis prognozavimo etape yra lėtesnis už Gradient Boosting, nors jo apmokymo laikas buvo daug mažesnis. Geriausių SVR konfigūracijų predict time reikšmės sistemingai viršijo analogiškas Gradient Boosting reikšmes, tačiau absoliutūs skirtumai vis tiek išliko labai maži (žr. **3.38 pav.**). Praktiniu požiūriu tai reiškia, kad SVR yra patrauklus kaip greitai apmokomas modelis, tačiau Gradient Boosting turi pranašumą tada, kai svarbus spartesnis pavienių ar pakartotinių prognozių vykdymas.



3.38 pav. 5 geriausių SVR ir GB hiperparametrų kombinacijų pagal MAE spėjimų laikai, n = 328, validavimo DOE

Apibendrinant galima teigti, kad įpjovos gylio regresijos uždavinyje Gradient Boosting ir SVR sudarė dvi stipriausias alternatyvas, tačiau jų pranašumai buvo skirtingi. Gradient Boosting pasižymėjo tiek geresniu galutiniu tikslumu, o SVR – gerokai mažesnėmis apmokymo sąnaudomis. Todėl galutinis pasirinkimas šiame uždavinyje priklauso nuo to, ar prioritetas teikiamas mažiausiai paklaidai, ar efektyvesniam skaičiavimui.

3.3.5. ML modelių ir hiperparametrų įtakos apibendrinimas

Atliktas hiperparametrų tyrimas parodė, kad modelių derinimas turi nevienodą reikšmę skirtingiems regresijos uždaviniams. Įpjovos kampo regresijoje Ridge modelio tikslumas labiausiai priklausė nuo reguliavimo parametro alpha, tačiau apmokymo laikas keičiant šį parametą išliko praktiškai nepakitęs. Tai rodo, kad šio modelio atveju hiperparametrų parinkimas daugiausia susijęs su generalizacijos kokybe, o ne su skaičiavimo sąnaudomis.

Gradient Boosting modelio analizė atsisluoksniavimo ilgio regresijos uždavinyje parodė aiškesnį tikslumo ir skaičiavimo kainos kompromisą. Didinant medžių skaičių ir jų gylį, kai kuriais atvejais buvo gaunamos mažesnės MAE reikšmės, tačiau kartu didėjo modelio apmokymo laikas. Todėl šio modelio parametrų parinkimas neturėtų būti grindžiamas vien mažiausia paklaida – svarbu įvertinti, ar tikslumo pagerėjimas yra proporcingas papildomoms skaičiavimo sąnaudoms.

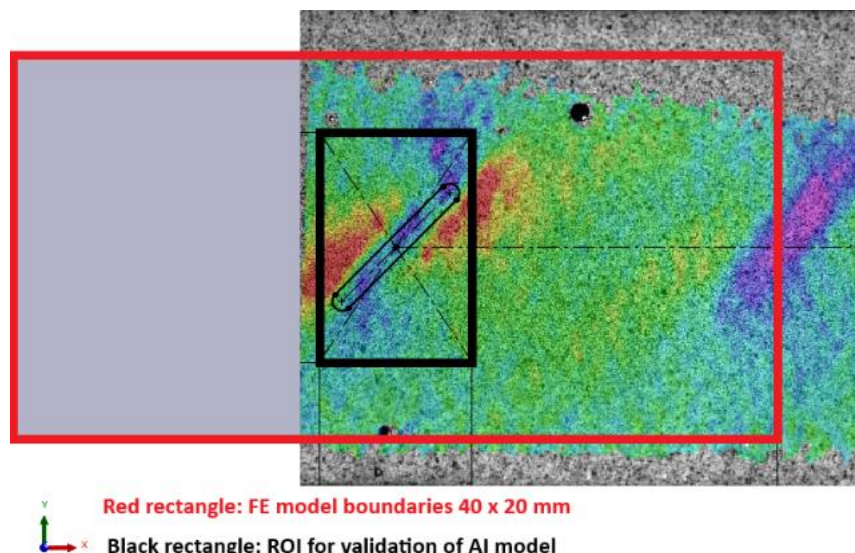
Įpjovos gylio regresijos uždavinyje Gradient Boosting ir SVR palyginimas parodė skirtingus šių modelių privalumus. Gradient Boosting konfigūracijos pasižymėjo labai maža paklaida, tačiau jų apmokymo laikas buvo didesnis. SVR modelio rezultatai stipriausiai priklausė nuo gamma parametro, o tinkamai jį parinkus buvo pasiektas artimas tikslumas su gerokai mažesnėmis apmokymo sąnaudomis.

Apibendrinant, hiperparametrų analizė parodė, kad galutinis modelio parametrų pasirinkimas turi būti siejamas ne tik su tikslumu, bet ir su modelio stabilumu bei skaičiavimo kaina. Tai ypač svarbu tais atvejais, kai keli parametrų deriniai duoda panašias MAE reikšmes, tačiau skiriasi apmokymo trukme.

3.4. Patikrinimas naudojant eksperimentinius DIC duomenis

Siekiant įvertinti, kaip apmokyti mašininio mokymosi modeliai veikia su realiais eksperimentiniais duomenimis, papildomai buvo atliktas patikrinimas naudojant DIC metodu išmatuotus deformacijų laukus. Kaip įvesties duomenys naudoti trys deformacijų komponentai (ε_x , ε_y , γ_{xy}), išmatuoti ciklinio apkrovimo pradiniam etape. Kad eksperimentiniai duomenys atitiktų sintetinių BEM duomenų struktūrą, DIC laukai buvo interpoliuoti į reguliarią 64×64 tinklę.

Šiame etape buvo naudojama mažesnė tiriamoji sritis, apibrėžta ribomis $x \in [16; 24]$ mm ir $y \in [4; 16]$ mm (žr. **3.39 pav.**). Dėl šios priežasties sintetinis treniravimo duomenų rinkinys buvo pergeneruotas taip, kad jo ROI ir interpoliacijos gardelė sutaptų su eksperimentinių DIC duomenų paruošimo schema. Tai yra svarbu, nes ankstesniuose skyriuose naudota platesnė ROI sritis ir kitoks gardelės formatas, todėl tiesioginis anksčiau apmokytų modelių taikymas eksperimentiniams DIC duomenims nebūtų metodologiškai tikslus.




3.39 pav. ML modelio patikrinimui naudojamos tiriamosios srities (ROI) apibrėžimas, pagrįstas eksperimentiniais DIC deformacijos laukais: ROI (juodas kontūras) ir atitinkama FE modelio sritis (raudonas kontūras)

Pasikeitus tiriamajai sričiai, pasikeitė ir deformacijų laukų reprezentacija, todėl ankstesniuose skyriuose nustatytos modelių tendencijos negali būti automatiškai perkeltos į šį patikrinimo etapą. Pavyzdžiui, ankstesnėje analizėje įpjovos kampo regresijai gerai veikė Ridge modelis, tačiau naujos ROI struktūros atveju šio modelio validavimo paklaida buvo gerokai didesnė nei ansamblinių modelių. Dėl to prieš taikant modelius eksperimentiniams DIC duomenims buvo atliktas trumpas modelių palyginimas su naujai sugeneruotu sintetiniu duomenų rinkiniu.

Modelių palyginimui naudotas 328 bandinių treniravimo rinkinys, o vertinimas atliktas pagal nepriklausomo validavimo duomenų rinkinio MAE rezultatus. Buvo lyginami keturi modeliai: Gradient Boosting, Random Forest, Ridge ir SVR su RBF branduoliu. Kiekvienas modelis buvo įvertintas taikant tris segmentavimo konfigūracijas: 8×4 , 16×8 ir 32×16 . Šio palyginimo tikslas nebuvo iš naujo atlikti pilną hiperparametrų optimizavimą, bet parinkti tinkamus bazinius modelius eksperimentinių DIC duomenų patikrinimui.

Įpjovos gylis regresijos rezultatai parodė, kad geriausiai veikė Random Forest ir Gradient Boosting modeliai (žr. **3.40 pav.**). Mažiausia validavimo paklaida buvo pasiekta naudojant Random Forest modelį su 32×16 segmentacija, o Gradient Boosting rezultatai buvo labai artimi visose segmentavimo konfigūracijose. Tuo tarpu Ridge modelio paklaidos buvo gerokai didesnės, todėl jis nebuvo tinkamas šiam patikrinimo etapui. SVR pasiekė tarpinius rezultatus, tačiau nepranoko ansamblinių modelių.

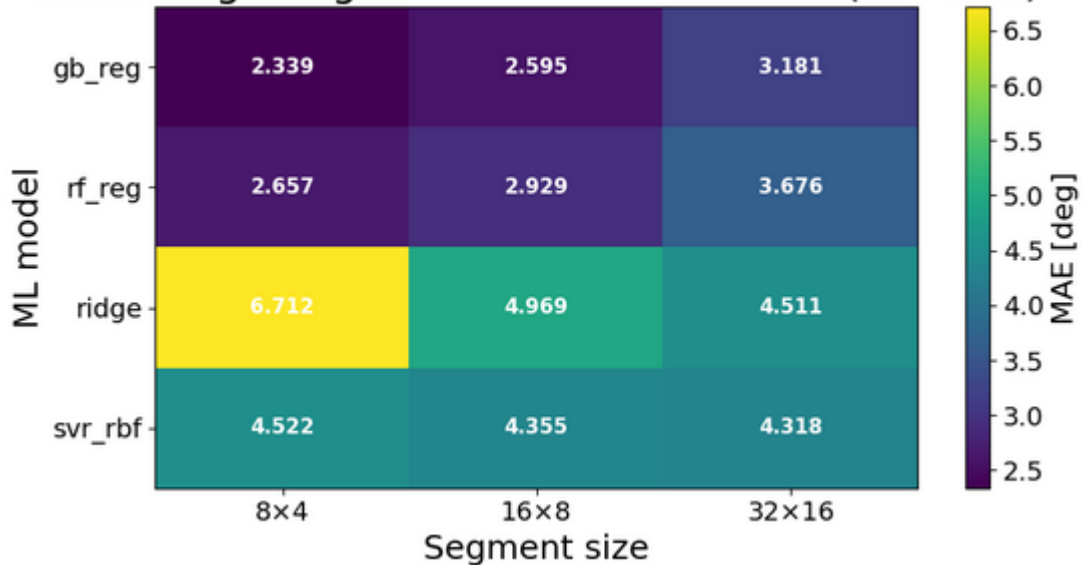
Notch depth regression: validation MAE (n = 328)



3.40 pav. ML modelių ir segmentų dydžio įtaka įpjovos gylio regresijai

Įpjovos kampo regresijoje aiškiai išsiskyrė Gradient Boosting modelis (žr. 3.41 pav.). Tai rodo, kad naujoje, siauresnėje ROI srityje įpjovos kampo prognozei palankesnė ne per daug detali požymių reprezentacija. Ridge modelis, kuris ankstesniuose tyrimuose buvo vienas stipriausių, šioje duomenų struktūroje veikė prastai. Tai patvirtina, kad modelio tinkamumas priklauso ne tik nuo uždavinio, bet ir nuo pasirinktos ROI bei požymių formavimo schemos.

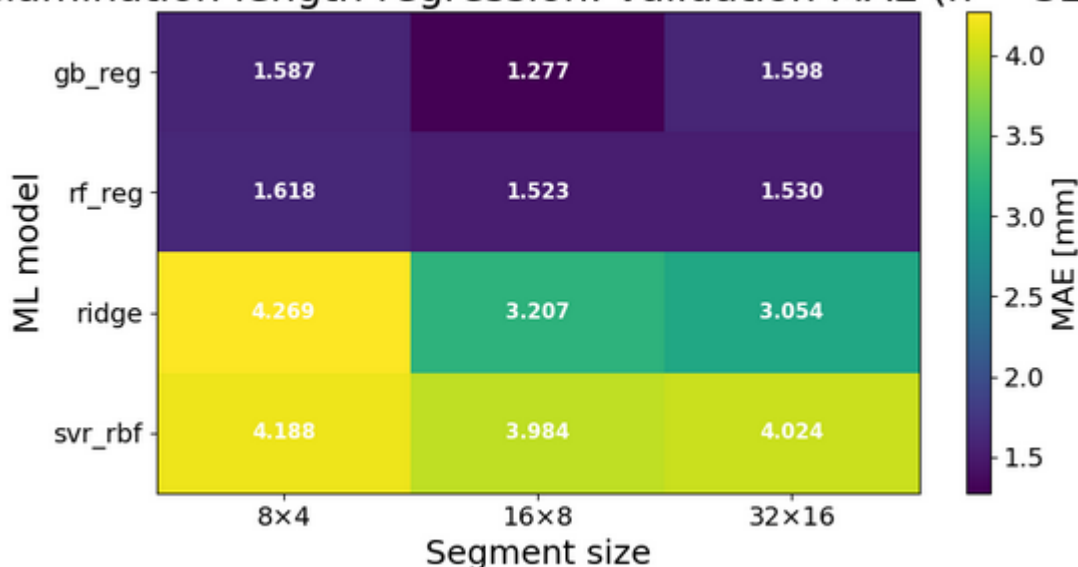
Notch angle regression: validation MAE (n = 328)



3.41 pav. ML modelių ir segmentų dydžio įtaka įpjovos kampo regresijai

Atsisluoksniavimo ilgio regresijos uždavinyje geriausias validavimo rezultatas buvo pasiektas naudojant Gradient Boosting modelį (žr. 3.42 pav.). Random Forest rezultatai buvo artimi, tačiau šiek tiek prastesni. Ridge ir SVR modeliai šiame uždavinyje pasirodė gerokai silpniau, todėl atsisluoksniavimo parametrų prognozei eksperimentiniuose DIC duomenyse pasirinktas Gradient Boosting modelis.

Delamination length regression: validation MAE (n = 328)



3.42 pav. ML modelių ir segmentų dydžio įtaka atsiskuoksnio ilgio regresijai

Eksperimentinių DIC duomenų patikrinimui klasifikacijos uždaviniuose buvo naudoti bazinės būsenos logistinės regresijos modeliai, o regresijos uždaviniuose – Gradient Boosting modeliai su vienodais hiperparametrais: $n_estimators = 200$, $max_depth = 2$, $learning_rate = 0.1$, $random_state = 42$. Toks pasirinkimas leido naudoti vienodą regresijos modelių struktūrą visoms kiekybinio prognozavimo uždaviniams ir išvengti papildomo modelių derinimo pagal vieną eksperimentinį atvejį. Gauti rezultatai atvaizduoti 3.1 lentelė

3.1 lentelė. Defektų identifikavimo ir parametrų prognozavimo iš eksperimentinių DIC duomenų rezultatai

Uždutis	Užduties tipas	Naudotas modelis	Žinoma reikšmė	Prognozė	Santykinė paklaida
Įpjovos aptikimas	Klasifikacija	Logistinė regresija		Įpjova aptikta	-
Atsiskuoksnio aptikimas	Klasifikacija	Logistinė regresija		Atsiskuoksnio aptiktas	-
Įpjovos gylio regresija	Regresija	Gradient Boosting	1.5 mm	1.348 mm	10.16 %
Įpjovos kampo regresija	Regresija	Gradient Boosting	45°	47.36°	5.25 %
Atsiskuoksnio ilgio regresija	Regresija	Gradient Boosting	-	13.50 mm	-

Modelių patikrinimas su eksperimentiniais DIC duomenimis parodė, kad įpjova buvo teisingai aptikta, o įpjovos kampo prognozė buvo artima žinomai 45° reikšmei. Įpjovos gylio prognozė buvo mažesnė už žinomą 1.5 mm reikšmę, tačiau paklaida išliko santykinai nedidelė, atsižvelgiant į tai, kad modelis buvo apmokytas tik sintetiniiais BEM duomenimis. Atsiskuoksnio klasifikacijos modelis taip pat identifikavo atsiskuoksnio požymius, o regresijos modelis prognozavo 13.50 mm atsiskuoksnio ilgį. Buvo priimta prielaida, kad tiriamas bandinys su dirbtiniu įpjovos defektu nebuvo atsiskuoksnio. Atsiskuoksnio eksperimentiškai taikant ultragarso bangas buvo matuojamas tam pačiam bandiniui po 250 000 apkrovimo ciklų. Kadangi šiame etape (pirmame

apkrovimo cikle) nėra patikimos eksperimentinės atsisluoksniavimo ilgio reikšmės, ši prognozė turėtų būti papildomai tikrinama.

3.5. Skyriaus apibendrinimas

Šiame skyriuje buvo aprašytas sukurtos duomenų generavimo, apdorojimo ir mašininio mokymosi modelių vertinimo sekos įgyvendinimas bei atlikti pagrindiniai eksperimentiniai tyrimai. BEM rezultatai buvo automatizuotai eksportuojami iš MAPDL aplinkos, apdorojami Python scenarijais, interpoliuojami į reguliarias gardeles ir transformuojami į požymių vektorius, tinkamus mašininio mokymosi modeliams. Tokia eiga leido sistemingai tirti skirtingų duomenų reprezentacijos, modelių ir hiperparametrų konfigūracijų įtaką defektų aptikimui bei parametrų prognozavimui.

Interpoliacijos gardelės ir segmentų dydžio tyrimas parodė, kad klasifikacijos užduotims šių parametrų įtaka buvo ribota. Įpjovos aptikimas visose nagrinėtose konfigūracijose buvo atliktas be klaidų, o atsisluoksniavimo aptikimo užduotyje segmentuoti požymiai buvo informatyvesni už globalius, tačiau skirtumai tarp vidutinio detalumo konfigūracijų nebuvo esminiai. Dėl šios priežasties pagrindinis dėmesys buvo skirtas regresijos užduotims, kuriose erdvinės reprezentacijos įtaka buvo ryškesnė.

Regresijos rezultatai parodė, kad skirtingi defektų parametrai pasižymi nevienodu jautrumu požymių formavimo parametrams. Įpjovos gylio regresijos paklaidos buvo mažos daugelyje konfigūracijų, todėl šis uždavinys nebuvo labai jautrus konkrečiam interpoliacijos ar segmentavimo pasirinkimui. Įpjovos kampo regresijai buvo svarbus pakankamas, bet ne perteklinis deformacijų lauko detalumas, o geriausi rezultatai dažniausiai buvo gaunami naudojant vidutinio detalumo reprezentacijas. Atsisluoksniavimo ilgio regresija buvo jautriausia užduotis, kuriai reikėjo išlaikyti lokalią deformacijų lauko informaciją ir taikyti modelius, gebančius aprašyti netiesinius ryšius tarp požymių ir prognozuojamo parametro.

Modelių mokymo laiko analizė parodė, kad segmentų skaičius daro reikšmingą įtaką skaičiavimo sąnaudoms, ypač naudojant ansamblinius modelius. Random Forest ir Gradient Boosting modelių apmokymo laikas didėjo didėjant požymių dimensijai, o Ridge ir SVR modeliai išliko gerokai greitesni. Tai parodė, kad vertinant modelių veikimą nepakanka remtis tik MAE reikšmėmis – būtina atsižvelgti ir į tikslumo bei skaičiavimo kainos kompromisą.

Hiperparametrų tyrimas patvirtino, kad modelių derinimo reikšmė priklauso nuo konkretaus regresijos uždavinio. Ridge modelio atveju svarbiausias buvo reguliavimo parametro parinkimas, tačiau skaičiavimo laikas praktiškai nekito. Gradient Boosting modelyje tikslumą ir apmokymo laiką reikšmingai veikė medžių skaičius ir gylis, todėl geriausia konfigūracija nebūtinai buvo praktiškai efektyviausia. SVR modelio atveju didžiausią įtaką turėjo branduolio parametro parinkimas, o tinkamai jį nustačius buvo galima pasiekti artimus rezultatus su gerokai mažesnėmis apmokymo sąnaudomis.

Galiausiai modeliai buvo patikrinti naudojant eksperimentinius DIC deformacijų laukus. Tam buvo pergeneruotas sintetinis treniravimo duomenų rinkinys, pritaikytas tai pačiai ROI sričiai ir interpoliacijos gardelei kaip eksperimentiniai duomenys. Patikrinimo rezultatai parodė, kad modeliai teisingai aptiko įpjovą ir prognozavo jos kampą bei gylį su santykinai nedidele paklauda. Atsisluoksniavimo aptikimo modelis taip pat identifikavo atsisluoksniavimo požymius, tačiau

kiekybinė atsisluoksniavimo ilgio prognozė šiame etape vertinama kaip orientacinė, nes nėra patikimos eksperimentinės šio parametro reikšmės.

Apibendrinant galima teigti, kad šiame skyriuje įgyvendinta ir patikrinta sintetiniiais BEM duomenimis paremta ML metodika leidžia spręsti tiek defektų klasifikavimo, tiek jų parametrų regresijos uždavinius. Gauti rezultatai parodė, kad modelių tikslumą lemia ne vien algoritmas, bet ir deformacijų laukų reprezentacija, požymių detalumas, treniravimo duomenų kiekis bei hiperparametrų parinkimas. Eksperimentinių DIC duomenų patikrinimas parodė, kad sukurta metodika gali būti taikoma realioms matavimo duomenims, tačiau tolimesniam kiekybiniam įvertinimui reikalingas platesnis eksperimentinių atvejų rinkinys ir papildomas modelių validavimas.

Išvados

1. Atlikta literatūros analizė parodė, kad kompozitinių konstrukcijų defektų identifikavimui viso lauko deformacijų duomenys yra tinkamesni nei taškiniai suvidurkinti matavimai, nes leidžia išlaikyti informaciją apie lokalius pažeidimo sukeltus deformacijų pasiskirstymo pokyčius. Skaitmeninio vaizdo koreliacijos duomenų derinimas su mašininio mokymosi metodais yra perspektyvus sprendimas, tačiau patikimam modelių apmokymui surinkti tinkamą kiekį eksperimentinių duomenų dažnai yra sudėtinga, todėl tam gali būti naudojami sintetiniai validuotų BE modelių duomenys.
2. BEM pagrindu sudaryti sintetiniai duomenų rinkiniai, apimantys 113 ir 328 skaitinius atvejus, leido įvertinti įpjovos ir atsisluoksniavimo defektų parametrų poveikį deformacijų laukams. Didesnis ir tolygiau parametrų erdvę padengiantis 328 atvejų rinkinys reikšmingai pagerino modelių tikslumą: lyginant geriausius nepriklausomo validavimo duomenų rinkinio MAE rezultatus su 113 atvejų rinkiniu, paklaida sumažėjo apie 48,3 % įpjovos gylio, 54,7 % įpjovos kampo ir 46,0 % atsisluoksniavimo ilgio regresijos uždaviniuose.
3. Deformacijų laukų interpoliavimas ir segmentavimas yra svarbūs požymių formavimo etapai, tačiau jų įtaka priklauso nuo sprendžiamo uždavinio. Klasifikacijos užduotims erdvinės reprezentacijos detalumas turėjo ribotą įtaką, o regresijos uždaviniuose segmentuoti požymiai buvo informatyvesni už globalius požymius – geriausiu atveju pasiektas 82,6% MAE sumažėjimas. Nustatyta, kad labai smulkus segmentavimas ne visada pagerina tikslumą, todėl tinkamiausia yra vidutinio detalumo reprezentacija, išlaikanti lokalią deformacijų informaciją be perteklinio požymių skaičiaus didinimo.
4. Mašininio mokymosi modelių ir hiperparametrų analizė parodė, kad modelių derinimo nauda priklauso nuo konkretaus regresijos uždavinio. Įpjovos kampo regresijoje Ridge modelio alpha parametro keitimas rezultatai pagerino tik nežymiai, nes šis modelis jau bazinėje konfigūracijoje veikė stabiliai. Ryškesnis poveikis nustatytas netiesiniams modeliams: atsisluoksniavimo ilgio regresijoje optimizuotas Gradient Boosting modelis pasiekė 12,8% mažesnę validavimo MAE reikšmę, lyginant su bazinių hiperparametrų konfigūracija, o įpjovos gylio regresijoje geriausia Gradient Boosting konfigūracija MAE sumažino apie 35,7%. Tačiau šie rezultatai taip pat parodė, kad tikslumo pagerėjimas turi būti vertinamas kartu su skaičiavimo kaina, nes sudėtingesnės modelių konfigūracijos apmokymo laiką padidino daugiau nei 8 kartus – nuo 3,8 s iki 30,6 s.
5. Patikrinimas naudojant eksperimentinius DIC deformacijų laukus parodė, kad sintetiniiais BEM duomenimis apmokyti modeliai gali būti taikomi realiems matavimo duomenims, kai sutampa tiriamoji sritis, interpoliacijos gardelė ir požymių formavimo struktūra. Modeliai teisingai identifikavo įpjovos buvimą, o regresijos uždaviniuose pasiektas 94,7 % tikslumas prognozuojant įpjovos kampą ir 89,8 % tikslumas prognozuojant įpjovos gylį. Kiekybinis atsisluoksniavimo ilgio įvertinimas išlieka ribotas dėl eksperimentinės atskaitinės reikšmės trūkumo, todėl tolimesniam metodikos validavimui būtinas platesnis eksperimentinių atvejų rinkinys.

Dalis tiriamojo darbo rezultatų publikuota moksliniame straipsnyje „Quantitative Damage Detection and Evolution in Composite Structures Using Digital Image Correlation, Machine Learning, and Peridynamics“ [17] ir konferencijos „30th International Conference Mechanics 2026“ pranešimų medžiagoje „From Surface Strains to Structural Integrity: A Multi-Method Approach for Damage Quantification and Remaining Life Assessment“ [18].

Literatūros sąrašas

- [1] A. Ghobadi, „Common Type of Damages in Composites and Their Inspections“, *World Journal of Mechanics*, t. 07, nr. 02, p. 24–33, 2017, doi: 10.4236/wjm.2017.72003.
- [2] M. Senthilkumar, T. G. Sreekanth, ir S. Manikanta Reddy, „Nondestructive health monitoring techniques for composite materials: A review“, 2021 m. birželio 1 d., *SAGE Publications Ltd.* doi: 10.1177/0967391120921701.
- [3] A. Malekloo, E. Ozer, M. AlHamaydeh, ir M. Girolami, „Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights“, 2022 m. liepos 1 d., *SAGE Publications Ltd.* doi: 10.1177/14759217211036880.
- [4] S. Gholizadeh, „A review of non-destructive testing methods of composite materials“, *Procedia Structural Integrity*, Elsevier B.V., 2016, p. 50–57. doi: 10.1016/j.prostr.2016.02.008.
- [5] Y. Wang, Q. Luo, H. Xie, Q. Li, ir G. Sun, „Digital image correlation (DIC) based damage detection for CFRP laminates by using machine learning based image semantic segmentation“, *Int. J. Mech. Sci.*, t. 230, rugs. 2022, doi: 10.1016/j.ijmecsci.2022.107529.
- [6] M. A. Mousa, M. M. Yussuf, T. S. Hussein, L. N. Assi, ir S. A. Ghahari, „A Digital Image Correlation Technique for Laboratory Structural Tests and Applications: A Systematic Literature Review“, *Sensors 2023, Vol. 23, Page 9362*, t. 23, nr. 23, p. 9362, lapkr. 2023, doi: 10.3390/S23239362.
- [7] P. Seventekidis, D. Giagopoulos, A. Arailopoulos, ir O. Markogiannaki, „Structural Health Monitoring using deep learning with optimal finite element model generated data“, *Mech. Syst. Signal Process.*, t. 145, p. 106972, lapkr. 2020, doi: 10.1016/J.YMSSP.2020.106972.
- [8] M. Azimi, A. D. Eslamlou, ir G. Pekcan, „Data-Driven Structural Health Monitoring and Damage Detection through Deep Learning: State-of-the-Art Review“, *Sensors 2020, Vol. 20, Page 2778*, t. 20, nr. 10, p. 2778, geg. 2020, doi: 10.3390/S20102778.
- [9] D. Nath, Ankit, D. R. Neog, ir S. S. Gautam, „Application of Machine Learning and Deep Learning in Finite Element Analysis: A Comprehensive Review“, *Archives of Computational Methods in Engineering 2024 31:5*, t. 31, nr. 5, p. 2945–2984, kovo 2024, doi: 10.1007/S11831-024-10063-0.
- [10] S. Teng, G. Chen, S. Wang, J. Zhang, ir X. Sun, „Digital image correlation-based structural state detection through deep learning“, *Frontiers of Structural and Civil Engineering*, t. 16, nr. 1, p. 45–56, saus. 2022, doi: 10.1007/s11709-021-0777-x.
- [11] B. K. Oh, W. C. Jung, ir H. S. Park, „Artificial intelligence-based damage localization method for building structures using correlation of measured structural responses“, *Eng. Appl. Artif. Intell.*, t. 121, geg. 2023, doi: 10.1016/j.engappai.2023.106019.
- [12] K. He, X. Zhang, S. Ren, ir J. Sun, „Deep residual learning for image recognition“, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, t. 2016-December, p. 770–778, gruodž. 2016, doi: 10.1109/CVPR.2016.90.
- [13] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, ir L.-C. Chen, „MobileNetV2: Inverted Residuals and Linear Bottlenecks“, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, p. 4510–4520. doi: 10.1109/CVPR.2018.00474.
- [14] F. Chollet, „Xception: Deep learning with depthwise separable convolutions“, *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017, p. 1800–1807. doi: 10.1109/CVPR.2017.195.

- [15] R. Ghiasi, M. R. Ghasemi, ir M. Noori, „Comparison of seven artificial intelligence methods for damage detection of structures“, *Civil-Comp Proceedings*, t. 108, 2015, doi: 10.4203/CCP.108.116.
- [16] H. T. Thai, „Machine learning for structural engineering: A state-of-the-art review“, *Structures*, t. 38, p. 448–491, bal. 2022, doi: 10.1016/J.ISTRUC.2022.02.003.
- [17] T. Vaitkūnas, E. Jasiūnienė, J. Griškevičius, V. Samaitis, ir P. Griškevičius, „Quantitative Damage Detection and Evolution in Composite Structures Using Digital Image Correlation, Machine Learning, and Peridynamics“, *Materials*, t. 19, nr. 10, p. 1917, geg. 2026, doi: 10.3390/ma19101917.
- [18] T. Vaitkūnas, J. Griškevičius, ir P. Griškevičius, „From Surface Strains to Structural Integrity: A Multi-Method Approach for Damage Quantification and Remaining Life Assessment“, *Mechanika 2026: proceedings of the 30th international scientific conference, 20-21 May 2026, Kaunas University of Technology, Lithuania: proceedings. Bialystok.*, 2026, p. 1–6.