

Lāsma Ratnika

**ADAPTĪVA SEGMENTĒTAS REGRESIJAS METODE
ĀRĒJĀS VIDES FAKTORU IETEKMES SAMAZINĀŠANAI
BŪVJU DINAMISKO PARAMETRU ILGTERMIŅA
TEHNISKĀ MONITORINGA DATOS**

Promocijas darbs



RĪGAS TEHNISKĀ UNIVERSITĀTE

Būvniecības un mašīnzinību fakultāte
Būvkonstrukciju inženierzinātņu institūts

Lāsma Ratnika

Doktora studiju programmas “Būvniecība” doktorante

ADAPTĪVA SEGMENTĒTAS REGRESIJAS METODE ĀRĒJĀS VIDES FAKTORU IETEKMES SAMAZINĀŠANAI BŪVJU DINAMISKO PARAMETRU ILGTERMIŅA TEHNISKĀ MONITORINGA DATOS

Promocijas darbs

Zinātniskā vadītāja
profesore *Dr.sc.ing.*
LĪGA GAILE

Konsultants
Dr.sc.ing.
RIMS JANELIUKŠTIS

Rīga 2026

Šis darbs ir izstrādāts ar:

- Rīgas Tehniskās universitātes Doktorantūras grantu programmas atbalstu 2021.–2023. gadā;
- Eiropas Sociālā fonda darbības programmas “Izaugsme un nodarbinātība” 8.2.2. specifiskā atbalsta mērķa “Stiprināt augstākās izglītības institūciju akadēmisko personālu stratēģiskās specializācijas jomās” projekts Nr. 8.2.2.0/20/1/008 “Rīgas Tehniskās universitātes un Banku augstskolas doktorantu un akadēmiskā personāla stiprināšana stratēģiskās jomās” atbalstu.

ANOTĀCIJA

Esošā ēku fonda pakāpeniskā novecošanās arvien vairāk aktualizē nepieciešamību pēc uzticamas, precīzas un automatizētas konstrukciju tehniskā stāvokļa novērtēšanas pieejas. Šī iemesla dēļ pēdējos gadus būvniecības un mehānikas nozarē strauji attīstās konstrukciju tehniskā stāvokļa monitoringa metodes. Tomēr sarežģītu būvju, piemēram, ēku, tiltu un torņu gadījumā konstrukciju dinamiskās īpašības būtiski ietekmē mainīgie ārējās vides apstākļi, tostarp gaisa temperatūra, relatīvais mitrums un vējš. Automatizētās monitoringa sistēmās šo faktoru ietekme var radīt gan nepamatotus viltus trauksmes signālus, gan arī kavēt savlaicīgu konstrukciju bojājumu noteikšanu. Līdz ar to ir nepieciešams izstrādāt metodes, kas ļauj samazināt ārējās vides apstākļu ietekmi uz konstrukciju dinamiskajiem parametriem, nodrošinot precīzu konstrukciju tehniskā stāvokļa novērtēšanu.

Promocijas darbā ir izstrādāta un eksperimentāli pārbaudīta jauna metode būvju konstrukciju ilgtermiņa tehniskā stāvokļa monitoringam, kas ļauj efektīvi samazināt ārējo vides faktoru ietekmi monitoringa datos un būtiski uzlabot konstrukciju bojājumu noteikšanas precizitāti. Izstrādātās metodes pamatā ir nelineāras un segmentētas regresijas algoritmu izmantošana, kas katram ārējās vides faktoram piemēro individuālu korekcijas pieeju, ņemot vērā ietekmes raksturu dažādos klimatiskos apstākļos.

Darba eksperimentālajā daļā tika analizēti divstāvu koka rāmja un tilta Filomena Delli Castelli ilgtermiņa monitoringa dati. Koka rāmim eksperimenta laikā tika simulēti dažādi konstrukciju bojājumu scenāriji. Iegūtie monitoringa dati tika apstrādāti, izmantojot vairākas mašīnmācīšanās metodes, nodrošinot iespēju detalizēti raksturot ārējo vides faktoru ietekmi un identificēt precīzākos modeļus ārējās vides faktoru ietekmes kompensēšanai. Metodes validācijai tika izmantoti statistiskie novērtējuma rādītāji un saliktas efektivitātes rādītājs, kas apstiprināja izstrādātās metodes uzticamību un precizitāti.

Pētījuma rezultāti apstiprināja, ka ārējo vides faktoru ietekme uz konstrukciju pašsvārstību frekvencēm ir būtiska, nelineāra un sezonāli mainīga. Ņemot vērā šo ietekmes raksturu, promocijas darbā tika izstrādāta adaptīva segmentācijas pieeja, kurā katra ārējās vides faktora ietekmes diapazons tiek analizēts atsevišķi, lai noteiktu visprecīzāko regresijas modeli konkrētā segmentā. Šāda segmentēta pieeja būtiski paaugstina prognožu precizitāti un samazina kļūdaini pozitīvo un kļūdaini negatīvo gadījumu klasifikāciju skaitu konstrukciju bojājumu identificēšanā.

Izstrādātā metode optimizē resursus esošo ēku apsaimniekošanā un konstrukciju tehniskā stāvokļa uzturēšanā, ļaujot reālā laikā precīzi novērtēt konstrukciju tehnisko stāvokli un laicīgi veikt uzturēšanas darbus. Promocijas darbā secinājumos formulētās praktiskās vadlīnijas par konstrukciju monitoringa ieviešanu reālām ēkām mainīgos ārējās vides apstākļos, veicina uz datiem balstītu pieejas nodrošināšanu par ēkas tehnisko stāvokli un uzturēšanas pasākumiem.

Promocijas darbs sastāv no darba vispārēja raksturojuma, piecām nodaļām, secinājumiem un izmantotās literatūras saraksta. Darba kopējais apjoms ir 127 lapaspuses, tajā iekļauti 74 attēli, 8 tabulas un 210 izmantoti literatūras avoti. Darbs izstrādāts latviešu valodā.

ANNOTATION

The increasing age of the existing building stock is creating a growing demand for reliable, accurate, and automated methods for assessing the technical condition of structures. For this reason, methods for structural health monitoring have been rapidly developing in the construction and mechanical engineering sectors in recent years. However, in the case of complex structures such as buildings, bridges, and towers, the dynamic properties of structures are significantly affected by variable environmental conditions, including air temperature, relative humidity, and wind. In automated monitoring systems, the impact of these factors can cause both false alarms and delayed identification of structural damage. Therefore, it is necessary to develop methods that reduce the impact of variable environmental conditions on the dynamic parameters of structures, ensuring accurate assessment of their technical condition.

The thesis develops and experimentally tests a new method for monitoring long-term structural health, which allows for effective removing of the influence of environmental factors on the natural frequencies of structures in monitoring data and significantly improves the accuracy of structural damage detection. The developed method is based on the use of nonlinear and segmented regression algorithms, which apply an individual correction approach to each environmental factor, considering the impact of various climatic conditions.

The experimental part of the work involved the analysis of long-term monitoring data for a two-story wooden frame and the Filomena Delli Castelli bridge. During the experiment, various structural damage scenarios were simulated for the wooden frame. The monitoring data obtained was processed using several machine learning methods, providing the opportunity to describe in detail the impact of environmental factors and identify the most accurate models for compensating for the impact of environmental factors. Statistical evaluation metrics and a composite performance metric were used to validate the method, confirming the reliability and accuracy of the developed method.

The results of the study confirmed that the influence of environmental factors on the natural frequencies of structures is significant, nonlinear, and seasonally variable. For these reasons, an adaptive segmentation approach was developed in the thesis, in which the impact range of each environmental factor is analyzed separately to determine the most accurate regression model for a specific segment. This segmented approach significantly increases the accuracy of forecasts and reduces the number of false positive and false negative classifications in the identification of structural damage.

The developed method optimizes resources in the management of existing buildings and maintenance of the technical condition of structures, allowing for accurate real-time assessment of the technical condition of structures and timely maintenance work. The practical guidelines formulated in the conclusions of the thesis on the implementation of structural monitoring for real buildings in variable environmental conditions promote a data-based approach to the technical condition of buildings and maintenance measures.

The thesis consists of the general description of the work, five chapters, conclusions, and a list of references. The total volume of the thesis is 127 pages, including 74 figures, 8 tables, and 210 references. The thesis is written in Latvian.

SATURS

ANOTĀCIJA	3
ANNOTATION	4
SATURS.....	5
DARBA VISPĀRĒJS RAKSTUROJUMS.....	7
1.Esošā ēku fonda novērtējums un tehniskā stāvokļa monitoringa sistēmas nepieciešamība .	15
1.1.Konstrukciju tehniskā stāvokļa monitoringa nepieciešamības pamatojums un monitoringa attīstība.....	17
1.2.Uz svārstībām balstīta nesošo konstrukciju tehniskā stāvokļa novērtēšana.....	20
1.2.1.Uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringa sistēmas darbības pamatprincipi	22
1.2.2.Uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringa sistēmu sensori datu iegūšanai.....	25
1.2.3.Pret bojājumiem jutīgo pazīmju identificēšana uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringā.....	28
1.3.Mainīgo ārējo vides apstākļu ietekme uz nesošo konstrukciju tehniskā stāvokļa monitoringa datiem	30
2.Mašīnmācīšanās metožu integrācija konstrukciju tehniskā stāvokļa monitoringā.....	34
2.1.Mašīnmācīšanās algoritmu darbības principi.....	34
2.2.Mašīnmācīšanās algoritmu iedalījums	35
2.3.Mašīnmācīšanās algoritmu iespējas un pielietojuma ierobežojumi	37
2.4.Mašīnmācīšanās algoritmu izmantošana ārējo vides faktoru ietekmes samazināšanai..	39
3.Metode ārējās vides faktoru ietekmes samazināšanai konstrukciju pašsvārstību frekvenču monitoringa datos	46
3.1.Datu apvienošana	47
3.2.Regresijas modeļu piemērošana datiem	47
3.3.Regresijas modeļu novērtēšana	50
3.4.Ārējo vides faktoru ietekmes segmentēšana	52
3.5.Daļējas atkarības diagrammu veidošana	53
3.6.Daļējas atkarības diagrammu vērtību interpolācija un frekvenču vērtību koriģēšana ...	54
4.Ārējās vides faktoru ietekmes samazināšanas metodes validācija.....	58
4.1.Divstāvu koka rāmja monitoringa izmantoto datu apraksts	58
4.2.Filomena Delli Castelli tilta monitoringa izmantoto datu apraksts.....	62
4.3.Ārējo vides faktoru ietekmes analīze uz pašsvārstību frekvencēm.....	65
4.4.Ārējo vides ietekmes faktoru un pašsvārstību frekvenču savstarpējā korelācija	72

4.5. Ārējo vides faktoru nelineārās ietekmes salīdzinājums	74
4.6. Konstrukciju bojājumu noteikšanas algoritmu rezultāti pirms ārējā vides ietekmes samazināšanas metodes piemērošanas	78
4.6.1. Mahalanobisa distancs algoritms.....	79
4.6.2. Galveno komponentu analīze (PCA).....	80
4.6.3. Vienklases atbalsta vektora (OC-SVM) algoritms	81
4.6.4. Gausa jauktā modeļa (GMM) metode.....	82
4.6.5. Algoritmu klasifikācijas efektivitātes novērtēšana	84
4.6.6. Algoritmu klasifikācijas rezultāti	85
4.6.7. Algoritmu klasifikācijas noviržu punktu analīze	87
4.7. Ārējās vides parametru ietekmes samazināšanas metodes validācijas rezultāti	88
4.7.1. Koka rāmja monitoringa datu validācijas rezultāti	89
4.7.2. Filomena Delli Castelli validācijas rezultāti	94
4.8. Konstrukciju bojājumu noteikšanas algoritmu rezultāti pēc ārējā vides ietekmes samazināšanas metodes piemērošanas	101
Secinājumi.....	109
Literatūras avoti.....	111

DARBA VISPĀRĒJS RAKSTUROJUMS

Tēmas aktualitāte

Ēku konstrukciju monitoringa kā zinātnes jomas aizsākums meklējams aptuveni kopš 1990. gada [1]. Cilvēku drošības un konstrukciju tehniskās apsekošanas uzlabošanas nodrošināšana arī pēdējos gados ir būtiski palielinājusi interesi par instrumentētu monitoringa sistēmu attīstīšanu un lietošanu reālām būvēm.

Pasaulē novērojama infrastruktūras un ēku fonda pakāpeniska novecošanās, kas rada jaunus izaicinājumus drošai būvju ekspluatācijai. Daudzas būves tiek ekspluatētas krietni pēc paredzētā kalpošanas laika beigām, līdz ar to pieprasot nodrošināt periodisku būvju konstrukciju tehniskā stāvokļa novērtēšanu. Piemēram, Latvijā spēkā esošie noteikumi [2] nosaka, ka ēku īpašniekiem ir pienākums veikt tehnisko apsekošanu līdz noteiktam laika periodam un atkārtota pārbaude ir noteikta kā obligāta tikai pēc 10 gadiem. Šo 10 gadu laikā ēkas īpašniekam netiek uzlikts pienākums veikt papildu konstrukciju tehnisko apsekošanu, lai pārliecinātos par ēkas kopējo vai atsevišķu konstrukciju pašreizējo tehnisko stāvokli. Balstoties sertificēta būvspeciālista sniegtajā vērtējumā, ieteikumos un ēkas kopējā tehniskā stāvokļa novērtējumā, ēku īpašnieki veic nepieciešamos remontdarbus, un lietotāji turpina ēkas ekspluatāciju. Likumdošana nenosaka arī to, ka izsniegtos tehniskos apsekošanas atzinumus ir nepieciešams pārbaudīt vai veikt atkārtoti kāda cita sertificēta būvspeciālista vadībā. Teorētiski turpmākie ēkas ekspluatācijas 10 gadi ir atkarīgi no būvspeciālista vērības, pieredzes, zināšanām un spējas pieņemt lēmumus.

Konstrukciju monitoringa kā periodiska būves un tās konstrukciju tehniskā stāvokļa noteikšana nodrošinātu cilvēku drošību arī periodā, kurā netiek noteikts obligāts pienākums veikt šo uzraudzību un periodiski atjaunotu informāciju par būves tehnisko stāvokli, neveicot vizuālās apsekošanas. Tieši praktiskā lietošanā līdz šim ir bijuši vairāki faktori, kas ietekmē turpmāko konstrukciju monitoringa attīstību. Galvenie faktori ir:

- augstās ieviešanas izmaksas;
- dažādu būvju tipu konstruktīvo risinājumu daudzveidība;
- ierobežots monitoringa datu apjoms par esošajām būvēm;
- grūtības atšķirt konstrukciju bojājumu radītās izmaiņas no apkārtējās vides izraisītām svārstībām.

Dažus no iepriekš minētajiem faktoriem var risināt ar iekārtu modernizāciju un monitoringam nepieciešamo datu iegūšanu, izmantojot galīgo elementu modeļus, bet ārējo vides faktoru ietekme ir atšķirīga katrā klimata joslā un ir sezonāli mainīga, kā arī neprognozējama. Konstrukciju dinamiskie parametri tiek pakļauti izmaiņām ne tikai bojājumu ietekmē, bet arī ārējo vides apstākļu iedarbībā. Ja ārējo vides apstākļu ietekme netiek ņemta vērā, tad konstrukciju monitoringa laikā kā viens no iespējamajiem riskiem ir viltus trauksmes rašanās, kas samazinātu monitoringa sistēmas uzticamību un efektivitāti, kā arī veidotu nepamatotas izmaksas ēkas konstrukciju bojājumu viltus trauksmes novēršanai. Savukārt gadījumā, ja ārējo vides apstākļu ietekme uz konstrukciju dinamiskajiem parametriem ir lielāka nekā bojājumu radītā ietekme, pastāv risks, ka konstrukciju bojājums netiek laikus atklāts un

nekavējoties novērsts. Līdz ar to mainīgos ārējās vides apstākļos konstrukciju tehniskā stāvokļa monitoringa sistēmai jāspēj adaptīvi ņemt vērā ārējās vides ietekme un minimizēt viltus trauksmes un bojājumu atklāšanas risku.

Darba mērķis un uzdevumi

Promocijas darba mērķis ir izstrādāt un validēt inovatīvu adaptīvu metodi ārējo vides faktoru ietekmes samazināšanai monitoringa datos, kas ļauj kompensēt mainīgo ārējo vides faktoru ietekmi uz būvju pašsvārstību frekvencēm un palielina konstrukciju bojājumu noteikšanas algoritmu precizitāti, nodrošinot uzticamu un efektīvu ilgtermiņa tehniskā stāvokļa monitoringu.

Lai īstenotu darba mērķi, ir definēti vairāki uzdevumi.

1. Izpētīt un apkopot esošo informāciju par ēku un inženierbūvju konstrukciju tehniskā stāvokļa monitoringa metodēm, kā arī analizēt ārējo vides apstākļu ietekmi uz konstrukciju dinamiskajiem parametriem.
2. Analizēt divstāvu koka rāmja un *Filomena Delli Castelli* tilta ilgtermiņa monitoringa eksperimentālos datus. Apkopot pašsvārstību frekvenču un ārējās vides ietekmes faktoru datus.
3. Izvērtēt ilgtermiņa monitoringa eksperimentāli iegūto pašsvārstību frekvenču datu izmaiņu raksturu un tendenci novērojumu laikā sezonāli mainīgo ārējās vides faktoru ietekmē. Izvērtēt ārējo vides faktoru ietekmes lielumu uz būvju konstrukciju pašsvārstību frekvencēm.
4. Izstrādāt adaptīvu ārējo vides faktoru ietekmes samazināšanas metodi, izmantojot kombinētu mašīnmācīšanās algoritmu lietojumu un segmentētu ārējo vides faktoru ietekmes modelēšanu, lai precīzi nošķirtu ārējās vides izraisītas pašsvārstību frekvenču vērtību izmaiņas no konstrukciju bojājumu radītajām izmaiņām.
5. Izvērtēt konstrukciju bojājumu noteikšanas algoritmu precizitāti pirms ārējās vides ietekmes samazināšanas metodes piemērošanas, nosakot ārējo vides faktoru ietekmi uz kļūdaini pozitīvo un kļūdaini negatīvo klasifikāciju.
6. Piemērot ārējo vides faktoru ietekmes samazināšanas metodi koka rāmja un *Filomena Delli Castelli* tilta ilgtermiņa monitoringa pašsvārstību frekvenču datiem.
7. Izvērtēt konstrukciju bojājumu noteikšanas algoritmu precizitāti pēc ārējās vides ietekmes samazināšanas metodes piemērošanas koka rāmja monitoringa datiem, nosakot algoritmu precizitāti identificēt bojāto un nebojāto konstrukciju datus.
8. Izvērtēt ārējās vides ietekmes samazināšanas metodes piemērošanas efektivitāti tilta monitoringa datiem, veicot frekvenču izmaiņu analīzi.

Pētījuma zinātniskā novitāte

Promocijas darbā izstrādāta jauna adaptīva metode ārējo vides faktoru ietekmes samazināšanai uz konstrukciju pašsvārstību frekvencēm, nodrošinot uzticamu un efektīvu konstrukciju bojājumu noteikšanas algoritmu darbību. Metode apvieno ēku konstrukciju

nepārtrauktu monitoringu ar mašīnmācīšanās algoritmu lietošanu datu analīzē, kas ir būtisks solis automatizētai un precīzai būvkonstrukciju tehniskā stāvokļa novērtēšanai reālā laikā.

Pētījuma laikā tika atklāts atsevišķu ārējās vides ietekmes faktoru raksturs. Analītiski, kā arī izmantojot mašīnmācīšanās algoritmus, tika pierādīts, ka ārējo vides faktoru ietekme ir nelineāra un sezonāli mainīga novērojumu periodā. Rezultāti padziļina teorētisko izpratni par konstrukciju pašsvārstību frekvenču izmaiņām atkarībā no ārējiem vides ietekmes faktoriem un liecina par nepieciešamību lietot nelineārus kompensācijas modeļus monitoringa sistēmās.

Darbā dažādu mašīnmācīšanās algoritmu lietošana konstrukciju tehniskā stāvokļa monitoringam pamatota nepieciešamība izmantot adaptīvu metodi, kurā algoritmu izvēle tiek balstīta ārējās vides faktoru vērtību segmentācijā un to ietekmes raksturā. Izmantojot regresijas modeļu salīdzinošo analīzi, iespējams noteikt efektīvākos modeļus katram konkrētam gadījumam, līdz ar to uzlabojot prognožu precizitāti un bojājumu identificēšanas uzticamību. Pētījumā izmantotais salikās efektivitātes rādītājs sniedz iespēju vispusīgi novērtēt katra modeļa precizitāti. Šis pieejas veids nodrošināja objektīvu vērtējumu par piemērotāko regresijas modeli katram ārējās vides ietekmes faktoram un katrai pašsvārstību frekvencei. Pēc korekcijas piemērošanas tika būtiski uzlabota konstrukciju bojājumu noteikšanas algoritma darbība – samazinājās kļūdaini pozitīvās un kļūdaini negatīvās klasifikācijas, uzlabojot monitoringa sistēmas efektivitāti. Tīla pašsvārstību frekvenču gadījumā tika samazināta frekvenču vērtību izkliede, nodrošinot stabilas vērtības novērojumu periodā.

Ārējās vides faktoru ietekmes samazināšanas metodes balstās daudzpakāpju pieejā. Tā ietver segmentētu datu analīzi un labākā regresijas modeļa izvēli katram ārējās vides faktora segmentam un pašsvārstību frekvencei, kā arī nelineārās korekcijas funkcijas lietošanu. Šāda pieeja nodrošina metodes atkārtojamību un adaptējamību dažādiem būvju veidiem un klimatiskajiem apstākļiem. Korekcijas funkcijas tiek izstrādātas individuāli katrai pašsvārstību frekvencei, ņemot vērā to atšķirīgo jutību pret konkrēto ārējās vides ietekmes faktoru. Šāda pieeja nodrošina augstu precizitāti vides ietekmes kompensēšanā un novērš kļūdas, kas var rasties, lietojot vispārinātas korekcijas. Izstrādātā metode balstīta eksperimentāli validētos datos, ļaujot to lietot plašākā mērogā dažādu būvju konstrukcijām.

Pētījuma secinājumos formulētas praktiskas vadlīnijas par konstrukciju monitoringa ieviešanu reālām ēkām mainīgos ārējās vides apstākļos. Šīs vadlīnijas var kalpot kā pamats konstrukciju tehniskā stāvokļa monitoringa sistēmu ieviešanai gan jaunbūvēs, gan esošo būvju atjaunošanā, nodrošinot datus balstītu lēmumu pieņemšanu par ēkas tehnisko stāvokli un uzturēšanas pasākumiem.

Promocijas darba praktiskais nozīmīgums

Pētījuma izstrādes gaitā gūtie rezultāti ir nozīmīgi būvju konstrukciju tehniskā stāvokļa monitoringa ieviešanai praksē mainīgos ārējās vides apstākļos, nodrošinot monitoringa efektivitāti, kompensējot ārējo vides apstākļu ietekmi un samazinot viltus trauksmju skaitu un paaugstinot lietotāju uzticēšanos monitoringa sistēmām. Metodes praktiskā piemērojamība izpaužas arī optimizētā resursu izmantošanā – uzturēšanas un atjaunošanas darbus var plānot, balstoties kvantitatīvos novērtējumos par konstrukcijas tehnisko stāvokli, nevis periodiski

veiktas vizuālās pārbaudes rezultātos. Tas veicina pāreju no tradicionālās datus balstītu būvju uzturēšanas praksi, kas ir būtiska ilgtspējīgas būvniecības un ekspluatācijas stratēģijas sastāvdaļa. Izstrādātā metode ir piemērojama dažādu tipu būvēm un konstrukciju materiāliem, līdz ar to sniedz praktisku ieguvumu būvju konstrukciju projektētājiem, būvuzraugiem, ēku īpašniekiem un apsaimniekotājiem, kuriem ir pienākums nodrošināt drošu būvju ekspluatāciju ilgtermiņā. Metode ir balstīta pieejamās mērierīcēs un aprēķinu algoritmos, kas ļauj to pakāpeniski ieviest, pamatojot ieviešanas nepieciešamību arī ekonomiski. Būtiska ir arī izstrādātā algoritma integrējamība esošajos konstrukciju tehniskā stāvokļa monitoringa datos. Piedāvātā pieeja ļauj sasaistīt pašsvārstību frekvenču izmaiņu datus ar ārējās vides faktoriem reālā laikā, līdz ar to nodrošinot automatizētu korekciju un risku identificēšanu bez manuālas datu analīzes nepieciešamības. Tas veicina pāreju uz datu vadītu ēku pārvaldību un veido pamatu nākamās paaudzes būvju pārbaudes un ekspluatācijas sistēmas.

Praktiskais nozīmīgums izpaužas arī iespējā pilnveidot normatīvos aktus un vadlīnijas attiecībā uz ēku ekspluatāciju uzraudzību. Pētījumā piedāvātā metode var kalpot par pamatu ieteikumiem, kā integrēt automatizētu konstrukciju tehniskā stāvokļa monitoringu būvju uzturēšanas plānos.

Pētīšanas metodika un izmantotie materiāli

Promocijas darbā tika izmantota daudzpusīga pētniecības pieeja, apvienojot teorētiskās literatūras analīzi, eksperimentālo datu apstrādi, skaitlisko modelēšanu un mašīnmācīšanās metožu lietošanu konstrukciju tehniskā stāvokļa novērtēšanā. Pētījuma sākotnējā posmā tika veikts padziļināts zinātniskās literatūras apskats par būvju nesošo konstrukciju monitoringa principiem, bojājumu noteikšanas metodēm, kā arī ārējo vides apstākļu ietekmi uz konstrukciju dinamiskajām īpašībām. Literatūras analīze sniedza iespēju identificēt būtiskākās problēmas, kas saistītas ar ārējās vides mainīguma izraisītām kļūdām monitoringa datu interpretācijā, kā arī izvērtēt esošo metožu ierobežojumus ārējās vides ietekmes korekcijā.

Eksperimentālajā daļā tika analizēti divstāvu koka rāmja prototipa un *Filomena Delli Castelli* tilta ilgtermiņa monitoringa dati. Koka rāmis tika novietots ārpus telpām un pakļauts mainīgiem sezonāliem ārējiem vides apstākļiem. Monitoringa ilgums bija viens gads – no 2021. gada 10. novembra līdz 2022. gada 2. septembrim, un šajā laikā koka rāimim netika simulēti bojājumi, līdz ar to pieņemot konstrukcijas nebojāto stāvokli. No 2022. gada 2. septembri līdz 27. septembrim koka rāmja modelī pakāpeniski tika ieviesti bojājumi, samazinot rāmja stingumu vai masu, palielinot bojājuma pakāpi ar katru soli. Bojājumi tika veidoti nesagraujošā veidā un atgriezeniski, un katrs nākamais bojājums ietvēra arī iepriekšējos, lai simulētu progresējošu konstrukcijas nestspējas samazināšanos. Tilta konstrukciju monitoringa ilgums bija no 2024. gada 30. septembra līdz 2025. gada 6. novembrim. Monitoringa laikā tika iegūtas tilta pašsvārstību frekvenču vērtības mainīgos ārējās vides apstākļos. Eksperimentālie dati tika apstrādāti *Matlab* vidē, izmantojot dažādus statistiskos un mašīnmācīšanās modeļus. Pētījumā tika veikta piemēroto regresijas modeļu analīze, izmantojot saliktās efektivitātes rādītāju, lai novērtētu modeļu piemērotību ārējās vides ietekmes korekcijai. Būtiska pētniecības pieeja bija datu segmentācija, sadalot ārējās vides faktorus

intervālos, kas sniedza iespēju precīzāk analizēt nelineāro ietekmes raksturu un izstrādāt ārējās gaisa temperatūras, relatīvā mitruma, vēja ātruma korekcijas funkcijas katrai pašsvārstību frekvencei atsevišķi. Šī segmentētā analīze nodrošināja pamatu regresijas modeļu adaptīvai izvēlei.

Ārējās vides ietekmes samazināšanas metodes validācija tika veikta, salīdzinot konstrukciju bojājumu identificēšanu pirms un pēc korekcijas piemērošanas koka rāmja pašsvārstību frekvenču gadījumā. Novērtējums balstījās klasifikācijas precizitātē, kā arī kļūdaini pozitīvo un kļūdaini negatīvo gadījumu skaita izmaiņās, analizējot algoritmu spēju precīzi atšķirt nebojātus un bojātus konstrukciju stāvokļus. Tīla pašsvārstību frekvenču gadījumā ārējās vides ietekmes samazināšanas metodes validācija tika veikta, salīdzinot frekvenču vērtību izkliedi pirms un pēc metodes piemērošanas.

Pētījuma galvenie secinājumi tika formulēti, balstoties iegūtajā datu analīzē, piedāvājot strukturētu un īstenojamu pieeju ārējās vides faktoru ietekmes samazināšanai uzticamai un efektīvai konstrukciju tehniskā stāvokļa monitoringa sistēmu ieviešanai praksē.

Pētījuma teorētiskais un metodoloģiskais pamats

Promocijas darba teorētiskais pamats balstīts vairākās būtiskās inženierzinātņu nozarēs, kas kopumā nodrošina integrētu pieeju būvju konstrukciju tehniskā stāvokļa novērtējuma un monitoringa datu analīzei.

Pētījumā izmantotas šādas inženierzinātņu sadaļas un analītiskās metodes:

- 1) būvmehānika – nodrošina izpratni par konstrukciju deformācijām un nestspējas robežstāvokļiem;
- 2) būvkonstrukcijas – konstrukciju materiālu īpašības un to uzvedības analīze ārējo vides faktoru ietekmē;
- 3) dinamika – galvenais teorētiskais pamats konstrukciju svārstību un pašsvārstību frekvenču izmaiņu interpretācijai ārējo slodžu un bojājumu ietekmē;
- 4) modālā analīze – tika izmantota konstrukciju dinamisko īpašību kvantitatīvai novērtēšanai, iekļaujot frekvenču, svārstību formu un rīšanas koeficientu izmaiņu analīzi;
- 5) signālu apstrāde – datu priekšapstrāde;
- 6) statistiskā modelēšana un regresijas analīze – tika izmantota, lai noteiktu sakarības starp ārējiem vides ietekmes faktoriem un konstrukciju dinamiskajiem parametriem, kā arī izvērtētu metožu efektivitāti;
- 7) mašīnmācīšanās metodes – tika izmantotas kā pamats ārējās vides faktoru ietekmes modelēšanai, adaptīvu korekcijas funkciju izveidei un konstrukciju bojājumu klasifikācijai;
- 8) konstrukciju tehniskā stāvokļa monitoringa teorija – nodrošināja konceptuālo pamatu monitoringa sistēmas izveidei bojājumu identifikācijas algoritmiem un to novērtēšanas kritērijiem.

Promocijas darba metodoloģiskais pamats balstās datu vadītā pieejā, kurā datu analīze un algoritmu salīdzinošā novērtēšana kalpoja kā metode pētījuma rezultātu ticamības novērtēšanai.

Tika izmantota segmentēta regresijas pieeja, kas apvienota ar adaptīvu modeļu izvēli un pielāgota konkrēta ārējās vides faktora diapazonam. Šī pieeja nodrošina korekcijas funkcijas noteikšanu katrai pašsvārstību frekvencei, līdz ar to padziļinot metodoloģisko izpratni par nelineāru sakarību modelēšanu un uzlabojot svārstībās balstītu konstrukciju tehniskā stāvokļa novērtēšanu.

Pētījuma ierobežojumi

Promocijas darbā izstrādātās metodes eksperimentālā validācija tika veikta, izmantojot divstāvu koka rāmja modeli, kura pašsvārstību frekvenču vērtības tika pielāgotas, lai atbilstu piecstāvu ēkas frekvenču vērtībām, kā arī izmantojot *Filomena Delli Castelli* tilta ilgtermiņa monitoringa laikā iegūtas pašsvārstību frekvenču vērtības. Koka rāmja modelis ar samazinātiem ģeometriskajiem parametriem un viendabīgu materiālu var daļēji ierobežot iegūto rezultātu vispārināmību attiecībā uz reālām daudzstāvu ēkām ar sarežģītām konstruktīvajām shēmām un dažādu materiālu kombinācijām.

Eksperimentā simulētie konstrukciju bojājumi tika ieviesti pakāpeniski un nesagraujoši, galvenokārt mainot rāmja stingumu un masu. Šāda pieeja, lai arī ļauj kontrolēti pētīt bojājumu ietekmi, neietver materiāla plaisāšanu, savienojumu pavājināšanos vai citu neatgriezenisku bojājumu formu analīzi, kas varētu rasties reālā ekspluatācijas procesā.

Izstrādātā metode balstīta neuzraudzīto mašīnmācīšanās algoritmu izmantošanā, tās efektivitāte ir tieši atkarīga no sākotnējo mācību datu kvalitātes. Pieņemtie monitoringa nosacījumi – datu nepārtrauktība, relatīvi augsts mērījumu biežums un sensoru precizitāte – ir būtiski priekšnoteikumi regresijas modeļu efektīvai darbībai. Reālās būvēs bieži vien ir novērojams neregulārs datu ieguves režīms, kā arī tiek izmantoti zemas kvalitātes sensori, kas šajā gadījumā var būtiski ietekmēt metodes efektivitāti.

Pētījumā tika pieņemts, ka ārējās vides dominējošie ietekmes faktori uz konstrukciju dinamiskajām īpašībām ir gaisa temperatūra, relatīvais mitrums un vēja ātrums. Citi iespējamie faktori, piemēram, intensīva satiksmes plūsma, cilvēku plūsma vai svārstības no blakus esošiem ierosmes avotiem, netika ņemti vērā. Līdz ar to metodes lietošanai reālos objektos var būt nepieciešama papildu korekcija un paplašināta vides ietekmes faktoru kopa, lai nodrošinātu pilnvērtīgu dinamisko parametru interpretāciju sarežģītās ekspluatācijas situācijās.

Aizstāvēšanai izvirzītie darba rezultāti

Promocijas darbā iegūtie galvenie rezultāti un secinājumi, kas tiek izvirzīti aizstāvēšanai, ir šādi:

1. Pierādīta ārējo vides faktoru būtiska, nelineāra un sezonāli mainīga ietekme uz konstrukciju pašsvārstību frekvencēm.

Promocijas darbā pierādīts un kvantitatīvi raksturots fakts, ka apkārtējās vides faktori ievērojami ietekmē būvju konstrukciju pašsvārstību frekvenču vērtības. Noteikta apkārtējās vides faktoru ietekme uz pašsvārstību frekvenču izmaiņām. Rezultāti apliecina, ka būvju konstrukciju tehniskā stāvokļa monitoringā ir jāņem

vērā apkārtējās vides ietekmes faktori, kas ietekmē konstrukciju materiāla mehāniskās un fizikālās īpašības.

2. Izstrādāta un validēta segmentēta regresijas un nelineārās korekcijas pieeja ārējo vides faktoru ietekmes modelēšanai.

Promocijas darbā izstrādātās adaptīvas metodes regresijas modeļa izvēle balstīta konkrētā ārējās vides faktora segmentā. Tā vietā, lai izmantotu vienu modeli visā datu apgabalā, tiek lietota daudzpakāpju segmentācija, kur katrā segmentā tiek izvēlēts labākais regresijas modelis, balstoties saliktajā efektivitātes rādītājā.

Ārējās vides faktoru ietekme nav vienmērīga un mainās dažādos sezonālos intervālos, līdz ar to segmentētā pieeja ļauj uzlabot prognozēšanas precizitāti un efektīvāk atdalīt ārējās vides ietekmi no iespējamām strukturālām izmaiņām.

3. Izstrādāta jauna metode ārējo vides faktoru ietekmes samazināšanai monitoringa datos, kas uzlabo konstrukciju bojājumu noteikšanas algoritmu precizitāti, nodrošinot uzticamu un efektīvu ilgtermiņa tehniskā stāvokļa monitoringu.

Promocijas darbā izstrādāta un eksperimentāli aprobēta metode, kas ļauj kompensēt mainīgo ārējās vides faktoru ietekmi, nodrošinot efektīvu konstrukciju tehniskā stāvokļa ilgtermiņa monitoringu. Izstrādātā metode apvieno datu ieguvu ar mašīnmācīšanās algoritmā balstītu datu analīzi, kas ļauj automatizēti identificēt konstrukciju bojājumus un uzlabot konstrukciju tehniskā stāvokļa analīzi. Eksperimentālā validācija veikta, izmantojot koka rāmja un tilta konstrukciju ilgtermiņa monitoringa datus.

4. Definēti ieteikumi konstrukciju tehniskā stāvokļa monitoringa lietošanai un ieviešanai praksē mainīgu ārējo vides apstākļu ietekmē.

Promocijas darbā norādītie ieteikumi un izstrādātā metode var kalpot kā pamats normatīvu un tehnisko specifikāciju veidošanai konstrukciju tehniskā stāvokļa monitoringam dažādām būvēm ārējo vides apstākļu ietekmē.

Darba aprobācija un publikācijas

Promocijas darba rezultāti ir ziņoti un apspriesti trīs starptautiskās konferencēs. Galvenie darba rezultāti izklāstīti četrās zinātniskajās publikācijās, kas indeksētas *WoS/Scopus* datubāzēs, un divos zinātnisko konferenču tēžu krājumos.

1. Zinātniskie raksti zinātniskajos žurnālos, kas indeksēti *WoS/Scopus*

1. Ratnika L., Gaile L., Vatin N. Impact of groundwater level change on natural frequencies of RC buildings. Buildings. vol. 11, no. 7, 2021, 265, doi: 10.3390/buildings11070265.
2. Gaile L., Pakrastins L., Ratnika L. Structural Health Monitoring by merging dynamic response data. Magazine of Civil Engineering, vol. 111, no. 3, 2022, doi: 10.34910/MCE.111.11.
3. Gaile L., Ratnika L., Pakrastins L. RC Medium-Rise Building Damage Sensitivity with SSI Effect. Materials, vol. 15, no. 5, Mar. 2022, doi: 10.3390/ma15051653.
4. R. Janeliukstis, L. Ratnika, L. Gaile, and S. Rucevskis, "Environmental Factors in Structural Health Monitoring – Analysis and Removal of Effects from Resonance

Frequencies,” *Journal of Sensor and Actuator Networks*, vol. 14, no. 2, Apr. 2025, doi: 10.3390/jsan14020033.

2. Zinātniskie raksti konferenču rakstu krājumos, kas indeksēti WoS/Scopus

1. Gaile, L., Sliseris, J., Ratnika, L. (2021). Towards SHM of medium-rise buildings in non-seismic areas. International Conference on Structural Health Monitoring of Intelligent Infrastructure: Transferring Research into Practice, SHMII, 2021-June, 1023–1030.
2. Ratnika L., Gaile L., Nicoletti V., Gara F., Multi-dataset OMA and Finite Element Model Updating of Steel Observation Tower, *Journal of Physics: Conference Series*, Institute of Physics, 2024. doi: 10.1088/1742-6596/2647/18/182014.

3. Zinātniskās konferences, kurās ziņoti un apspriesti promocijas darba rezultāti

1. Ratnika L., Gaile L., Nicoletti V., Gara F., Multi-dataset OMA and Finite Element Model Updating of Steel Observation Tower. 12th International Conference on Structural Dynamics. 12th International Conference on Structural Dynamics, Delft, Netherlands, 2–5 July 2023.
2. Ratnika L., Daudzdzīvokļu dzīvojamo un sabiedrisko ēku nesošo konstrukciju instrumentētās monitoringa sistēmas metodikas izstrāde. RTU 62nd International Scientific Conference, Riga, Latvia, 2021.
3. Gaile, L., Sliseris, J., Ratnika, L. Towards SHM of medium-rise buildings in non-seismic areas. 10th International Conference on Structural Health Monitoring of Intelligent Infrastructure: Transferring Research into Practice, 30 June–2 July 2021.


Darba saturs un apjoms

Promocijas darbā ir anotācija, darba vispārējs raksturojums, četras nodaļas, secinājumi un izmantotās literatūras saraksts. Darba apjoms ir 127 lapaspuses, kas ietver 74 attēlus, astoņas tabulas un 210 izmantotos literatūras avotus.

Darba vispārējā raksturojumā izklāstīta problēmas aktualitāte un definēts promocijas darba mērķis, uzdevumi un pētījuma novitāte. Izvērtēta konstrukciju tehniskā stāvokļa monitoringa nozīme, kā arī pamatota nepieciešamība ieviest metodes, kas samazinātu ārējo vides faktoru ietekmi uz konstrukciju monitoringa datiem. Pirmajā nodaļā aprakstīts esošo ēku fonda novērtējums, pamatojot nesošo konstrukciju ilgtermiņa monitoringa nepieciešamību. Otrajā nodaļā apkopotas un analizētas dažādu mašīnmācīšanās algoritmu lietojamību nesošo konstrukciju tehniskā stāvokļa novērtēšanā un ārējo vides faktoru ietekmes samazināšanā. Trešajā nodaļā norādīti izstrādātās ārējās vides faktoru ietekmes samazināšanas metodes galvenie posmi – piedāvātā segmentētā ārējās vides faktoru ietekmes pieceja ar adaptīvu regresijas modeļu izvēli, kas ļauj noteikt optimālo regresijas modeli katram ārējās vides faktora segmentam un katrai pašsvārstību frekvencei, nodrošinot precīzu un automātisku vērtību korekciju. Ceturtajā nodaļā aprakstīta ārējās vides ietekmes samazināšanas metodes validācija koka rāmja un tilta konstrukciju monitoringa datiem. Šajā nodaļā analizēta arī eksperimentāli iegūto datu un ārējo vides ietekmes faktoru savstarpējās korelācijas un nelineārās sakarības, apkopoti izstrādātās metodes validācijas rezultāti pirms un pēc ārējās vides ietekmes samazināšanas, kā arī salīdzināta ārējā vides faktoru ietekmes samazināšanas metodes efektivitāte. Promocijas darba noslēgumā apkopoti galvenie secinājumi.


1. Esošā ēku fonda novērtējums un tehniskā stāvokļa monitoringa sistēmas nepieciešamība

Jaunu ēku būvniecības skaita rādītājs jau kopš seniem laikiem ir kalpojis kā būtisks atskaites punkts, lai novērtētu būvniecības sektora attīstības virzienu. Šo rādītāju izmaiņas liecina par pārmaiņām sabiedrības vajadzībās, kā arī par izmaiņām pieprasījumā pēc dažādiem ēku veidiem un mūsdienīgu risinājumu ieviešanu. Pēdējo gadu statistika liecina, ka būvniecības aktivitāte kopumā samazinās, īpaši kopš 2021.gada (1.1.att.), tomēr vienlaikus var novērot būtiskas pārmaiņas būvniecības struktūrā – pieaug pieprasījums pēc dzīvojamām ēkām. Dzīvojamo ēku īpatsvara pieaugums, salīdzinot ar nedzīvojamo ēku būvniecību, liecina par pakāpenisku pārvirzīšanos uz mājokļu sektoru būvniecību un iedzīvotāju vajadzībām piemērotu ēku risinājumiem.



1.1.att. Jaunbūvju skaita indekss (2021=100) Latvijā laika posmā no 2003.gada līdz 2022.gadam, sadalot ēkas dzīvojamās un nedzīvojamās. Indekss aprēķināts, izmantojot 2021.gadu kā bāzes gadu, kuram piešķirta vērtība 100. Pārējo gadu indeksa vērtības parāda jaunbūvju skaita līmeni salīdzinājumā ar bāzes gadu [3].

Savukārt, apskatot jaunbūvju skaitu atsevišķos ēku veidos, var secināt, ka pēdējos gados pieaug tieši daudzdzīvokļu jeb divu vai vairāku dzīvokļu ēku būvniecība (1.2.att.). Salīdzinot ar situāciju laika posmā no 2007.gada līdz 2010.gadam, kad tika novērota būtiska daudzdzīvokļu ēku būvniecības lejupslīde, kopš 2015.gada redzams, ka daudzdzīvokļu ēku segmentā pakāpeniski pieaug jauno projektu skaits.




1.2.att. Jaunbūvju skaita indekss (2021=100) Latvijā laika posmā no 2003.gada līdz 2022.gadam, sadalot pa ēku veidiem. Indekss aprēķināts, izmantojot 2021.gadu kā bāzes gadu, kuram piešķirta vērtība 100. Pārējo gadu indeksa vērtības parāda jaunbūvju skaita līmeni salīdzinājumā ar bāzes gadu [3].

Jaunu ēku būvniecība ir cieši saistīta ar ekonomisko attīstību un cilvēku iespējām un vēlmēm izvēlēties būvēt jaunas ēkas, nevis saglabāt esošās. Tomēr pēdējos gados ir novērojama tendence saglabāt arī esošās ēkas – galvenokārt ēku nesošo konstrukciju karkasu. Sevišķi raksturīgi tas ir Rīgas vēsturiskajā centrā un vēsturiskajām ēkām Latvijas teritorijā. Pēc georiga.lv [4] datiem galvenokārt Rīgas pilsētas apkaimēs - Vecpilsētā un Centrā ir noteikta kultūrvēsturiski nozīmīga apbūves fronte, kas ēkas pārbūves un jaunbūves gadījumā tiek pakļauta virknei Rīgas vēsturiskā centra un tā aizsardzības zonas apbūves veidošanas pamatnosacījumiem, kas nosaka teritorijas turpmāko izmantošanu un kultūrvēsturiskā mantojuma saglabāšanu un attīstību. Rīgas vēsturiskā centra teritorijas plānojuma un apbūves struktūras saglabāšanas un pilnveidošanas pamatuzdevums ir esošās vēsturiskās apbūves saglabāšana, līdz ar to akcentējot nepieciešamību pēc ēku pārbūvēm nevis jaunbūvēm.

Pārbūves gadījumā ēkas esošajām konstrukcijām tiek veikts tehniskais apsekojums un, pamatojoties uz šī apsekojuma slēdzienu un būvkonstrukciju projektētāja pieņemto lēmumu, tiek saglabātas vai nojauktas ēkas nesošās konstrukcijas. Ēkas pārbūvju gadījumā netiek uzlikts pienākums monitorēt ēkas esošās konstrukcijas ekspluatācijas laikā, bet gan, piemēram, LBN 217-24 “Ģeotehniskā projektēšana”[5], kā arī citos noteikumos ir minēts, ka, ja esošajām konstrukcijām pārbūves vai atjaunošanas gadījumā netiek palielināta slodze, netiek mainīta konstruktīvā elementa aprēķina shēma vai, ja nav konstatētas virsnormatīvās izlieces vai citas konstrukciju nedrošuma pazīmes, tad konstrukciju nestspējas aprēķini netiek veikti. Tomēr, zinot projektēšanas un būvniecības laikā iespējamās kļūdas un nepilnības, šīs esošās konstrukcijas var tikt pakļautas slodzes pieaugumam un iespējamiem bojājumiem ēkas ekspluatācijas laikā.

Apskatot georiga.lv [6] pieejamos datus par vidi degradējošām būvēm un zemes vienībām, uzskatāmi var redzēt, ka tieši Rīgas vēsturiskajā centrā šo būvju un zemes vienību skaits ir vislielākais (1.3.att.). Šīs būves tiek klasificētas atbilstoši to radītajai ietekmei uz cilvēku drošību. Tās var būt pilnīgi vai daļēji sagruvušas un cilvēku drošībai apdraudošas būves bīstamā tehniskā stāvoklī, cilvēku drošību apdraudošas būves potenciāli bīstamā tehniskajā stāvoklī, kā arī vidi degradējošas būves.



1.3.att.Vidi degradējošu objektu izvietojums Rīgas teritorijā [6].

Lielais skaits būvju, kas tiek klasificētas kā vidi degradējošas un cilvēku dzīvību apdraudošas, liecina par to, ka ēku tehniskais stāvoklis ir nolietojies un visbiežāk finansiālu apsvērumu dēļ tas netiek uzlabots vai atjaunots noteiktā laika posmā, līdz ar to pasliktinot ēkas kopējo tehnisko stāvokli līdz brīdim, kad konstrukciju atjaunošana vairs nav iespējama.

Rīgas pilsētas apkaimēs un Latvijas teritorijā ir aptuveni 15 tipveida daudzdzīvokļu dzīvojamo ēku veidi. Sākot ar 1958.gadu, Rīgā tika būvēti daudzdzīvokļu dzīvojamo ēku masīvi Āgenskalna priedēs, tam sekoja dzīvojamo namu kompleksi Grīvas ielā, Juglā (1962.-1970.), Ķengaragā (1971.), Purvciemā (pēc 1965.), kā arī Imantā (pēc 1966.) [7]. Šīm dzīvojamām ēkām atbilstoši MK noteikumiem Nr. 907 "Noteikumi par dzīvojamās mājas apsekošanu, tehnisko apkopi, kārtējo remontu un energoefektivitātes minimālajām prasībām" vidējais kalpošanas ilgums ir 60 līdz 70 gadi [8]. Arī Eiropas Savienībā aptuveni 35% ēku pārsniedz 50 gadu kalpošanas laiku, kas nozīmē arvien pieaugošu nepieciešamību pēc to atjaunošanas, pastiprinātas uzraudzības un rekonstrukcijas [9].

LBN 405-21 "Būvju tehniskās apsekošanas būvnormatīvs" nosaka, ka tehniskā apsekošana ir jāveic periodiski ne retāk kā reizi 10 gados otrās un trešās grupas publiskām un daudzstāvu daudzdzīvokļu dzīvojamām ēkām [2]. Līdz ar to normatīvs nosaka, ka, piemēram, 2019.gadā izpētes veiktajām ēkām nākamā tehniskā apsekošana ir paredzēta tikai pēc 10 gadiem un šajā periodā neuzliekot par pienākumu ēkas īpašniekam noteiktā laika posmā veikt papildu ēkas nesošo konstrukciju monitoringu.

Konstrukciju tehniskā stāvokļa pasliktināšanās ir atkarīga no dažādiem faktoriem: konstrukciju materiāla veida, pakļautās slodzes veida, vides apstākļiem un ēkas lietošanas veida. Tomēr praksē konstrukcijas ar 30 – 40 gadu kalpošanas laiku ietilpst kritiskās novecošanās kategorijā, kurām būtu nepieciešams veikt konstrukciju periodisku pārbaudi un sistematisku apkopi [10].


1.1. Konstrukciju tehniskā stāvokļa monitoringa nepieciešamības pamatojums un monitoringa attīstība

Konstrukciju tehniskā stāvokļa monitorings (*SHM, Structural Health Monitoring*) ir konstrukciju bojājumu noteikšanas metode, kas ietver konstrukciju novērošanu noteiktā laika posmā, izmantojot periodiskus vai nepārtrauktus mērījumus. No šiem mērījumiem tiek iegūti konstrukciju fizikālo vai mehānisko īpašību raksturlielumi, kas ir pakļauti izmaiņām konstrukciju bojājumu rezultātā [11], [12]. Konstrukciju tehniskā stāvokļa monitoringa mērķis ir apkopot pietiekamu informāciju par bojājumiem, lai varētu veikt atbilstošus novēšanas pasākumus un atjaunot konstrukcijas vai sistēmas kvalitatīvu darbību un nodrošināt ēkas lietotāju drošību. Turklāt, lai nodrošinātu monitoringa efektivitāti, tad mērījumu datiem ir jāsaturs tikai nepieciešamā informācija. Līdz ar to konstrukciju bojājumu noteikšanu jāuztver kā hierarhisku struktūru, līdzīgi kā bojājumu attīstību [12].

Ēkas ekspluatācijas laikā konstrukciju kalpošanas laiks pakāpeniski samazinās dažādu faktoru ietekmē – novecošanās, ģeometrisku izmaiņu, mainīgu slodžu un konstrukciju bojājumu rezultātā [13]. Būvēm, kas sasniegušas vai tuvojas vidējam kalpošanas ilgumam, būtu nepieciešams veikt periodisku vai ilgstošu konstrukciju tehniskā stāvokļa monitoringu. Ja šīm

būvēm noteiktā laika posmā vai ilgtermiņā tiktu veikts konstrukciju tehniskā stāvokļa monitorings, iespējams tām tiktu nodrošināts ilgāks ekspluatācijas laiks, kā arī tās neapdraudētu cilvēku dzīvību un netiktu iekļautas vidi degradējošo objektu sarakstā. Līdzīgi arī vēsturiskām ēkām nepieciešama uzturēšana un restaurācija. Ar konstrukciju tehniskā stāvokļa monitoringa palīdzību ir iespējams novērtēt vēsturisko ēku konstrukciju stāvokli, lai plānotu un kontrolētu tehniskās apkopes un restaurācijas darbus [14].

Būvju konstrukciju kvalitāti no funkcionalitātes viedokļa raksturo drošuma līmenis un uzturēšanas izmaksas. 1.4.attēlā ir salīdzināta konstrukciju ekspluatācija ar tehniskā stāvokļa monitoringu un bez tā.




1.4.att. Konstrukciju salīdzinājums ar ietvertu konstrukciju monitoringu un neietvertu konstrukciju monitoringu [10].

Konstrukcijām bez uzstādītām monitoringa sistēmām uzticamība sākotnēji ir augstā līmenī un pēc tam tā samazinās, jo konstrukciju bojājumi netiek identificēti savlaicīgi. Konstrukciju uzturēšanas izmaksas, kas saistītas ar bojājumu novēlotu konstatēšanu, to progresējošo attīstību, nepieciešamību veikt apjomīgākus remonta vai pastiprināšanas darbus, kā arī neplānotu ekspluatācijas pārtraukuma risku, šajā gadījumā palielinās līdz ar ekspluatācijas laiku. Savukārt, konstrukcijām ar uzstādītām monitoringa sistēmām uzticamība saglabājas augstā līmenī visā ekspluatācijas laikā, jo bojājumi tiek identificēti agrīnā stadijā, bet uzturēšanas izmaksas ir stabilas un zemākas. Salīdzinājums apstiprina konstrukciju monitoringa sistēmu nozīmīgumu drošuma saglabāšanas un ekonomisko izmaksu samazināšanas nodrošināšanā [10].

Konstrukciju tehniskā stāvokļa monitorings sniedz iespēju atjaunināt informāciju par slodzes ietekmi un konstrukcijas nestspējas rādītājiem. Konstrukciju monitoringa datu izmantošana ļauj precizēt gan slodzes iedarbību, gan konstrukcijas nestspēju, līdz ar to samazinot nenoteiktību un nodrošinot precīzāku konstrukciju drošuma novērtējumu. Tas būtiski samazina risku kļūdaini noteikt konstrukcijas nestspējas robežsliekšni. Ja nestspējas robežsliekšņa sasniegšana tiek prognozēta par vēlu, iespējami konstrukciju bojājumi vai pat sabrukums. Savukārt, ja robežsliekšnis tiek prognozēts pāragri, tad rodas nevajadzīgas uzturēšanas un tehniskās apkopes izmaksas. Rezultātā ir iespējams pieņemt pamatotākus lēmumus par konstrukciju tehnisko apkopi [13].


Šobrīd konstrukciju tehniskā stāvokļa monitoringa sistēmu aizstāj vizuālās pārbaudes un vairākas nesagraujošās testēšanas metodes, piemēram, akustiskās, ultraskaņas, magnētiskā lauka, radiogrāfijas, virpuļstrāvu un termiskā lauka metodes [10]. Šajās metodēs parasti tiek izmantoti viena tipa sensori un to darbība lielākoties ir manuāla un salīdzinoši vienkārša. Tomēr nesagraujošās testēšanas metodēm ir nepieciešamas iepriekšējās zināšanas par iespējamo bojājuma atrašanās vietu un veidu, jo nodrošina lokālu bojājuma identifikāciju tikai tad, ja bojājuma vieta ir pieejama pārbaudei. Šo metožu priekšrocība ir augsta ticamība bojājumu raksturojumam noteikšanā, kā arī to pielietojumam nav nepieciešama detalizēta informācija par visu konstrukciju vai analītiskā modeļa izmantošana, jo pietiek ar salīdzinoši vienkāršiem aprēķiniem [15]. Konstrukciju tehniskā stāvokļa monitoringa sistēmas, salīdzinot ar tradicionālajām nesagraujošās testēšanas metodēm un vizuālās pārbaudes metodēm, sniedz globālu pieeju un autonomu datu ieguvu un analīzi, kas ļauj veikt nepārtrauktu konstrukciju tehniskā stāvokļa novērtēšanu dažādos ekspluatācijas un vides apstākļos. Tomēr konstrukciju monitoringa sistēmas ieviešanu būtiski ierobežo augstās izmaksas un nepieciešamība pielāgot to katrai konstrukcijai. Līdz ar to projektētāji un ēku īpašnieki praksē joprojām bieži izvēlas tradicionālās konstrukciju uzraudzības metodes [10].

Konstrukciju tehniskā stāvokļa monitoringa attīstība ir cieši saistīta ar digitālo skaitļošanas iekārtu attīstību. Lai gan pētījumi par konstrukciju tehniskā stāvokļa monitoringu tiek veikti jau kopš 1972.gada, tikai kopš 2006.gada ir novērojams būtisks zinātnisko publikāciju skaita pieaugums (1.5.att.).



1.5.att. Publikāciju skaits laika posmā no 1972.gada līdz 2024.gadam, kuru atslēgas vārdos ir iekļauts konstrukciju tehniskā stāvokļa monitorings [16], ēkas [17], dinamiskās svārstības [18] saskaņā ar scopus.com datiem.

Konstrukciju monitorings tiek plaši pētīts un pielietots arī visu veidu civilām un inženiertehniskām konstrukcijām, līdz ar to lielu daļu no publikācijām pēdējos gados veido tieši inženierbūvju monitoringa izpētes rezultāti (1.6.att.).



1.6.att. Publikāciju skaits laika posmā no 1972.gada līdz 2024.gadam, kuru atslēgas vārdos ir iekļauts konstrukciju tehniskā stāvokļa monitorings [16], tilti [19], dinamiskās svārstības [20] saskaņā ar scopus.com datiem.

Apskatot publikāciju skaita tendenci konstrukciju tehniskā stāvokļa monitoringā atsevišķi tikai ēkām un tiltiem, var novērot, ka ir līdzīgs pakāpenisks pieaugums, tomēr publikāciju skaits attiecībā pret kopējo konstrukciju monitoringa publikāciju skaitu ēkām ir krietni mazāks. Tas norāda, ka būtiska daļa pētījumu ir veltīta citu konstrukciju un sistēmu monitoringa risinājumiem, piemēram, mašīnbūves, aeronautikas un jūras inženierijas objektiem, kā arī dažādām industriālām un tehnoloģiskām sistēmām. Līdz ar to var secināt, ka ēku konstrukciju monitoringa pielietojuma izpēte turpinās aizvien un nākotnē ieņems būtisku lomu zinātnes sasniegumu un atklājumu jomā.

Konstrukciju monitoringa attīstība sākās līdz ar ideju noteikt plaisas dzelzceļa riteņos 19.gadsimta beigās un turpinājās ar Marvina Minska izveidoto pirmo neironu tīklu mācīšanās mašīnu. Pirmais monitoringa nozīmīgais aizsākums 1960. gados bija rotējošo iekārtu tehniskā stāvokļa uzraudzība ar vienkāršu trieciena impulsu metodi. Vēlāk uz svārstībām balstīts konstrukciju monitorings tika piemērots naftas platformām atklātā jūrā. Līdz ar konstrukciju monitoringa pielietojuma sākumposmu aviācijas nozarē, civilām ēkām un infrastruktūrām 1980.gadā, tika uzsāktas nozīmīgas inovācijas mašīnmācīšanās, mākslīgā intelekta un datoru vizualizēšanas jomās. Līdz ar mākoņskaitļošanas ieviešanu 2002.gadā un "Rūpniecības 4.0" ieviešanu 2010.gadā tika veikts nozīmīgs solis pretī jaunās paaudzes skaitļošanas un monitoringa risinājumu ieviešanai [1].

Pēdējos gados strauji pieaugoša interese par konstrukciju tehniskā stāvokļa monitoringu varētu būt saistīta ar potenciālo ekonomisko ieguvumu un cilvēku drošību, kas saistīta ar būvju saglabāšanu. Papildus tam arvien lielāku nozīmi iegūst nepieciešamība pagarināt būvju ekspluatācijas laiku un optimizēt uzturēšanas izmaksas, balstoties uz faktisko konstrukcijas tehnisko stāvokli nevis pieņēmumiem. Līdz ar to konstrukciju tehniskā stāvokļa monitorings kļūst par būtisku instrumentu ilgtspējīgas būvniecības un drošas infrastruktūras attīstībā [21].

1.2. Uz svārstībām balstīta nesošo konstrukciju tehniskā stāvokļa novērtēšana

Izmantojot vizuālās konstrukciju tehniskā stāvokļa pārbaudes metodes, bija ļoti sarežģīti precīzi identificēt konstrukciju bojājumus lielām un komplicētām būvēm, jo šo metožu izmantošana nevar nodrošināt kvantitatīvu bojājumu novērtēšanu un nespēj sniegt uzticamu kopējo konstrukciju vai ēkas tehniskā stāvokļa novērtējumu, ja bojājumi atrodas grūti pieejamās vai neredzamās vietās un tos nav iespējams identificēt. Lai noteiktu konstrukciju bojājumus šādām būvēm, tika izstrādāta uz svārstībām balstīta metode. Izmantojot šo metodi, konstrukciju svārstības tiek ierosinātas ar apkārtējā vidē esošiem ierosinātajiem, ārēju ierosinātāju vai iebūvētiem mehānismiem [15]. Apkārtējās vides ierosinātāji - piemēram, vējš vai intensīvas satiksmes ierosinātas svārstības, salīdzinājumā ar piespiedu svārstību ierosinātajiem ir ekonomiski izdevīgāki, lai nodrošinātu nepārtrauktu, ilgtermiņa konstrukciju monitoringu [22].

Apkārtējās vides svārstību ierosinātāju ierosmes signāls mainās ne tikai pēc amplitūdas, bet arī pēc ierosmes frekvenču spektra [22]. Šādos apstākļos konstrukciju dinamisko īpašību noteikšanai bieži tiek izmantota operacionālā modālā analīze (*OMA, Operational Modal*

Analysis), kas nodrošina iespēju identificēt konstrukcijas dinamiskos parametrus reālos ekspluatācijas apstākļos, neizmantojot kontrolētu ierosinātāju [23]. OMA balstās uz pieņēmumu, ka apkārtējās vides ierosinātāji ir nejauši procesi, ar pietiekami plašu frekvenču spektru, kas nodrošina enerģiju visu konstrukciju pašsvārstību formu ierosināšanai. Šajā metodē ierosinātājs netiek tieši mērīts, bet tiek aprakstīts kā nejaušs, stacionārs process ar aptuveni vienmērīgu enerģijas sadalījumu frekvenču diapazonā [24]. Savukārt eksperimentālā modālā analīze (*EMA, Experimental Modal Analysis*) tiek veikta kontrolētos apstākļos, izmantojot zināmu un izmērāmu ierosinātāju, piemēram, trieciena āmuru vai svārstību ģeneratoru. Šī pieeja nodrošina augstu precizitāti dinamisko parametru noteikšanā, jo ir zināmi gan ievades, gan izvades signāli. Tomēr EMA praktiska pielietošana lielām būvēm ir ierobežota, jo tās pielietošanai ir nepieciešams specifiskas iekārtas, jānodrošina piekļuve konstrukcijām, kā arī tās ieviešana ir saistīta ar ievērojamām izmaksām [25]. Tāpēc OMA ir kļuvusi par galveno metodi lielu būvju dinamiskās uzvedības novērtēšanai. Tā ļauj iegūt dinamiskos parametrus, nepārtraucot būves ekspluatāciju un neizmantojot mākslīgus ierosinātājus, kas ir īpaši nozīmīgi konstrukciju ilgtermiņa monitoringa sistēmās [26].

Konstrukciju tehniskā stāvokļa monitorings, kas balstās uz konstrukciju dinamisko parametru izmaiņām, ēkām un inženierbūvēm, tiek pētīts jau kopš 1980. gadu sākuma [21]. Uz konstrukciju svārstībām balstītas metodes pamatprincipu var izskaidrot ar to, ka dinamiskie parametri, piemēram, pašsvārstību frekvences, pašsvārstību formas un svārstību rimšanas koeficienti, ir konstrukciju raksturlielumu – masas un stinguma funkcijas [15]. Bojājumi samazina konstrukcijas stingumu un maina tās dinamiskos parametrus. Līdz ar to dinamiskie parametri spēj sniegt informāciju par konstrukcijas bojājuma eksistenci, bojājuma atrašanās vietu un tā pakāpi [27], [28].

Pašsvārstību frekvenču izmaiņas noteikt ir vieglāk nekā pašsvārstību formas un mērījumu kļūda parasti ir mazāka par 1% [29]. Kā arī pašsvārstību formu noteikšanai ir nepieciešams lielāks skaits sensoru nekā frekvenču gadījumā, kas palielina arī konstrukciju tehniskā stāvokļa monitoringa sistēmas uzstādīšanas izmaksas [15]. Līdz ar to konstrukciju bojājumu identificēšanā visbiežāk izmanto frekvenču izmaiņas, nevis svārstību formu vai rimšanas koeficienta izmaiņas.

Salīdzinot ar vizuālās pārbaudes un nesagraujošās testēšanas metodēm, uz svārstībām balstītai pašsvārstību frekvenču monitoringa metodei ir daudz priekšrocību:

- 1) Konstrukcijas bojājuma vieta iepriekš nav jānoskaidro;
- 2) Svārstību mērījumiem sensori nav jānovieto konstrukcijas bojājuma tuvumā;
- 3) Pat lielās un konstruktīvi sarežģītās būvēs ierobežots sensoru skaits var nodrošināt pietiekamu informāciju konstrukcijas bojājuma esamības noteikšanai un tā novērtēšanai;
- 4) Svārstību mērījumiem nav nepieciešamas liela izmēra iekārtas, un tās var iegūt mērījumus apkārtējās vides ietekmē [27].

Tomēr šīs metodes praktiskai pielietošanai konstrukciju monitoringā tiek novēroti dažādi ierobežojumi:

- 1) Konstrukciju pašsvārstību frekvencēm ir zema jutība pret bojājumiem, jo bojājumi konstrukcijā ir parasti lokāla parādība. Lokālo bojājumu radītās dinamisko parametru


izmaiņas ir sarežģīti identificējamas, ja vien konstrukcijas bojājums nav ļoti nopietns vai svārstību mērījumi nav ļoti precīzi. Turklāt pieaugot pašsvārstības formas kārtai, būtiski pieaug arī nepieciešamais sensoru skaits;

- 2) Ēkai parasti piemīt liels skaits brīvības pakāpju un līdz ar to liels skaits pašsvārstību frekvenču un pašsvārstību formu. Praksē ir ļoti grūti precīzi noteikt augstākās frekvences un pašsvārstību formas. Svārstību mērījumu kļūdas un svārstību formu nepilnības var radīt kļūdas konstrukciju bojājumu noteikšanā;
- 3) Konstrukciju bojājumu identifikācija balstās uz liela apjoma monitoringa datiem, kuru ilgtermiņa uzglabāšanai un apstrādei ir nepieciešami ievērojami datu atmiņas un skaitļošanas resursi;
- 4) Konstrukcijas dinamiskos parametrus ietekmē arī apkārtējās vides un ekspluatācijas faktori, kas nav konstrukciju bojājumi, piemēram, temperatūra, mainīgs mitrums, mainīgi slodzes apstākļi un robežnosacījumu izmaiņas [15].

Uz svārstībām balstīta nesošo konstrukciju tehniskā stāvokļa monitoringa pieejas informatīvā kapacitāte ir atkarīga no spējas precīzi identificēt dominējošās pašsvārstību formas izmēritajā frekvenču diapazonā. Taču praksē tas bieži vien ir sarežģīti, jo tuvu novietotu pašsvārstību formu savstarpējā saistība, īpaši augstākās kārtas frekvenču diapazonos, apgrūtina atsevišķu svārstību formu nošķiršanu [30]. Papildus tam, konstrukciju monitoringa procesa laikā var rasties ar mērījumu datu ieguvu un pārraidi saistīti traucējumi, kas var izraisīt daļēju informācijas zudumu un negatīvi ietekmēt dinamisko parametru noteikšanas stabilitāti [31]. Līdz ar to uz svārstībām balstīta monitoringa rezultātu ticamība ir atkarīga arī no izmantoto metožu spējas nodrošināt stabilu un atkārtojamo konstrukcijas dinamisko parametru, tai skaitā dominējošo pašsvārstību frekvenču un pašsvārstību formu, novērtējumu situācijās ar nepilnīgu mērījumu informāciju un paaugstinātu būves konstruktīvo sarežģītību [32], [33].

1.2.1. Uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringa sistēmas darbības pamatprincipi

1993.gadā Rytter pirmo reizi izstrādāja konstrukciju bojājumu noteikšanas shēmu. Tā tika iedalīta četrās daļās: bojājuma noteikšana, bojājuma lokalizācija, bojājuma pakāpes novērtēšana un prognozēšana [34]. Būtībā konstrukciju bojājumu noteikšanā tiek meklētas atbildes uz vairākiem jautājumiem: vai konstrukcijai ir konstatēts bojājums; kur atrodas šis bojājums; kāda ir bojājuma pakāpe, proti, cik nopietns tas ir attiecībā pret konstrukcijas nestspēju; kāds ir bojājuma apjoms jeb cik lielā mērā bojājums ir izplatījies konstrukcijā attiecībā pret tās kopējo apjomu; kā arī kāds ir konstrukcijas prognozējamais darbības laiks. Šie soļi papildina Rytter izveidoto shēmu. Shematiski bojājumu noteikšanas soļus var attēlot 1.7.attēlā [12].



1.7.att. Konstrukciju bojājumu noteikšanas shēma [12].

Konstrukciju tehniskā stāvokļa noteikšanas procesa pirmajā solī jeb **darbības novērtējumā** tiek analizēti ekspluatācijas un ārējās vides apstākļi, identificēti datu iegūšanas ierobežojumi un definēti monitoringa mērķi, lai pielāgotu bojājumu noteikšanas pieeju konkrētās konstrukcijas darbības īpatnībām, paredzamajiem bojājumu veidiem un to izpausmes raksturam.

Datu iegūšanas un apstrādes posmā tiek noteikts piemērotākais sensoru veids, to novietojums, nepieciešamais skaits, kā arī datu iegūšanas, saglabāšanas un apstrādes iekārtas. Šajā solī tiek izvērtēts arī datu iegūšanas biežums - no periodiskai līdz nepārtrauktai datu iegūšanai. Datu iegūšanas procesā ir nepieciešams noteikt mainīguma avotus, kas var ietekmēt mērījumu precizitāti un rezultātu stabilitāti. Datu apstrādes procesa laikā tiek izvērtēts, kuri dati ir piemēroti turpmākai izmantošanai un kuri ir jāizslēdz no analīzes.

Pēc datu iegūšanas un apstrādes posma seko **pazīmju atlasē** posms, kura mērķis ir identificēt konstrukcijas raksturlielumus, kas visvairāk reaģē uz bojājumu veidošanos. Šajā posmā tiek izvēlētas un apvienotas pazīmes, kas ļauj atšķirt nebojātu konstrukciju no bojātas, vienlaikus samazinot datu apjomu un saglabājot būtisko informāciju par strukturālām izmaiņām.


Pēc pazīmju atlasē posma seko **statistisko modeļu izstrādes** posms, kura mērķis ir izveidot algoritmus, kas, balstoties uz iegūtajām pazīmēm, spēj identificēt konstrukciju bojājumus un statistiski novērtēt bojājuma pakāpi [11]. Šajā posmā izmantotās metodes parasti iedalās trīs kategorijās: grupu klasifikācijā, noviržu analīzē un regresijas analīzē [35],[36],[37] (skat.2.nodaļu). Statistiskie modeļi palīdz atbildēt uz konstrukciju tehniskā stāvokļa monitoringa galvenajiem jautājumiem. Šo modeļu izstrādes posma rezultātā tiek noteikts, vai konstrukcija ir bojāta, kur bojājums atrodas, kāds ir tā veids un apjoms, kā arī noteikts konstrukcijas atlikušais lietderīgās izmantošanas laiks, izvērtējot arī iespējamās kļūdainās bojājumu indikācijas [11].

Konstrukciju bojājumu noteikšanā viens no pamatprincipiem ir salīdzināt divus konstrukciju stāvokļus – esošo un references stāvokli [21], [38]. Salīdzināšanas mērķis ir identificēt statistiski nozīmīgas novirzes konstrukcijas dinamiskajos parametros, kas var liecināt par konstrukcijas bojājuma esamību un attīstību.

References stāvoklim jāatbilst konstrukcijas nebojātam ekspluatācijas stāvoklim. Ja references stāvoklis nav definēts precīzi, tad bojājumu noteikšanas rezultāti var kļūt nenoteikti vai maldinoši, īpaši gadījumos, kad analizētās izmaiņas dinamiskajos parametros ir nelielas. Līdz ar to bojājumu noteikšanas uzdevums tiek formulēts kā statistiska lēmumu pieņemšanas problēma, kurā tiek vērtēts, vai novērotās izmaiņas dinamiskajos parametros pārsniedz references stāvokļa parametru vērtību. Konstrukciju bojājumu noteikšanas precizitāte ir saistīta ar pieejamo datu apjomu, kvalitāti un atbilstību konstrukcijas nebojātajam stāvoklim. Līdz ar to augstāku bojājumu noteikšanas līmeņu sasniegšanai nepietiek ar vienkāršu parametru salīdzināšanu, bet ir nepieciešama sistemātiska pieeja, kas apvieno mērījumu datus, modeļus un statistiskās novērtēšanas metodes [39].

1.2.2. Uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringa sistēmu sensori datu iegūšanai

Uz svārstībām balstītas konstrukciju tehniskā stāvokļa monitoringa sistēmās datu iegūšanas posmā, izmantojot sensorus, tiek iegūti mērījumi, kas raksturo konstrukcijas dinamisko reakciju. Sensoru uzdevums ir pārveidot konstrukcijas dinamisko reakciju signālos, kurus tālāk iespējams uzglabāt un pārveidot datu apstrādes sistēmā (*DAS, Data Acquisition System*). Līdz ar to signālu iegūšana jeb monitoringa iedalās divos apakšposmos – signāla sadalīšanā un datu apstrādē (1.9.att.) [40].



1.9.att. Konstrukciju monitoringa signāla iegūšanas posma nepieciešamie soļi [40].

Sensoru informācijas posmā sensori iegūst mērījumu signālus, kas raksturo konstrukcijas dinamisko reakciju un kalpo kā ievades dati signālu apstrādei un datu iegūšanas posmiem.

Konstrukciju tehniskā stāvokļa monitoringā izmantoto sensoru mērījumus var iedalīt trīs grupās [41]:

- 1) kinemātiskie – pārvietojums, ātrums, paātrinājums;
- 2) mehāniskie – spēks, deformācija, spriegums;
- 3) apkārtējā vides iedarbība – vējš, temperatūra, mitrums, sniega segas biezums.

Sensori ir viena no vissvarīgākajām konstrukciju tehniskā stāvokļa monitoringa sistēmas daļām, jo rezultātu kvalitāte ir tieši atkarīga no iegūto datu kvalitātes. Konstrukciju monitoringā izmantojamie tipiskie sensoru veidi ir pjezoelektriskie, optiskās šķiedras un mikroelektromagnētiskie (*MEMS, Micro-Electro-Mechanical Systems*) [15].

Pjezoelektriskos sensoros tiek izmantots pjezoelektrisks materiāls, kas rada elektrisko strāvu, kura ir proporcionāla materiālam pieliktajam spiedienam. Spiedienam palielinoties, palielinās arī izejošais signāls. Salīdzinot ar jaudas sensoriem, kuriem ir iebūvēta signāla pastiprināšana un apstrāde, šāda veida sensoriem ir nedaudz mazāka jutība, tāpēc tie ir mazāk piemēroti zemu frekvenču mērījumiem [40].

Mikroelektromagnētiskie sensori tiek izgatavoti no vairākiem mikrokondesatoriem, kas ļauj samazināt sensora izmēru. Visiem MEMS sensoriem ir nepieciešamas speciālas analogās jaukto signālu sistēmas, lai apstrādātu sensora izejas datus. MEMS ierīces spēj nodrošināt stabila sprieguma novirzes, pastiprināt signāla lādiņa plūsmas līdz izmērāmajam līmenim, vienlaikus maksimizējot signāla un trokšņa attiecību (*SNR, Signal-to-Noise Ratio*), nodrošināt nepieciešamās signāla apstrādes, lai filtrētu un iegūtu vēlamo signālu, kā arī stabilizētu sensora darbību temperatūras ietekmē. Šobrīd MEMS sensori ir visbiežāk izmantotās ierīces konstrukciju tehniskā stāvokļa monitoringā [42], [43].

Lai izvēlētos atbilstošu sensoru konstrukciju tehniskā stāvokļa monitoringam, ir svarīgi ņemt vērā arī katra sensora ražotāja norādītās specifiskās īpašības un veiktspēju (1.10.att.). Sensoriem, kuri tiek izmantoti ēku un inženierbūvju konstrukciju tehniskā stāvokļa monitoringam, ir jābūt ar lielu jutību un zemu trokšņu līmeni [44], [45].

Modeļa numurs 3191A1	TEHNISKIE PARAMETRI	
	IEPE VIENAS ASS AKSELEROMETRS	
	- HERMĒTISKI NOSLĒGTS - AUGSTA JUTĪBA	
FIZISKĀ		
Svars, Max	775	grami
Savienotājs	2 -PIN, MIL-C-5015-10SL-4P	
Savienotāja stiprinājums	1/4-28, vītņveida	
Materiāls, Korpus/Savienotājs	300 sērija	
Sensora elements	Keramika	
Elementa veids	Gredzenveida griezumš	
VEIKTSPEĒJA		
Jutība, ±5%	10	V/g
Diapazons ± 5 Voltiem Ievadei	5	m/s ²
Frekvenču diapazons, ±5%	0.08 to 1000	Hz
±10%	0.065 to 1500	Hz
±3db	0.045 to 3000	Hz
Rezonanses frekvence	> 8	kHz
Linearitāte	± 2	% F.S.
Maksimālā šķērsvirziena jutība @250μe	5	%
Termiskās jutības koeficients	0.01	m/s ² /μe
Frekvenču joslas izšķirtspēja	0.14	%/°C
Trokšņa līmenis	2.9E-05	m/s ² rms
	3.0E-06	m/s ² rms/√(Hz)
1Hz	1.5E-06	m/s ² rms/√(Hz)
10Hz	6.0E-07	m/s ² rms/√(Hz)
100Hz	2.9E-07	m/s ² rms/√(Hz)
1000Hz		

1.10.att. Pjoelektriskā paātrinājuma sensora DYTRAN 3191A1 ražotāja norādītie tehniskie parametri [46].

Sensora datu pārneses spēja ir funkcionāla sakarība starp fizisko ieejas signālu – paātrinājumu (m/s^2 vai g) un elektrisko izejas signālu – sprieguma (V , mV) vai digitālo vienību (*counts*) veidā. *Sensora jutība* ir attiecība, kas norāda cik lielu izejas signālu iegūst uz vienu ieejas vienību, un to parasti izsaka kā $mV/(m/s^2)$ vai V/g . Dažos sensoros jutību definē kā ieejas parametra izmaiņu, kas nepieciešama, lai iegūtu standartizētas izejas izmaiņas.

Sensoru diapazons vai dinamiskais diapazons nosaka paātrinājuma intervālu (piemēram, 62 g, 65 g, 610 g), kurā tiek prognozēts datu lapās aprakstīto veiktspējas parametru pielietojums. *Sensora frekvenču josla jeb darba frekvenču diapazons* (piemēram, 0.1-100 Hz vai 0.5-500 Hz) ir frekvenču intervāls, kurā sensora izejas signāla amplitūdas-frekvences raksturlīknes novirze nepārsniedz pieļaujamo robežu (parasti 63dB).

Sensora rezonanses frekvence raksturo frekvences vērtību, pie kuras sensora mehāniskā struktūra sāk rezonēt un izejas signāls vairs precīzi neatbilst ieejas paātrinājuma izmaiņām. To parasti izsaka kHz .

Sensora precizitāte raksturo maksimāli pieļaujamo novirzi starp faktisko un ideālo izejas signālu un parasti tiek izteikta kā 6% no pilna diapazona (FS , *Full Scale*) vai absolūtās vienībās, piemēram, 60.01 m/s^2 . *Sensora trokšņu blīvums* tiek izteikts kā $\mu g/\sqrt{Hz}$ vai $(m/s^2)/\sqrt{Hz}$ un raksturo sensora iekšējo trokšņu līmeni uz frekvenču vienību. Zemāks trokšņu līmenis nodrošina iespēju uztvert ļoti mazas svārstību amplitūdas un precīzāk identificēt konstrukciju pašsvārstību frekvences.

Sensora kļūda ir maksimālā novirze no lineārās pārnešanas funkcijas noteiktajā dinamiskajā diapazonā, savukārt *sensora izšķirtspēja* tiek definēta kā minimālās identificējamās signāla svārstības. *Sensora stabilitāte* ir tā spēja mērot noteiktu laika periodu dot tādu pašu izejas signālu, kā mērot nemainīgu ieejas signālu. Izmaiņas, kuras tiek konstatētas, sauc par dreifu un parasti tiek izteiktas kā $\% FS/gadā$ vai $m/s^2/gadā$. *Signāla un trokšņa attiecība* (SNR), ko parasti izsaka decibelos (*dB*), raksturo noderīgā signāla un trokšņa komponentes attiecību un ir būtisks kritērijs mērījumu kvalitātes novērtēšanai [47], [48], [49].

Sensoru mērījumu signāls papildus satur arī sensora iekšējā trokšņa, elektronisko komponentu un vides traucējumu radītas augstas frekvences un zemas frekvences komponentes. Trokšņu samazināšanai mērījumu signāla apstrādē tiek izmantota *filtrēšana*. Tiek izmantoti augsto frekvenču filtri lēnu signāla nobīžu un dreifa komponentu noņemšanai un zemo frekvenču filtri augsto frekvenču trokšņu slāpēšanai. Pareizi izvēlēta filtrēšanas metode ļauj būtiski uzlabot signāla un trokšņa attiecību un nodrošināt stabilāku pašsvārstību frekvenču identificēšanu ilgtermiņa konstrukciju monitoringa apstākļos. Daudzos sensoros augstfrekvenču trokšņu ietekmes samazināšana bieži tiek nodrošināta sensora iekšējā signāla apstrādes posmā, izmantojot iebūvētus analogos vai digitālos zemo frekvenču filtrus ar ražotāja definētām robežfrekvencēm pirms signāla digitalizācijas [49].

Svārstību mērījumiem tiek pieņemts, ka ir nepieciešams izmantot augstas kvalitātes sensorus, taču pēdējos gados ir novērojama pāreja uz lielāku skaitu lētāku un izkliekti izvietotu sensoru izmantošanu. Konstrukciju svārstību mērījumiem atsevišķos gadījumos tiek izmantoti arī viedtālruņos iebūvētie akselerometri, kuriem trokšņu slāpēšana tiek panākta izmantojot augstfrekvences filtrēšanu, kas uzlabo sistēmas darbības efektivitāti, samazinot integrēto troksni. Tomēr tā rada arī risku, ka no signāla tiek izņemta būtiska informācija [50]. Sākot ar 2015.gadu, atsevišķos pētījumos tiltu konstrukciju monitoringā mērījumi tiek iegūti arī, izmantojot viedtālruņos iebūvētos sensorus [51].

Signālu apstrādes posma mērķis ir iegūt no nolasītajiem datiem pazīmes, lai noteiktu vai konstrukcija ir bojāta vai nē, kā arī lai noteiktu bojājuma pakāpi, tā atrašanās vietu un novērtētu bojājuma smaguma pakāpi turpmākai prognozei. Konstrukciju tehniskā stāvokļa monitoringā, kas tiek balstīts uz svārstību izmaiņām, tiek izmantoti daudzi signālu apstrādes paņēmieni. Visizplatītākie no tiem ir:

- statistiskie laika rindu (*TS, Time Series*) modeļi;
- ātrā Furjē transformācija (*FFT, Fast Fourier Transform*);
- momentānā Furjē transformācija (*STFT, Short-Time Fourier Transform*);
- Kohena klase;
- Kalmana filtrs (*KF, Kalman Filter*);
- vilnīšu transformācija (*WT, Wavelet Transform*);
- S-Transformācija;
- vairāku signālu klasifikācijas (*MUSIC, Multiple Signal Classification*) algoritms;
- Hilberta-Huanga transformācija (*HHT, Hilbert-Huang Transform*);
- avota aklā atdalīšana (*BSS, Blind Source Separation*);
- Vignera-Villes sadalījums.

Katrai signālu apstrādes metodei ir noteiktas priekšrocības un trūkumi, kas saistīti ar skaitļošanas efektivitāti, noturību pret trokšņa ietekmi, piemērotību nelineāru signālu analīzei un spējai identificēt tuvu izvietotas frekvenču formas [52].

1.2.3. Pret bojājumiem jutīgo pazīmju identificēšana uz svārstībām balstīta konstrukciju tehniskā stāvokļa monitoringā

Konstrukciju tehniskā stāvokļa monitoringā viens no galvenajiem aspektiem ir atlasīt un iegūt tās konstrukciju īpašības, kuru vērtības ietekmē bojājums. Ne katrai konstrukciju īpašībai ir novērojamas nozīmīgas izmaiņas konstrukciju bojājuma rezultātā, lai varētu noteikt bojājumus pat ar visjaunākajiem mašīnmācīšanās algoritmiem [1]. Īpašību atlases mērķis būtībā ir no datiem izgūt tādu mainīgo īpašību apakšgrupu, kas efektīvi apraksta bojājumu izraisītu konstrukciju dinamisko īpašību izmaiņu, vienlaikus samazinot trokšņa vai nebūtisko mainīgo ietekmi, saglabājot pietiekami labus prognozēšanas rezultātus [53].

Īpašību iegūšanas procesu var iedalīt divās lielākās kategorijās: uz datiem balstīta un uz modeļiem balstīta īpašību iegūšana. Papildus šīm divām metodēm tiek izmantota arī uz viļņu izplatīšanās un uz mehānisko impedanci balstīta metode, kuras ir uz datiem balstītas metodes apakškopas. Tomēr tās nav izmantojamas masīvām civilām ēkām un inženierbūvēm, bet biežāk izmanto aeronautikā un automašīnu ražošanā kā kvalitātes kontroles rīku [1]. Uz modeļiem balstītas metodes pamatā ir galīgo elementu modeļa izveide, kura ietvaros tiek veikta modālā analīze, lai iegūtu konstrukcijas modālos parametrus, piemēram, pašsvārstību frekvences, pašsvārstību formas un rīšanas koeficientus. Konstrukciju tehniskā stāvokļa monitoringa tiek veikts pēc modeļa parametru izmaiņām vai arī prognozējot kļūdas modeļa izejas datus, lai noteiktu bojājumus. Savukārt uz datiem balstītas metodes balstās tieši uz mērījumu signālu analīzi un tiek veiktas divos galvenajos posmos. Pirmajā posmā tiek veikta pazīmju iegūšana no signāla, savukārt otrajā posmā tiek veikta lēmumu pieņemšana, balstoties uz iegūtajām pazīmēm, lai novērtētu konstrukcijas tehnisko stāvokli un identificētu bojājumus [46].

Konstrukciju bojājumu jutīgo īpašību iegūšana, izmantojot **uz datiem balstītas** metodes, tiek klasificēta pēc izmantotā signāla apstrādes apgabala un iedalās:

- laika apgabala;
- frekvences apgabala;
- laika un frekvences;
- mašīnmācīšanās algoritmos.

Laika apgabala metodes tiek plaši izmantotas pret bojājumiem jutīgu īpašību vērtību vektoru iegūšanai gadījumos, kad mērījumu signālu dinamiku iespējams aprakstīt ar zemākas dimensijas laika rindu modeļiem, kur īpašību vērtību vektora dimensija raksturo pazīmju skaitu, ar kurām tiek aprakstīts mērījumu signāls. Šajā grupā ietilpst, piemēram, autoregresīvo mainīgās vidējās vērtības modeli (*ARMA, Autoregressive Moving Average*), savstarpējās korelācijas funkciju (*CCF, Cross-Correlation Function*) un stohastisko apakštelpas identifikāciju (*SSI, Stochastic Subspace Identification*). Savukārt situācijās, kad īpašību vērtību vektoru dimensija ir liela vai mērījumu signālu dinamika ir sarežģīta, tiek izmantotas augstākas kārtas laika rindu modelēšana. Frekvences apgabala metodes balstās uz signālu spektrālo

raksturlielumu analīzi un ļauj iegūt konstrukcijas dinamiskās īpašības frekvenču telpā. Dažas no visbiežāk izmantojamām metodēm ir jaudas spektrālā blīvuma (*PSD, Power Spectral Dnesity*), šķērsspektrālā blīvuma (*CSD, Cross-Spectral Density*), impulsa reakcijas funkcijas (*IRF, Impulse Response Function*) un frekvenču apgabala sadalīšanas (*FDD, Frequency Domain Decomposition*) metodes.

Uz modeļiem balstītas metodes pamatā ir precīza galīgo elementu modeļa izveide, kas ir īpaši efektīva gadījumos, kad pieejamais monitoringa datu apjoms ir ierobežots [1]. Galīgo elementu modeļi tiek izmantoti gan optimālai sensoru tīkla projektēšanai, gan bojājumu simulācijai un uz datiem balstītu algoritmu kontrolētai apmācībai [55], [60]. Metodes efektivitāte ir tieši atkarīga no modeļa precizitātes, ko uzlabo, izmantojot galīgo elementu modeļu atjaunināšanas pieejas, pielāgojot masas un stinguma matricas [57], [58], lai nodrošinātu modeļa atbilstību reālai konstrukcijai [59], [60], [61]. Dinamisko parametru izmaiņu kvantitatīva analīze ekspluatācijas un ārējo vides apstākļu ietekmē ir būtiska gan bojājumu novērtēšanai, gan analītisko modeļu kalibrēšanai [62].

1.1.tabulā ir apkopotas priekšrocības un trūkumi uz modeļa balstītas un uz datiem balstītas metodes izmantošanai konstrukciju monitoringā. Jaunākos pētījumos ir ieviestas hibrīda pieejas, kas apvieno abas iepriekšminētās metodes un uzlabo konstrukciju monitoringa bojājuma identifikācijas modeļus [63].

1.1.tabula

Uz modeļa balstītu un uz datiem balstītu metožu priekšrocības un trūkumi konstrukciju monitoringā

Metode	Priekšrocības	Trūkumi
Uz modeļa balstīts konstrukciju monitorings	• Vienkārša fizikāla datu interpretācija. Bojājums izraisa konstrukcijas stinguma izmaiņas; • Nodrošina visus bojājumu identificēšanas līmeņus, ja konstrukcijas parametri ir zināmi; • Iespējama scenāriju modelēšana un drošības robežvērtību noteikšana.	• Sarežģītu modeļu aprēķini nav piemēroti reāllaikam skaitļošanas laika dēļ; • Nenoteiktības un parametru mainīgums samazina modeļa precizitāti; • Reālu ēku un inženierbūvju modeļu izveidei un analīzei nepieciešams ievērojams skaitļošanas resurss.
Uz datiem balstīts konstrukciju monitorings	• Mašīnmācīšanās algoritmi spēj samazināt līdz minimumam trokšņa un apkārtējās vides ietekmi; • Bojājumus iespējams noteikt arī bez zināmiem konstrukcijas parametriem.	• Netiek parādīts risināšanas process un daudzu algoritmu izskaidrojamība ir zema; • Nepieciešama liela un kvalitatīva mācību datu kopa, lai izvairītos no pārprielāgošanas; • Bojājumu datu apjoms no reālām konstrukcijām bieži vien ir ierobežots, līdz ar to apmācībai tiek izmantoti simulēti bojājumu dati; • Sarežģītu algoritmu apmācības process var būt laikietilpīgs.


1.3. Mainīgo ārējo vides apstākļu ietekme uz nesošo konstrukciju tehniskā stāvokļa monitoringa datiem

Ēku konstrukciju tehniskā stāvokļa monitoringa nepieciešamība ir pierādīta un pamatota vairākos pētījumos, tomēr tā ieviešana reālām ēku konstrukcijām, kuras ir pakļautas ārējiem vides apstākļiem, ir izaicinoša un joprojām ir nepieciešama papildus izpēte [64][14], lai šo metodi pielietotu praktiski. Galvenie ierobežojumi konstrukciju monitoringa ieviešanai praksē ir ekonomiskie aspekti, liela ēku konstruktīvo sistēmu daudzveidība, nepietiekams datu apjoms par esošajām ēkām, kā arī vides un ekspluatāciju apstākļu ietekme uz esošajām konstrukcijām [65].


Konstrukciju bojājumi tiek uzskatīti par lokālu parādību, tomēr lokālu ierosinātāju izmantošana parasti maz ietekmē konstrukcijas kopējo dinamisko uzvedību. Liela mēroga būvēm efektīvākais ierosināšanas avots ir apkārtējā vide, kas nodrošina pietiekamus impulsus ar pietiekami lielu amplitūdu un pietiekami plašu frekvenču diapazonu konstrukcijas pašsvārstību formu ierosmei. Tomēr šiem ierosmes avotiem atšķirībā no lokāliem impulsiem, kuri ir stacionāri, ir jāņem vērā apkārtējās vides mainīgums [1].

Pētījumos 1996.gadā [66] un 1998. gadā [67] tika sniegts plašs literatūras pārskats par konstrukciju bojājumu noteikšanu, lokalizāciju un raksturošanu, izmantojot uz konstrukciju svārstībām balstītas metodes. Šajos pētījumos arī tika konstatētas būtiskas nepilnības – daudzas metodes ir atkarīgas no iepriekš izveidotiem analītiskajiem modeļiem konstrukciju bojājumu un to atrašanās vietas noteikšanai. Gandrīz visas minētās bojājumu noteikšanas metodes tika balstītas uz kāda veida lineāro konstrukcijas modeli. Pētījumi netika vērsti uz reālu konstrukciju testēšanu mainīgā ārējā vidē, bet gan uz vienkāršu konstrukciju sistēmu laboratorijas kontrolētos apstākļos [68].

Ārējo vides parametru ietekme uz konstrukciju tehniskā stāvokļa monitoringa attīstību tiek uzsvērtā kā būtisks izpētes punkts, kas ietekmē pašreizējo konstrukciju monitoringa sistēmu uzticamību un precizitāti [15]. Līdz ar kopējo ēku un tiltu konstrukciju tehniskā stāvokļa monitoringa pētījumu pieaugumu, kopš 2010.gada ir novērojams arī publikāciju skaita pieaugums par konstrukciju monitoringu ārējo vides apstākļu ietekmē (1.11.att.,1.12.att.).




1.11.att. Publikāciju skaits laika posmā no 1991.gada līdz 2024.gadam, kuru atslēgas vārdos ir iekļauts konstrukciju tehniskā stāvokļa monitorings, ēkas, ārējie vides apstākļi [69], dinamiskās svārstības [70] saskaņā ar scopus.com datiem.



1.12.att. Publikāciju skaits laika posmā no 2000.gada līdz 2024.gadam, kuru atslēgas vārdos ir iekļauts konstrukciju tehniskā stāvokļa monitorings, tilti, ārējie vides apstākļi [71], dinamiskās svārstības [72] saskaņā ar scopus.com datiem.

Ārējie vides apstākļi ietver vēju, temperatūru, mitrumu un sniegu. Savukārt ekspluatācijas apstākļi ietver apkārtējās slodzes apstākļus, darbības ātrumu un masas slodzi [73],[74]. Realitātē konstrukcijas vienlaicīgi tiek pakļautas dažādiem ekspluatācijas un ārējās vides apstākļiem [73]. Ārējo vides faktoru ietekme uz konstrukciju dinamiskajām īpašībām var būt nozīmīga un, iespējams, var radīt lielāku ietekmi uz dinamiskajiem parametriem, piemēram, pašsvārstību frekvencēm nekā konstrukciju bojājumu rezultātā. Līdz ar to konstrukciju tehniskā stāvokļa monitoringa gadījumā ārējo vides parametru ietekme uz konstrukcijām var tikt uzskatīta par viltus bojājumu [75].

Lielākā uzmanība konstrukciju tehniskā stāvokļa monitoringa izpētē tiek pievērsta ārējās vides temperatūras un vēja radīto slodžu un ietekmju izpētei (1.13.att.). Citi ietekmes faktori, piemēram, mitrums un robežnosacījumu izmaiņu ietekme tiek apskatīti retāk [65].



1.13.att. Dažādu ārējo ietekmes faktoru sadalījums, kuru ietekme tiek pētīta konstrukciju tehniskā stāvokļa monitoringa izpētē zinātniskajās publikācijās [65].


Jebkuras ārējo vides faktoru izmaiņas ietekmē arī konstrukcijas materiāla īpašības. Ārējās vides temperatūras ietekme tiek uzskatīta par vienu no galvenajiem vides ietekmes faktoriem uz konstrukciju dinamiskajām īpašībām. Temperatūras izmaiņu ietekmes mehānismi konstrukcijās var tikt klasificēti trīs galvenajās kategorijās:

- ģeometrisku izmēru izmaiņas, kas rodas termiskās izplešanās un saraušanās rezultātā;
- mehānisko īpašību izmaiņas, kas rodas elastības moduļa vērtību izmaiņu rezultātā;
- robežnosacījumu un iekšējo spēku izmaiņas statiski nenoteicamās sistēmās.

Konstrukciju tehniskā stāvokļa monitoringā ir jāņem vērā temperatūras izmaiņas laikā – gan diennakts, gan sezonālās temperatūras svārstības.

Vēja slodze tiek raksturota ar divām galvenajām īpašībām – vēja ātrumu un vēja virzienu, kas ietekmē konstrukcijas dinamiskos parametrus. Spēcīgas vētras laikā vēja dinamiskā iedarbība uz konstrukciju rada lielāku enerģijas pieplūdumu, nekā rimšanas mehānismi to spēj kompensēt.

Relatīvā mitruma svārstības izraisa izmaiņas konstrukcijas masā un robežnosacījumos, jo materiāls pakāpeniski uzsūc vai zaudē mitrumu. Šo pārmaiņu rezultātā mainās konstrukcijas mehāniskās īpašības, kas izpaužas pašsvārstību frekvenču vērtību un citu dinamisko parametru izmaiņās (1.14.att.) [76].




1.14.att. Dažādu ārējo vides faktoru ietekme uz konstrukciju dinamiskajām īpašībām [65].

Pētījumā, kurā tika apkopoti dati no tilta ilgtermiņa tehniskā stāvokļa monitoringa sistēmas, tilta pašsvārstību frekvences un ārējā gaisa temperatūra tika iegūtas ar vienas stundas intervālu, lai ietvertu pilnu ekspluatācijas un ārējo vides apstākļu ciklu. Tika konstatēts, ka ārējās vides temperatūras ietekmē, pašsvārstību frekvenču relatīvās izmaiņas ir no 0.20% līdz 1.52% pirmajām desmit svārstību formām. Līdz ar to šīs izmaiņas varētu noslēpt konstrukciju bojājumu izraisītās dinamisko parametru izmaiņas [77].

Pētījumā [78] tika analizēti Milānas katedrāles konstrukciju ilgtermiņa monitoringa rezultāti, kas tika iegūti laika posmā no 2018.gada oktobra līdz 2019.gada februārim. Datu analīze parādīja, ka pašsvārstību frekvenču izmaiņas ir cieši saistītas ar apkārtējās vides temperatūras svārstībām, kas ir galvenais faktors konstrukciju dinamisko īpašību izmaiņām. Ārējai gaisa temperatūrai samazinoties, katedrāles pašsvārstību frekvences pieauga gandrīz lineāri. Relatīvā mitruma ietekme bija salīdzinoši neliela vai vispār netika novērota. Savukārt, pētījumā [79], kurā tika mēģināts nodalīt mehāniski radītās slodzes no termiski radītajām slodzēm TV tornim Prāgā, Čehijā, tika secināts, ka šīs slodzes nav iespējams tieši nošķirt, izmantojot laika rindu grafikus. Tomēr tika novērots, ka ārējās gaisa temperatūras izmaiņas rada lielas un lēni mainīgas mehāniskā sprieguma vērtību izmaiņas, bet vēja slodzes rada ātrākās izmaiņas.

Konstrukciju tehniskā stāvokļa monitoringā Kampobasso pilsētas “Cardarelli” slimnīcas konstrukcijām bija iespējams novērot frekvenču izmaiņas ārējās vides temperatūras ietekmē

visām četrām zemākajām svārstību formām. Mērījumu svārstības sistemātiski atkārtojās katru dienu ar pēkšņu kritumu naktī un pakāpenisku pieaugumu no rīta līdz maksimālajai vērtībai, kas tika sasniegta pēcpusdienā (1.15.att.). Frekvenču izmaiņas tika skaidrotas ar to, ka abus ēkas blokus sadala šuve un paaugstinoties temperatūrai, attālums starp blokiem termiskās izplešanās rezultātā samazinās un bloku savstarpēja sasaiste rada zināmu stinguma pieaugumu ēkas garenvirzienā [80].



1.15.att. Kampobasso pilsētas “Cardarelli” slimnīcas ēkas konstrukciju monitoringa rezultāti viena mēneša periodā [80].

Vēja ietekmē ēkai ir jābūt pietiekami izturīgai, lai tā atbilstu lietotāja komforta un ekspluatācijas kritērijiem. Vējš var izraisīt arī ēkas dinamisko reakciju. Ēkas dinamiskā reakcija uz vēja slodzi un vēja slodžu raksturs var atšķirties. Vēja brāzmu dominējošā frekvence ir relatīvi zemāka salīdzinājumā ar ēku pašsvārstību frekvenci un tā galvenokārt ierosina zemāko svārstību formu [81].

Ārējie vides apstākļi, kas varētu ietekmēt ēkas dinamiskos parametrus, ir arī gruntsūdens līmenis [82]. Līmeņa izmaiņas ietekmē atmosfēras nokrišņu daudzums, gaisa temperatūra, iežu litoloģiskais sastāvs un drenēšanas pakāpe [83]. Gruntsūdens līmeņa svārstības ietekmē vairāku grunts slāņu raksturlielumus. Gruntsūdens līmeņa dziļums no zemes virsmas ietekmē grunts nestspēju un deformāciju, kā arī pamatu stabilitāti un noturību [84].

Ēkas konstrukciju tehniskā stāvokļa monitoringā gan nenesošo konstrukciju, gan grunts parametru ietveršana ir jāņem vērā, veidojot galīgo elementu modeli. Iekļaujot grunts ietekmi galīgo elementu modeļa izveidē, ir iespējams novērot pašsvārstību frekvenču izmaiņas 21%, 25% un 20% apmērā no references modeļa, līdz ar to pamatojot grunts ietekmi uz ēkas dinamiskajiem parametriem [85]. Augsnes veids arī var būt faktors, kas ietekmē ēkas svārstību formu un pat modificē to, radot vertikālās svārstības [86]. Augsnes ietekme uz ēkas dinamiskajiem parametriem tiek ievērtēta, izmantojot elastīgas pamatu konstrukcijas analīzi. Elastīgās pamatu atsperes ir atkarīgas no grunts tipa, slāņu biezuma, gruntsūdens līmeņa un iežu dziļuma [87].

2. Mašīnmācīšanās metožu integrācija konstrukciju tehniskā stāvokļa monitoringā

Konstrukciju tehniskā stāvokļa monitoringa speciālisti šobrīd ir pievērsuši arvien vairāk uzmanību mākslīgā intelekta izmantošanas iespējām, lai paaugstinātu ēku un inženierbūvju stāvokļa novērtēšanas un tehniskās apkopes automatizācijas līmeni, izmantojot patstāvīgu, precīzu un stabilu monitoringa datu apstrādi [88].

Fengs un Bahngs jau 1999.gadā [89], iespējams, bija pirmie zinātnieki, kas izmantoja atgriezeniskās izplatīšanās neironu tīklu, lai noteiktu bojājumu izraisīto stinguma samazināšanos, pamatojoties uz dinamiskajām īpašībām, kas iegūtas no cikliski slogotu dzelzsbetona kolonnu svārstībām.

Mašīnmācīšanās metožu pielietošana dažādās pētniecības nozarēs joprojām tiek aktīvi pētīta, lai uzlabotu mācīšanās procesu, galveno uzmanību pievēršot datu dimensiju samazināšanai [90]. Dažādas konstrukciju tehniskā stāvokļa monitoringa sistēmas spēj ātri noteikt, pārraidīt un uzglabāt lielu datu apjomu. Taču šajos tīklos datu apjoms ir tik milzīgs, ka datu kvalitāte, atbilstība, atkārtota izmantošana un lēmumu pieņemšana, balstoties uz iegūtajiem datiem, ir viena no aktuālākajām problēmām.

Aizvien vairāk ir nepieciešams izmantot jaunās tehnoloģijas, lai automatizētu datu novērtēšanas procesus un uzlabotu šo novērtēšanas procesu objektivitāti [91], [88]. Lai sistēma, kas atrodas mainīgā vidē, būtu automatizēta un inteligenta, tai ir jābūt spējīgai mācīties. Līdz ar to, ja sistēma spēj mācīties un pielāgoties pārmaiņām, sistēmas izstrādātājam nav jāparedz un jānodrošina visi iespējamie situāciju risinājumi [92].

Mašīnmācīšanās algoritmi ir nepieciešami ne tikai, lai apstrādātu lielo datu apjomu, bet arī lai klasificētu dažādas novirzes un kļūdas mērījumos. Atsevišķi konstrukciju dinamisko parametru mērījumi var neatbilst vispārējiem datu modeļiem un var tikt uzskatīti par anomālijām. Šādas anomālijas var rasties dažādu iemeslu dēļ un var ietvert mērījumu kļūdas, piemēram, signāla nobīdi, precizitātes samazināšanos vai pilnīgu datu reģistrēšanas traucējumu. Līdz ar to konstrukciju novērtēšanai nepieciešama automatizēta metode šo anomāliju precīzai klasifikācijai un tehniskā stāvokļa novērtēšanai [93].

Automatizēto metožu galvenais pieņēmums ir, ka bojājumi – plaisas, pakāpenisks konstrukcijas nolietojums, ir raksturīgi kā datu anomālijas jeb novirzes no normālā stāvokļa, ko var atpazīt. Ja datu analīzē tiek konstatētas iespējamās novirzes, konstrukciju bojājumu lokalizācijai, bojājuma veidam un pakāpei var izmantot īpaši izstrādātus algoritmus [94].

2.1. Mašīnmācīšanās algoritmu darbības principi

Mašīnmācīšanās algoritmu mērķis ir noteikt statistisko struktūru datos [95] un būtībā nodrošināt spēju automātiski mācīties un pilnveidoties no gūtās informācijas, to tieši neieprogrammējot. Mācīšanās un pilnveidošanas procesā sistēma automātiski apgūst sakarības starp iezīmju modeļiem un rezultātu.

Mašīnmācīšanās algoritma veiktos uzdevumus var apkopot šādi:

- 1) klasifikācija – uzdevuma mērķis ir noteikt, kurai kategorijai pieder izejas dati;

- 2) regresija – šī uzdevuma mērķis ir izveidot sakarību starp skaitliskiem rezultātiem un vairākiem izejas datiem;
- 3) prognozēšana – uzdevuma mērķis ir prognozēt turpmākās vērtības noteiktā laikā;
- 4) grupēšana – šī uzdevuma mērķis ir sadalīt izejas datu kopu grupās ar līdzīgiem paraugiem [96].


Pamatojoties uz literatūru, kas tika publicēta aptuveni divdesmit gadu laikā līdz 2007.gadam, pētījumā [97] tika formulētas septiņas aksiomas jeb vispārpieņemti konstrukciju tehniskā stāvokļa monitoringa principi:

- I aksioma: visiem materiāliem ir raksturīgi trūkumi vai defekti;
- II aksioma: bojājumu novērtēšanai ir nepieciešams salīdzināt divus sistēmas stāvokļus;
- III aksioma: bojājumu konstatēšanu un atrašanās vietu var noteikt izmantojot nekontrolēto mācīšanās veidu, bet konstatēt bojājuma veidu un tā pakāpi var tikai kontrolētā mācīšanās veidā;
- IVa aksioma: sensori nevar izmērīt bojājumus. Lai sensoru datus pārvērstu informācijā par bojājumiem, ir nepieciešama pazīmju iegūšana, izmantojot signālu apstrādi un statistikas klasifikāciju;
- IVb aksioma: jo jutīgāks ir pret bojājumiem mērījums, jo jutīgāks tas ir pret mainīgiem ārējās vides un ekspluatācijas apstākļiem, ja netiek veikta automatizēta pazīmju nodalīšana;
- V aksioma: garuma un laika skalas, kas saistītas ar bojājumu rašanos un attīstību, nosaka nepieciešamās konstrukciju tehniskā stāvokļa monitoringa sensoru sistēmas īpašības;
- VI aksioma: pastāv savstarpējs līdzsvars starp algoritma jutību pret bojājumiem un tā trokšņu slāpēšanas spēju;
- VII aksioma: bojājuma lielums, ko var noteikt no sistēmas dinamiskajām izmaiņām, ir apgriezti proporcionāls ierosmes frekvenču diapazonam.

Šīs aksiomas kļuva par nozīmīgu pamatu turpmākajiem pētījumiem konstrukciju tehniskā stāvokļa monitoringa un mašīnmācīšanās metožu integrācijai. Aksiomu autori faktiski sniedza sākumpunktu turpmākajiem pētījumiem konstrukciju tehniskā stāvokļa monitoringā, kas iekļāva arī mašīnmācīšanās algoritmu izmantošanu bojājumu identificēšanā un klasificēšanā [97]. Lielākā daļa teorētisko darbu mašīnmācīšanās jomā ir koncentrēti uz vispārīgu mācīšanās metožu izveidi, raksturošanu un analīzi, akcentējot metodes vispārīgumu un efektivitātes analīzi [98].

2.2. Mašīnmācīšanās algoritmu iedalījums

Mašīnmācīšanās algoritmus var iedalīt četrās grupās (2.1.att.). Visbiežāk tiek izmantotas uzraudzītas, neuzraudzītas un daļēji uzraudzītas mašīnmācīšanās metodes. Neuzraudzītās mašīnmācīšanās algoritmi tiek izmantoti lielām un sarežģītām ēkām un inženierbūvēm, ja nav pieejams bojāto konstrukciju pietiekams datu apjoms. Gadījumos, kad ēkām un inženierbūvēm ir pieejami gan bojātās konstrukcijas, gan nebojātās konstrukcijas dati, visbiežāk tiek izmantota uzraudzītā mašīnmācīšanās metode [1].




2.1.att. Četru dažādu mašīnmācīšanās algoritmu sadalījums [1].

Mašīnmācīšanās algoritms, kuru nepieciešams izmantot attiecīgajam konstrukciju tehniskā stāvokļa monitoringa uzdevumam, ir atkarīgs no spējas veikt uzraudzītu vai neuzraudzītu mācīšanos [99].

Uzraudzītā mācīšanās mēģina vispārināt atbildes, pamatojoties uz mācību kopu, kurā norādītas pareizās atbildes. Šajos algoritmos tiek izmantotas klasifikācijas metodes, lai apgūtu kartēšanu no novērojumu datiem mācīšanās datu kopā uz to attiecīgajiem izejas datu marķējumiem. Algoritma galvenais mērķis ir izmantot no mācību datiem apgūtos modeļus, lai prognozētu iepriekš neatpazīta novērojuma klases marķieri.

Savukārt **neuzraudzītā mācīšanās** mēģina klasificēt ievades datus, pamatojoties uz to līdzību. Neuzraudzītās mašīnmācīšanās algoritma metodes tiek izmantotas, ja ievades datiem nav pieejami marķējumi. Šādos gadījumos algoritmi grupē līdzīgus novērojumus klāsteros vai identificē anomālijas, lai noteiktu datu punktus, kas būtiski atšķiras un var liecināt par konstrukcijas bojājumiem, trokšņiem vai ārējās vides ietekmi [100]. Visbiežāk anomāliju noteikšanas metodes paredz, ka normālais stāvoklis veido vienu klasi vai grupu un punkti ārpus klases robežas tiek apzīmēti kā jaunumi vai anomālijas (2.2.att.). Šāda veida anomāliju noteikšana ir vienas klases klasifikācijas problēma un viens no šīs metodes piemēriem ir anomāliju analīze. Ja dati veido vairākas grupas dažādu neobjektu vai objektu apstākļu dēļ, tad par atbilstošāko metodi tiek uzskatīta klāsteru analīze.




2.2.att. Novitāšu noteikšanas metodes: a) vienas klases novitātes noteikšanas metode; b) vairāku klašu novitātes noteikšanas jeb klāsteru analīze [37].

Daļēji uzraudzītas mašīnmācīšanās algoritmi tiek pielietoti gadījumos, ja ir pieejami izejas dati ar ierobežotu kontrolēto informāciju. Respektīvi daļēji uzraudzītos mašīnmācīšanās algoritmos tiek izmantota marķēto datu informācija, savukārt nemarķētie dati tiek izmantoti, lai papildus ierobežotu klasifikācijas algoritmu [101]. Padziļinātās mašīnmācīšanās algoritmi var iemācīties ne tikai sasaistīt pazīmes ar vēlamu rezultātu, bet arī paši veikt pazīmju ieguves procesu. Algoritms spēj izskaidrot augsta līmeņa un abstraktas iezīmes kā vienkāršu un zema līmeņa apgūtu pazīmju kopumu hierarhiju. Šī spēja ļauj padziļinātās mašīnmācīšanās algoritmiem risināt sarežģītus uzdevumus, sadalot tos lielā skaitā vienkāršu problēmu [96].

2.3. Mašīnmācīšanās algoritmu iespējas un pielietojuma ierobežojumi

Mašīnmācīšanās algoritmi attiecīgai problēmsituācijai tiek izvēlēti pēc vairākiem kritērijiem. Specifiskai problēmai un pieejamo datu veidam iespējams ir nepieciešami dažādi algoritmi vai pat algoritmu kombinācija. Daži no faktoriem, kas ietekmē algoritma izvēli, ir, piemēram, apmācības datu skaits, paredzamais apmācības laiks un precizitātes pakāpe. 2.3.attēlā apkopoti vispopulārākie mašīnmācīšanās algoritmi [1].




2.3.att. Trīs visbiežāk izmantoto mašīnmācīšanās algoritmu grupu sadalījums [1].

Mašīnmācīšanās metodes algoritma izvēlē noteicošais faktors ir arī sasniedzamais rezultāts – konstrukciju monitoringa bojājumu identifikācijas līmenis. Dažādi mašīnmācīšanās algoritmi spēj atrisināt vairākus konstrukciju bojājumu identifikācijas monitoringa līmeņus, savukārt citi algoritmi spēj noteikt tikai pirmos trīs līmeņus.

Izvēloties mašīnmācīšanās metodi, ir jāņem vērā katras metodes ierobežojumi un konstrukciju tehniskā stāvokļa monitoringa prasības attiecībā uz bojājumu identificēšanas līmeni un ekspluatācijas apstākļiem [63].

2.4.attēlā apkopoti mašīnmācīšanās metožu algoritmi un ar tiem sasniedzamie konstrukciju monitoringa bojājumu identifikācijas līmeņi. Kā redzams, tad 1.līmeni var sasniegt praktiski ar katru mašīnmācīšanās algoritma metodi. Arī 2.un 3.līmenis tiek sasniegts ar lielāko daļu algoritmu. Tomēr attiecībā uz 4. un 5.līmeni daudzos pētījumos tiek uzskatīts, ka algoritmi nav piemēroti vai nav spējīgi noteikt bojājumu pakāpi un prognozēt konstrukcijas darbības laiku [1].



2.4.att. Sakarība starp konstrukciju monitoringa bojājumu identifikācijas līmeņiem un mašīnmācīšanās algoritmiem, pamatojoties uz analizētajiem dažādiem pētījumiem (DT- lēmums pieņemšanas koks (*Decision Tree*), RF- gadījuma meža metode (*Random Forest*), SVM - atbalsta vektora metode (*Support Vector Machine*), kNN – k-tuvāko kaimiņu algoritms (*k-Nearest Neighbours*), Bajesa – Bajesa metode (*Bayesian Method*), NN – neironu tīkli (*Neural Network*), GMM – Gausa sadalījuma modelis (*Gaussian Mixture Model*), BSS – aklā avota atdalīšana (*Blind Source Separation*) [1].

Pamata mākslīgie neironu tīkli (*ANN, Artificial Neural Network*) konstrukciju monitoringā tiek izmantoti jau vairākus gadus. ANN tiek pielietoti, lai apgūtu datu reprezentācijas un samazinātu to dimensionalitāti. Konstrukciju monitoringā daļa tīklu tiek apmācīti, izmantojot uzraudzītās mācīšanās pieeju, kur mācību procesā tiek izmantoti dati no konstrukcijas nebojātā stāvokļa. Marķēšanas process šādās metodēs parasti notiek automātiski, balstoties uz esošo nebojāto datu kopu. Šajās metodēs tiek integrētas reprezentatīvās mācīšanās un novitātes noteikšanas stratēģijas, kas ļauj modelim identificēt novirzes un noteikt iespējamus konstrukcijas bojājumus.

Klasiskajiem neironu tīkliem ir salīdzinoši maz parametru, un to struktūrā parasti ir ne vairāk kā divi slēptie slāņi, kuros notiek informācijas apstrāde un tiek apgūtas sakarības starp ievades parametriem un modeļa prognozētajām vērtībām. Šādus tīklus visbiežāk izmanto datu dimensiju samazināšanai.

Konvolūcijas neironu tīkls (*CNN, Convolutional Neural Network*) ir dziļā neironu tīkla veids, kura darbība balstās uz konvolūcijas principu, izmantojot iemācītus filtrus, kas ļauj automātiski noteikt un izcelt datu nozīmīgākās pazīmes. Šāda pieeja samazina nepieciešamo parametru skaitu, padarot CNN efektīvāku nekā dziļos blīvus neironu tīklus. CNN visbiežāk tiek izmantoti datu analīzei ar tīklveida struktūru un lokālu telpisku korelāciju.

Atbalsta vektoru mehānismu (SVM) metode ir viena no klasiskajām mašīnmācīšanās metodēm, kas tiek plaši izmantota datu klasifikācijai un regresijai. Tās pamatā ir optimālas robežvirsmas jeb hiperplaknes noteikšana starp datu klasēm, maksimāli palielinot attālumu starp robežu un tuvākajiem datu punktiem jeb atbalsta vektoriem. SVM spēj precīzi klasificēt pazīmes, nosakot gan lineāras, gan nelineāras sakarības starp datiem, izmantojot dažādas kodolfunkcijas [63].

Galveno komponentu analīze (*PCA, Principal Component Analysis*) galvenokārt tiek izmantota, lai samazinātu datu dimensiju, saglabājot tikai būtiskāko informāciju no sākotnējiem datiem. PCA pielietošana mašīnmācīšanās algoritmos uzlabo apmācības ātrumu un modeļa

efektivitāti, jo no datu kopas tiek ņemta lielā un maznozīmīgā informācija. Sākotnējie dati tiek projicēti jaunos mainīgajos – galvenajās komponentēs, kas raksturo datus ar lielāko dispersiju. Konstrukciju tehniskā stāvokļa monitoringa sistēmās PCA izmantošana samazina lielu sensoru datu apstrādes laiku un uzlabo sistēmas spēju reaģēt uz konstruktīvajām izmaiņām vai bojājumu izraisītiem notikumiem. PCA uzlabo arī mācību datu pazīmju kvalitāti, padarot tās savstarpēji nekorelētas [63], [102]. Nelineāru datu apstrādē galveno komponentu analīze tiek aizvietota ar šīs analīzes modifikāciju – kodola galveno komponentu analīzi (KPCA, *Kernel Principal Component Analysis*). Šī metode izmanto kodolfunkcijas, kas ļauj modelēt nelineāras sakarības, pārveidojot sākotnējos datus augstākas dimensijas telpā. Līdz ar to KPCA spēj efektīvāk analizēt sarežģītas datu struktūras un atklāt nelineāras sakarības, kas raksturīgas konstrukciju monitoringa datiem [103], [104], [105], [106].

2.4. Mašīnmācīšanās algoritmu izmantošana ārējo vides faktoru ietekmes samazināšanai

Ārējie vides ietekmes faktori konstrukcijas dinamiskās īpašības spēj ietekmēt dažādi – piemēram, samazināt vai palielināt pašsvārstību frekvences. Lai uzlabotu konstrukciju monitoringa precizitāti un uzticamību, ārējo vides faktoru ietekmes samazināšanai tiek izmantoti dažādi mašīnmācīšanās algoritmi [65]. 2.1.tabulā ir apkopoti vairāki mašīnmācīšanās algoritmi, to pielietojums un konkrētais ārējās vides ietekmes faktors, kura ietekme attiecīgi ir analizēta šajā pētījumā.

2.1.tabula

Publikācijās izmantotie mašīnmācīšanās algoritmi ārējo vides faktoru ietekmes samazināšanai

Algoritma nosaukums	Pielietojums	Analizētais un koriģētais ārējās vides faktors
Galveno komponentu analīze (PCA)	Izmantojot ar PCA transformētus ārējās vides parametrus, saliktais ansambla mācīšanās modelis precīzāk prognozēja dinamisko parametru atkarību no ārējās vides apstākļiem, ļaujot netieši kompensēt ārējās vides ietekmi, analizējot prognozēšanas atlikumus [107].	Ārējā gaisa temperatūra, mitrums, vēja ātrums, vēja virziens, virsmas temperatūra
Autoregresīvie modeļi (<i>ARX</i> , <i>Autoregressive Models with Exogenous Inputs</i>)	Autoregresīvie modeļi (ARX) tika izmantoti, lai modelētu Z24 tilta pašsvārstību frekvenču izmaiņas, vienlaikus ņemot vērā ārējās gaisa temperatūras svārstības [108].	Ārējā gaisa temperatūra
Gausa procesa regresija (<i>GPR</i> , <i>Gaussian Process Regression</i>)	GPR algoritms tika izmantots, lai prognozētu vēja generatoru lāpstiņu pašsvārstību frekvences, vienlaikus ņemot vērā ārējās vides svārstības [109].	Ārējā gaisa temperatūra

Galveno komponentu analīze (PCA) un meta apmācība (MAML, <i>Model-Agnostic Meta-Learning</i>)	PCA tika izmantota, lai no frekvenču datiem noņemtu dažas mazāk nozīmīgās izmaiņas. MAML tika izmantota, lai pielāgotu modeļus dažādām vidēm un konstrukcijām, ļaujot uzlabot sistēmas spēju pielāgoties ārējās vides variācijām [110].	Ārējā gaisa temperatūra
Konvolūcijas neironu tīkli (CNN) un Gausa jauktie modeļi (GMM)	Tā vietā, lai tieši atdalītu konkrētus vides parametrus, GMM apguva CNN iegūto pazīmju statistiskos sadalījumus, ļaujot modeļim filtrēt vides ietekmi un koncentrēties uz konstrukciju bojājumu noteikšanu [111].	Ārējā gaisa temperatūra
Bajesa modeļa atjaunināšana	Metode tika izmantota, lai pusautomātiski pielāgotu temperatūras korekcijas funkciju, lai samazinātu temperatūras izraisītās kļūdas [112].	Ārējā gaisa temperatūra
Uz modeļiem balstīta pieeja	Temperatūras modelēšana tika integrēta skaitliskajā modelī, lai atšķirtu bojājumu no apkārtējās vides izraisītām izmaiņām [113].	Ārējā gaisa temperatūra

Metode, kurā ārējās vides faktoru dimensijas samazināšanai tiek izmantota **galveno komponentu analīze (PCA)** un dinamisko parametru prognozēšanai – saliktā ansambla mācīšanās pieeja [107], balstās uz datiem balstītu ārējās vides ietekmes netiešu samazināšanu. Metodes pamatideja ir balstīta uz monitoringa datiem, kuros pašsvārstību frekvenču laika rindas tiek analizētas kopā vienlaikus ar mērītiem ārējās vides faktoriem. Ārējās vides faktoru dimensija tiek samazināta, izmantojot galveno komponentu analīzi (PCA), un iegūtās komponentes tiek izmantotas pašsvārstību frekvenču prognozēšanai ar regresijas modeļiem. Katras pašsvārstību frekvences izmaiņas tiek prognozētas kā ārējās vides faktoru funkcija. Ārējās vides faktoru ietekme tiek netieši noņemta, analizējot prognozēšanas atlikumus starp mērītajām un prognozētajām pašsvārstību frekvenču vērtībām:

$$e_i(t) = \hat{Y}(t) - Y(t), \quad (2.1)$$

kur $e_i(t)$ ir prognozēšanas atlikums. Šādā veidā netiek tieši koriģēti dinamiskie parametri laikā vai frekvenču apgabalā, bet tiek atdalīta ārējās vides faktoru ietekme no bojājumu izraisītām izmaiņām, izmantojot prognozēšanas atlikumu analīzi [107].

Metodes priekšrocības:

- Metode ļauj vienlaikus ņemt vērā vairākus ārējās vides faktorus, aprakstīt nelineāras un sarežģītas sakarības starp ārējās vides ietekmi un konstrukciju dinamiskajiem parametriem;
- Metode tika validēta, izmantojot pilna mēroga režģa konstrukciju monitoringa datus.

Metodes trūkumi:

- Rezultāti būtiski atkarīgi no apmācības datu kvalitātes;
- Tiek pieņemta ārējās vides faktoru un dinamisko parametru savstarpējās sakarības nemainība laikā;
- Mašīnmācīšanās modeļu interpretējamība ir ierobežota un metode tika validēta, izmantojot īstermiņa monitoringa datus, kurā netika novērotas pēkšņas ārējo vides faktoru vērtību izmaiņas.

Metode, kura balstās uz datiem balstītu ārējās vides faktoru ietekmes samazināšanu, izmantojot **autoregresīvos modeļus (ARX)** [108], apraksta konstrukcijas dinamisko parametru izmaiņas mainīgu ārējo vides apstākļu ietekmē. Metodes pamatideja balstās uz ilgtermiņa konstrukcijas monitoringa datiem, kuros pašsvārstību frekvenču laika rindas tiek iegūtas, izmantojot automātisko modālo analīzi (*AMA, Automated Modal Analysis*), vienlaikus nosakot ārējās vides faktoru vērtības, no kuriem dominējošā ir ārējā gaisa temperatūra. Tiek pieņemts, ka monitoringa sākuma periodā konstrukcija atrodas nebojātā tehniskā stāvoklī, un šajā periodā novērotās pašsvārstību frekvenču izmaiņas galvenokārt ietekmē ārējās vides faktori. Ārējās gaisa temperatūras ietekme uz pašsvārstību frekvencēm tiek modelēta, izmantojot autoregresīvos modeļus (ARX):

$$y_k + a_1 y_{k-1} + \dots + a_{n_a} y_{k-n_a} = b_1 u_{k-n_k} + \dots + b_{n_b} u_{k-n_k-n_b+1} + e_k, \quad (2.2)$$

kur y_k ir pašsvārstību frekvence laika momentā k , u_k ir ārējās gaisa temperatūras mērījums, a_i un b_i ir modeļa koeficienti, n_a , n_b un n_k ir modeļa kārtas un nobīde, bet e_k ir atlikums. Autoregresīvā modeļa (ARX) koeficienti tiek noteikti, izmantojot mazāko kvadrātu metodi, balstoties uz nebojātās konstrukcijas monitoringa datiem. Ārējās gaisa temperatūras ietekme tiek ņemta netieši, analizējot starpību starp mērītajām un prognozētajām frekvenču vērtībām:

$$e_k = y_k - \hat{y}_k, \quad (2.3)$$

kur $\hat{y}_k$ ir autoregresīvā modeļa (ARX) prognozētā pašsvārstību frekvences vērtība.

Šādā veidā ārējās vides ietekme netiek tieši koriģēta, bet tiek modelēta un kompensēta prognozēšanas līmenī, izmantojot atlikumu analīzi [108].

Metodes priekšrocība:

- Metode tika validēta, izmantojot pilna mēroga tilta konstrukciju ilgtermiņa monitoringa datus, kas apliecina tās piemērojamību arī citām inženierbūvēm mainīgos ārējās gaisa temperatūras apstākļos.

Metodes trūkumi:

- Tika analizēta tikai ārējās gaisa temperatūras ietekme un ietekmes samazināšanā tika izmantotas tikai pozitīvas temperatūras vērtības, neņemot vērā konstrukcijas dinamisko parametru izmaiņas pie negatīvām ārējās gaisa temperatūras vērtībām;
- Metode balstās uz empīriskiem modeļiem ar ierobežotu interpretējamību.

Metode, kurā tiek izmantota **Gausa procesa regresija (GPR)** [109], balstās uz ārējās vides faktoru netiešu samazināšanu, modelējot relatīvās sakarības starp nomināli identisku konstrukcijas elementu dinamiskajiem parametriem. Metodes pamatideja balstās uz pieņēmumu, ka ārējās vides un ekspluatācijas faktori līdzīgā veidā ietekmē visus nomināli identiskus konstrukcijas elementus. No monitoringa datiem iegūtās pašsvārstību frekvenču laika rindas tiek izmantotas, lai ar Gausa procesa regresiju (GPR) modelētu funkcionālu sakarību starp divu elementu dinamiskajiem parametriem:

$$y = f(x) + \varepsilon, \quad (2.4)$$

kur x ir viena elementa dinamiskais parametrs (pašsvārstību frekvence), y ir cita elementa dinamiskais parametrs, $f(\cdot)$ ir nezināma funkcija, bet ε ir baltais troksnis ar nulles vidējo vērtību.

Apmācītais Gausa process tiek izmantots viena elementa dinamisko parametru prognozēšanai, balstoties uz cita elementa mērījumiem, savukārt ārējās vides faktoru ietekme tiek netieši samazināta, analizējot prognozēšanas atlikumus:

$$r = y - \hat{y}, \quad (2.5)$$

kur $\hat{y}$ ir Gausa procesa prognozētā vērtība.

Šādā veidā ārējās vides faktoru ietekme netiek tieši koriģēta vai atņemta no dinamisko parametru vērtībām, bet tiek kompensēta relatīvo sakarību modelēšanas līmenī, saglabājot jutību pret konstrukcijas bojājumiem.

Metodes priekšrocības:

- Relatīvā modelēšana starp nomināli identiskiem konstrukciju elementiem, kas ļauj samazināt kopīgo ārējās vides un ekspluatācijas faktoru ietekmi uz prognozēšanas atlikumiem;
- Gausa procesa regresija (GPR) nodrošina nelineāru sakarību modelēšanu ar nenoteiktības novērtējumu, kas ir būtiski dinamisko parametru izmaiņu interpretācijai.

Metodes trūkumi:

- Ārējās vides faktoru ietekmes samazināšanai tiek ņemta vērā tikai ārējā gaisa temperatūra;
- Metode ir piemērojama tikai konstrukcijām ar vairākiem nomināli identiskiem vai savstarpēji salīdzināmiem elementiem;
- Tiek pieņemts, ka ārējās vides ietekme uz visiem elementiem ir līdzīga, kas reālos ekspluatācijas apstākļos var nebūt patiesa. Metodes rezultāti ir būtiski atkarīgi no nebojātā stāvokļa apmācības datu kvalitātes un apjoma.

Metode, kurā tiek izmantota **meta-apmācība (MAML)** un **galveno komponentu analīze (PCA)** [110], balstās uz datiem balstītu ārējās vides faktoru ietekmes samazināšanu, modelējot konstrukcijas dinamisko reakciju kā ārējās gaisa temperatūras funkciju. Metodes pamatideja balstās uz pieņēmumu, ka ārējā gaisa temperatūra ietekmē konstrukcijas stingumu un līdz ar to arī tās dinamiskos parametrus. Temperatūras ietekme uz stingumu tiek aprakstīta ar nelineāru sakarību:

$$k(T) = -13T^2 + 500T + 7200, \quad (2.5)$$

kur $k(T)$ ir konstrukcijas stingums pie ārējās gaisa temperatūras T .

Lai samazinātu augstas dimensijas dinamisko datu sarežģītību, tiek izmantota galveno komponentu analīze (PCA), saglabājot galvenās komponentes, kas izskaidro vairāk nekā 90% no kopējās datu dispersijas. Meta-apmācības algoritms (MAML) tiek apmācīts, izmantojot skaitliski simulētus galīgo elementu modeļus ar dažādiem temperatūras-stinguma scenārijiem, ļaujot prognozēt ārējās gaisa temperatūras izraisīto dinamisko parametru izmaiņu daļu. Ārējās vides faktoru ietekme tiek netieši noņemta, analizējot novirzes starp novērotajām un prognozētajām vērtībām.

Metodes priekšrocības :

- Ārējās gaisa temperatūras samazināšana bez tiešas signāla korekcijas laikā vai frekvenču vērtību izmaiņām;

- Efektīva pielietojamība konstrukcijām ar ierobežotu datu apjomu, izmantojot populācijas informāciju.

Metodes trūkumi:

- Tiek analizēta tikai ārējās gaisa temperatūras ietekme, neņemot vērā citus ārējās vides ietekmes faktorus;
- Metodes validācija tika veikta uz skaitliski simulētiem konstrukciju modeļiem, kuros temperatūras ietekme tika modelēta, mainot konstrukcijas stinguma parametrus, kas ierobežo metodes tiešu piemērošanu ēkām un inženierbūvēm reālos mainīgos ārējās vides apstākļos.

Metode, kurā tiek izmantoti **konvolūcijas neironu tīkli un Gausa jauktie modeļi** [111], balstās uz datiem balstītu ārējās vides faktoru ietekmes samazināšanu, izmantojot automātiski apgūtas pazīmes un varbūtības modeļus. Metodes pamatideja balstās uz automātisku pazīmju iegūšanu no mērījumu signāliem, izmantojot 1D konvolūcijas neironu tīklu (CNN), iegūstot pazīmju vektorus, kas ietver gan konstrukcijas bojājuma ietekmi, gan ārējās gaisa temperatūras izraisītās variācijas. Ārējās gaisa temperatūras ietekme tiek statistiski modelēta, aprakstot pazīmju sadalījumu ar Gausa jaukto modeli (GMM):

$$p(x) = \sum_{i=1}^{i=k} \pi_i \cdot \mathcal{N}(x|\mu_i \cdot \sigma_i), \quad (2.6)$$

kur x ir pazīmju vektors, k ir Gausa komponentu skaits, μ_i ir i -tās komponentes vidējā vērtība, σ_i ir i -tās komponentes standartnovirze, π_i ir i -tās komponentes svars un $\mathcal{N}(\cdot)$ ir normālsadalījuma funkcija. Iegūtā varbūtības blīvuma funkcija $p(x)$ raksturo references stāvokļa pazīmju sadalījuma varbūtisko struktūru.

Ārējās vides ietekme tiek netieši samazināta, kvantitatīvi salīdzinot abu sadalījumu atšķirību ar Kullbeka-Leiblera (KL , *Kullback-Leibler*) diverģenci:

$$KL(p||q) = - \sum_x x \cdot p(x) \cdot \log \left(\frac{q(x)}{p(x)} \right), \quad (2.7)$$

kur $p(x)$ ir references stāvokļa GMM varbūtības blīvuma funkcija un $q(x)$ ir monitoringa GMM varbūtības blīvuma funkcija.

KL diverģence kalpo kā signāla atšķirības koeficients (SDC , *Signal Difference Coefficient*), kas ir jutīgs pret bojājumiem, bet noturīgs pret ārējās gaisa temperatūras izmaiņām. Šādā veidā netiek tieši koriģēts signāls, bet tiek salīdzināta pazīmju sadalījumu statistiskā struktūra, kas ļauj atdalīt bojājuma ietekmi no ārējās gaisa temperatūras radītās ietekmes [111].

Metodes priekšrocības:

- Netieša ārējās gaisa temperatūras ietekmes samazināšana, neizmantojot tiešu parametra mērīšanu monitoringa laikā.

Metodes trūkumi:

- Tiek ņemta vērā tikai ārējās gaisa temperatūras ietekme;
- Nepieciešams liels apmācības datu apjoms, kas ietver ārējās vides faktoru ietekmes variācijas diapazonu;
- Ierobežota metodes interpretējamība, jo pazīmju iegūšana balstās uz “melnās kastes” principu;

- Metode tika eksperimentāli validēta laboratorijas apstākļos uz nepilna mēroga konstrukcijas elementu un līdz ar to ierobežo metodes tiešu pārnēsamību uz pilna mēroga ēku vai inženierbūvju monitoringu.

Metodē, kurā tiek izmantota **Bajesa modeļa atjaunināšana** [112], ārējās gaisa temperatūras ietekme tiek apskatīta kā mērījumu sistēmas temperatūras atkarība. Metodes pamatā ir pieņēmums, ka mērījumu signāla izmaiņas temperatūra ietekmē var aprakstīt kā temperatūras atkarīgu pārnēses funkciju. Metodes pamatā ir temperatūras atkarīgas pārnēses funkcijas noteikšana un tās izmantošana mērījumu korekcijai. Katram ārējās gaisa temperatūras līmenim T tiek aprēķināts pārnēses koeficients $H(T)$, kas tiek definēts kā attiecība starp izmērīto attālumu pie temperatūras T un references temperatūras $T_{ref} = 10^{\circ}\text{C}$ mērījumu. Diskrētie pārnēses koeficienti tiek aproksimēti ar otrās kārtas polinomu, iegūstot temperatūras atkarīgo pārnēses funkciju:

$$H(T) = a_0 + a_1T + a_2T, \quad (2.8)$$

kur a_0 , a_1 , a_2 ir regresijas koeficienti, T ir ārējā gaisa temperatūra. Šī funkcija tiek izmantota tiešai mērījumu korekcijai, kompensējot ārējās gaisa temperatūras ietekmi uz sensora signālu.

Lai ņemtu vērā laika gaitā mainīgu temperatūras ietekmi, regresijas koeficienti tiek adaptīvi atjaunināti, izmantojot Bajesa modeļa atjaunošanu:

$$D = M(x, \theta) + \varepsilon, \quad (2.9)$$

kur D ir mērījumu vektors, $M(\cdot)$ ir pārnēses funkcija, θ ir atjaunināmie regresijas koeficienti un ε ir modeļa vai mērījumu kļūda.

Metodes priekšrocības:

- Metode ir tieša un interpretējama ārējās gaisa temperatūras ietekmes samazināšanai;
- Regresijas koeficientu atjaunošana ļauj ņemt vērā ārējās gaisa temperatūras mainīgumu laikā.

Metodes trūkumi:

- Tiek analizēta tikai ārējās gaisa temperatūras ietekme;
- Metodes praktiskai ieviešanai nepieciešama kontrolēta temperatūras kalibrācija, kas reālās ēkās un inženierbūvēs bieži vien nav iespējama;
- Metode tiek validēta laboratorijas apstākļos uz nepilna mēroga eksperimentālās sistēmas, kas ierobežo tās tiešu pārnēsamību uz pilna mēroga ēku vai inženierbūvju monitoringu ar mainīgiem ārējās vides ietekmes faktoriem.

Metodē, kurā tiek izmantota **uz modeļiem balstīta** ārējās vides faktoru ietekmes samazināšana [113], ārējās gaisa temperatūras ietekme tiek integrēta skaitliskajā modelī. Metodes pamatideja ir vienlaikus modelēt ārējās gaisa temperatūras izraisītās izmaiņas konstrukcijas dinamiskajos parametros un bojājuma ietekmi, līdz ar to novēršot temperatūras svārstību kļūdainu interpretēšanu kā konstrukcijas bojājumu. Metodes pamatideja balstās uz konstrukcijas dinamisko parametru noteikšanu ar galīgo elementu modeli, kurā ārējās gaisa temperatūras ietekme tiek iekļauta kā papildus mainīgais. Tiek pieņemts, ka temperatūras izmaiņas ietekmē materiāla elastības moduli un līdz ar to arī konstrukcijas dinamiskos parametrus.

Materiāla elastības modulis tiek definēts kā temperatūras funkcija:

$$E(T) = E_0 \cdot f(T), \quad (2.10)$$

kur $E(T)$ ir elastības modulis pie temperatūras T , E_0 ir elastības modulis references temperatūrā T_0 , bet $f(T)$ ir temperatūras korekcijas funkcija.

Ārējās gaisa temperatūras izraisītas termiskās deformācijas tiek aprakstītas ar lineārās termiskās izplešanās sakarību:

$$\delta = \alpha_T \cdot (T - T_0), \quad (2.11)$$

kur α_T ir lineārās termiskās izplešanās koeficients.

Šajā metodē netiek veikta tieša signālu korekcija laika vai frekvenču apgabalā. Tā vietā ārējās gaisa temperatūras ietekme tiek fizikāli integrēta konstrukcijas modelī, kas ļauj atdalīt ārējās vides izraisītas izmaiņas no bojājumu radītām izmaiņām.

Metodes priekšrocības:

- Tieši un fizikāli pamatota ārējās gaisa temperatūras ietekmes samazināšana, nodrošinot augstu rezultātu interpretējamību.

Metodes trūkumi:


- Analizēta tikai ārējās gaisa temperatūras ietekme;
- Atkarība no precīza galīgo elementu modeļa pieejamības, kas reālām ēkām un inženierbūvēm bieži var būt sarežģīti nodrošināma, kā arī metodes efektivitāte ir jutīga pret modeļa parametru nenoteiktību un robežnosacījumu pieņēmumiem;
- Validācija tika veikta, izmantojot skaitliski ģenerētus dinamiskos parametrus, kas ierobežo tiešu izmantošanu ilgtermiņa konstrukciju monitoringa apstākļos.

Analizētās ārējās vides faktoru ietekmes samazināšanas metodes konstrukciju tehniskā stāvokļa monitoringā ļauj būtiski samazināt ārējās vides izraisīto dinamisko parametru izmaiņas, saglabājot jutību pret konstrukciju bojājumiem. To galvenā priekšrocība ir spēja nošķirt ārējās vides faktoru radītās izmaiņas no bojājumu izraisītām izmaiņām, izmantojot vai nu uz datiem balstītu statistisku un mašīnmācīšanās modelēšanu, vai arī fizikāli pamatotu skaitlisko modelēšanu. Tomēr šo metožu pielietojamību bieži ierobežo pieņēmumi par ārējās vides ietekmes nemainīgumu, apmācības datu kvalitāti un apjomu, kā arī ierobežota modeļu interpretējamība uz datiem balstītās pieejās. Vairumā metožu analizē tikai dominējošā ārējās gaisa temperatūras ietekme tiek apskatīta, neņemot vērā vairāku faktoru kombinētu ietekmi. Kā arī metožu validācija bieži vien balstās uz īstermiņa monitoringa datiem, laboratorijas eksperimentiem vai skaitliski simulētiem modeļiem, kas ierobežo rezultātu tiešu piemērošanu uz pilna mēroga ēku un inženierbūvju ilgtermiņa monitoringa datiem. Ņemot vērā minētos ierobežojumus, esošās ārējās vides faktoru ietekmes samazināšanas metodes pilnībā neatbilst ēku un inženierbūvju ilgtermiņa monitoringa apstākļiem. Ēkas un inženierbūves ekspluatācijas laikā konstrukcijas vienlaikus ietekmē vairāki ārējās vides faktori piemēram, relatīvais mitrums, vēja ātrums, nokrišņi un sniegs, kuru ietekmes raksturs un intensitāte laika gaitā būtiski mainās [114]. Tāpēc ir nepieciešams izstrādāt adaptīvu, viegli interpretējamu metodi, kas ļauj samazināt ne tikai ārējās gaisa temperatūras, bet arī citu apkārtējās vides parametru ietekmi uz konstrukciju dinamiskajām īpašībām, vienlaikus saglabājot augstu jutību pret konstrukciju bojājumiem un nodrošinot praktisku pielietojamību ilgtermiņa monitoringa apstākļos.


3. Metode ārējās vides faktoru ietekmes samazināšanai konstrukciju pašsvārstību frekvenču monitoringa datos

Konstrukciju tehniskā stāvokļa monitoringa sistēmas efektivitātes un uzticamības nodrošināšanai tika izstrādāta ārējās vides faktoru ietekmes samazināšanas metode, kas, īstenojot astoņu secīgus posmus (3.1.att., 3.2.att.), ļauj iegūt stabilas un salīdzināmas pašsvārstību frekvenču vērtības un nodrošina precīzāku bojājumu identificēšanu neatkarīgi no apkārtējās vides mainības.

Izstrādātā pieeja nodrošina katra ārējās vides ietekmes faktora kvantificēšanu, ļaujot precīzi aprēķināt nepieciešamās korekcijas. Šī metode ir viegli interpretējama, praktiski ērti pielietojama un integrējama monitoringa sistēmas algoritmos, kā arī sniedz iespēju pielāgoties sezonālajām klimata izmaiņām, kas raksturīgas ilgtermiņa monitoringa procesam.



3.1.att. Ārējās vides ietekmes samazināšanas metodes 1. – 6.posms.



3.2.att. Ārējās vides ietekmes samazināšanas metodes 7. – 8.posms.

3.1. Datu apvienošana

Ārējās vides faktoru ietekmes samazināšanas metodes **1.posmā** tiek veikta pašsvārstību frekvenču mērījumu datu un ārējās vides faktoru apvienošana vienā datu kopā. Dati tiek apvienoti pēc mērījumu laika norādēm, nodrošinot, ka katram pašsvārstību frekvences mērījumam tiek piešķirtas tajā pašā laika brīdī reģistrētās ārējās vides faktoru vērtības. Rezultātā tiek iegūta apvienota datu matrica, kur katra rinda raksturo konstrukciju dinamisko reakciju konkrētos ārējās vides apstākļos. Šis solis nodrošina pamatu turpmākai analīzei un korekcijas modeļu izveidei.

3.2. Regresijas modeļu piemērošana datiem

Ārējās vides faktoru ietekmes samazināšanas metodes **2.posmā** tiek izmantoti septiņi dažādi regresijas modeļi, lai modelētu katras pašsvārstību frekvences atkarību no ārējās vides parametriem:

- atbalsta vektora regresija (SVR, *Support Vector Regression*) ar Gausa kodolfunkciju;
- gadījuma meža regresija (RF, *Random Forest*);
- lineārā regresija (LR, *Linear Regression*);
- lēmumu koku regresija (DT, *Decision Tree Regression*);
- gradientu palielināšanas regresija (XGBoost, *Extreme Gradient Boosting*);
- Gausa procesu regresija (GPR, *Gaussian Process Regression*) ar Matern 3/2 kodolfunkciju;
- Bajesa regresija (BR, *Bayesian Regression*) ar Matern 5/2 kodolfunkciju.

Dažādu modeļu izmantošana ļauj salīdzināt prognožu kvalitāti un identificēt, kura pieeja vislabāk atbilst konkrētajam datu kopumam [115].

Atbalsta vektora regresija (SVR) ir atbalsta vektora mašīnmācīšanās algoritma (SVM) paplašinājums regresijas uzdevumiem, kas ir datiem ar sarežģītām un nelineārām sakarībām starp mainīgajiem. SVR mērķis ir noteikt funkciju, kas aproksimē datus noteiktā tolerances intervālā ε , vienlaikus ierobežojot modeļa sarežģītību un pieļaujot kontrolētas novirzes ārpus

šī intervāla [116]. Algoritmā tiek izmantota Gausa jeb radiālās bāzes (RBF) kodolfunkcija, kas nodrošina efektīvu nelineāru sakarību modelēšanu [117], [118].

Gadījuma meža regresija (RF) ir mašīnmācīšanās algoritms, kas apvieno vairākus lēmumu kokus. Katrs lēmumu koks tiek apmācīts, izmantojot nejauši atlasītus datu apakšparaugus un mainīgo apakškopas, līdz ar to nodrošinot stabilas un precīzas prognozes. Šāda pieeja samazina pārprielāgošanās risku un palielina metodes stabilitāti. Metode ir īpaši piemērota konstrukciju monitoringa datiem ar sarežģītām nelineārām sakarībām, kā arī augstas dimensijas datu kopā [119].

Lineārā regresija (LR) sniedz vienkāršu un viegli interpretējamu modeli, kas pieņem, ka starp atkarīgo mainīgo – pašsvārstību frekvenci f un neatkarīgo mainīgo – ārējās vides faktoru x_j pastāv lineāra sakarība. Modelis mēģina atrast taisni, kas vislabāk pielāgojas datiem, minimizējot vidējo kvadrātisko kļūdu (*MSE, Mean Squared Error*) starp faktisko un prognozēto pašsvārstību frekvenču vērtību. Metode ir piemērota gadījumos, kad ārējās vides faktoru ietekme uz dinamiskajiem parametriem ir aptuveni lineāra un skaidra neatkarīgo mainīgo ietekmes interpretācija [120].

Lēmumu koku regresija (DT) ir viegli interpretējama metode, kas, balstoties uz ārējās vides faktoru vērtībām, sadala datu telpu atsevišķos reģionos ar raksturīgām pašsvārstību frekvenču prognozēm, minimizējot kļūdu katrā reģionā. Taču tās precizitāte var samazināties sarežģītu nelineāru sakarību gadījumā [121].

Gradientu palielināšanas regresija (XGBoost) ir ansambļa mācīšanās metode, kas secīgi veido lēmumu kokus, katrā itērācijā koriģējot iepriekšējo modeļu kļūdas un, izmantojot regularizāciju, ierobežo modeļa sarežģītību un samazina pārprielāgošanas risku. Šī metode ir īpaši piemērota liela apjoma konstrukciju monitoringa datiem ar sarežģītām nelineārām sakarībām starp ārējās vides faktoriem un pašsvārstību frekvencēm [122].

Gausa procesu regresija (GPR) ir neparametriska mašīnmācīšanās metode, kas modelē nelineāras sakarības starp ārējās vides faktoriem un pašsvārstību frekvencēm. Metodē tiek izmantots Gausa procesa modelis ar noteiktu kovariācijas struktūru, kur sakarību raksturu nosaka apmācības datu savstarpējā līdzība, ko raksturo izvēlētā kodolfunkcija un tās parametri. GPR ir piemērota gadījumos ar ierobežotu monitoringa datu apjomu un nodrošina ne tikai prognozēto vērtību noteikšanu, bet arī prognožu nenoteiktības kvantitatīvu novērtējumu [123], [118].

Bajesa regresija (BR) šajā gadījumā izmanto Gausa procesu regresijas metodi (GPR) ar automatizētās atbilstības noteikšanas (*ARD, Automatic Relevance Determination*) Matern 5/2 kodolfunkciju, kas modelē sakarību starp ārējās vides faktoriem un pašsvārstību frekvencēm. Katram ievades parametram tiek noteikts atsevišķs garuma mēroga parametrs, kas nodrošina augstu prognozes precizitāti ar nenoteiktības kvantitatīvu novērtējumu [123].

Lai nodrošinātu katra modeļa optimālu pielāgošanu datiem, tiek izmantota **Bajesa optimizācija**, kas automātiski meklē labākos modeļu hiperparametrus. Bajesa optimizācija cenšas minimizēt vai maksimizēt funkciju:

$$\hat{f}(x) = \mathbb{E}[Y|X = x] \quad (3.1)$$

kur $\hat{f}(x)$ ir modelī prognozētā konstrukciju pašsvārstību frekvences vērtība; Y ir atbildes mainīgais, kuru nepieciešams prognozēt jeb šajā gadījumā konstrukcijas pašsvārstību

frekvence; X ir ārējās vides mainīgie faktori; x ir ievades parametru vektors, kas satur attiecīgajā mērījuma brīdī novērotās ārējās vides faktoru vērtības.

Optimizācijas procesā tiek izveidots varbūtību modelis par mērķa funkcijas vērtību sadalījumu, izmantojot Gausa procesu regresiju (GPR) kā aizstājējfunkciju:

$$P(f(x)|D) \sim \mathcal{N}(\mu(x), \sigma^2(x)) \quad (3.2)$$

kur D ir jau novērtētie punkti; $\mu(x)$ ir vidējā vērtība x punktā; $\sigma^2(x)$ ir variānces novērtējums [123].

Bajesa optimizācija tiek pielietota katrai regresijas metodei, veicot 30 hiperparametru testus, lai atrastu optimālus hiperparametrus:

- 1) SVR metodei tiek optimizēts $\mathcal{C}$ – regulēšanas parametrs un γ – kodolfunkcijas parametrs;
- 2) RF metodei tiek optimizēts T – lēmumu koku skaits, maksimālais sadalījumu skaits, minimālais lapas izmērs un minimālais paraugu skaits mezglā pirms sadalīšanas;
- 3) XGBoost metodei tiek optimizēts η – mācīšanās ātrums, gradienta palielināšanas koku skaits, maksimālais sadalījuma skaits, minimālais lapas izmērs;
- 4) GPR metodei tiek optimizēts kodolfunkcijas tips – tiek izvēlēta Matern3/2, Matern5/2 vai Kvadrātiskā eksponenciālā funkcija. Tiek optimizēti garuma mēroga ℓ un signāla variānces hiperparametri, kas nosaka procesa gludumu un amplitūdu;
- 5) BR metodei tiek optimizēta automatizēta atbilstības noteikšanas (ARD) garuma vērtība ℓ_j katrai dimensijai, kas nosaka parametru relatīvo nozīmīgumu Matern5/2 kodolā;
- 6) DT metodei tiek optimizēts maksimālais sadalījumu skaits, minimālais lapas izmērs [124].

Optimizācijas problēma tiek formulēta kā:

$$\min_{\theta} \mathbb{E}[MSE(\theta)], \quad (3.3)$$

kur θ ir hiperparametru vektors un MSE ir vidējā kvadrātiskā kļūda.

Vidējā kvadrātiskā kļūda (MSE) tiek aprēķināta pēc formulas:

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - \hat{f}_i)^2, \quad (3.4)$$

kur N ir datu punktu skaits; f_i ir faktiskā pašsvārstību frekvences vērtība novērojuma i gadījumā un $\hat{f}_i$ ir prognozētā pašsvārstību frekvences vērtība [125].

Katram θ punktam Bajesa optimizācija novērtē aizstājējfunkciju $P(f(x)|D)$ un apgūšanas funkciju, kas nosaka, vai meklēt jaunu parametru reģionu vai izmantot iepriekšējās zināšanas.

Šajā gadījumā tiek izmantota paredzamā uzlabojuma plus funkcija (EI+), kura tiek aprēķināta pēc formulas:

$$EI(x) = (\mu(x) - f^*)\Phi(z) + \sigma(x)\phi(z) \quad (3.5)$$

kur f^* ir labākā līdz šim atrastā vērtība – minimālā kļūda; $\Phi(z)$ un $\phi(z)$ ir normālā sadalījuma kumulatīvā un blīvuma funkcijas [124].

3.3. Regresijas modeļu novērtēšana

Ārējās vides faktoru ietekmes samazināšanas metodes **3.posmā** tiek veikta katra modeļa precizitātes novērtēšana, lai analizētu modeļa spēju pielāgoties datiem un sniegt precīzas prognozes. Tiek izmantoti četri galvenie rādītāji:

- 1) determinācijas koeficients (R^2 , *Coefficient of Determination*);
- 2) vidējā kvadrātiskā kļūda ($RMSE$, *Root Mean Squared Error*);
- 3) vidējā absolūtā kļūda (MAE , *Mean Absolute Error*);
- 4) vidējā procentuālā absolūtā kļūda ($MAPE$, *Mean Absolute Percentage Error*).

R^2 vērtība norāda, kādu daļu no atkarīgā mainīgā dispersijas skaidro modelis. Šo koeficientu aprēķina pēc formulas:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}}, \quad (3.6)$$

kur $SS_{res} = \sum (f_i - \hat{f}_i)^2$ ir atlikumu kvadrātu summa, kur f_i ir faktiskā pašsvārstību frekvences vērtība novērojuma i gadījumā un $\hat{f}_i$ ir prognozētā pašsvārstību frekvences vērtība; $SS_{tot} = \sum (f_i - \bar{f})^2$ ir kopējā dispersijas kvadrātu summa, $\bar{f}$ ir visu N novērojumu vidējā pašsvārstību frekvences vērtība; N ir datu punktu skaits. Ja $R^2 = 1$, tad modelis pilnībā skaidro datus; ja $R^2 = 0$, tad modelis datus neskaidro labāk par vienkāršu vidējās vērtības prognozi; ja $R^2 < 0$, tad modelis ir sliktāks nekā vidējās vērtības prognoze [126].

RMSE nosaka vidējo prognožu kļūdu, ko veic modelis, salīdzinot ar faktiskajām vērtībām. Zemāka **RMSE** vērtība norāda uz labāku modeļa prognožu precizitāti, savukārt lielākas **RMSE** vērtības norāda, ka modelis prognozē ar lielākām kļūdām. To aprēķina pēc formulas:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - \hat{f}_i)^2} \quad (3.7)$$

MAE nosaka vidējo absolūto atšķirību starp faktiskajām vērtībām un modeļa prognozēm. To aprēķina pēc formulas:

$$MAE = \frac{1}{N} \sum_{i=1}^N |f_i - \hat{f}_i|, \quad (3.8)$$

MAE aprēķina šīs absolūtās kļūdas vidējo vērtību visos datu punktos. Zemāka **MAE** vērtība liecina, ka modeļa prognozes ir tuvāk faktiskajām vērtībām, kas norāda uz labāku modeļa precizitāti.

MAPE ir kļūdu rādītājs, kas izsaka kļūdu procentuālā izteiksmē. Tā norāda, cik lielā mērā prognozētās vērtības atšķiras no faktiskajām vērtībām procentuālā mērogā. To aprēķina pēc formulas:

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{f_i - \hat{f}_i}{f_i - \varepsilon} \right| \quad (3.9)$$

kur ε ir neliels skaitlis, kas pievienots, lai izvairītos no dalīšanas ar nulli [121].

Katram no modeļiem tiek aprēķināts saliktās efektivitātes rādītājs (*CPM*, *Composite Performance Metric*), kas apvieno R^2 , *RMSE*, *MAE* un *MAPE* efektivitātes rādītājus, lai sniegtu vienotu rādītāju, pēc kura var salīdzināt dažādu regresijas modeļu vispārējo precizitāti. *CPM* tiek aprēķināts pēc formulas:

$$CPM = M_{norm}(RMSE) + M_{norm}(MAE) + M_{norm}(MAPE) - M_{norm}(R^2) \quad (3.10)$$

kur $M_{norm}(M_m)$ nozīmē, ka attiecīgais rādītājs tiek normalizēts pēc formulas:

$$M_{norm}(M_m) = \frac{M_m - \mu_M}{\sigma_M + \varepsilon} \quad (3.11)$$

kur M_m ir konkrētā modeļa rādītāja *RMSE*, *MAE*, *MAPE* vai R^2 vērtība; μ_M ir attiecīgā rādītāja vidējā vērtība, kas tiek aprēķināta starp visiem modeļiem analizētajā frekvencē; σ_M ir attiecīgā rādītāja standartnovirze; ε ir ļoti maza konstante, kas pievienota, lai izvairītos no dalīšanas ar nulli un uzlabotu skaitlisko stabilitāti [127].

Attiecīgā rādītāja vidējā vērtība tiek noteikta, izmantojot formulu:

$$\mu_M = \frac{1}{K} \sum_{m=1}^K M_m \quad (3.12)$$

kur K ir modeļu skaits ($K = 7$); m ir regresijas modeļa indekss.

Attiecīgā rādītāja standartnovirze tiek noteikta izmantojot formulu:

$$\sigma_M = \sqrt{\frac{1}{K-1} \sum_{m=1}^K (M_m - \mu_M)^2} \quad (3.13)$$

Katrai regresijas metodei m tiek aprēķināta vidējā *CPM* vērtība visām pašsvārstību frekvencēm:

$$CPM_m = \frac{1}{N_f} \sum_{i=1}^{N_f} CPM_{i,m}, \quad (3.14)$$

kur N_f ir frekvenču skaits un $CPM_{i,m}$ ir *CPM* vērtība i -tajai frekvencei un m -tajam modelim.

Modelis, kas tiks ārejo vides faktoru ietekmes segmentu noteikšanai, tiek noteikts pēc formulas:

$$M_m = \arg \min_m (CPM_m), \quad (3.15)$$

kur $\arg \min_m (CPM_m)$ ir funkcija, kas nosaka to regresijas modeli m , kuram vidējā CPM_m vērtība ir viszemākā. Zemāka *CPM* vērtība norāda uz labāku modeļa veiktspēju, jo tas liecina par zemākām prognožu kļūdām un augstāku datu dispersijas skaidrojumu. Vidējā vērtība raksturo modeļa kopējo sniegumu visā pašsvārstību frekvenču spektrā, nodrošinot konsekventu veiktspēju gan zemākajām, gan augstākajām frekvencēm, mazāku jutību pret atsevišķu frekvenču izteiktām novirzēm, kā arī stabilu un vispārīgi piemērojamu modeli ārejo vides faktoru ietekmes raksturošanai [128], [63].

3.4. Ārējo vides faktoru ietekmes segmentēšana

Ārējās vides faktoru ietekme uz pašsvārstību frekvencēm var būt atšķirīga dažādos diapazonos. Lai precīzāk tiktu koriģētas frekvenču vērtības, ārējās vides faktoru ietekmes samazināšanas metodes **4.posmā** tiek izmantots segmentācijas princips, kur monitoringa dati tiek sadalīti vairākos segmentos atbilstoši ārējo vides faktoru izmaiņu raksturam un dinamikai.

Ārējās gaisa temperatūras, relatīvā mitruma un vēja komponentu monitoringa dati tiek sadalīti trīs segmentos, kas atbilst zemam, vidējam un augstam attiecīgā ārējās vides faktora vērtību līmenim. Šāda pieeja nodrošina iespēju analizēt iespējamās nelineārās sakarības dažādos ārējās vides faktoru diapazonos. Katrā segmentā tiek saglabāts pietiekams datu apjoms stabilai regresijas modeļu apmācībai, līdz ar to izvairoties no pārmērīgas segmentācijas un modeļu pārpīlāgošanas riska [129],[130],[131].

Pašsvārstību frekvenču korekcija tiek veikta katram segmentam atsevišķi. Katram ārējās vides ietekmes faktoram segmentu robežas tiek noteiktas automātiski, balstoties uz izvēlētajā regresijas modeļa daļējas atkarības diagrammas (*PDP, Partial Dependence Plots*) līknes. PDP metode ļauj analizēt prognozēto pašsvārstību frekvenču izmaiņas atkarībā tikai no viena izvēlētajā ārējās vides faktora, saglabājot pārējo parametru faktiskās vērtības visā datu kopā. Daļējas atkarības funkcija tiek aprēķināta kā modeļu prognožu vidējā vērtība visiem novērojumiem, aizstājot analizējamā faktora vērtību ar noteiktu režģa punktu, bet pārējo ārējās vides faktoru vērtības saglabājot tādas, kādas tās ir faktiski novērotas:

$$f_{PDP(x_j)} = \frac{1}{N} \sum_{n=1}^N f(x_j, X_{-j}^n), \quad (3.16)$$

kur x_j ir analizējamā ārējās vides faktora vērtība, bet X_{-j}^n ir pārējo apkārtējās vides ietekmes faktoru faktiskās vērtības n -tajam datu novērojumam un N ir monitoringa novērojumu skaits [125].

PDP diagrammas ļauj skaidri interpretēt vai konkrētais faktors izraisa prognozēto frekvenču pieaugumu vai samazinājumu un vai pastāv ietekmes lūzuma punkti [132], [133]. PDP būtiska priekšrocība ir tās modeļa neatkarība – tā balstās uz prognozēm, nevis modeļa iekšējo struktūru, līdz ar to ir universāli piemērojama dažādiem regresijas algoritmiem, nodrošinot konsekventu un salīdzināmu rezultātu analīzi dažādos vides segmentos [122],[134]. PDP rezultāts ir vienmērīga, nepārtraukta funkcija, kas ļauj veidot nepārtrauktas korekcijas funkcijas katram segmentam, ja analizēto faktoru savstarpējā korelācija ir zema [135].

Pēc 3.posmā veiktās regresijas modeļu novērtēšanas, tiek izvēlēts modelis ar zemāko CPM_m vērtību. Izmantojot šo regresijas modeli, tiek noteiktas vidējās PDP vērtības visām pašsvārstību frekvencēm un no tām iegūta vidējā PDP funkcija:

$$\bar{f}(x_j) = \frac{1}{N_f} \sum_{i=1}^{N_f} \hat{f}_i(x_j) \quad (3.17)$$

kur $N_f = 6$ ir analizēto frekvenču skaits. Šī vidējā funkcija $\bar{f}(x_j)$ tiek papildus izlīdzināta, izmantojot Gausa procesa regresiju, lai iegūtu gludu funkciju:

$$\tilde{f}(x_j) = GPR[\bar{f}(x_j)]. \quad (3.18)$$

Gausa procesu regresija šajā gadījumā tiek izmantota, jo tā nodrošina gludu sakarības aprakstu, nepieņemot iepriekš noteiktu analītisku sakarības izteiksmi. Izlīdzināšana ir būtiska, jo tā nodrošina, ka segmentu robežas tiek noteiktas no kopīgās ārējās vides ietekmes faktora un pašsvārstību frekvences sakarības, nevis lokālām novirzēm [123], [136].

Segmentu maiņas punktu meklēšanai tiek izmantota Matlab komanda *findchangepts*:

$$\text{findchangepts}(\tilde{f}(x_j), \text{MaxNumChanges} = 2, \text{Statistic} = 'linear') \quad (3.19)$$

kas atrod tās ārējo vides parametru vērtības c_1 , c_2 , kurās mainās PDP līknes lineārā tendence. Matlab komanda *findchangepts* [137], [138] meklē ārējā vides faktora vērtības c_1 , c_2 , kur funkcija vislabāk sadalās trīs lineārās daļās:

$$\tilde{f}(x) = \begin{cases} a_1x + b_2, & x < c_1 \\ a_2x + b_2, & c_1 \leq x < c_2 \\ a_3x + b_3, & x \geq c_2 \end{cases} \quad (3.20)$$

kur x ir ārējās vides faktora vērtība; c_1 un c_2 ir segmentu maiņas punkti, a_k un b_k ir lineārā modeļa atbilstoši slīpuma koeficients un brīvais loceklis.

Segmentu maiņas punkti tiek izvēlēti, minimizējot kopējo atlikumu kvadrātu summu:

$$J = \sum_{k=1}^N \sum_{x \in I_k} [\tilde{f}(x) - (a_kx - b_k)]^2 \quad (3.21)$$

kur I_k ir k -tā segmenta diapazons un N ir segmentu skaits. Tas nozīmē, ka funkcija izvēlas maiņas punktus, kur būtiski mainās slīpums $\frac{d\tilde{f}}{dx}$ [139].

Kad maiņas punkti ir atrasti, ārējās vides faktoru vērtību diapazons tiek sadalīts trīs intervālos:

$$(-\infty, c_1), [c_1, c_2], [c_2, +\infty) \quad (3.22)$$

3.5. Daļējas atkarības diagrammu veidošana

Ārējās vides faktoru ietekmes samazināšanas metodes **5.posmā** katram ārējās vides faktoram x_j tiek veikts regresijas modeļu novērtējums katrā segmentā atsevišķi, lai identificētu to regresijas modeli, kas nodrošina visprecīzākās prognozes konkrētajā ārējā vides faktora diapazonā.

Lai novērtētu regresijas modeļu precizitāti, monitoringa dati tiek sadalīti segmentos, izmantojot 5.posmā noteiktos maiņas punktus c_1 un c_2 , kas sadala ārējās vides faktora x_j vērtību diapazonu trīs segmentos. Katram segmentam tiek atlasīti tie mērījumi, kuru ārējās vides faktoru vērtības $x_j(n)$ ietilpst attiecīgajā intervālā. Katram segmentam s tiek veikts visu septiņu regresijas modeļu novērtējums. Katrai pašsvārstību frekvencei f_i un katram regresijas modelim m segmentā tiek aprēķināti četri galvenie rādītāji: R^2 , $RMSE$, MAE un $MAPE$. Katra rādītāja aprēķins tiek veikts tikai attiecīgajā segmentā ietilpstošajiem datiem, līdz ar to precīzi atspoguļojot modeļa lokālās prognozēšanas spējas konkrētajā ārējā vides faktora diapazonā. No četriem galvenajiem rādītājiem tiek iegūts segmentētais saliktās efektivitātes rādītājs (CPM), kas tiek aprēķināts pēc 3.14. formulas. Katram segmentam s tiek aprēķināta vidējā saliktās efektivitātes rādītāja (CPM) vērtība visām pašsvārstību frekvencēm. Modelis, kas tiek uzskatīts par labāko attiecīgajā ārējās vides faktora segmentā un tiek noteikts pēc minimālās vidējās CPM

vērtības. Regresijas modelis ar viszemāko *CPM* vērtību katrā segmentā *s* tiek izvēlēts, lai veidotu samazinātu vērtību daļējas atkarības diagrammu (PDP) katrai pašsvārstību frekvencei f_i un katram ārējās vides faktoram x_j .

Samazinātu vērtību daļējas atkarības diagramma (PDP) tiek veidota diskrētā režģī:

$$\left\{ \left(x_j^{(g)}, \hat{f}_i^{(g)} \right) \right\}_{g=1}^G, \quad (3.23)$$

kur $x_j^{(g)}$ ir *g*-tā režģa punkta vērtība ārējās vides faktoram x_j , $\hat{f}_i^{(g)}$ ir attiecīgās regresijas metodes prognozētā pašsvārstību frekvences vērtība šajā režģa punktā, fiksējot pārējos ārējās vides faktorus to vidējās vērtībās un tiek aprēķināta izmantojot formulu [122],[125]:

$$\hat{f}_i^{(g)} = \hat{f}_{i,m_s} \left(x_j^{(g)}, \bar{x}_{s,j} \right). \quad (3.24)$$

Optimālais režģa punktu skaits G_i katrai pašsvārstību frekvencei tiek noteikts, izmantojot iteratīvu režģa meklēšanas procesu ar konverģences kritēriju [125], [136]. Diskrētās daļējas atkarības diagrammu (PDP) vērtības tiek interpolētas faktiskajās ārējās vides faktora vērtībās $x_j(n)$, iegūstot [140],[136]:

$$\hat{f}_i(n) = \text{Interp} \left(\left\{ \left(x_j^{(g)}, \hat{f}_i^{(g)} \right) \right\}_{g=1}^G, x_j(n) \right). \quad (3.25)$$

Diskrēto vērtību kvalitāte tiek novērtēta, aprēķinot vidējo kvadrātisko kļūdu MSE. Optimālais režģa punktu skaits G_i tiek noteikts pēc konverģences kritērija [141]:

$$|MSE_i(G) - MSE_i(G - \Delta G)| < \varepsilon, \quad (3.26)$$

kur $\varepsilon = 1 \times 10^{-3}$ ir pieļaujamā vidējās kvadrātiskās kļūdas (MSE) izmaiņa, *G* ir režģa punktu skaits, ΔG ir režģa pieauguma solis.

Pēc katra režģa aprēķina diskrētās daļējas atkarības diagrammu (PDP) vērtības tiek interpolētas faktiskajās ārējās vides faktora vērtībās $x_j(n)$, iegūstot $\hat{f}_i(n)$, un tiek aprēķināta vidējā kvadrātiskā kļūda starp faktisko un prognozēto pašsvārstību frekvenci. Ja iepriekšējā un tekošā vidējās kvadrātiskās kļūdas (MSE) vērtību starpība ir mazāka par toleranci ε , tiek fiksēts optimālais režģa punktu skaits un atbilstošā daļējas atkarības diagrammas (PDP) vērtību kopa katrai pašsvārstību frekvencei. Optimizācijas procesā tiek izmantots minimālais režģa punktu skaits $G_{min} = 50$, maksimālais $G_{max} = 500$ un režģa palielināšanas solis $\Delta G = 50$. Optimāli izvēlētas daļējas atkarības diagrammas (PDP) diskretizācija nodrošina, ka interpolētā līkne precīzi atspoguļo ārējās vides faktora ietekmi visā datu diapazonā, neveidojot lokālas svārstības vai mākslīgas anomālijas. Rezultātā katrai pašsvārstību frekvencei tiek iegūta datiem pielāgota diskrētu PDP vērtību kopa, kas saglabā ārējās vides faktora ietekmes galveno tendenci un tiek izmantota nākamajos metodikas posmos pašsvārstību frekvenču korekcijai.

3.6. Daļējas atkarības diagrammu vērtību interpolācija un frekvenču vērtību koriģēšana

Ārējās vides faktoru ietekmes samazināšanas metodes **6.posmā** katrai pašsvārstību frekvences f_i vērtībai un katram ārējās vides ietekmes faktoram x_j tiek izmantota iepriekš

iegūtā diskreto segmentētā daļējas atkarības (PDP) vērtību kopa, lai interpolētu šīs vērtības pie faktiskās ārējās vides faktora vērtības. Katram ārējās vides faktoram x_j ir definēti segmenti ar robežām c_1 un c_2 . Ja n -tais novērojums pieder segmentam s , tad tiek interpolēta daļējas atkarības diagrammas (PDP) vērtība pie $x_j(n)$ tikai šī segmenta režģa robežvērtību intervālā. Lai izvairītos no ekstrapolācijas, tiek izmantota vērtības ierobežošanas darbība, ar kuru ārējās vides faktora vērtība tiek piesaistīta segmenta režģa minimālajai vai maksimālajai vērtībai [142]:

$$x_j^{cl}(n) = \min(\max(x_j(n), \min(x_{j,s})), \max(x_{j,s})), \quad (3.27)$$

kur $x_{j,s}$ ir daļējas atkarības diagrammas (PDP) režģa x vērtības segmentā s .

Pēc tam tiek aprēķināta interpolētā daļējas atkarības diagrammas (PDP) vērtība:

$$\hat{f}_{i,j,s}^{PDP}(n) = \text{Interp}(x_{j,s}, \hat{f}_{i,j,s}(x_{j,s}), x_j^{cl}(n)), \quad (3.28)$$

kur $\text{Interp}(\cdot)$ ir apzīmē gabalu veida kubisko Hermīta interpolāciju (*PCHIP, Piecewise Cubic Hermite Interpolation Polynomial*), kas veido gludu, nepārtrauktu interpolācijas līkni un saglabā sākotnējo datu vienmērīgu izmaiņu raksturu, neieviešot mākslīgas lokālas svārstības starp režģa punktiem [143], [144].

Aprēķinu rezultātā tiek iegūta ietekmes izmaiņu matrica:

$$\Delta(n, s, j, i) = \hat{f}_{i,j,s}^{PDP}(n) - \hat{f}_{i,j,s}^{PDP}(\bar{x}_{j,s}), \quad (3.29)$$

kur $\hat{f}_{i,j,s}^{PDP}(n)$ ir interpolētā daļējas atkarības diagrammas (PDP) vērtība pie faktiskās $x_j(n)$, $\bar{x}_{j,s}$ ir segmenta režģa vidējā vērtība, $\hat{f}_{i,j,s}^{PDP}(\bar{x}_{j,s})$ ir segmenta vidējās vērtības līmeņa vērtība [122], [136].

Lielums $\Delta(n, s, j, i)$ raksturo i -tās pašsvārstību frekvences izmaiņu jeb novirzi no segmenta vidējās vērtības līmeņa, ko izraisa ārējās vides faktora x_j novirze konkrētajā novērojumā [145].

Lai noteiktu katra segmenta s un arī katra ārējās vides faktora x_j relatīvo nozīmīgumu, ārējās vides faktoru ietekmes samazināšanas metodes **7.posmā** tiek atrasts nenegatīvs ietekmes īpatsvaru vektors w_i katrai pašsvārstību frekvencei f_i . Vispirms tiek definēta daļējas atkarības diagrammas (PDP) ietekmju matrica:

$$D_i(n, p) = \Delta(n, p, i), \quad (3.30)$$

kur p ir globālais ietekmes komponentes indekss, kas apvieno konkrēto ārējās vides faktoru x_j un tā segmentu s vienotā indeksā, ļaujot visus segmentētos ārējās vides ietekmes elementus no dažādiem faktoriem apkopot vienotā ietekmju matricā un analizēt kopīgā optimizācijas līmenī [146].

No matricas D_i tiek izvēlēti tikai tie segmenti, kuros pietiekami bieži parādās nenulles ietekme:

$$\text{cov}_p = \frac{1}{N} \sum_{n=1}^N 1(|D_i(n, p)| > 0), \quad \mathcal{P} = \{p: \text{cov}_p \geq \rho\} \quad (3.31)$$

kur ρ ir minimālais pārklājums ($\rho = 0.05$) [146], [147].

Izvēlētajiem segmentiem tiek veikta robusta mērogošana [148], [149]:

$$D_i^{(s)}(:, p) = \frac{D_i(:, p)}{IQR(D_i(:, p))}. \quad (3.32)$$

Tas samazina ietekmi no segmentiem ar ļoti atšķirīgiem mērogiem [147].

Ietekmes īpatsvari tiek noteikti, risinot regularizētu nenegatīvu mazāko kvadrātu uzdevumu:

$$w_i^{(s)} = \arg \min_{w \geq 0} (\|D_i^{(s)} \cdot w - f_{c,i}\|^2 + \lambda \cdot \|w\|^2) \quad (3.33)$$

kur $w_i^{(s)}$ ietekmes īpatsvaru vektors mērogotajā telpā, λ ir Tihonova regularizācijas parametrs ($\lambda = 10^{-3}$), $f_{c,i}$ ir pašsvārstību frekvences novirze no tās vidējās vērtības.

Pašsvārstību frekvences novirze no tās vidējās vērtības tiek noteikta, izmantojot formulu:

$$f_{c,i}(n) = f_i(n) - \bar{f}_i, \quad (3.34)$$

kur $f_i(n)$ nekoriģētā i -tā pašsvārstību frekvences vērtība novērojumā n , $\bar{f}_i$ ir vidējā pašsvārstību frekvences vērtība [149], [147].

Pēc tam īpatsvari tiek “atgriezti” sākotnējā mērogā (atceļot starpkvartīlu diapazonu (*IQR*, *Interquartile Range*) mērogošanu) un ievietoti pilnā īpatsvaru vektorā w_i . Lai īpatsvari būtu interpretējami, tie tiek normalizēti [146]:

$$w_i \leftarrow \frac{w_i}{\sum_p w_i(p)}, \quad \text{ja } \sum_p w_i(p) > 0 \quad (3.35)$$

Līdz ar to visiem p ir $w_i(p) \geq 0$ un $\sum_p w_i(p) = 1$ [147].

Kopējā segmentētā ārējās vides ietekme novērojumā n tiek aprēķināta kā [147]:

$$\hat{e}_i^{PDP}(n) = \sum_p w_i(p) \cdot D_i(n, p). \quad (3.36)$$

Koriģētā pašsvārstību frekvences vērtība pēc 7.posma tiek aprēķināta pēc formulas:

$$f_{PDP}(n, i) = f(n, i) - \hat{e}_i^{PDP}(n) = f(n, i) - \sum_p w_i(p) \cdot D_i(n, p) \quad (3.37)$$

Šajā solī tiek noņemta segmentētā daļējas atkarības diagrammas (PDP) ietekme, savukārt īpatsvaru vektors w_i ļauj kvantitatīvi interpretēt, kuri segmenti un kuri ārējās vides faktori dominē pašsvārstību frekvenču izmaiņu ietekmē [108].

Lai novērtētu atlikušās nelineārās vai sarežģītas vides ietekmes, ārējās vides faktoru ietekmes samazināšanas metodes **8.posmā** uz koriģētām vērtībām $f_{PDP}(n, i)$ tiek trenēti papildus regresijas metodes (LSBoost, GPR, SVR un Bagging, (*Bootstrap Aggregating*)). LSBoost un Bagging izmanto modeļu kopu veidošanas pieeju, kas ļauj aprakstīt lokālas nelineāras sakarības un vienlaikus paaugstina prognožu stabilitāti [122]. GPR nodrošina atlikušās ietekmes modelēšanu, izmantojot varbūtības sadalījumu [123]. Savukārt SVR ir piemērota gadījumos, kad atlikušās ietekmes ir vājākas, bet saglabā sistemātisku raksturu [116]. Līdz ar to šo metožu izmantošana pēc sākotnējās korekcijas ļauj papildus samazināt ārējās vides faktoru un ekspluatācijas apstākļu ietekmi, vienlaikus samazinot pārpīlāgošanās risku [73].

Katrai metodei tiek vērtēts laika-bloku krosvalidācijas MSE [150], un tiek izvēlēts labākā metode. Tiek izvēlēts modelis ar zemāko MSE un gala korekcija tiek iegūta:

$$f_2(n, i) = f_{PDP}(n, i) - \hat{y}_{best}(n, i) \quad (3.38)$$

kur $f_{PDP}(n, i)$ ir pašsvārstību frekvences vērtība pēc segmentētās PDP ietekmes noņemšanas; $\hat{y}_{best}(n, i)$ ir labākā (ar viszemāko MSE) izvēlētais regresijas metodes prognozētā atlikušās ārējās vides ietekmes daļa attiecīgajā novērojumā n un pašsvārstību frekvencei i ; $f_2(n, i)$ ir starpposma koriģētā pašsvārstību frekvence, kuras vērtībai vairs nav segmentētā un nelineārās ārējās vides ietekme, taču joprojām saglabājas sezonālā (ilgtermiņa periodiskā) ietekme.

Šis solis nepieciešams, lai atklātu un novērstu jebkādas sarežģītas nelineāras vai periodiskas ietekmes, kas var nebūt pilnībā kompensētas ar pirmreizējo segmentēto PDP korekciju [108],[141],[151].

Nākamajā solī tiek veikta sezonālības noņemšana ar harmonisko regresiju. Sezonālās komponentes noteikšanai izmanto harmonisko regresiju ar K harmonikām. Katram i tiek noteikta dizaina matrica, izmantojot formulu:

$$Z(n) = \left[1, \sin\left(\frac{2\pi \cdot 1 \cdot d(n)}{T}\right), \cos\left(\frac{2\pi \cdot 1 \cdot d(n)}{T}\right), \dots, \sin\left(\frac{2\pi \cdot K \cdot d(n)}{T}\right), \cos\left(\frac{2\pi \cdot K \cdot d(n)}{T}\right) \right], \quad (3.39)$$

kur $d(n)$ ir attiecīgā novērojuma gada dienas numurs, K ir izmantot harmoniku skaits, T ir gada perioda ilgums dienās, kas nodrošina nepārtrauktu periodiskās komponentes aprakstu laika skalā ($T = 365.25$).

Pirmā dizaina matricas konstante raksturo pašsvārstību frekvences vidējo līmeni, savukārt sinusa un kosinusa pāri katrai harmonikai $k = 1, \dots, K$ ļauj modelēt sezonālās komponentes periodiskās svārstības ar dažādiem frekvenču komponentiem. Pirmā harmonika ($k = 1$) apraksta pamatperiodu ar viena gada ciklu, bet augstākās harmonikas ($k > 1$) ļauj modelēt sarežģītākas sezonālās formas, piemēram, asimetrisku vai vairāku maksimumu sadalījumu gada laikā [152], [153].

Sezonālā komponente tiek novērtēta ar mazāko kvadrātu metodi [152]:

$$\hat{\beta}_i = \arg \min_{\beta} \sum_n (f_2(n, i) - Z(n) \cdot \beta)^2, \quad SK(n) = Z(n) \cdot \hat{\beta}_i. \quad (3.40)$$

Tad sezonāli koriģētā pašsvārstību frekvence tiek aprēķināta, izmantojot formulu:

$$f_{corr}(n, i) = f_2(n, i) - SK(n, i) + \overline{SK(i)}, \quad (3.41)$$

kur $f_2(n, i)$ ir koriģētā pašsvārstību frekvence konkrētajā novērojuma rindā pēc ārējās vides faktoru ietekmes korekcijas; $SK(n, i)$ ir sezonālās komponentes vērtība n -tajam novērojumam un i -tajai pašsvārstību frekvencei; $\overline{SK(i)}$ ir sezonālās komponentes vidējā vērtība, kas nodrošina koriģētās pašsvārstību frekvences vidējā līmeņa saglabāšanu [149], [153].


Iegūtās frekvenču vērtības pēc sezonālās ietekmes noņemšanas vairs nesatur atkārtotas gada laika svārstības, kas uzlabo konstrukciju bojājumu noteikšanas jutību. Ja sezonālā ietekme netiek noņemta, periodiskas izmaiņas dominē atlikušajos datos, samazinot monitoringa sistēmas spēju identificēt bojājumus [154].

4. Ārējās vides faktoru ietekmes samazināšanas metodes validācija

Ārējās vides faktoru ietekmes samazināšanas metodes validācijai tika izmantoti ilgtermiņa monitoringa dati no diviem neatkarīgiem objektiem – divstāvu koka rāmja un tilta Filomena Delli Castelli. Šajā darbā tika izmantoti pētījumā [155] analogi iegūtie Tiltā Filomena Delli Castelli monitoringa dati, jo šī tilta konstrukcijām kopš pētījuma veikšanas tiek veikts nepārtraukts konstrukciju dinamisko datu monitorings. Savukārt koka rāmja konstrukcijas monitoringa dati, kas iepriekš analizēti pētījumā [156] ārējo vides apstākļu ietekmē, šajā darbā tiek atkārtoti analizēti, izmantojot izstrādāto ārējās vides faktoru ietekmes samazināšanas metodi.

4.1. Divstāvu koka rāmja monitoringa izmantoto datu apraksts

Ekspperimentālie monitoringa dati, izmantojot iepriekš izveidotu **divstāvu koka rāmi**, tika iegūti laika posmā no 2021.gada 10.novembra līdz 2022.gada 27.oktobrim. Divstāvu koka rāmja ģeometrija tika izvēlēta tā, lai pietuvinātu pētījuma objektu reālajiem apstākļiem un vidēja augstuma ēkām raksturīgiem dinamiskajiem parametriem. Koka konstrukciju divstāvu rāmja izmēri plānā ir 705x584 mm un rāmja kopējais augstums ir 1.2 metri (4.1.att.). Kā koka rāmja galvenie nesošie elementi tika izmantoti 15x15 mm koka līstes kā rāmja nesošās kolonnas un 4 mm bieza kokšķiedras plāksne kā rāmja pārseguma plātne.



4.1.att. Eksperimentālā koka rāmja modeļa shēma.

Ekspperimentā koka rāmis tika novietots 4.5 km attālumā no Baltijas jūras krasta, kas nodrošina apkārtējās vides ietekmes mainību. Rāmja modelis tika novietots 10 metru attālumā no apdzīvotas vietas piebraucamā ceļa, līdz ar to dinamisko reakciju mērījumu dati ietver arī blakus esošās satiksmes ietekmi. Ziemas periodā koka konstrukciju rāmim tika pārklāts pagaidu jumts, kas netika balstīts uz rāmja konstrukcijām, bet tikai nodrošināja, lai uz pārseguma plātnes neveidotos papildus sniega masa un neradītu frekvenču izmaiņas. Koka rāmis eksperimenta laikā tika pasargāts no tiešas vēja iedarbības, līdz ar to vējš šajā gadījumā netiek iekļauts ārējo vides ietekmes faktoru analizē.

Divstāvu koka rāmim tika veidoti konstrukciju bojājumi ar pieaugošu bojājuma pakāpi (skat. 4.1. tabulu), kas izraisa rāmja noturības un/vai masas izmaiņas. Šajā darbā ar terminu “bojājums” tiek apzīmēta jebkura apzināta konstrukcijas robežnosacījumu izmaiņa, kas tiek raksturota ar savienojumu stinguma palielināšanos vai samazināšanos un izraisa izmaiņas konstrukcijas dinamiskajos parametros. Līdz ar to termins “bojājums” netiek interpretēts tikai kā konstrukcijas degradācija, bet arī kā savienojuma stāvokļa izmaiņa. Dažādas pakāpes bojāto konstrukciju dati tika iegūti laika posmā no 2022.gada 2.septembra līdz 2022.gada 27.oktobrim.


4.1.tabula

Eksperimentālā modeļa bojājumu apraksts un pakāpe

Bojājuma datums	Bojājuma apraksts	Bojājuma pakāpe
24.09. 2022.	Visu savienojumu skrūvju pievilkšana	1
01.11.2022.	Saišu Nr.1.+Nr.2 noņemšana	2
09.11.2022.	Saišu Nr.1.+Nr.2+Nr.3 noņemšana	3
15.11.2022.	Saišu Nr.1.+Nr.2+Nr.3+Nr.4 noņemšana	4
22.11. 2022.	Saišu Nr.1.+Nr.2+Nr.3+Nr.4+Nr.5 noņemšana	5

Mērījumu noteikšanai tika izmantoti seši Dytran IEPE piezoelektriskie paātrinājuma sensori ar iebūvētu Faradeja ekranēšanu, kas nodrošina aizsardzību pret elektrostatisko troksni. Izmantotais sensoru modelis ir DY 3191A1 ar jutību 10 V/g un darbības diapazonu no -51°C līdz 121°C gaisa temperatūrā. Eksperimentam tika izmantots dinamiskais signālu pārveidotājs DT9857E ar izejas diapazonu ± 10 V. Ar sensoriem tas tika savienots ar 15 m gariem poliuretāna, 2-pin(F) signālu kabeļiem. Sensori koka rāmim tikai izvietoti trīs savienojumu stūros divos horizontālajos virzienos – x un y virzienā. Katra sensora svars ir aptuveni 800 g. Līdz ar to, lai nodrošinātu koka rāmja lielāku stabilitāti, rāmja stūros tika piestiprināta 1.6 kg papildus masa. Eksperimenta gaitā tika veikti nepārtraukti datu mērījumi ar nolasīšanas frekvenci $f_s=400$ Hz.

Meteoroloģiskie dati eksperimenta laikā tika iegūti no tuvākās meteoroloģiskās stacijas, ietverot ārējā gaisa temperatūru, relatīvo mitrumu un nokrišņu daudzumu. Eksperimenta novērojumu perioda ārējās vides ietekmes faktoru izmaiņas apkopotas laika grafikos (4.2.att.).




4.2.att. Ārējās gaisa temperatūras (°C), relatīvā mitruma (%) un nokrišņu daudzuma (mm) izmaiņas koka rāmja monitoringa periodā.

Ārējā gaisa temperatūra novērojumu periodā mainījās no aptuveni -15°C ziemas mēnešos līdz pat $+30^{\circ}\text{C}$ vasaras mēnešos. Ziemas mēnešos ārējā gaisa temperatūra saglabājas zem 0°C vai nelielos pozitīvos diapazonos, savukārt vasaras mēnešos temperatūra sasniedza maksimumu, bieži pārsniedzot $+25^{\circ}\text{C}$, ar maksimumu ap $+30^{\circ}\text{C}$. Relatīvais mitrums novērojumu periodā mainījās no 30% līdz 100% un lielākā daļu novērojumu atradās diapazonā virs 60%. Ziemas periodā relatīvais mitrums bija salīdzinoši augsts, lielākoties no 80% līdz 100% diapazonā, savukārt pavasarī mitrums bija zemāks, ar biežām svārstībām no 40% līdz 80%. Nokrišņu daudzums lielākajā daļā novērojumu periodā bija neliels, nepārsniedzot 5 mm stundā. Ziemas periodā nokrišņu daudzums bija minimāls, savukārt vasarā nokrišņi sasniedza maksimumu, īpaši jūlijā ar nokrišņu daudzumus no 20 mm līdz 25 mm stundā.

Ekspperimentā iegūtie paātrinājuma signāli tika sadalīti pa 30 minūšu porcijām. Pēc tam šīs laika rindas tika atdalītas, filtrētas frekvenču joslās un pēc tam pamatdati izmantoti īpašvērtību sistēmas realizācijas algoritmā (*ERA, Eigensystem Realization Algorithm*), lai noteiktu koka rāmja pirmās sešas svārstību formas frekvences:

- šķērsvirziena f_1 svārstību formai;
- garenvirziena f_2 svārstību formai;
- vērpes f_3 frekvenču formas pirmajai lieces un vērpes svārstību formai;
- šķērsvirziena f_4 svārstību formai;
- garenvirziena f_5 svārstību formai;
- vērpes f_6 frekvenču formas otrajai lieces un vērpes svārstību formai.

Ekspperimenta pirmo sešu pašsvārstību frekvenču izmaiņas novērojumu periodā ir apkopotas laika grafikos (4.3.att.).




4.3.att. Koka rāmja pašsvārstību frekvences $f_1 - f_6$ izmaiņas monitoringa periodā.

Pirmajām trīs - šķērsvirziena f_1 , garenvirziena f_2 , vērpes f_3 frekvenču formas pirmajai lieces un vērpes svārstību formas pašsvārstību frekvencēm ir novērojami izteikti svārstību periodi ziemas mēnešos – decembrī, janvārī un februārī. Sākot ar februāri, ir novērojama frekvenču vērtību samazināšanās un laika posmā no aprīļa līdz augustam (bojājuma Nr.1 sākuma periodam) frekvenču vērtību zonu var uzskatīt kā stabilu. Pēc konstrukciju bojājumiem visas trīs pirmās pašsvārstību frekvenču vērtības kļūst nestabilas. Grafiski lielākās izmaiņas ir novērojamas pēc konstrukciju bojājuma Nr. 5.

Otrajām trīs - šķērsvirziena f_4 , garenvirziena f_5 un vērpes f_6 frekvenču formas otrajai lieces un vērpes svārstību formai pašsvārstību frekvencēm arī ir novērojami svārstību periodi ziemas mēnešos, tomēr, salīdzinot ar pirmajām trīs pašsvārstību frekvencēm, šīs izmaiņas ziemas mēnešos nav tik izteiktas. Sākot ar februāri, ir novērojams frekvenču vērtību samazinājums un periodā no martam līdz augustam (bojājuma Nr.1 sākuma periodam) frekvenču vērtību zonu var uzskatīt kā stabilu ar mazāk izteiktām svārstībām. Augstākām frekvencēm f_5 un f_6 ir novērojamas lielākas izmaiņu amplitūdas un izteiktāki vērtību kritumi pēc konstrukciju bojājumiem, salīdzinot ar zemākām frekvencēm. Savukārt, f_4 frekvences uzrāda mazākas svārstības un pakāpenisku samazinājumu.

Lai novērtētu, vai pašsvārstību frekvenču dati atbilst normālsadalījumam, katrai frekvencei tika izveidota histogramma un aprēķināta teorētiskā normālā sadalījuma varbūtības blīvuma funkcija, izmantojot attiecīgās frekvences vidējo vērtību un standartnovirzi (4.4.att.). Histogramma ļauj grafiski attēlot datu empīrisko sadalījumu, savukārt normālā sadalījuma līkne reprezentē ideālo teorētisko modeli, ar kuru tiek salīdzināti iegūtie dati.




4.4.att. Koka rāmja pašsvārstību frekvenču f_1 – f_6 histogrammas ar normālsadalījuma varbūtības blīvuma funkciju monitoringa periodā.


Analizējot histogrammas un salīdzinot tās ar teorētisko normālā sadalījuma blīvuma līkni, var secināt, ka visu sešu pašsvārstību frekvenču datu sadalījumi būtiski atšķiras no normālsadalījuma. Datu sadalījumi vairumā gadījumu ir asimetriski un tiem ir augstāka blīvuma apgabali, kas norāda uz neviendabīgiem sadalījuma apgabaliem.

4.2. Filomena Delli Castelli tilta monitoringa izmantoto datu apraksts

Lai validētu ārējās vides faktoru ietekmes samazināšanas metodi izmantojot, inženierbūves ilgtermiņa monitoringa datus, tika izmantoti **Filomena Delli Castelli tilta** konstrukciju eksperimentāli iegūtie dinamiskie parametri. Tilts atrodas Itālijā un, šķērsojot Saline upi, savieno Montesilvano un Citta Sant'Angelo pilsētas. Monitoringa dati tika iegūti laika posmā no 2024.gada 30.septembra līdz 2025.gada 6.novembrim. Filomena Delli Castelli tilts ir tērauda-betona kompozītmateriāla daudzslāņveida vanšu tilts ar kopējo garumu 188.6 metri (4.5.att.). Kopējais tilta platums variē no 19.2 m līdz 22.8 m. Tilta nesošās konstrukcijas ir 1.2 m augstas dubult-T veida sijas, kas savienotas ar dubult-T veida šķērssijām ar mainīgu augstumu no 0.8 m līdz 1.2 m. Tilta klāju veido 25 cm bieza dzelzsbetona plātne.



4.5.att. Filomena Delli Castelli tilta konstruktīvā shēmas un galvenie izmēri: (a) sāna skats un plāna shēma [157].




4.6.att. Filomena Delli Castelli tilta konstruktīvā shēmas un galvenie izmēri: (b) A-A šķērss griezum, (c) B-B šķērss griezum un (d) pila konstrukcijas šķērss griezum [157].

Pilonu konstrukcijas sastāv no četrām slīpām tērauda caurulēm ar diametru 1.9 m un augstumu 33.45 m augšupstraumes pusē un 36.4 m lejupstraumes pusē, kurām apakšējā daļā 16 m augstumā ir aizpildīts ar betonu (4.6.att.). Katra pila pamatu konstrukcija sastāv no 2 m biezām un 9.2 m platām kvadrātveida betona plātnēm, kas savstarpēji savienotas ar 3 m platu

un 2 m augstu pamatu siju. Katra pilona pamats ir balstīts uz 35 m gariem urbtajiem pāļiem ar diametru 1.2 m. Vanšu sistēma ir veidota no 19, 25, 30 un 37 stieplu kūļiem, kur katra stieple sastāv no septiņiem cinkotiem, auksti velmēta tērauda stieplu slāņiem, kas ir pārklāti ar augsta blīvuma polietilēna (*HDPE, High-Density Polyethylene*) apvalku. Vantis pie piloniem tiek stiprinātas piecos līmeņos aptuveni 2.5 metru attālumā starp katru stiprinājumu. Savienojumā ar tilta klāju vantīm ir iestrādāti regulējami stiprinājumi, kas savienoti ar klāju ar ribotu plākšņu palīdzību, kuras ir piemetinātas pie galvenajām sijām.

Tilta konstrukciju krasta balstu kopējais augstums virs grunts ir aptuveni 5 m. Krasta balstu pamatus veido 16 urbti pāļi ar diametru 1.2 m, kas izvietoti trīs šķērsrindās. Uz pāļiem tiek balstīta taisnstūra formas 1.4 m bieza pamatu plātne ar izmēriem plānā 10.3x16.3m. Galveno siju balstiem ir izmantoti daudzvirzienu stiprinājumi, kuri spēj uzņemt negatīvās slodzes. Savukārt divu pilonu šķērssiju vidusdaļā ir izveidoti svina gumijas stiprinājumi, kas kontrolē tilta klāja horizontālos pārvietojumus un nodrošina tilta seismisko aizsardzību [157].

Ekspperimenta laikā tika noteikta ārējā gaisa temperatūra, relatīvais mitrums, vēja ātrums un vēja virziens. Novērojumu perioda ārējās vides ietekmes faktoru izmaiņas apkopotas laika grafikos (4.7.att.).




4.7.att. Ārējās gaisa temperatūras (°C), relatīvā mitruma (%), vēja ātruma (m/s) un dominējošo vēja virzienu sadalījums (°) tilta Filomena Delli Castelli monitoringa periodā.

Filomena Delli Castelli tilta monitoringa periodā ārējā gaisa temperatūra mainījās no aptuveni 0°C ziemas mēnešos līdz pat +30°C vasaras mēnešos. Ziemas mēnešos gaisa temperatūra lielāko daļu novērojuma dienu saglabājas zem +10°C, savukārt vasaras mēnešos galvenokārt pārsniedza +20°C. Relatīvais mitrums visā novērojumu periodā saglabājās galvenokārt virs 60%. Vēja ātrums novērojumu periodā mainījās no 0 līdz aptuveni 20 m/s, ar atsevišķiem kāpumiem līdz 35 m/s. Vidējais vēja ātrums novērojuma periodā bija aptuveni 6 m/s. Vēja virziena sadalījums liecina par dominējošo dienvidrietumu virzienu, kas norāda uz noturīgu vēja plūsmu monitoringa laikā.

Dinamisko parametru noteikšanai tika izmantoti 20 PCB un B&K tipa pjezoelektriskie sensori ar augstu jutību un zemu trokšņa līmeni. No tiem 16 tika izvietoti uz tilta klāja un četri tika izvietoti uz abiem dzelzsbetona piloniem vanšu enkurojuma līmenī (4.8.att.). Sensori ar koaksiālajiem kabeļiem tika savienoti gan ar četrkanālu NI 9234, gan ar trīskanālu NI 9230

svārstību ievades moduļu iekārtām, kas tika uzstādīti uz 8 kanālu NI CompactDAQ 9178 vadības bloka, kas ļāva signālus iegūt vienlaicīgi. Datu iegūšanas vadībai un datu uzglabāšanai tika izmantots portatīvais dators ar LabVIEW lietojumprogrammu [157].

Ekspérimenta laikā iegūtie svārstību paātrinājumu mērījumu dati tika nolasīti ar nolasīšanas frekvenci $f_s=100$ Hz un sadalīti pa 30 minūšu porcijām. Pēc tam šīs laika rindas tika atdalītas, filtrētas frekvenču joslās un pašsvārstību frekvenču noteikšanai tika izmantota uz kovariānci balstīta stohastiskās apakštelpas identifikācijas metode (SSI-COV).




4.8.att. Filomena Delli Castelli tilta sensoru izvietošanas shēma [157].

Tika noteiktas tilta pirmās sešas svārstību formas frekvences:

- pirmā klāja lieces f_1 svārstību formai;
- pirmā klāja vērpes f_2 svārstību formai;
- otrā klāja lieces f_3 svārstību formai;
- otrā klāja vērpes f_4 un f_5 svārstību formai;
- trešā klāja lieces f_6 svārstību formai.


Tilta pirmo sešu pašsvārstību frekvenču izmaiņas novērojumu periodā ir apkopotas laika grafikos (4.9.att.).



4.9.att. Filomena Delli Castelli tilta pašsvārstību frekvenču $f_1 - f_6$ izmaiņas monitoringa periodā.

Filomena Delli Castelli tilta pirmajām trīs pašsvārstību frekvencēm pirmā klāja lieces f_1 , pirmā klāja vērpes f_2 svārstību formai un otrā klāja lieces f_3 svārstību formai izmaiņu grafikā novērojamas nelielas sezonālās izmaiņas ar frekvenču vērtību pieaugumu ziemas mēnešos un nelielu vērtību samazinājumu vasaras mēnešos. Otrajām trīs pašsvārstību frekvencēm - otrā klāja vērpes f_4 un f_5 svārstību formai un trešā klāja lieces f_6 svārstību formai izmaiņu grafikā nav novērojami izteikti vērtību pieaugumu vai kritumu periodi, saglabājot nemainīgu vidējo frekvenču vērtību līmeni visā novērojumu periodā.

Visām sešām pašsvārstību frekvencēm redzami atsevišķi īslaicīgi frekvenču vērtību kritumi un pieaugumi, taču izteiktas īslaicīgas frekvenču vērtību izmaiņas visvairāk ir novērojamas pašsvārstību frekvencēm f_3 , f_4 un f_5 . Izteikta ilgtermiņa frekvenču vērtību pieauguma vai samazinājuma tendence nav novērojama.



4.10.att. Filomena Delli Castelli tilta pašsvārstību frekvenču f_1 – f_6 histogrammas ar normālsadalījuma varbūtības blīvuma funkciju monitoringa periodā.

Analizējot Filomena Delli Castelli tilta pašsvārstību frekvenču histogrammas un to salīdzinājumu ar teorētisko normālsadalījuma blīvuma funkciju (4.10.att.), var secināt, ka zemāko frekvenču f_1 un f_2 datu sadalījumi ir gandrīz simetriski un pietuvojas normālsadalījumam. Savukārt pašsvārstību frekvencēm no f_3 līdz f_6 novērojama izteikta datu sadalījuma asimetrija un vairāki lokāli maksimumi, kas norāda uz nevienmērīgu un no normālsadalījuma būtiski atšķirīgu datu sadalījumu monitoringa periodā.

4.3. Ārējo vides faktoru ietekmes analīze uz pašsvārstību frekvencēm

Lai noteiktu ārējo vides faktoru ietekmi, tika analizētas pašsvārstību frekvenču un katra ārējās vides ietekmes faktora sakarības, izmantojot lineāro un kvadrātisko funkciju. Tika noteikta šo funkciju piemērotība datu aprakstīšanai. Šāda regresijas funkciju izvēle ir balstīta uz regresijas modeļu sarežģītības pakāpenisku palielināšanas principu, sākot ar vienkāršākiem modeļiem, lai saglabātu rezultātu fizikālo interpretējamību un izvairītos no datu pārpilnāšanās riska [151], [158], [125].

Lineārā funkcija kalpo kā sākotnējais solis, lai pārbaudītu pieņēmumu par proporcionālu saikni starp ārējās vides faktoriem un pašsvārstību frekvencēm [159],[160]. Lai noteiktu iespējamās nelineārās sakarības, papildus lineārajai funkcijai tiek izmantota kvadrātiskā funkcija. Kvadrātiskā funkcija spēj precīzāk aprakstīt paraboliskas nelineāras sakarības, identificējot lokālus ekstrēmums vai simetriskas izmaiņas [161],[162].

Lineārā modeļa atbilstība tika noteikta, izmantojot vienādojumu:

$$f_i = ax + b, \quad (4.1)$$

kur a ir slīpuma koeficients, kas raksturo pašsvārstību frekvences izmaiņas ārējā vides faktora izmaiņu rezultātā, un b ir brīvais loceklis jeb frekvences vērtība, ja ārējās vides faktora vērtība ir nulle un x ir attiecīgais ārējās vides faktors [163]. Modelis tika aprēķināts izmantojot Matlab komandu *polyfit(x,f,1)*.

Kvadrātiskā modeļa atbilstība tika noteikta, izmantojot vienādojumu:

$$f_i = ax^2 + bx + c, \quad (4.2)$$

kur x ir attiecīgais ārējās vides faktors un a, b, c ir polinoma koeficienti. Kvadrātiskā komponente ax^2 ļauj modelim aprakstīt nelineārās izmaiņas [163]. Modelis tika aprēķināts izmantojot Matlab komandu *polyfit(x,f,2)*.

Lai novērtētu regresijas modeļu piemērotību datu aprakstīšanai un noteiktu, vai ārējās vides faktora ietekme uz pašsvārstību frekvencēm ir aprakstāma ar lineāru vai nelineāru sakarību, tika izmantota modeļu salīdzināšanas pieeja, kas balstīta uz Bajesa informācijas kritēriju (*BIC*, *Bayesian Information Criterion*) [164]. *BIC* ir relatīvs modeļu izvēles kritērijs, kas ļauj salīdzināt modeļus ar atšķirīgu parametru skaitu, ņemot vērā gan atlikumu kļūdu, gan modeļa sarežģītību. Par labāku tiek uzskatīts modelis ar mazāku *BIC* vērtību, jo tas nodrošina optimālu kompromisu starp datu aproksimācijas kvalitāti un modeļa vienkāršību [165]. Bajesa informācijas kritērijs (*BIC*) tika aprēķināts katram modelim, lai salīdzinātu lineārā un kvadrātiskā modeļa piemērotību, vienlaikus ņemot vērā gan modeļa pielāgošanās kvalitāti, gan tā sarežģītību. Bajesa informācijas kritērijs (*BIC*) tiek aprēķināts pēc izteiksmes:

$$BIC = n \cdot \ln\left(\frac{SSE}{n}\right) \cdot p \ln(n), \quad (4.3)$$

kur n ir novērojumu skaits, *SSE* (*Sum of Squared Errors*) ir atlikumu kvadrātu summa, p ir modeļa parametru skaits [165].

Atlikumu kvadrātu summa *SSE* tiek aprēķināta pēc izteiksmes:

$$SSE = \sum_{i=1}^n (f_i - \hat{f}_i)^2, \quad (4.4)$$

kur f_i eksperimentāli novērotās pašsvārstību frekvenču vērtības, $\hat{f}_i$ ir attiecīgā modeļa prognozētā pašsvārstību frekvenču vērtības [120].

Lai kvantitatīvi novērtētu atšķirību starp lineāro un kvadrātisko modeli, tika analizēta *BIC* starpība:

$$\Delta BIC = BIC_{lin} - BIC_{kvad}, \quad (4.5)$$

kur BIC_{lin} ir lineārā modeļa Bajesa informācijas kritērijs (*BIC*), BIC_{kvad} ir kvadrātiskā modeļa Bajesa informācijas kritērijs (*BIC*). Pozitīva ΔBIC vērtība norāda uz kvadrātiskā


(nelineārā) modeļa piemērotību, savukārt negatīva – uz lineārā modeļa piemērotību datu aprakstīšanai [166].

Regresijas modeļu pielāgošanās kvalitātes raksturošanai tika izmantots koriģētais determinācijas koeficients ($Adj R^2$, *Adjusted Coefficient of Determination*), kas tiek aprēķināts pēc izteiksmes:

$$Adj R^2 = 1 - (1 - R^2) \frac{n - 1}{n - p - 1}, \quad (4.6)$$

kur n ir novērojumu skaits un p ir regresijas modeļa neatkarīgo skaits [167]. Augstāka $Adj R^2$ vērtība norāda uz labāku pielāgošanos, kas liecina par spēcīgāku sakarību starp ārējās vides parametru un pašsvārstību frekvenci [120].


Koka rāmja gadījumā tika analizētas pašsvārstību frekvenču un ārējās gaisa temperatūras, relatīvā mitruma un nokrišņu daudzuma sakarības. Katras pašsvārstību frekvences un attiecīgā ārējā vides ietekmes faktora sakarības kopā ar statistiskajiem novērtēšanas rādītājiem ir attēlotas grafikos (4.11.att., 4.12.att., 4.13.att.).



4.11.att. Koka rāmja monitoringa perioda ārējās gaisa temperatūras un pašsvārstību frekvenču sakarības.


Koka rāmja pašsvārstību frekvenču un ārējās gaisa temperatūras sakarības grafiki (4.11.att.) parāda, ka frekvenču vērtības samazinās, pieaugot ārējai gaisa temperatūrai. Lineārais modelis atspoguļo vispārējo tendenci un modelim ir vidēji augstas koriģētā determinācijas koeficienta $Adj R^2$ vērtības, kas liecina par būtisku, taču vienkāršotu sakarības aprakstu. Tomēr visos gadījumos kvadrātiskais modelis nodrošina zemāku Bajesa informācijas kritērija (BIC) vērtību. Tas norāda, ka nelineārais modelis sniedz statistiski pamatotu uzlabojumu datu aprakstā.

Lai gan koriģētā determinācijas koeficienta $Adj R^2$ vērtības pieaugums, salīdzinot ar lineāro modeli, ir salīdzinoši neliels, lielās ΔBIC vērtības norāda, ka pašsvārstību frekvenču atkarība no ārējās gaisa temperatūras nav pilnībā aprakstāma ar lineāru sakarību.



4.12.att. Koka rāmja monitoringa perioda relatīvā mitruma un pašsvārstību frekvenču sakarības.

Koka rāmja pašsvārstību frekvenču un relatīvā mitruma sakarības grafiki (4.12.att.) parāda, ka pašsvārstību frekvences pieaug, palielinoties relatīvā mitruma vērtībām. Lineārais modelis pietiekami precīzi apraksta vispārējo tendenci, taču koriģētā determinācijas koeficienta $Adj R^2$ vērtības ir salīdzinoši zemas. Tas liecina, ka sakarība starp relatīvo mitrumu un pašsvārstību frekvencēm nav pilnībā aprakstāma ar lineāro modeli. Kvadrātiskais modelis visos gadījumos nodrošina zemāku Bajesa informācijas kritērija (BIC) vērtību un tas norāda uz statistiski pamatotu nelineārā modeļa priekšrocību.



4.13.att. Koka rāmja monitoringa perioda nokrišņu daudzuma un pašsvārstību frekvenču sakarības.

Koka rāmja pašsvārstību frekvenču un nokrišņu daudzuma sakarības grafiki (4.13.att.) liecina, ka starp nokrišņu daudzumu un pašsvārstību frekvencēm nav novērojama būtiska statistiska sakarība visā analizētajā frekvenču diapazonā. To apstiprina ļoti zemās koriģētā determinācijas koeficienta $Adj R^2$ vērtības, kas abiem modeļiem ir nulle. Bajesa informācijas kritērija analīze norāda, ka ΔBIC vērtības ir nelielas un vairumā gadījumu nespēj pamatot nelineārā modeļa priekšrocību, kas apliecina, ka sarežģītāka kvadrātiskā modeļa izmantošana nav statistiski pamatota.


Filomena Delli Castelli tilta gadījumā tika analizētas pašsvārstību frekvenču un ārējās gaisa temperatūras, relatīvā mitruma un vēja ātruma sakarības. Katras pašsvārstību frekvences un attiecīgā ārējā vides ietekmes faktora sakarības ir attēlotas grafikos (4.14.att., 4.15.att., 4.16.att., 4.17.att.).

Vēja ātruma ietekmes analīzē uz pašsvārstību frekvencēm papildus tiek ņemta vērā vēja virziena ietekme attiecībā pret būves orientāciju [168],[169],[170]. Turpmākajā analīzē vēja ātrums tiek sadalīts divās komponentēs – garenvirziena komponentē V_g un šķērsvirziena komponentē V_{sk} , kas atbilst vēja projekcijām paralēli un perpendikulāri tilta garenasij [169].

Vēja komponentes tiek aprēķinātas, izmantojot sakarības:

$$V_g = V \cdot \cos(\Delta\theta) \text{ un } V_{sk} = V \cdot \sin(\Delta\theta), \quad (4.7)$$


kur V ir vēja ātrums attiecīgajā novērojumu brīdī, $\Delta\theta$ ir relatīvais leņķis starp vēja plūsmas virzienu un tilta garenass virzienu. Relatīvais leņķis tiek noteikts kā starpība starp meteoroloģiski noteikto vēja virzienu un tilta garenass orientācijas leņķi, kas Filomena Delli Castelli tilta gadījumā ir 102° . Garenvirziena komponente V_g raksturo vēja iedarbību paralēli tilta garenasij, savukārt šķērsvirziena komponente V_{sk} raksturo vēja iedarbību perpendikulāri tilta garenasij [170].



4.14.att. Filomena Delli Castelli tilta monitoringa perioda ārējās gaisa temperatūras un pašsvārstību frekvenču sakarības.


Filomena Delli Castelli tilta pašsvārstību frekvenču un ārējās gaisa temperatūras sakarības grafiki (4.14.att.) parāda, ka pieaugot ārējai gaisa temperatūrai pašsvārstību frekvenču vērtības samazinās. Lineārais modelis kopumā atspoguļo frekvenču samazināšanās virzienu, taču koriģētā determinācijas koeficienta $Adj R^2$ vērtības lielākajai daļai pašsvārstību frekvenču ir zemas, kas norāda uz ierobežotu spēju pielāgoties datiem. Kvadrātiskais modelis atsevišķos gadījumos nodrošina nedaudz augstāku $Adj R^2$ vērtību un zemāku Bajesa informācijas kritēriju (BIC) vērtību, ko apstiprina pozitīvas ΔBIC vērtības. Tas norāda, ka dažos ārējās gaisa temperatūras diapazonos pašsvārstību frekvenču izmaiņas nav pilnībā aprakstāmas ar lineāru sakarību.

Vairākām pašsvārstību frekvencēm ΔBIC vērtības ir nelielas vai negatīvas, kas liecina, ka sarežģītāka nelineārā modeļa priekšrocība nav statistiski pamatota visā attiecīgo frekvenču vērtību diapazonā. Kopumā iegūtie rezultāti norāda, ka ārējās gaisa temperatūras ietekme uz tilta pašsvārstību frekvencēm ir vājāka un mazāk izteikta salīdzinot ar koka rāmja datiem, un nelineārā modeļa izmantošana ir nozīmīga tikai atsevišķām pašsvārstību frekvencēm.




4.15.att. Filomena Delli Castelli tilta monitoringa perioda relatīvā mitruma un pašsvārstību frekvenču sakarības.

Filomena Delli Castelli tilta pašsvārstību frekvenču un relatīvā mitruma sakarības grafiki (4.15.att.) parāda, ka palielinoties relatīvā mitruma līmenim, frekvenču pieaugums ir ļoti minimāls. Novērojumu punktu izkliede ir salīdzinoši liela, savukārt regresijas modeļu līkņu slīpums ir mazs, kas norāda uz vāju statistisku sakarību starp pašsvārstību frekvencēm un relatīvo mitrumu. Lineārais regresijas modelis spēj raksturot vispārējo tendenci, tomēr zemas koriģētā determinācijas koeficienta $Adj R^2$ vērtības liecina par ierobežotu regresijas modeļa spēju pielāgoties datiem. Kvadrātiskā modeļa piemērošana tikai atsevišķos gadījumos nodrošina nedaudz zemākas Bajesa informācijas kritērija (BIC) vērtības, ko apstiprina pozitīvas, taču nelielas ΔBIC vērtības, norādot, ka sarežģītāks modelis būtiski neuzlabo relatīvā mitruma un pašsvārstību frekvenču vērtību izmaiņu sakarību.



4.16.att. Filomena Delli Castelli tilta monitoringa perioda vēja garenvirziena komponentes V_g un pašsvārstību frekvenču sakarības.

Filomena Delli Castelli tilta pašsvārstību frekvenču un vēja garenvirziena komponentes V_g sakarības grafiki (4.16.att.) parāda, ka mainoties vēja garenvirziena komponentes vērtībām, pašsvārstību frekvenču izmaiņas ir nelielas un kopējā sakarības tendence ir vāji izteikta.



4.17.att. Filomena Delli Castelli tilta monitoringa perioda vēja šķērsvirziena komponentes V_{sk} un pašsvārstību frekvenču sakarības.


Filomena Delli Castelli tilta pašsvārstību frekvenču un vēja garenvirziena komponentes V_{sk} sakarības grafiki (4.17.att.) parāda, ka mainoties vēja šķērsvirziena komponentes vērtībām, pašsvārstību frekvenču vērtību izmaiņas ir nelielas. Lineārais modelis vairumā gadījumu raksturo nelielu pašsvārstību frekvenču samazināšanos vai gandrīz nemainīgu izmaiņu tendenci, savukārt kvadrātiskā modeļa piemērošana atsevišķos gadījumos nodrošina tikai nelielu uzlabojumu un kopumā būtiski neuzlabo pielāgošanos datiem.

Analizējot kopumā koka rāmja un Filomena Delli Castelli tilta pašsvārstību frekvenču sakarības ar ārējās vides faktoriem, var secināt, ka ārējo vides faktoru ietekme uz pašsvārstību frekvenču vērtībām var būt gan vāji, gan izteikti nelineāra. Iegūtie rezultāti apliecina, ka vienkāršots lineārs pieņēmums nav pietiekams, lai precīzi novērtētu ārējās vides faktoru izraisītās pašsvārstību frekvenču vērtību izmaiņas. Līdz ar to, lai precīzi identificētu konstrukciju bojājumus ārējo vides apstākļu ietekmē, ir nepieciešams izmantot nelineārus modeļus.

4.4. Ārējo vides ietekmes faktoru un pašsvārstību frekvenču savstarpējā korelācija

Analizējot ārējās vides faktoru ietekmi uz konstrukciju dinamiskajām īpašībām, ir svarīgi izvērtēt ne tikai katra faktora individuālo ietekmi, bet arī šo faktoru savstarpējo korelāciju, kā arī pašsvārstību frekvenču savstarpējās korelācijas. Ja starp faktoriem pastāv būtiska savstarpējā korelācija, tad katra faktora atsevišķā ietekme var tikt neprecīzi interpretēta, jo faktori var ietekmēt pašsvārstību frekvences kombinētā veidā. Savukārt, augsta savstarpējā korelācija starp pašsvārstību frekvencēm norāda, ka tās līdzīgi reaģē uz ārējās vides apstākļu izmaiņām un ka viena faktora ietekme var vienlaikus radīt līdzīgas izmaiņas vairākās frekvencēs. Zema korelācija norāda, ka dažādas frekvences reaģē neatkarīgi vai atšķirīgi, kas var būt svarīgi konstrukcijas dinamikas analīzē un tās izmaiņu interpretācijā [108].

Lai novērtētu ārējo vides faktoru un pašsvārstību frekvenču savstarpējo lineāro korelāciju, tika aprēķināti Pīrsona lineārie korelācijas koeficienti gan koka rāmja gadījumā, gan Filomena Delli Castelli tilta gadījumā (4.18.att., 4.19.att.). Pīrsona lineāro koeficientu vērtības tuvu nullei norāda uz vāju lineāru sakarību, savukārt vērtības tuvu viens liecina par spēcīgu lineāru sakarību [171].



4.18.att. Koka rāmja pašsvārstību frekvenču un ārējo vides ietekmes faktoru savstarpējie Pīrsona lineārie korelācijas koeficienti (1 – ārējā gaisa temperatūra, 2 – relatīvais mitrums, 3 – nokrišņu daudzums).

1	1.00	-0.39	-0.36	0.20	-0.80	-0.52	-0.38	-0.17	-0.22	-0.20
2	-0.39	1.00	0.21	-0.08	0.44	0.35	0.22	0.08	0.13	0.11
3	-0.36	0.21	1.00	-0.39	0.41	0.36	0.19	0.10	0.15	0.12
4	0.20	-0.08	-0.39	1.00	-0.29	-0.27	-0.15	-0.08	-0.12	-0.14
f1	-0.80	0.44	0.41	-0.29	1.00	0.77	0.51	0.29	0.29	0.25
f2	-0.52	0.35	0.36	-0.27	0.77	1.00	0.72	0.44	0.37	0.25
f3	-0.38	0.22	0.19	-0.15	0.51	0.72	1.00	0.71	0.49	0.28
f4	-0.17	0.08	0.10	-0.08	0.29	0.44	0.71	1.00	0.63	0.49
f5	-0.22	0.13	0.15	-0.12	0.29	0.37	0.49	0.63	1.00	0.73
f6	-0.20	0.11	0.12	-0.14	0.25	0.25	0.28	0.49	0.73	1.00
	1	2	3	4	f1	f2	f3	f4	f5	f6

4.19.att. Filomena Delli Castelli tilta pašsvārstību frekvenču un ārējo vides ietekmes faktoru savstarpējie Pīrsona lineārie korelācijas koeficienti (1 – ārējā gaisa temperatūra, 2 – relatīvais mitrums, 3 – vēja garenvirziena komponente V_g , 4 – vēja šķērsvirziena komponente V_{sk})

Koka rāmja gadījumā (4.18.att.) pastāv ļoti augstas savstarpējās korelācijas vērtības starp visām pašsvārstību frekvencēm. Visaugstākā korelācija novērojama starp zemākajām pašsvārstību frekvencēm f1, f2 un f3. Savukārt starp zemākajām un augstākajām pašsvārstību frekvencēm vērojama nedaudz zemāka, tomēr joprojām spēcīga korelācija. Šāda saistība norāda, ka konstrukcijas zemākās un augstākās pašsvārstību frekvences kopumā reaģē līdzīgi, bet ietekmes var atšķirties atkarībā no ārējās vides faktoriem. Augstas korelācijas vērtības starp visām pašsvārstību frekvencēm apstiprina to, ka ārējās vides faktori, kas ietekmē vienu no pašsvārstību frekvencēm, līdzīgā veidā vienlaicīgi ietekmē arī pārējās pašsvārstību frekvences.

Filomena Delli Castelli tilta gadījumā (4.19.att.) frekvenču savstarpējā korelācija ir zemāka nekā koka rāmja gadījumā. Zemākajām pašsvārstību frekvencēm f1, f2 un f3 savstarpējā korelācija ir augstāka, bet starp zemākajām un augstākajām frekvencēm savstarpējā korelācija ir mērena vai vāja. Tilta gadījumā ārējās vides faktoru ietekme uz katru pašsvārstību frekvenci var būt atšķirīga.

Analizējot ārējās vides faktoru savstarpējās lineārās korelācijas, var secināt, ka gan koka rāmja, gan tilta gadījumā spēcīgākā negatīvā korelācija novērojama starp ārējo gaisa temperatūru un relatīvo mitrumu. Tas nozīmē, ka pieaugot ārējai gaisa temperatūrai, relatīvais mitrums parasti samazinās.

Koka rāmja gadījumā (4.18.att.) vāja korelācija ir starp nokrišņu daudzumu un visiem pārējiem faktoriem, kas norāda, ka nokrišņu daudzums ir neatkarīgs faktors un tā izmaiņas nav cieši saistītas ar ārējo gaisa temperatūru un relatīvo mitrumu.

Filomena Delli Castelli tilta gadījumā (4.19.att.) novērojama negatīvā korelācija starp relatīvo mitrumu un vēja ātruma komponentēm. Savukārt starp ārējo gaisa temperatūru un vēja garenvirziena komponenti V_g un vēja šķērsvirziena komponenti V_{sk} ir vāja pozitīva korelācija, kas liecina par nelielu savstarpēju saistību.

Ārējo vides ietekmes faktoru savstarpējās korelācijas matrica apstiprina, ka starp dažiem vides faktoriem pastāv mērenas korelācijas, tomēr vairumā faktoru ietekme ir savstarpēji neatkarīga vai vāji saistīta. Tas norāda, ka katra faktora ietekmi uz konstrukciju dinamiskajām īpašībām var analizēt individuāli, ņemot vērā, ka spēcīgas savstarpējās mijiedarbības nav novērojamas.

4.5. Ārējo vides faktoru nelineārās ietekmes salīdzinājums

Ārējo vides ietekmes faktoru un pašsvārstību frekvenču sakarību grafiski parādīja, ka frekvenču izmaiņas šo faktoru ietekmē ir nelineāras un atkarībā no faktora rakstura novērojams gan frekvenču pieaugums, gan samazinājums ar atšķirīgu ietekmes intensitāti dažādos diapazonos. Lai analizētu dažādu ārējās vides faktoru ietekmi uz pašsvārstību frekvencēm, tika izmantoti trīs algoritmi: XGBoost algoritms, Gausa procesa regresijas (GPR) un gadījuma meža regresijas algoritms (RF). Šo algoritmu izvēle balstīta uz to spēju modelēt sarežģītas nelineāras un nehomogēnas sakarības starp ārējās vides faktoriem un konstrukciju pašsvārstību frekvencēm, vienlaikus nodrošinot augstu vispārināšanas spēju un samazinātu pārpilnāšanās risku [119],[172],[123]. Regularizācijas mehānismi XGBoost struktūrā nodrošina efektīvu trokšņa ietekmes samazinājumu ilgtermiņa monitoringa datos, saglabājot modeļa stabilitāti ārējās vides faktoru lielas mainības apstākļos [173]. Šis algoritms nodrošina iespēju noteikt un kvantitatīvi raksturot atsevišķu ievades mainīgo ietekmi uz mērķa funkciju, kas ir būtiski konstrukciju tehniskā stāvokļa novērtēšanā un dominējošo ārējās vides faktoru ietekmes noteikšanā [174]. RF algoritms ir piemērots sarežģītu un nelineāru sakarību modelēšanai starp ievades un mērķa mainīgajiem, jo tas spēj efektīvi apstrādāt augstas dimensijas datu kopas un būtiski samazina pārpilnāšanās risku [119]. GPR algoritms ir piemērots nepārtrauktu un nelineāru sakarību modelēšanai starp mainīgajiem, nodrošinot augstu prognožu precizitāti un prognožu nenoteiktības kvantitatīvu novērtējumu [123].

Visu modeļu apmācībai un iegūto rezultātu izvērtēšanai tika izmantota k -kārtas krosvalidācija ar parametra vērtību $k = 5$, kuras ietvaros sākotnējais datu kopums tika sadalīts piecās apakškopās. Katrā iterācijā viena apakškopa tika izmantota testēšanai, savukārt pārējās četras apakškopas tika izmantotas modeļa apmācībai. Līdz ar to netiek izdalīta atsevišķa testēšanas kopa, vienlaikus samazinot novērtējuma rezultātu izkliedi ilgtermiņa monitoringa datu analizē. Parametra vērtība $k = 5$ tiek pamatota ar nepieciešamību nodrošināt pietiekamu apmācības datu apjomu katrā iterācijā, saglabājot stabilu un izticamu modeļu vispārināšanas spējas novērtējumu [175], [176], [177].

Ārējo vides faktoru ietekmes analīzes rezultāti tika apkopoti kopējā izmaiņu grafikā, kur katram ārējās vides faktoram ir norādīta kopējā ietekme uz pašsvārstību frekvenču vērtībām. Kopējā faktora ietekme $\Delta \hat{f}_i$ tiek aprēķināta, izmantojot formulu [178], [123]:

$$\Delta \hat{f}_i = \hat{f}_i^{\max} - \hat{f}_i^{\min}, \quad (4.8)$$

kur $\hat{f}_i^{\max}$ ir prognozētā vērtība, kad x_j ir maksimāls; $\hat{f}_i^{\min}$ ir prognozētā vērtība, kad x_j ir minimāls; i ir konkrētās pašsvārstību frekvences indekss (no f_1 līdz f_6); j ir konkrētā ārējās vides faktora indekss; $\hat{f}$ ir regresijas modeļa prognozētā pašsvārstību frekvences vērtība, kas tiek aprēķināta, mainot tikai vienu konkrēto ārējo vides faktoru x_j , fiksējot pārējos faktorus to vidējās vērtībās. Rezultāti tika apkopoti ietekmes matricā:

$$M = [\Delta \hat{f}_{ij}]_{i=1,\dots,6; j=1,\dots,3} \quad (4.9)$$

kur $\Delta \hat{f}_{ij} = \hat{f}_i^{\max}(x_j) - \hat{f}_i^{\min}(x_j)$ apzīmē prognozētās i -tās pašsvārstību frekvences izmaiņu j -tā ārējās vides faktora ietekmē; $M \in \mathbb{R}^{6 \times 3}$ sniedz kvantitatīvu novērtējumu par katra ārējās vides faktora ietekmes lielumu uz katru pašsvārstību frekvenci.

Kopējās izmaiņas norāda, cik ļoti mainās pašsvārstību frekvences absolūtā vērtība, kad ārējās vides faktors mainās visā tā diapazonā. Kopējās ietekmes izmaiņu zīme norāda vai konkrētais ārējās vides ietekmes faktors palielina (pozitīva zīme) vai samazina (negatīva zīme) attiecīgo pašsvārstības frekvences vērtību.

Lai nodrošinātu dažādu pašsvārstību frekvenču savstarpēju salīdzināmību, papildus tika analizēta arī relatīvā kopējā ietekme, kas raksturo absolūtās izmaiņas īpatsvaru attiecībā pret attiecīgās pašsvārstību frekvences vidējo vērtību. Relatīvā ietekme tika aprēķināta izmantojot formulu [25]:

$$\Delta \hat{f}_{ij}^{rel} = \frac{\Delta \hat{f}_{ij}}{\bar{f}_i} \cdot 100\%, \quad (4.10)$$

kur $\bar{f}_i$ ir i –tās pašsvārstību frekvences vidējā vērtība analizētajā laika periodā.

Relatīvās ietekmes analīze ļauj kvantitatīvi salīdzināt ārējās vides faktoru ietekmi uz dažādām pašsvārstību frekvencēm, nosakot katras pašsvārstību frekvences relatīvās izmaiņas apjomu attiecīgā ārējā vides faktora ietekmē.

Ārējo vides faktoru ietekmes novērtēšanai ar **XGBoost metodi** tiek izmantota Matlab komanda *fitrensemble*, kas veido regresijas modeli, balstoties uz Mazāko kvadrātu palielināšanas (LSBoost) algoritmu. Lai nodrošinātu precīzāku modelēšanu, tiek veikta hiperparametru optimizācija, nevis izmantoti fiksēti parametri. Optimizējamie parametri ietver:

- mācību ciklu skaitu (E);
- mācīšanās ātrumu η ;
- maksimālo sadalījuma skaitu;
- minimālo lapu izmēru.

Hiperparametru optimizācija tiek veikta, izmantojot iegūšanas funkciju *AcquisitionFunctionName*, kas palīdz minimizēt kļūdas un novērst pārpriekšlāgošanos [179]. Modelis tiek apmācīts, iteratīvi koriģējot kļūdas katrā iterācijā. Pēc E iterācijām gala prognoze tiek aprēķināta kā visu iterāciju laikā izveidoto lēmumu koku svērtā summa pēc 3.15. formulas [125].

Ārējo vides faktoru ietekmes novērtēšanā, izmantojot **RF metodi**, prognozētās pašsvārstību frekvences tiek noteiktas kā visu koku prognožu vidējā vērtība [180], [181]. Katram pašsvārstību frekvenču mērķim – no f_1 līdz f_6 tiek trenēts atsevišķs RF modelis ar apkopošanas metodi, kas sastāv no optimizēta lēmumu koku skaita. Hiperparametri tiek optimizēti, izmantojot Matlab *fitrensemble* komandu, kurā tiek noteikti sekojoši parametri:

- lēmumu koku skaits (T);
- minimālais lapu skaits;
- mainīgo skaits, ko izmantot katrā dalīšanas solī.


Ārējo vides faktoru ietekmes novērtēšanā, izmantojot **GPR metodi** tiek modelēta funkcija $\hat{f}(x)$, kas apraksta pašsvārstību frekvenču atkarību no ārējās vides faktoriem, pieņemot, ka šī funkcija tiek modelēta kā Gausa process atbilstoši 3.18. formulai. Katrai pašsvārstību frekvencei tiek izveidots GPR modelis, izmantojot Matlab komandu *fitrgp* ar automātisku hiperparametru pielāgošanu, kas optimizē:

- garuma mērogu ℓ ;

- trokšņa variācijas parametra vērtību;
- deterministiskās bāzes funkcijas veidu, izvēloties starp konstanto, lineāro vai kvadrātisko [182].

Kodolfunkcija tiek izmantota, lai aprakstītu punktu līdzību. Tiek izmantota Matern 5/2 kodolfunkcija. Šī kodolfunkcija nodrošina modelētās funkcijas gluduma pakāpi, kas atbilst konstrukciju pašsvārstību frekvenču pakāpeniskai mainībai ārējo vides faktoru ietekmē. Tā ir mazāk pakļauta pārsvārstības riskam, līdz ar to uzlabojot modeļa stabilitāti un vispārināšanas spēju ilgtermiņa monitoringa datos [123], [183],[184]. Modeļa apmācība un hiperparametru optimizācija tiek veikta netieši, minimizējot negatīvo logaritmiskās ticamības funkciju (*NLL*, *Negative Log-Likelihood*), kas Gausa procesa regresijas gadījumā raksturo novēroto pašsvārstību frekvenču vektoru atbilstību pieņemtajam varbūtības sadalījumam [123].


Koka rāmja gadījumā tika analizēta ārējās gaisa temperatūras un relatīvā mitruma ietekme uz visām sešām pašsvārstību frekvencēm.



4.20.att. Ārējās vides faktoru ietekme uz koka rāmja pašsvārstību frekvencēm, izmantojot XGBoost metodi (a), gadījuma meža regresijas metodi (RF) (b), Gausa procesa regresijas metodi (c) (1 - ārējā gaisa temperatūra (°C), 2 – relatīvais mitrums (%)).

Analizējot ārējās vides faktoru absolūto un relatīvo ietekmi uz koka rāmja pašsvārstību frekvencēm, izmantojot trīs dažādas metodes (4.20.att.), iegūtie rezultāti liecina par līdzīgām vispārējām tendencēm. Absolūtās ietekmes analizē ārējā gaisa temperatūra visās metodēs uzrāda vislielāko negatīvo ietekmi uz pašsvārstību frekvencēm, kas norāda uz frekvenču samazināšanos, pieaugot ārējai gaisa temperatūrai. Relatīvās mitrums visās metodēs uzrāda mērenu pozitīvu absolūto ietekmi uz pašsvārstību frekvencēm. Relatīvās ietekmes analīze gan ārējās gaisa temperatūras, gan relatīvā mitruma gadījumā norāda, ka ietekmes vērtības starp atsevišķām pašsvārstību frekvencēm ir līdzīgas un neuzrāda būtiskas atšķirības.

Filomena Delli Castelli tilta gadījumā arī tika analizēta ārējās gaisa temperatūras, relatīvā mitruma, vēja garenvirziena un šķērsvirziena komponentu ietekme uz visām sešām pašsvārstību frekvencēm.



4.21.att. Ārējās vides faktoru ietekme uz Filomena Delli Castelli tilta pašsvārstību frekvencēm, izmantojot XGBoost metodi (a), gadījuma meža regresijas metodi (RF) (b), Gausa procesa regresijas metodi (c) (1 - ārējā gaisa temperatūra ($^{\circ}\text{C}$), 2 - relatīvais mitrums (%), 3 - vēja garenvirziena komponente V_g , (m/s), 4 - vēja šķērsvirziena komponente V_{sk} (m/s)).

Analizējot ārējās vides faktoru kopējo ietekmi uz tilta pašsvārstību frekvencēm, izmantojot XGBoost, RF un GPR regresijas metodes (4.21.att.), iegūtie rezultāti uzrāda, ka visās trīs metodēs izteiktākā ietekme uz tilta pašsvārstību frekvencēm ir ārējai gaisa temperatūrai, kas rada negatīvu kopējo ietekmi visām analizētajām frekvencēm. Relatīvais mitrums pašsvārstību frekvenču vērtības ietekmē mērenāk, un tā ietekmes tendence atšķiras starp dažādām metodēm atsevišķām analizētajām frekvencēm. Vēja garenvirziena komponentes V_g ietekmes analīze vairumā gadījumu uzrāda nelielu pozitīvu ietekmi uz pašsvārstību frekvencēm. Savukārt vēja šķērsvirziena komponentei V_{sk} raksturīga izteiktāka negatīvā ietekme, īpaši augstāko frekvenču f_4 , f_5 un f_6 gadījumā.

4.6. Konstrukciju bojājumu noteikšanas algoritmu rezultāti pirms ārējā vides ietekmes samazināšanas metodes piemērošanas

Lai analizētu **koka rāmja** konstrukciju pašsvārstību frekvenču izmaiņu raksturu daudzzimensiju telpā un novērtētu novirzes no konstrukcijas nebojātā stāvokļa, tika izmantotas četras metodes – Mahalanobisa distances algoritms, galveno komponentu analīze (*PCA, Principal Component Analysis*), vienklares atbalsta vektora (*OC-SVM, One-Class Support Vector Machine*) analīze un Gausa jauktā modeļa (*GMM, Gaussian Mixture Model*) noviržu analīze. Katra metode darbojas, izmantojot atšķirīgu noviržu noteikšanas principu un ļauj identificēt konstrukcijas pašsvārstību frekvenču izmaiņas, novērtējot to attālumu, projekciju, robežvērtību vai sadalījuma atšķirības no nebojātā stāvokļa datu kopas [185].

Algoritmu darbības sākumā gan bojātās, gan nebojātās konstrukcijas dati tiek apvienoti vienā datu kopā, kurā katrs novērojums satur sešas pašsvārstību frekvences. Lai nodrošinātu datu salīdzināmību, visas apvienotajā datu kopā esošās pašsvārstību frekvenču vērtības tiek normalizētas, izmantojot robusto normalizācijas metodi, kas balstīta uz mediānu un interkvartīļu diapazonu (IQR). Šī metode tiek izvēlēta, jo pašsvārstību frekvenču datiem nav izteikts normālsadalījums un datu kopā iespējami atsevišķi novirzes punkti.

Normalizācija tiek veikta, izmantojot formulu:

$$Z_i^{(rob)} = \frac{f_i - \text{median}(f_i)}{IQR}, \quad (4.11)$$

kur f_i ir sākotnējā pašsvārstību frekvences vērtība, $\text{median}(f_i)$ – attiecīgās pašsvārstību frekvences mediāna; $IQR = Q_3 - Q_1$ ir starpkvartīļu diapazons, kas raksturo datu izkliedi starp pirmo un trešo kvartīli. Normalizētās frekvences raksturo cik starpkvartīļu apgabalu attālumā konkrētā frekvence atrodas no tās mediānas [186], [187].

Lai noteiktu nebojātā stāvokļa datu sadalījumu, tiek aprēķināts vidējais vektors μ visām pašsvārstību frekvencēm pēc formulas:

$$\mu = \frac{1}{N} \sum_{i=1}^N F_i, \quad (4.12)$$

kur N ir kopējais novērojumu skaits; F_i ir individuālais pašsvārstību frekvenču vektors katram novērojumam [108].

Lai noteiktu frekvenču savstarpējās sakarības, atsevišķiem algoritmiem tiek aprēķināta kovariances matrica pēc formulas [188]:

$$S = \frac{1}{N-1} \sum_{i=1}^N (F_i - \mu)(F_i - \mu)^T \quad (4.13)$$

Kovariances matrica S raksturo, kā frekvences kopīgi mainās laikā, un ļauj ņemt vērā to savstarpējo korelāciju, nevis analizēt katru pašsvārstību frekvenci atsevišķi. Ja frekvences sistemātiski pieaug vai samazinās vienlaicīgi, tad šīs sakarības tiek tieši atspoguļotas kovariances matricā.

4.6.1. Mahalanobisa distances algoritms

Mahalanobisa distances algoritms ir neuzraudzītās mašīnmācīšanās anomāliju noteikšanas metode, kas ļauj novērtēt katra novērojuma attālumu no nebojātā stāvokļa datu kopas daudzdimensiju telpā, ņemot vērā analizēto parametru savstarpējās korelācijas un dispersijas raksturu. Metode ļauj daudzdimensiju datu telpu samazināt līdz vienam skaitlim jeb noviržu indeksam, kas raksturo katra novērojuma distanci no nebojātā stāvokļa. Augstāka distances vērtība norāda uz lielāku neatbilstību konstrukcijas nebojātā stāvokļu datu kopai un norāda uz potenciālu konstrukciju bojājumu [36], [185]. Mahalanobisa distances algoritms ņem vērā pašsvārstību frekvenču savstarpējo korelāciju, līdz ar to nodrošinot precīzāku anomāliju noteikšanu daudzdimensiju datu struktūrā. Algoritms ļauj veikt anomāliju noteikšanu bez bojājumu marķējumiem, balstoties tikai uz nebojātā stāvokļa datu statistiku [151]. Anomāliju analīze, izmantojot Mahalanobisa distanci, tiek plaši izmantota konstrukciju tehniskā stāvokļa monitoringā, piemēram, plaisu veidošanās un attīstības novērtēšanai dzelzsbetona konstrukcijās [189], kā arī tiltu un ēku nesošo konstrukciju ilgtermiņa monitoringā [190], [191].

Mahalanobisa distances algoritma sākumā tiek noteikts nebojātā stāvokļa bojājumu jutīgo pazīmju vidējais vektors μ un kovariances matrica S . Pēc šo lielumu iegūšanas tiek aprēķināta Mahalanobisa distance visiem datu punktiem. Šī distance novērtē, cik lielā mērā konkrētais novērojums atšķiras no nebojātā stāvokļa datu sadalījuma, un to aprēķina pēc formulas [192]:

$$D_M^2 = (F_i - \mu)^T S^{-1} (F_i - \mu), \quad (4.14)$$

kur S^{-1} ir inversā kovariances matrica.

Aprēķinātā vērtība tiek invertēta ar mīnus zīmi, lai iegūtu interpretāciju, kur lielākas Mahalanobisa distances vērtības nozīmē lielāku novirzi no nebojātā konstrukcijas stāvokļa. Līdz ar to lielākas D_M^2 vērtības norāda uz iespējamu konstrukcijas bojājumu, bet mazākas vērtības – uz stāvokli, kas līdzīgs nebojātam.

Algoritmam tiek noteikta augšējā kontroles robeža (*UCL*, *Upper Control Limit*), izmantojot Hī-kvadrāta sadalījumu [193]:

$$UCL = \xi_{1-PFA}^2(k), \quad (4.15)$$

kur *PFA* (*Probability of False Alarm*) ir pieļaujamais viltus trauksmeju līmenis; k ir brīvības pakāpes; $\xi_{1-PFA}^2(k)$ ir Hī-kvadrāta inversā funkcija [194].

Viltus trauksmju varbūtība ir pieļaujamais līmenis, kas nosaka augšējās kontroles robežas (*UCL*) vērtību. Izvēlētais *PFA* līmenis ir 0.05 jeb 5%, kas nosaka, ka tikai 5% nebojāto datu var tikt klasificēti kā novirzes. Brīvības pakāpes *k* nosaka datu dimensiju skaits jeb šajā gadījumā izmantoto pašsvārstību frekvenču skaits. Palielinoties *k*, *UCL* pieaug, kas samazina kļūdaini pozitīvo gadījumu skaitu, bet var palielināt kļūdaini negatīvo gadījumu skaitu. Pašsvārstību frekvenču vērtības ar Mahalanobisa distanci, kas pārsniedz *UCL*, tiek uzskatītas par anomālajām [193].

4.6.2. Galveno komponentu analīze (PCA)

Galveno komponentu analīze (PCA) konstrukciju bojājumu noteikšanai balstās uz dimensiju samazināšanu, identificējot datu struktūras galvenās iezīmes. PCA transformē sākotnējos datus uz jaunu ortogonālo telpu, kur galvenās komponentes tiek izvēlētas tā, lai maksimizētu datu dispersiju katrā komponentē un tās būtu savstarpēji ortogonālas jeb neatkarīgas. PCA pamatā ir kovariācijas matricas diagonalizācija, kas ļauj iegūt īpašvērtības un īpašvektorus [195]. PCA algoritma sākumā tiek normalizēti dati, izmantojot robusto normalizācijas metodi, un tiek aprēķināta kovariācijas matrica *S*. No kovariācijas matricas *S* tiek iegūtas īpašvērtības λ_i un atbilstošie īpašvektori ψ_i , risinot vienādojumu:

$$S\psi_i = \lambda_i\psi_i, \quad (4.16)$$

Dati tiek projicēti uz galveno komponentu telpu, izmantojot iegūtos īpašvektorus:

$$Z = X_{norm}V, \quad (4.17)$$

kur *Z* ir $m \times n$ matrica, kur katra kolonna ir datu novērojumi jaunajā telpā; *V* ir $n \times n$ matrica, kur kolonnas ir īpašvektori ψ_i .

Katras galvenās komponentes nozīmīgums tiek izteikts kā izskaidrotās dispersijas attiecība. Galvenajām komponentēm tiek piešķirti svarīguma koeficienti, izmantojot formulu:

$$\text{Izskaidrotās dispersijas attiecība} = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j}. \quad (4.18)$$

Šī vērtība parāda, cik lielu daļu no kopējās datu dispersijas izskaidro galvenā komponente [195].

Lai optimizētu bojājumu noteikšanu, tiek izmantota režģa meklēšana divu būtisku parametru izvēlei – saglabātās variānces līmenim un nozīmīguma līmenim α , kas tiek izmantots Hotellinga T^2 statistikas robežvērtības aprēķināšanai. Tiek optimizētas saglabātās variānces līmeņa vērtības 90%, 95% un 99%. Augstāka saglabātā variānces vērtība ļauj saglabāt vairāk informācijas, savukārt zemāka vērtība var ignorēt nozīmīgas komponentes, kas palīdz samazināt datu dimensionalitāti un trokšņa ietekmi. Nozīmīguma optimizētās vērtības ir 0.01, 0.05 un 0.1. Zemāka α vērtība norāda uz konservatīvāku pieeju un atšķir bojājumus tikai tad, ja tie ievērojami atšķiras. Augstāka α vērtība atļauj vairāk anomāliju, kas var uzlabot jutību, bet arī palielināt kļūdaini pozitīvo gadījumu skaitu [196].

Katrā parametru iterācijā tiek aprēķinātas galvenās komponentes un noteikts minimālais komponentu skaits *nPCs*, kas nodrošina vēlamu dispersijas saglabāšanu. Lai novērtētu

konstrukcijas datu novirzes no robežvērtības, tiek aprēķināta Hotellinga T^2 statistika visiem novērojumiem:

$$T^2 = \sum_{i=1}^{nPCs} \frac{s_i^2}{\lambda_i}, \quad (4.19)$$

kur s_i ir transformētās vērtības galveno komponentu telpā; λ_i ir attiecīgās komponentes dispersija [195].

Hotellinga T^2 statistikas robežvērtība tiek aprēķināta, izmantojot F-sadalījumu:

$$T_{robežvērtība}^2 = \frac{nPCs(N-1)}{N-nPCs} \cdot F(1-\alpha, nPCs, N-nPCs), \quad (4.20)$$

kur N ir kopējais datu punktu skaits; $F(1-\alpha, nPCs, N-nPCs)$ ir F-sadalījuma kvantile [188]. Ja $T^2 > T_{robežvērtība}^2$, tad novērojums tiek uzskatīts par bojājumu. Tiek izvēlēti parametri, kas dod augstāku sabalansēto precizitāti. Kad labākie parametri saglabātās variānces līmenim un nozīmīguma līmenim α ir izvēlēti, tiek veikts galīgais Hotellinga T^2 statistikas aprēķins un T^2 statistikas robežvērtības $T_{robežvērtība}^2$ aprēķins [196].

PCA metode ļauj samazināt datu dimensiju skaitu, saglabājot pēc iespējas lielāku sākotnējo datu dispersijas daļu. Tas padara datu apstrādi un analīzi efektīvāku, īpaši lielu datu kopu gadījumā, samazinot skaitļošanas resursu patēriņu un uzlabojot datu interpretējamību. Tomēr PCA metodes analīzē dažām datu kopām galvenās komponentes var būt grūti interpretējamās, jo tās ir lineāras kombinācijas no sākotnējiem datiem [197].

4.6.3. Vienklasses atbalsta vektora (OC-SVM) algoritms

Konstrukciju bojājumu noteikšana, pielietojot vienklasses atbalsta vektora (OC-SVM) mašīnmācīšanas algoritmu tiek izmantota, lai noteiktu anomālijas jeb novirzes datu kopās, kurās lielākā daļa datu ir nebojātas konstrukcijas dati un tikai daļa datu ir novirzes. OC-SVM metodes būtība ir veidot modeli, kas raksturo “normālos” jeb nebojātā konstrukcijas stāvokļa datus un pēc tam identificēt novirzes jeb anomālijas, kas ievērojami atšķiras no šī normālā sadalījuma. Algoritms apmācības fāzē mēģina definēt normālo datu robežu un pēc tam klasificē jaunus novērojumus kā normālus vai anomālijas. Algoritma sākumā dati tiek normalizēti, izmantojot robusto normalizācijas metodi (skat.formulu 4.11). OC-SVM mēģina atrast robežu, kas maksimāli nošķir lielāko daļu datu no pārējiem, izveidojot minimālu reģionu, kurā dati atrodas. Atšķirībā no divklasses SVM, kur mērķis ir atdalīt divas klases, vienklasses SVM mēģina atdalīt datus no izcelsmes (0) punkta, izveidojot optimālu hiperplakni.

OC-SVM mērķis ir atrast optimālu lēmumu robežu, risinot šādu optimizācijas uzdevumu:

$$\min_{\varpi, \rho, \varphi} \frac{1}{2} \|\varpi\|^2 - \rho + \frac{1}{\nu \cdot n} \sum_{i=1}^n \varphi_i, \quad (4.21)$$

ar nosacījumiem: $\varpi \cdot \phi(x_i) \geq \rho - \varphi_i, \quad \varphi_i \geq 0, \quad i = 1, \dots, n,$

kur $\phi(x)$ ir transformācijas funkcija uz kodola telpu, ko nosaka izvēlētais kodols K , ω ir lēmumu robežas parametrs; ρ ir robežas novirze jeb robežvērtība; φ_i ir nepareizās klasifikācijas vai “kļūdu” mainīgie, kas atļauj datu punktiem atrasties ārpus lēmuma robežas; $\nu \in (0,1]$ ir hiperparametrs, kas nosaka anomāliju proporciju datu kopā [198].

Lai noteiktu nelineārās sakarības, tiek izmantota radiālās bāzes kodolfunkcija (*RBF, Radial Basis Function*), kas tiek aprēķināta pēc 3.5. formulas [115]. Lai atrastu optimālos hiperparametrus, tiek izmantota Bajesa optimizācija. Tā iteratīvi izvēlas labākās γ un ν vērtības, maksimizējot sabalansēto precizitāti. Optimizācija tiek veikta 30 iterācijās un optimālie hiperparametri tiek izmantoti gala modeļa trenēšanai [124].

Kad modelis ir apmācīts, OC-SVM meklē hiperplakni vai robežu, kas maksimāli nošķir datus no izcelsmes un vienlaikus minimāli ieskauj datus kodola telpā. Rezultātā OC-SVM nosaka lēmuma funkciju:

$$f(x) = \varpi \cdot \phi(x) - \rho, \quad (4.22)$$

kur $f(x)$ norāda punkta x piederību “normālajai” jeb nebojātās konstrukcijas stāvokļa daļai. Ja $f(x) \geq 0$, tas punkts pieder “normālajai” daļai, ja $f(x) < 0$, tad punkts pieder “anomālajai” daļai.

Katram datu punktam tiek aprēķināts rādītājs, kas parāda attālumu līdz lēmuma robežai:

$$score(x) = \varpi \cdot \phi(x) - \rho. \quad (4.23)$$

Positīvs vai tuvs nullei rādītājs norāda uz to, ka datu punkts tiek uzskatīts par “normālu”. Negatīvs rādītājs norāda uz to, ka punkts tiek atzīts par anomāliju jeb novirzi [198]. Novirzes tiek noteiktas izmantojot rādītāju sadalījumu. Robeža tiek definēta kā 5% kvantile:

$$threshold = Q_{0.05}(scores), \quad (4.24)$$

kur $Q_{0.05}$ ir zemākā 5% vērtība rādītāju sadalījumā. Punkti, kuru rādītājs ir mazāks par šo robežu, tiek klasificēti kā novirzes [199]:

$$score(x) < threshold \quad (4.25)$$

OC-SVM spēj “iemācīties” raksturot lielāko daļu jeb “normālo” datu un tad noteikt, kuri punkti no šī normālā sadalījuma atšķiras. Izmantojot nelineāru kodolfunkciju, OC-SVM spēj identificēt anomālijas arī sarežģītās datu telpās, kur robeža starp normāliem un anomāliem datiem nav lineāra. Parametrs ν ļauj definēt gaidāmo anomāliju daļu no kopējā datu skaita. Tomēr, ja ν netiek pareizi izvēlēts, modelis var pārmērīgi atzīmēt datus par anomālijām vai arī var rasties daudz patieso kļūdu datu. Ja dati satur ļoti daudz slēptu anomāliju, tad modelis var netikt galā ar to identificēšanu, jo tiek pieņemts, ka lielākā daļa datu ir normāli. Līdzīgi kā citas metodes, arī OC-SVM var kļūt neefektīva, ja datu dimensijas ir ļoti lielas un datu ir daudz. Tā kā OC-SVM izmanto nelineāras pārveides un kodolfunkcijas, var būt sarežģīti interpretēt, kāpēc konkrēts datu punkts ir klasificēts kā novirze. Ja bojātie dati pēc savām vērtībām maz atšķiras no normālajiem, tie var netikt uzskatīti par anomālijām [115].

4.6.4. Gausa jauktā modeļa (GMM) metode

Gausa jauktā modeļa (GMM) metode balstās uz pieņēmumu, ka konstrukcijas nebojātā stāvokļa pašsvārstību frekvenču dati veido daudzdimensiju sadalījumu, kuru iespējams pietiekami precīzi aproksimēt ar vairāku daudzdimensiju normālsadalījumu kopumu. Būtiska novērojumu atkāpe no kopējā raksturlieluma var norādīt uz konstrukcijas bojājumu jeb anomāliju. Šajā gadījumā tiek izmantots vairāku komponentu modelis, kas ļauj precīzāk pielāgoties dažādiem konstrukcijas stāvokļiem. Metodes sākumā, lai izlīdzinātu dažādu

frekvenču mērogus, tiek izmantota robustā normalizācijas metode. GMM ietvaros tiek modelēts, ka konstrukcijas nebojātā stāvokļa pašsvārstību frekvenču kopējais (daudzdimensiju) sadalījums var tikt aproksimēts ar modeli, kas sastāv no K daudzdimensiju normālsadalījumiem, kur katra komponente raksturo iespējamu konstrukcijas stāvokli:

$$p(x) = \sum_{k=1}^K \pi_k \cdot \mathcal{N}(x|\mu_k, S_k), \quad (4.26)$$

kur K ir komponentu skaits; π_k ir katras komponentes svars, kas norāda, cik liela datu daļa tai atbilst; μ_k ir katras komponentes vidējās pašsvārstību frekvences; S_k katras komponentes kovariances matrica, kas raksturo savstarpējās sakarības starp pašsvārstību frekvencēm.

Katras GMM komponentes varbūtības blīvums tiek aprēķināts kā daudzdimensiju normālais sadalījums:

$$\mathcal{N}(x|\mu_k, S_k) = \frac{1}{\sqrt{(2\pi)^d |S_k|}} \exp\left(-\frac{1}{2}(x - \mu_k)^T S_k^{-1}(x - \mu_k)\right), \quad (4.27)$$

kur d ir datu dimensiju skaits, kas atbilst izmantoto pašsvārstību frekvenču skaitam; $|S_k|$ ir kovariances matricas determinanta absolūtā vērtība, kas raksturo, cik daudz komponente izklidē datus dažādos virzienos [200].

Pēc GMM apmācības katram novērojumam x_i , tiek aprēķināta negatīvā logaritmiskā ticamība (NLL):

$$NLL_i = -\log(p(x_i)). \quad (4.28)$$

Lielāka NLL vērtība norāda uz mazāku ticamību, ka attiecīgais punkts atbilst GMM modelim, kas nozīmē, ka novērojums varētu atbilst bojātas konstrukcijas datiem [199].

Lai atrastu piemērotākos modeļa parametrus, tiek veikta režģveida meklēšana, testējot komponentu skaita K un nozīmīguma līmeņa α vērtības. Tiek testētas vērtības $K = 1, 2, 3$ un $\alpha = 0.01, 0.05, 0.1$. Pārāk maza K vērtība var nepietiekami modelēt dažādus konstrukciju stāvokļus. Savukārt pārāk liela K vērtība var radīt pārpielāgošanas risku. Mazāka α vērtība pieļauj mazāk noviržu un var radīt vairāk kļūdaini negatīvus gadījumus. Lielāka α vērtība palielina anomāliju noteikšanu, bet var radīt vairāk kļūdaini pozitīvus gadījumus [200]. Par optimālo hiperparametru kombināciju tiek izvēlēta tā, kurai ir visaugstākā sabalansētā precizitāte [201].

Pēc optimālā modeļa noteikšanas tiek aprēķināta klasifikācijas robežvērtība τ , izmantojot $(100\% \cdot (1 - \alpha))$ procentpunktu no NLL sadalījuma:

$$\tau = \text{prctile}(NLL, 100 \cdot (1 - \alpha)) \quad (4.29)$$


Novērojumi, kuriem $NLL > \tau$, tiek klasificēti kā bojājumi jeb anomālijas. Savukārt novērojumiem ar $NLL \leq \tau$ tiek uzskatīti par normāliem [199]. Piemēram, ja $\alpha = 0.05$, tad 5% no novērojumiem tiek klasificēti kā anomālijas.

Daudzkomponenšu GMM modelis spēj precīzāk modelēt sarežģītu uzvedību, izvairoties no pārmērīgi vienkāršotas pieejas, ja pašsvārstību frekvenču izmaiņas ir daudzveidīgas. Tomēr, ja apmācības dati satur ievērojamu bojājumu īpatsvaru vai izteiktas novirzes, modelis var “iemācīties” arī bojājuma raksturlielumus, kas samazina kontrastu starp nebojāto un bojāto

stāvokli un palielina viltus negatīvo gadījumu skaitu. Ja starp apmācības datiem ir izteikti novirzes punkti, GMM centīsies iekļaut arī tos. Tas iespējams rezultētos ar to, ka daudzas anomālijas netiktu atklātas [200].

4.6.5. Algoritmu klasifikācijas efektivitātes novērtēšana

Mahalanobisa distances algoritma, PCA, OC-SVM un GMM metožu novērojumu klasifikācija tiek veikta, balstoties uz noteiktu sliekšņa jeb robežvērtību, kura nosaka, vai konkrētais novērojums tiek uzskatīts par tipisku konstrukcijas nebojātajam stāvoklim vai novirzītu no tā (4.22.att.). Šī robežvērtība tiek definēta katram algoritmam atsevišķi. Ja robežsliekšnis ir noteikts pārāk zems, tad lielāko daļu nebojātās konstrukcijas datu var tik uzskatīti kā novirzes, palielinot kļūdaini pozitīvo rezultātu skaitu. Savukārt, ja robežsliekšņa vērtība ir noteikta pārāk augsta, novērojumus, kas atbilst bojātai konstrukcijai, var klasificēt kā nebojātai [202] [203].



4.22.att. Novērojumu klasifikācijas princips, balstoties uz noteiktu novirzes robežvērtību [202].

Divu klasifikatoru problēmuzdevumam konstrukciju tehniskā stāvokļa monitoringā, kurā abas datu kopas tiek apzīmētas kā bojātas jeb P-pozitīvas un nebojātas jeb N-negatīvas, katrai robežvērtībai ir četri iespējamie rezultāti, kas norādīti 4.2.tabulā. Pozitīvs klasifikācijas rezultāts var būt patiesi pozitīvs (*TP, True Positive*), ja novērojums ir pozitīvs, vai kļūdaini pozitīvs (*FP, False Positive*), ja novērojums patiesībā ir negatīvs. Savukārt negatīvs rezultāts var būt kļūdaini negatīvs (*FN, False Negative*), ja novērojums ir pozitīvs, vai patiesi negatīvs (*TN, True Negative*), ja tas ir negatīvs. Kļūdu matrica attēlo četrus gadījumus, kur FP un FN atbilst I tipa un II tipa kļūdām [204].

4.2.tabula

Kļūdu matrica [204]

Rezultāts	Novērojums		
	Pozitīvs	Negatīvs	Kopā
Pozitīvs	Patiesi pozitīvs (TP)	Kļūdaini Pozitīvs (FP)	TP+FP
Negatīvs	Kļūdaini Negatīvs (FN)	Patiesi Negatīvs (TN)	FN+TN
Kopā	TP+FN	FP+TN	TP+FP+FN+TN

Izmantoto metožu klasifikācijas efektivitātes novērtēšanai tiek aprēķināta **sabalansētā precizitāte**, analizējot pareizi klasificēto un kļūdaini klasificēto gadījumu skaitu [201]. Sabalansētās precizitātes noteikšanai tiek izmantoti divi galvenie kritēriji – sensitivitāte un specifitāte [185].

Sensitivitāte jeb pareizo pozitīvo gadījumu skaitu attiecība tiek aprēķināta pēc formulas:

$$\text{Sensitivitāte} = \frac{TP}{TP + FN} \quad (4.30)$$

kur TP ir pareizi pozitīvi jeb pareizi identificētie bojājumi; FN ir kļūdaini negatīvi jeb bojājumi, kas kļūdaini klasificēti kā nebojāti.

Specificitāte jeb pareizo negatīvo gadījumu skaitu attiecība tiek aprēķināta pēc formulas:

$$\text{Specificitāte} = \frac{TN}{TN + FP} \quad (4.31)$$

kur TN ir pareizi negatīvi jeb pareizi identificētie nebojātie dati; FP ir kļūdaini pozitīvi jeb nebojāti dati, kas kļūdaini klasificēti kā bojāti.


Ņemot vērā, ka nebojāto un bojāto datu skaits nav līdzīgs, tiek noteikta sabalansētā precizitāte, kas nodrošina, ka modelis tiek vērtēts vienmērīgi neatkarīgi no kļaušu disproporcijas:

$$\text{Sabalansētā precizitāte} = \frac{\text{Sensitivitāte} + \text{Specificitāte}}{2} \quad (4.32)$$


Šī vērtība ļauj novērtēt modeļa spēju atšķirt bojātas un nebojātas konstrukcijas mērijumus, nepieļaujot, ka viena klase dominē novērtējumā [205].

4.6.6. Algoritmu klasifikācijas rezultāti

Mahalanobisa distances algoritma, galveno komponentu analīzes (PCA), vienklases atbalsta vektora (OC-SVM) analīzes un Gausa jauktā modeļa (GMM) klasifikācijas rezultāti, izmantojot koka rāmja monitoringa datus pirms ārējās vides ietekmes samazināšanas metodes piemērošanas, apkopoti 4.23.att. un 4.24.att.



4.23.att. Mahalanobisa distances algoritma (a) un PCA metodes (b) rezultāti konstrukciju bojājumu noteikšanai, izmantojot visas sešas koka rāmja pašsvārstību frekvences.



4.24.att. OC-SVM metodes (c) un GMM metodes (d) rezultāti konstrukciju bojājumu noteikšanai, izmantojot visas sešas koka rāmja pašsvārstību frekvences.

Analizējot Mahalanobisa distances algoritma iegūtos rezultātus (4.23.att.,(a)), var secināt, ka lielākā daļa nebojātās konstrukcijas dati tiek identificēti pareizi un to vērtības nepārsniedz definēto robežvērtību. Sabalansētā precizitāte tika sasniegta 0.70 jeb 70% un kļūdaini pozitīvo datu skaits bija 404, kas tika novēroti ziemas periodā. Algoritms spēj veiksmīgi identificēt konstrukcijas bojājumus, sākot ar bojājuma pakāpi Nr.2. Taču kļūdaini negatīvo rezultātu skaits ir salīdzinoši liels – 464, kas nozīmē, ka ievērojama daļa bojātās konstrukcijas novērojumu netiek atpazīti kā anomālijas.

Iegūtie PCA metodes rezultāti (4.23.att., (b)) uzrāda sabalansēto precizitāti 0.65 jeb 65%, kas ir zemāka nekā Mahalanobisa distances algoritmam (0.70). Šī metode kļūdaini identificēja 422 novērojumus kā konstrukciju bojājumus, salīdzinot ar 404 kļūdaini pozitīvajiem gadījumiem Mahalanobisa metodes rezultātos. Savukārt kļūdaini negatīvo novērojumu skaits PCA metodei ir 535, kas ir vairāk nekā Mahalanobisa distances algoritmam (464). Šajā gadījumā PCA metode spēja sliktāk identificēt bojātās konstrukcijas novērojumus, kas samazina monitoringa sistēmas efektivitāti.


OC-SVM metodes analīzes grafiks (4.24.att.,(c)) parāda, ka algoritms ir efektīvs nebojātās konstrukcijas datu atpazīšanā – lielākā daļa novērojumu atrodas virs robežvērtības, kas norāda uz normālu nebojātu konstrukcijas stāvokli. Kļūdaini pozitīvie rezultāti (202) galvenokārt koncentrējas ziemas periodā, tomēr kļūdu skaits šajā metodē ir ievērojami zemāks, kas liecina par OC-SVM metodes augstāku noturību pret ārējās vides faktoru ietekmi. Arī kļūdaini

negatīvo rezultātu skaits (410) ir mazāks nekā Mahalanobisa distances algoritma gadījumā (464) norādot uz to, ka OC-SVM algoritms spēj labāk noteikt konstrukciju bojājumus, sākot jau ar bojājumu pakāpi Nr.2.


GMM metodes analīzē (4.24.att.,(d)) konstrukciju bojājumu noteikšanā tika iegūta sabalansētā precizitāte 0.70 jeb 70%, kas norāda uz mēreni labu spēju atšķirt nebojātās un bojātās konstrukcijas datus. Tomēr tika identificēti 377 kļūdaini pozitīvi un 467 kļūdaini negatīvi gadījumi, kas norāda, ka metode nespēj precīzi klasificēt visus bojātās un nebojātās konstrukcijas gadījumus, īpaši ziemas mēnešos, kad rodas visvairāk kļūdaini pozitīvo rezultātu.

4.6.7. Algoritmu klasifikācijas noviržu punktu analīze

Konstrukcijas bojājumu noteikšanas algoritmu iegūtie rezultāti skaidri norāda, ka algoritmu efektivitāti būtiski ietekmē ārējās vides faktori. Īpaši nozīmīgi tas ir ziemas periodā, kad ārējās vides faktoru svārstības, piemēram, būtiskas temperatūras izmaiņas un paaugstināts relatīvais mitrums var izraisīt konstrukciju dinamisko parametru vērtību izmaiņas. Šīs ārējās vides faktoru radītās frekvenču svārstības konstrukciju bojājumu noteikšanas algoritmi bieži kļūdaini klasificē kā bojājumu pazīmes, līdz ar to palielinot kļūdaini pozitīvo jeb viltus trauksmju skaitu. Lai gan ārējās vides ietekmes analīze skaidri norāda, kurš ārējās vides faktors visvairāk ietekmē frekvenču svārstības, šī analīze nenorāda, kad šī ietekme izraisa algoritma kļūdainu bojājumu klasifikāciju. Kļūdaini pozitīvo punktu analīze ārējās vides faktoru grafikos ļauj noteikt konkrētus periodus un ekstrēmas vērtības, kuros dominējošā ārējās vides faktora izmaiņas tiek interpretētas kā konstrukcijas bojājums. Noviržu punktu atrašanās ārējo vides faktoru izmaiņu laika grafikos ir apkopotas 4.25.att. un 2.26.att.



4.25.att. Mahalanobisa distances algoritma (a) un PCA metodes (b) kļūdaini pozitīvo rezultātu izvietojums ārējās vides faktoru izmaiņu grafikos.



4.26.att. OC-SVM metodes (c) un GMM metodes (d) kļūdaini pozitīvo rezultātu izvietojums ārējās vides faktoru izmaiņu grafikos.


Analizējot kļūdaini pozitīvo izvietojumu ārējās vides faktoru izmaiņu grafikos, var novērot, ka Mahalanobisa distances (4.25.att.,(a)), PCA metodes (4.25.att.,(b)), OC-SVM (4.26.att.,(c)) un GMM (4.26.att.,(d)) metodes kļūdaini pozitīvie rezultāti galvenokārt koncentrējas periodos ar straujām ārējās vides faktoru izmaiņām. Visbiežāk anomālijas rodas zemas ārējās gaisa temperatūras apstākļos - ja temperatūra ir zemāka par 0 °C, kā arī periodos, kad tiek novērotas straujas un intensīvas temperatūras izmaiņas, it īpaši ziemas periodā. Kļūdaini pozitīvo rezultātu izvietojums relatīvā mitruma izmaiņu grafikā norādīja, ka anomāliju blīvums ir liels tieši pie augsta relatīvā mitruma līmeņa, galvenokārt virs 80%. Šīs straujas relatīvā mitruma izmaiņas sakrīt ar ziemas periodu, kad relatīvais mitrums ir visaugstākais un bieži mainās ļoti īsā laika intervālā. Tomēr līdzīgi kā ārējās gaisa temperatūras izmaiņu grafikā, arī relatīvā mitruma izmaiņu grafikā atsevišķi kļūdaini pozitīvie datu punkti atrodas visā novērojumu periodā un neatbilst maksimālajām vai minimālajām ārējā vides faktora vērtībām kādā no laika posmiem.

4.7. Ārējās vides parametru ietekmes samazināšanas metodes validācijas rezultāti

Ārējās vides faktoru ietekmes samazināšanas metodes validācijai tika izmantoti iepriekš eksperimentāli iegūti divstāvu **koka rāmja** un **Filomena Delli Castelli tilta** konstrukciju monitoringa dati, kuros ietvertas pirmās sešas pašvārstību frekvenču vērtības.

4.7.1. Koka rāmja monitoringa datu validācijas rezultāti


Koka rāmja ārējās vides faktoru ietekmes samazināšanas metodes **1.posmā** pašsvārstību frekvenču mērījumu dati un ārējās vides faktoru vērtības tika apvienotas vienā datu kopā pēc mērījumu laika norādēm, nodrošinot, ka katram pašsvārstību frekvences mērījumam tiek piešķirtas attiecīgās ārējās vides faktoru vērtības. Metodes **2.posmā** tika izmantoti septiņi dažādi regresijas modeļi, lai modelētu katras pašsvārstību frekvences atkarību no ārējās vides faktoriem (SVR, RF, LR, DT, XGBoost, GPR un BR). Metodes **3.posmā** katra modeļa precizitātes novērtēšana tika veikta, izmantojot saliktās efektivitātes rādītāju *CPM*, kas apvieno R^2 , *RMSE*, *MAE* un *MAPE* rādītājus. Katram no regresijas modeļiem tika aprēķinātas vidējās globālās *CPM* vērtības (4.27.att.) visu ārējās vides faktoru (ārējās gaisa temperatūras, relatīvā mitruma) un pašsvārstību frekvenču sakarības modelēšanai.



4.27.att. Regresijas modeļu vidējās globālās *CPM* vērtības ārējās vides faktoru un koka rāmja pašsvārstību frekvenču sakarības modelēšanai.

Visu regresijas modeļu iegūto vidējo globālo *CPM* vērtību salīdzinājums (4.27.att.) norāda, ka XGBoost metode sasniedz viszemāko vērtību, kas norāda uz metodes spēju nodrošināt augstāku prognožu precizitāti un labāku vispārējo modeļa piemērotību pašsvārstību frekvenču prognozēšanai. BR, RF un GPR metodes sasniedz nedaudz zemākas *CPM* vērtības, savukārt DT, SVR un LR metodes uzrāda augstākās *CPM* vērtības, kas pamato šo metožu nepietiekamu piemērotību pašsvārstību frekvenču un ārējās vides ietekmes modelēšanai.

Metodes **4.posmā** tiek izvēlēts XGBoost regresijas modelis, kurš uzrādīja viszemāko globālo *CPM* vērtību, lai noteiktu segmentu robežas. Ārējās gaisa temperatūras un relatīvā mitruma ietekmes segmenti apkopoti 4.28.att.



4.28.att.XGboost metodes PDP līkne ārējās gaisa temperatūras (a) un relatīvā mitruma (b) ietekmes segmentu noteikšanai koka rāmja monitoringa datos.


Ārējai gaisa temperatūras ietekmei tiek definētas trīs segmentu robežas: līdz -2.14°C , no -2.14°C līdz $+4.09^{\circ}\text{C}$, un virs $+4.09^{\circ}\text{C}$. Relatīvā mitruma ietekmes robežas tiek definētas: līdz 52.05%, no 52.05% līdz 84.14% un virs 84.14% (4.28.att.).

Iegūtie maiņas punkti (4.28.att.) atspoguļo ārējās gaisa temperatūras ietekmes izmaiņu punktus konstrukcijas dinamiskajā reakcijā. Salīdzinot ar citos pētījumos minētajiem rezultātiem, būtiskas izmaiņas koksnes mehāniskajās īpašībās notiek, ja ārējā gaisa temperatūra ir zemāka par -5°C , jo šajā diapazonā notiek ūdens sasalšana koksnes struktūrā, kas palielina koksnes stingrību un samazina elastību [206]. Kā arī ārējā gaisa temperatūrā zem -5°C koksnes līmvielas zaudē elastību, kas var radīt saķeres zudumu un iespējamās plaisas līmētajos slāņos. Šī temperatūras vērtība bieži tiek izmantota kā robežvērtība ekspluatācijas un testēšanas standartos [207], [208]. Līdz ar to koka rāmja gadījumā iegūtie ārējās gaisa temperatūras ietekmes maiņas punktu vērtības gandrīz sakrīt ar citos pētījumos izmantotajām robežvērtībām.

Koka rāmja monitoringa datus iegūtās relatīvā mitruma ietekmes segmentu maiņas punktu vērtības ir ļoti tuvas LVS EN 1995-1-1:2005 noteiktajām koka konstrukciju lietojamības klašu robežvērtībām, kur relatīvā mitruma segments zem 65% atbilst 1.lietojamības klasei, relatīvā mitruma segments no 65% līdz 85% atbilst 2.lietojamības klasei un segments virs 85% atbilst 3.lietojamības klasei, kur koksnes mitruma saturs palielinās virs šķiedru piesātinājuma punkta, būtiski samazinot mehāniskās īpašības [209], [210].

Metodes **5.posmā** tiek noteikti atsevišķi regresijas modeļi katrā no ārējās vides faktora ietekmes segmentā. Katrai pašvārstību frekvencei un katram regresijas modelim ārējās vides faktora ietekmes segmentā tiek aprēķināts saliktās efektivitātes rādītājs *CPM*.

Ārējās gaisa temperatūras un pašvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.29.att.



4.29.att. PDP līknes koka rāmja pašvārstību frekvencēm ārējās gaisa temperatūras ietekmē.

Kopējā tendence visos PDP grafikos norāda uz skaidru negatīvu korelāciju starp ārējo gaisa temperatūru un pašsvārstību frekvencēm – frekvenču vērtība pazeminās, pieaugot gaisa temperatūrai (4.29.att.). PDP grafiku rezultāti arī norāda, ka ārējās gaisa temperatūras ietekme uz pašsvārstību frekvencēm nav vienmērīga visā temperatūras diapazonā. Segmentā līdz -2.14°C gandrīz visiem regresijas modeļiem ir novērojams frekvenču vērtību pakāpenisks samazinājums. Segmentā no -2.14°C līdz $+4.09^{\circ}\text{C}$ visām pašsvārstību frekvencēm ir novērojams straujš vērtību kritums un visu septiņu regresijas modeļu prognozes šajā zonā savstarpēji pārklājas. Šis segments raksturo temperatūras galveno ietekmi uz frekvenču vērtību samazināšanos un nodrošina visaugstāko regresijas modeļu savstarpējo precizitāti. Savukārt segmentā virs $+4.09^{\circ}\text{C}$ parādās izteiktas nelineāras novirzes, kas atšķiras gan starp modeļiem, gan starp pašsvārstību frekvencēm. Daļai regresijas modeļu novērojams lēzens kritums jeb frekvenču vērtību samazinājums, citos – lokāls frekvenču vērtību pieaugums.


Regresijas modeļu *CPM* vērtības ārējās gaisa temperatūras un pašsvārstību frekvenču sakarības modeļēšanai atsevišķos segmentos ir apkopotas 4.30.attēlā.

	T ≤ -2.14 °C							-2.14 °C < T ≤ 4.09 °C							T > 4.09 °C							
f1	1.25	-1.70	8.35	-0.15	-2.24	-1.93	-3.57	2.98	-0.26	7.27	-1.15	-4.63	-1.07	-3.14	0.84	0.68	8.16	-1.02	-3.51	-1.82	-3.34	5 0 -5
f2	-0.27	-2.02	8.63	0.67	-2.39	-2.00	-2.61	1.91	-4.69	7.60	0.90	-1.89	-1.44	-2.40	0.90	-4.21	7.95	0.48	0.03	-2.13	-3.01	
f3	-0.70	-0.29	8.66	-0.20	-3.04	-2.88	-1.54	1.37	0.36	7.22	0.26	-5.75	-2.75	-0.71	-0.29	0.60	8.24	-0.30	-4.18	-2.88	-1.19	
f4	-0.88	-3.82	7.85	2.55	-2.55	-1.51	-1.65	0.81	-3.58	7.39	1.42	-4.88	-0.34	-0.83	0.03	-2.07	7.79	1.80	-4.67	-1.27	-1.60	
f5	0.36	-3.05	7.93	2.14	-3.05	-2.11	-2.21	2.78	-4.51	6.79	0.65	-4.49	-0.48	-0.74	2.40	-4.23	6.98	1.51	-4.22	-1.09	-1.35	
f6	-1.34	-0.67	8.48	0.63	-0.80	-2.61	-3.69	0.29	-0.64	8.35	-0.51	-0.88	-2.33	-4.28	-0.63	0.35	7.95	-0.38	0.40	-2.80	-4.89	
Mean	-0.26	-1.92	8.32	0.94	-2.35	-2.17	-2.54	1.69	-2.22	7.44	0.26	-3.75	-1.40	-2.02	0.54	-1.48	7.84	0.35	-2.69	-2.00	-2.56	
Std.dev.	0.94	1.35	0.35	1.16	0.83	0.49	0.92	1.07	2.29	0.52	0.95	1.91	0.98	1.50	1.10	2.35	0.45	1.12	2.28	0.75	1.45	
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	

4.30.att. *CPM* vērtības regresijas modeļiem ārējās vides temperatūras segmentos līdz -2.14°C , no -2.14°C līdz 4.09°C un virs 4.09°C koka rāmja monitoringa datos.

Ārējās gaisa temperatūras ietekmes analīze liecina, ka regresijas modeļu veikspēja būtiski mainās atkarībā no temperatūras segmenta, savukārt lineārā regresija (LR) visos segmentos uzrāda visaugstākās *CPM* vērtības un līdz ar to zemāko prognožu precizitāti. Ārējās gaisa temperatūras segmentā līdz -2.14°C visprecīzākos rezultātus nodrošina Bajesa regresija (BR), kas uzrāda labāko pielāgošanos datiem un visprecīzāk raksturo temperatūras ietekmi uz pašsvārstību frekvenču vērtībām šajā segmentā. Segmentā no -2.14°C līdz 4.09°C vairākas nelineāras metodes uzrāda augstu precizitāti, tomēr vidēji visefektīvākā ir XGBoost metode. Arī ārējās gaisa temperatūras segmentā virs 4.09°C nelineārie modeļi saglabā līdzīgu veikspēju, bet XGBoost sasniedz zemāko vidējo *CPM* vērtību, apliecinot tās stabilitāti un piemērotību sarežģītām nelineārām sakarībām.

Relatīvā mitruma un pašsvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.31.att.



4.31.att. PDP līknes koka rāmja pašsvārstību frekvencēm relatīvā mitruma ietekmē.

Balstoties uz iegūtajiem relatīvā mitruma daļējas atkarības grafikiem (PDP), ir iespējams novērot pozitīvu korelāciju starp relatīvo mitrumu un konstrukciju pašsvārstību frekvencēm (4.31.att.). Lielākajai daļai regresijas modeļu un pašsvārstību frekvenču vērojama tendence, ka pieaugot mitrumam, pieaug arī prognozētā frekvenču vērtība. Tomēr šī sakarība nav lineāra visā relatīvā mitruma diapazonā. Segmentā līdz 52.05% relatīvā mitruma PDP līknes vairumā gadījumu parāda salīdzinoši nemainīgu vai ļoti lēnu pieaugumu. Segmentos no 52.05% līdz 84.14% un virs 84.14% novērojama izteiktāka frekvenču vērtību pieauguma tendence. Salīdzinot dažādu regresijas modeļu līknes, redzams, ka nelineārie modeļi nodrošina daudz precīzāku pielāgošanos frekvenču izmaiņām atkarībā no relatīvā mitruma. Lineārais modelis sniedz vispārīgu izmaiņu tendenci.

Regresijas modeļu *CPM* vērtības relatīvā mitruma un pašsvārstību frekvenču sakarības modelēšanai atsevišķos segmentos ir apkopotas 4.32.attēlā.

	RH ≤ 52.05%							52.05% < RH ≤ 84.14%							RH > 84.14%							
f1	-1.15	-0.40	8.84	-0.49	-1.99	-2.08	-2.74	1.46	-0.36	8.23	-1.18	-3.24	-1.60	-3.31	3.13	0.00	6.97	-0.70	-4.90	-1.20	-3.31	
f2	-1.30	-2.11	8.23	1.87	-0.79	-2.78	-3.10	0.86	-3.71	8.25	0.43	-1.04	-1.98	-2.81	2.00	-4.96	7.46	0.91	-1.50	-1.44	-2.47	
f3	-1.95	-0.66	8.57	0.97	-2.36	-2.53	-2.05	0.19	0.03	8.30	-0.25	-4.07	-2.78	-1.41	1.13	0.74	7.11	0.22	-5.84	-2.91	-0.46	
f4	-2.46	-0.99	8.67	0.90	-2.03	-1.81	-2.28	-0.28	-2.27	8.12	1.32	-4.29	-1.09	-1.51	1.13	-3.70	6.91	2.18	-5.08	-0.55	-0.89	
f5	-0.71	-2.13	8.62	0.99	-2.14	-2.07	-2.56	2.06	-4.00	7.42	1.04	-4.02	-1.08	-1.41	3.08	-4.72	6.25	1.36	-4.69	-0.58	-0.70	
f6	-1.30	-0.23	8.53	-0.11	-0.49	-2.87	-3.53	-0.51	-0.11	8.26	-0.44	-0.05	-2.68	-4.46	0.10	-0.13	8.01	-0.21	-0.39	-2.46	-4.92	
Mean	-1.48	-1.09	8.58	0.69	-1.63	-2.36	-2.71	0.63	-1.74	8.10	0.15	-2.78	-1.87	-2.49	1.76	-2.13	7.12	0.63	-3.73	-1.52	-2.12	
Std. dev.	0.62	0.84	0.20	0.85	0.79	0.43	0.54	1.01	1.84	0.34	0.95	1.80	0.75	1.26	1.20	2.61	0.59	1.06	2.22	0.97	1.77	
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	

4.32.att. *CPM* vērtības regresijas modeļiem relatīvā mitruma segmentā no 0% līdz 52.05 %, no 52.05% līdz 84.14% un virs 84.14% koka rāmja monitoringa datos.

Relatīvā mitruma ietekmes analīze liecina, ka regresijas modeļu prognozēšanas precizitāte ir nevienmērīga un būtiski atkarīga gan no mitruma diapazona, gan no izvēlētajās metodes. Lineārā regresija (LR) visos segmentos uzrāda visaugstākās *CPM* vērtības, līdz ar to uzrādot zemāko pielāgošanās spēju salīdzinājumā ar citiem regresijas modeļiem. Relatīvā mitruma segmentā no 0% līdz 52.05% vislabāko vidējo veiktspēju nodrošina Bajesa regresija (BR), kas visprecīzāk pielāgojas datiem zema mitruma apstākļos. Augstākos relatīvā mitruma segmentos no 52.05% līdz 84.14% un virs 84.14% viszemākās *CPM* vērtības sasniedz XGBoost, nodrošinot visprecīzāko pašsvārstību frekvenču vērtību prognozēšanu šajos abos relatīvā mitruma segmentos.

Apkopojot visus *CPM* vērtību rezultātus, zemākās vērtības tika iegūtas, izmantojot:

- 1) Bajesa regresijas (BR) metodi - ārējās vides temperatūras segmentā līdz -2.14°C , relatīvā mitruma segmentā no 0% līdz 52.05%;
- 2) XGBoost metodi - ārējās vides temperatūras segmentā no -2.14°C līdz $+4.09^{\circ}\text{C}$, ārējās vides temperatūras segmentā virs $+4.09^{\circ}\text{C}$, relatīvā mitruma segmentā no 52.05% līdz 84.14%, relatīvā mitruma segmentā no 84.14% līdz 100%.

Izmantojot šos attiecīgos regresijas modeļus, tika veidotas samazinātu vērtību punktu daļējas atkarības līknes katrai pašsvārstību frekvencei un katram ārējās vides ietekmes faktoram. Optimālais režģu punktu skaits, kas maksimāli precīzi apraksta līknes funkciju ar noteiktu konverģences kritēriju, apkopots 4.3.tabulā.

4.3.tabula

Optimālais režģa punktu skaits katram ārējās vides faktoram koka rāmja monitoringa datiem

Pašsvārstību frekvences Nr.	Ārējās vides ietekmes faktors	
	Ārējā gaisa temperatūra	Relatīvais mitrums
f1	400	500
f2	150	150
f3	400	350
f4	400	150
f5	100	500
f6	500	500

Apkopojot optimālo režģu punktu skaitu rezultātus katram ārējās vides faktoram un pašsvārstību frekvencei, redzams, ka izvēlētie regresijas modeļi pielāgoti ar atšķirīgu detalizācijas līmeni, atkarībā no datu struktūras un konkrētā faktora ietekmes nelinearitātes. Režģa punktu skaits, kas nepieciešams, lai sasniegtu konverģences kritēriju, būtiski atšķiras starp frekvencēm un ārējiem vides faktoriem. Augstākais režģu punktu skaits (500) visbiežāk izmantots relatīvā mitruma PDP līknēm, kas norāda uz sarežģītu un mainīgu šī faktora ietekmes raksturu. Savukārt, atsevišķos gadījumos dažām pašsvārstību frekvencēm bija pietiekami izmantot mazāku punktu skaitu (100 un 150), kas liecina par vienkāršāku pašsvārstību frekvenču vērtību prognozēšanu.

Attiecīgā PDP līkne tika interpolēta katrai pašsvārstību frekvences vērtībai un katram ārējās vides ietekmes parametram pēc faktiskās ārējās vides faktora vērtības. Nākamajā solī tika


koriģētas pašsvārstību frekvenču vērtības, atņemot kopējo segmentēto ārējās vides ietekmes vērtību. Līdz ar to tika panākta ārējās vides faktora segmentētās ietekmes noņemšana.

Uz šīm koriģētām pašsvārstību frekvenču vērtībām tika trenēti papildus regresijas modeļi – LSBoost, GPR, SVR un Bagging, lai novērtētu atlikušās nelineārās ietekmes sakarības. Tika izvēlēts modelis ar zemāko *MSE* un gala korekcija iegūta, atņemot prognozēto atlikušās ārējās vides ietekmes daļu attiecīgajā mērījuma brīdī katrai pašsvārstību frekvencei. Pēdējā posmā tika noņemta sezonālā ietekme un gala koriģētā pašsvārstību frekvences vērtība tika iegūta, atņemot sezonālo komponenti un pieskaitot sezonālās komponentes vidējo vērtību.

4.7.2. Filomena Delli Castelli validācijas rezultāti

Ārējās vides ietekmes samazināšanas metodes piemērošanai **Filomena Delli Castelli** tilta visām sešām pašsvārstību frekvencēm:


- **1.posmā** pašsvārstību frekvenču dati un ārējās vides faktoru vērtības tika apvienotas vienā datu kopā;
- **2.posmā** katras pašsvārstību frekvences atkarība no ārējās vides faktoriem tika modelēta izmantojot septiņus dažādus regresijas modeļus;
- **3.posmā** tika aprēķinātas vidējās globālās *CPM* vērtības katram regresijas modelim (4.35.att.).



4.35.att. Regresijas modeļu vidējās globālās *CPM* vērtības ārējās vides faktoru un Filomena Delli Castelli tilta pašsvārstību frekvenču sakarības modelēšanai.

Visu regresijas modeļu iegūto vidējo globālo *CPM* vērtību salīdzinājums norāda, ka XGBoost metode sasniedz viszemāko vērtību, kas apliecina tās spēju visprecīzāk prognozēt pašsvārstību frekvenču izmaiņas ārējās vides faktoru ietekmē tilta monitoringa gadījumā. GPR un BR metodes iegūtās vidējās globālās *CPM* vērtības ir augstākas, kas liecina par šo modeļu ierobežoto spēju pilnībā uztvert datu nelinearitāti un nodrošināt precīzu prognožu kvalitāti. Savukārt SVR un LR metodes uzrāda visaugstākās vidējās globālās *CPM* vērtības, kas apstiprina šo metožu nepiemērotību ārējās vides faktoru un pašsvārstību frekvenču sakarības modelēšanai šajā gadījumā.

Metodes **4.posmā** tika izvēlēts XGBoost regresijas modelis ar viszemāko vidējo globālo *CPM* vērtību, lai noteiktu ārējās vides faktoru ietekmes segmentu robežas. Ārējās gaisa temperatūras, relatīvā mitruma, vēja garenvirziena komponentes V_g un vēja šķērsvirziena komponentes V_{sk} ietekmes segmenti apkopoti 4.36.att.




4.36.att. XGBoost metodes PDP līkne ārējās gaisa temperatūras (a), relatīvā mitruma (b), vēja garenvirziena komponentes V_g (c) un vēja šķērsvirziena komponentes V_{sk} (d) ietekmes segmentu noteikšanai koka rāmja monitoringa datos.

Ārējai gaisa temperatūrai tika definēti trīs ietekmes segmenti: līdz $+11.11^{\circ}\text{C}$, no $+11.11^{\circ}\text{C}$ līdz $+24.35^{\circ}\text{C}$, un virs $+24.35^{\circ}\text{C}$ (4.36.att. (a)). Relatīvā mitruma ietekmei tika definēti segmenti: līdz 59.73%, no 59.73% līdz 72.20%, un virs 72.20% (4.36.att. (b)). Vēja garenvirziena komponentes V_g ietekmei tika definēti segmenti: līdz -14.09 m/s, no -14.09 m/s līdz 4.11 m/s, un virs 4.11 m/s (4.36.att. (c)). Vēja šķērsvirziena komponentes V_{sk} ietekmei tika definēti segmenti: līdz -3.14 m/s, no -3.14 m/s līdz 14.17 m/s, un virs 14.17 m/s (4.36.att. (d)).

Ārējā gaisa temperatūrā līdz $+11.11^{\circ}\text{C}$ vidējās prognozētās pašsvārstību frekvenču vērtības pakāpeniski palielinās pieaugot temperatūras vērtībai. Segmentā no $+11.11^{\circ}\text{C}$ līdz $+24.35^{\circ}\text{C}$ novērojams pašsvārstību frekvenču vērtību samazinājums. Savukārt ārējās gaisa temperatūras segmentā virs $+24.35^{\circ}\text{C}$ frekvenču vērtību kritums kļūst mazāk izteikts salīdzinot ar iepriekšējo segmentu. Relatīvā mitruma ietekmes segmentā līdz 59.73% vidējās prognozētās pašsvārstību frekvenču vērtības pakāpeniski samazinās. Savukārt ietekmes segmentā no 59.73% līdz 72.20% un virs 72.20% novērojams vidējo prognozēto frekvenču vērtību pieaugums ar atsevišķiem lokāliem vērtību kritumiem. Vēja garenvirziena komponentes V_g visos trīs ietekmes segmentos vidējās prognozētās pašsvārstību frekvenču vērtības pakāpeniski pieaug ar atsevišķiem lokāliem vērtību kritumiem. Savukārt vēja šķērsvirziena komponentes V_{sk} ietekmes segmentā līdz -3.14 m/s novērojams frekvenču vērtību pieaugums, savukārt no -3.14 m/s līdz 14.17 m/s un virs 14.17 m/s frekvenču vērtības samazinās ar atsevišķiem lokāliem vērtību pieaugumiem.

Metodes **5.posmā** tiek noteikti atsevišķi regresijas modeļi katrā no ārējās vides faktora ietekmes segmentā. Katrai pašsvārstību frekvencei un katram regresijas modelim ārējās vides faktora ietekmes segmentā tiek aprēķināts saliktās efektivitātes rādītājs *CPM*.

Ārējās gaisa temperatūras un pašsvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.39.att.



4.39.att. PDP līknes tilta Filomena Delli Castelli pašsvārstību frekvencēm ārējās gaisa temperatūras ietekmē.

Kopējā tendence visos PDP grafikos (4.39.att.) norāda uz izteikti negatīvu korelāciju starp ārējā gaisa temperatūru un pašsvārstību frekvenču vērtībām. Ārējās gaisa temperatūras ietekmes segmentā no +11.11°C līdz +24.35°C regresijas modeļu prognozētās pašsvārstību frekvenču vērtības ir diezgan līdzīgas un kopējā izmaiņu tendence saglabājas nemainīga. Savukārt ietekmes segmentā līdz +11.11°C un segmentā virs +24.35°C frekvenču vērtību prognozes atšķiras gan starp dažādām frekvencēm, gan regresijas modeļiem.

Regresijas modeļu *CPM* vērtības ārējās gaisa temperatūras un pašsvārstību frekvenču sakarības modelēšanai atsevišķos segmentos ir apkopotas 4.40.attēlā.


	T ≤ 11.11°C							11.11°C < T ≤ 24.35°C							T > 24.35°C						
f1	0.61	3.74	5.59	-2.94	-5.86	-0.06	-1.08	-2.17	5.29	6.31	-2.62	-2.68	-2.38	-1.75	-1.89	8.91	0.18	-1.83	-1.72	-1.83	-1.82
f2	-2.42	3.04	7.57	-1.48	-2.84	-2.66	-1.21	-3.31	1.23	7.80	-0.08	-0.89	-4.26	-0.49	-3.93	4.82	5.91	0.04	-0.98	-3.86	-2.00
f3	-1.96	2.29	1.57	0.59	-4.16	0.91	0.76	-2.84	0.47	3.27	1.30	-4.37	0.90	1.28	-3.03	1.89	0.11	1.87	-1.95	0.45	0.66
f4	5.43	-0.07	2.28	0.32	-7.49	-0.62	0.15	4.68	0.08	3.76	0.46	-7.47	-1.60	0.09	0.38	1.54	2.75	2.12	-8.07	0.11	1.16
f5	1.46	-7.00	5.02	2.04	-3.31	0.81	0.98	1.59	-5.14	5.04	3.59	-4.94	-0.19	0.05	-2.05	-4.40	4.99	0.80	1.94	-0.49	-0.79
f6	6.67	-2.93	3.42	-0.44	-5.20	-1.53	-0.00	5.97	-3.33	3.82	0.13	-5.55	-1.11	0.06	7.00	-1.55	0.98	1.68	-4.73	-3.59	0.22
Mean	1.63	-0.15	4.24	-0.32	-4.81	-0.53	-0.07	0.65	-0.23	5.00	0.46	-4.32	-1.44	-0.13	-0.59	1.87	2.49	0.78	-2.58	-1.53	-0.43
Std	3.75	4.15	2.24	1.73	1.73	1.39	0.91	4.03	3.66	1.76	2.02	2.29	1.79	0.98	3.99	4.68	2.50	1.49	3.43	1.87	1.32
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR

4.40.att. *CPM* vērtības regresijas modeļiem ārējās gaisa temperatūras segmentā līdz +11.11°C, no +11.11°C līdz +24.35°C un virs +24.35°C tilta Filomena Delli Castelli monitoringa datos.

Ārējās gaisa temperatūras analīze norāda, ka temperatūras segmentos līdz +11.11°C, no +11.11°C līdz +24.35°C un virs +24.35°C viszemākās *CPM* vērtības sasniedz gradientu

palielināšanas regresijas (XGBoost) metode. GPR modelis visos segmentos uzrāda nedaudz augstākas, bet joprojām salīdzinoši zemas *CPM* vērtības, savukārt lineārā regresija (LR) un atbalsta vektora regresija (SVR) sasniedz visaugstākās *CPM* vērtības.

Relatīvā mitruma un pašsvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.41.att.



4.41.att. PDP līknes Filomena Delli Castelli tilta pašsvārstību frekvencēm relatīvā mitruma ietekmē.

Kopējā tendence relatīvā mitruma daļējas atkarības grafikos (4.41.att.) liecina, ka pašsvārstību frekvenču vērtības pieaug, palielinoties relatīvajam mitrumam. Relatīvā mitruma ietekmes segmentā līdz 59.73% var novērot ievērojamu prognozēšanas līkņu atšķirību starp dažādiem regresijas modeļiem salīdzinot ar pārējiem ietekmes segmentiem. Savukārt, pārējos relatīvā mitruma ietekmes segmentos vairumam pašsvārstību frekvencēm regresijas modeļu prognozēšanas vērtības ir līdzīgas un līknes grafikos pārklājas.


	RH ≤ 59.73%							59.73% < RH ≤ 72.20%							RH > 72.20%							
f1	-2.63	7.29	4.01	-1.43	-2.59	-2.24	-2.41	-1.32	8.73	0.66	-1.61	-2.79	-1.44	-2.24	-0.91	5.05	5.94	-3.29	-3.84	-1.64	-1.31	
f2	-4.78	2.75	6.54	1.25	-0.94	-4.28	-0.53	-4.37	3.99	5.83	1.04	-1.06	-4.44	-1.00	-2.23	1.82	8.11	-1.54	-2.08	-3.02	-1.07	5
f3	-7.27	1.25	4.58	1.89	-2.60	0.96	1.19	-4.04	2.70	1.20	1.47	-3.76	1.18	1.25	-1.89	1.06	2.11	0.97	-3.95	0.77	0.93	0
f4	2.61	1.54	3.26	1.99	-8.35	-1.11	0.06	2.53	1.09	2.86	2.02	-8.47	-0.73	0.71	5.32	-0.31	3.37	-0.05	-7.29	-1.19	0.15	
f5	-1.11	-6.58	4.69	5.08	-0.27	-0.94	-0.87	1.56	-7.06	2.82	4.52	-3.24	0.33	1.07	1.85	-5.32	5.59	2.12	-4.98	0.34	0.41	
f6	5.28	-2.11	3.47	2.99	-4.62	-3.66	-1.35	6.37	-2.28	2.03	1.56	-5.70	-2.02	0.04	6.25	-3.30	3.77	-0.47	-5.37	-1.06	0.17	
Mean	-1.32	0.69	4.43	1.96	-3.23	-1.88	-0.65	0.12	1.20	2.57	1.50	-4.17	-1.19	-0.03	1.40	-0.17	4.82	-0.38	-4.59	-0.97	-0.12	
Std. dev.	4.65	4.68	1.18	2.14	2.93	1.93	1.23	4.16	5.42	1.82	1.96	2.59	1.97	1.36	3.70	3.72	2.16	1.90	1.75	1.37	0.88	
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	

4.42.att. *CPM* vērtības regresijas modeļiem relatīvā mitruma segmentā līdz 59.73%, no 59.73% līdz 72.20% un virs 72.20% Filomena Delli Castelli tilta monitoringa datos.

Relatīvā mitruma ietekmes analīze liecina, ka segmentos līdz 59.73%, no 59.73% līdz 72.20% un virs 72.20% viszemākās vidējās *CPM* vērtības sasniedz XGBoost metode, apliecinot

tās labāko pielāgošanos nelineārām sakarībām. Lineārās regresijas (LR) modelis visos mitruma segmentos uzrāda visaugstākās *CPM* vērtības, kas norāda uz tā ierobežoto prognozēšanas spēju.

Vēja garenvirziena komponentes V_g un pašsvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.43.att.



4.43.att. PDP līknes Filomena Delli Castelli tilta pašsvārstību frekvencēm vēja garenvirziena komponentes V_g ietekmē.

Vēja garenvirziena komponentes V_g segmentā līdz -14.09 m/s regresijas modeļu spēja prognozēt pašsvārstību frekvenču vērtības atšķiras gan starp modeļiem, gan atsevišķām frekvencēm. Savukārt, ietekmes segmentos no -14.09 m/s līdz 4.11 m/s un virs 4.11 m/s vairumā regresijas modeļu pašsvārstību frekvenču vērtību prognozes ir savstarpēji līdzīgas.


	$V_g \leq -14.09$ m/s							$-14.09 < V_g \leq 4.11$ m/s							$V_g > 4.11$ m/s						
f1	-1.66	4.47	4.03	1.55	-6.54	-1.75	-0.10	-1.27	6.76	4.46	-3.02	-3.13	-1.86	-1.94	-1.35	6.10	4.68	-1.57	-5.33	-1.21	-1.32
f2	-5.08	1.61	7.31	1.20	-1.11	3.12	0.83	2.55	2.05	7.96	1.02	1.91	3.30	1.24	4.10	3.49	6.63	0.11	1.55	4.20	0.17
f3	-7.84	2.26	5.07	0.77	-1.30	0.28	0.76	-2.11	1.09	2.35	0.91	-3.92	0.90	0.78	-5.50	2.08	2.01	2.22	-4.27	1.10	2.35
f4	3.22	2.48	0.93	2.46	-8.40	-1.15	0.46	4.25	0.24	3.56	0.56	-7.95	-0.94	0.27	5.43	0.04	2.69	0.82	-7.30	-1.76	0.08
f5	-3.35	-4.40	-1.66	6.74	3.58	-0.82	-0.09	1.34	-5.76	5.26	2.73	-4.65	0.40	0.68	1.94	-6.36	5.24	3.66	-2.75	-0.73	-1.00
f6	7.46	-0.07	-0.80	2.70	-2.59	-3.98	-2.73	6.22	-3.30	3.48	-0.01	-5.56	-1.12	0.28	6.28	-2.40	4.31	-0.16	-4.74	-2.39	-0.89
Mean	-1.21	1.06	2.48	2.57	-2.73	-1.76	-0.42	0.98	0.18	4.51	0.03	-4.52	-0.99	-0.19	0.45	0.49	4.26	0.81	-4.32	-1.53	-0.16
Std. dev.	5.63	3.05	3.54	2.17	4.27	1.56	1.25	3.61	4.36	1.95	1.94	2.10	1.52	1.12	4.90	4.44	1.69	1.88	2.01	1.77	1.34
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR

4.44.att. *CPM* vērtības regresijas modeļiem vēja garenvirziena komponentes V_g segmentā līdz -14.09 m/s, no -14.09m/s līdz 4.11m/s un virs 4.11 m/s tilta Filomena Delli Castelli monitoringa datos.

Vēja garenvirziena komponentes V_g ietekmes analīze norāda, ka visos segmentos viszemākās *CPM* vērtības sasniedz XGBoost regresijas modelis. GPR sasniedz nedaudz augstāku vidējo *CPM* vērtību, atsevišķām pašsvārstību frekvencēm uzrādot labāku

prognozēšanas spēju nekā XGBoost metode. LR metode uzrāda visaugstākās vidējās CPM vērtības, kas apstiprina lineārā modeļa ierobežoto spēju precīzi prognozēt pašsvārstību frekvences vēja ātruma ietekmē šajā gadījumā.

Vēja šķērsvirziena komponentes V_{sk} un pašsvārstību frekvenču sakarību PDP grafiki kopā ar segmentu robežām ir apkopoti 4.43.att.



4.43.att. PDP līknes Filomena Delli Castelli tilta pašsvārstību frekvencēm vēja šķērsvirziena komponentes V_{sk} ietekmē.

Vēja šķērsvirziena komponentes V_{sk} segmentā līdz -3.14 m/s regresijas modeļu spēja prognozēt pašsvārstību frekvenču vērtības atšķiras gan starp modeļiem, gan atsevišķām frekvencēm līdzīgi kā vēja garenvirziena komponentes V_g gadījumā. Savukārt, ietekmes segmentos no -3.14 m/s līdz 14.17 m/s un virs 14.17 m/s arī vairumā regresijas modeļu pašsvārstību frekvenču vērtību prognozes ir savstarpēji līdzīgas un ir novērojams pašsvārstību frekvenču vērtību kritums.

	$V_{sk} \leq -3.14$ m/s							$-3.14 < V_{sk} \leq 14.17$ m/s							$V_{sk} > 14.17$ m/s						
f1	-1.66	4.47	4.03	1.55	-6.54	-1.75	-0.10	-1.74	7.93	2.88	-2.69	-2.41	-2.17	-1.80	-1.23	1.14	7.20	0.06	-6.17	0.43	-1.43
f2	-5.08	1.61	7.31	1.20	-1.11	-3.12	-0.83	-2.89	2.23	7.74	-0.90	-1.86	-3.56	-0.76	-4.34	2.65	7.09	1.47	-1.68	-3.03	-2.16
f3	-7.84	2.26	5.07	0.77	-1.30	0.28	0.76	-2.24	1.28	1.87	0.91	-3.85	1.17	0.86	-7.18	0.62	4.56	1.27	-3.09	1.42	2.40
f4	3.22	2.48	0.93	2.46	-8.40	-1.15	0.46	3.66	0.35	3.42	1.11	-8.12	-1.20	0.77	2.08	2.39	2.29	1.92	-8.71	-0.44	0.48
f5	-3.35	-4.40	-1.66	6.74	3.58	-0.82	-0.09	0.58	-4.45	5.90	1.78	-5.42	0.74	0.87	-0.52	-8.07	2.21	4.26	2.13	0.35	-0.37
f6	7.46	-0.07	-0.80	2.70	-2.59	-3.98	-2.73	7.15	-3.04	2.94	-0.58	-4.79	-1.39	-0.30	6.64	-0.44	-0.59	2.43	-3.08	-2.98	-1.98
Mean	-1.21	1.06	2.48	2.57	-2.73	-1.76	-0.42	0.75	0.72	4.13	-0.06	-4.41	-1.07	-0.06	-0.76	-0.29	3.79	1.90	-3.44	-0.71	-0.51
Std. dev.	5.63	3.05	3.54	2.17	4.27	1.56	1.25	3.95	4.37	2.23	1.65	2.27	1.78	1.09	4.84	3.98	3.07	1.40	3.73	1.87	1.74
	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR	SVR	RF	LR	DT	XGBoost	GPR	BR

4.44.att. CPM vērtības regresijas modeļiem vēja šķērsvirziena komponentes V_{sk} segmentā līdz -3.14 m/s, no -3.14 m/s līdz 14.17 m/s un virs 14.17 m/s Filomena Delli Castelli tilta monitoringa datos.

Vēja šķērsvirziena komponentes V_{sk} ietekmes analīze norāda, ka visos segmentos viszemākās CPM vērtības sasniedz XGBoost regresijas modelis. Līdzīgi kā vēja garenvirziena komponentes V_g ietekmes analīzē, RF, LR un DT metodes uzrāda visaugstākās vidējās CPM vērtības, kas apstiprina lineārā modeļa un atsevišķu nelineāro modeļu ierobežoto spēju precīzi prognozēt pašsvārstību frekvences vēja ātruma ietekmē šajā gadījumā.

Apkopojot visus CPM vērtību rezultātus no visiem septiņiem regresijas modeļiem zemākās CPM vērtības katram ārējās vides ietekmes faktoram konkrētā segmentā tika iegūtas izmantojot:

- 1) Gradientu palielināšanas regresijas (XGBoost) metodi - ārējās vides temperatūras segmentos līdz $+11.11^{\circ}\text{C}$, no $+11.11^{\circ}\text{C}$ līdz $+24.35^{\circ}\text{C}$, virs $+24.35^{\circ}\text{C}$, relatīvā mitruma segmentos no 0% līdz 59.73%, no 59.73% līdz 72.20%, virs 72.20%, vēja garenvirziena komponentes V_g segmentos līdz -14.09 m/s , no -14.09 m/s līdz 4.11 m/s , virs 4.11 m/s , kā arī vēja šķērsvirziena komponentes V_{sk} segmentos līdz -3.14 m/s , no -3.14 m/s līdz 14.17 m/s , virs 14.17 m/s .

Izmantojot XGBoost regresijas metodi, tika veidotas samazinātu vērtību punktu daļējas atkarības līknes katrai pašsvārstību frekvencei un katram ārējās vides ietekmes faktoram. Optimālais režģu punktu skaits apkopots 4.4.tabulā.

4.4.tabula

Optimālais režģa punktu skaits katram ārējās vides parametram Filomena Delli Castelli tilta monitoringa datiem

Pašsvārstību frekvences Nr.	Ārējās vides ietekmes faktors			
	Ārējā gaisa temperatūra	Relatīvais mitrums	Vēja garenvirziena komponente V_g	Vēja šķērsvirziena komponente V_{sk}
f1	100	100	100	100
f2	100	100	100	100
f3	100	100	100	100
f4	100	100	100	100
f5	100	100	100	100
f6	100	100	100	100

Apkopojot optimālo režģu punktu skaitu rezultātus redzams, ka XGBoost regresijas modeļa prognozēšanas detalizācijas līmenis sakrīt visām pašsvārstību frekvencēm un visiem ārējās vides ietekmes faktoriem. Režģu punktu skaits, kas nepieciešams, lai sasniegtu konverģences kritēriju, ir 100 punkti.

Ārējās vides ietekmes samazināšanas metodes nākamajos posmos pašsvārstību frekvenču vērtības tika koriģētas, izmantojot segmentētās PDP līknes katram ārējās vides ietekmes faktoram atsevišķi. Pēc segmentētās ietekmes noņemšanas uz koriģētajām pašsvārstību frekvenču vērtībām tika trenēti papildu regresijas modeļi, lai identificētu atlikušās nelineārās sakarības. Pēdējā posmā tika veikta sezonālās variācijas noņemšana, iegūstot koriģētās pašsvārstību frekvenču vērtības.

4.8. Konstrukciju bojājumu noteikšanas algoritmu rezultāti pēc ārējās vides ietekmes samazināšanas metodes piemērošanas

Mahalanobisa distances algoritms, galveno komponentu analīze (PCA), vienklares atbalsta vektora (OC-SVM) analīze un Gausa jauktā modeļa (GMM) noviržu analīze tika izmantota, lai novērtētu citās publikācijās izmantoto ārējās vides faktoru ietekmes samazināšanas metožu efektivitāti. Salīdzinājumam tika izmantotas tikai tās metodes, kurās ārējās vides parametri tiek tieši modelēti un to ietekme tiek samazināta, balstoties uz konstrukciju dinamisko parametru analīzi. Metodes tika pielāgotas koka rāmja monitoringa datiem. Katras metodes ietvaros tika analizēts un samazināta tikai publikācijā norādītā ārējās vides faktora ietekme.


4.5.tabula

Publikācijās izmantoto ārējo vides ietekmes samazināšanas metožu rezultāti konstrukciju bojājumu noteikšanai, izmantojot visas sešas koka rāmja pašsvārstību frekvences


	Mahalanobisa distances algoritms	PCA metode	OC-SVM metode	GMM metode
Galveno komponentu analīze (PCA) [107]				
Kļūdaini pozitīvi	423	345	355	374
Kļūdaini negatīvi	459	430	446	464
Sabalansētā precizitāte	0.70	0.72	0.71	0.70
Δ Sab.prec.	-	+0.07	-0.03	-
Autoregresīvie modeļi [108]				
Kļūdaini pozitīvi	591	680	653	652
Kļūdaini negatīvi	757	733	743	742
Sabalansētā precizitāte	0.51	0.52	0.51	0.51
Δ Sab.prec.	-0.19	-0.13	-0.23	-0.19
Bajesa modeļa atjaunināšana [112]				
Kļūdaini pozitīvi	340	342	234	361
Kļūdaini negatīvi	455	440	413	451
Sabalansētā precizitāte	0.71	0.72	0.74	0.71
Δ Sab.prec.	+0.01	+0.07	-	+0.01

Ārējās vides faktoru ietekmes samazināšanas metožu iegūtie rezultāti koka rāmja pašsvārstību frekvenču korekcijai liecina, ka publikācijās piedāvātās metodes nenodrošina būtisku konstrukciju bojājumu noteikšanas precizitātes uzlabojumu. Lai gan atsevišķos gadījumos novērojams neliels sabalansētās precizitātes pieaugums, kopumā rezultāti atšķiras un ir atkarīgi no izvēlētas konstrukciju bojājumu noteikšanas metodes.


Lai novērtētu promocijas darbā izstrādātās adaptīvās ārējo vides faktoru ietekmes samazināšanas metodes efektivitāti **koka rāmja** pašsvārstību frekvencēm, tika izmantoti iepriekš analizētie visi četri konstrukciju bojājumu noteikšanas algoritmi. Katrai metodei tika noteikta sabalansētā precizitāte, kļūdaini pozitīvo un kļūdaini negatīvo rezultātu skaits, līdzīgi kā tas tika noteikts pirms ārējās vides ietekmes samazināšanas metodes piemērošanas (4.45.att.). Ņemot vērā šos rādītājus, tika analizēts vai ārējās vides ietekmes samazināšanas metode uzlabo katra modeļa spēju identificēt konstrukciju bojājumus un vai algoritms samazina kļūdaini pozitīvo rezultātu skaitu, kas šajā eksperimentā tika novēroti ziemas periodā.




(a)




(b)



(c)



(d)



4.45.att. Mahalanobisa distances algoritma (a), PCA metodes (b), OC-SVM metodes (c) un GMM metodes (d) rezultāti konstrukciju bojājumu noteikšanai, izmantojot visas sešas koka rāmja pašsvārstību frekvences pēc ārējo vides faktoru ietekmes korekcijas.


Mahalanobisa distances algoritmam, pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas ievērojami mainījās kļūdaino rezultātu skaits – kļūdaini pozitīvo

rezultātu skaits nepārsniedza 148 un kļūdaini negatīvo rezultātu skaits samazinājās līdz 195. Metodes sabalansētā precizitāte sasniedza 87%. Pēc ārējās vides ietekmes samazināšanas, Mahalanobisa distances algoritms identificē pilnībā konstrukciju bojājumu datus sākot ar 2.pakāpi, kā arī daļēji identificē 1.pakāpes konstrukciju bojājumu datus, kas tika izraisīts, pievelkot visu skrūvju savienojumus.


Galveno komponentu (PCA) metodei, pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas, sabalansētā precizitāte sasniedza 95%. Kļūdaini pozitīvo rezultātu skaits samazinājās līdz 48 un kļūdaini negatīvo rezultātu skaits – līdz 77. Pēc ārējās vides faktoru ietekmes samazināšanas, PCA metode identificēja konstrukciju bojājuma datus sākot ar 2.pakāpi, kā arī daļēji identificē 1.pakāpes bojājumu datus.

Vienklasses atbalsta vektora (OC-SVM) metodei, pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas, pašsvārstību frekvenču datiem kļūdaini pozitīvo rezultātu datu skaits samazinājās līdz 76 un kļūdaini negatīvo skaits līdz 166 datu punktiem. OC-SVM metodes sabalansētā precizitāte šajā gadījumā sasniedza 0.90 jeb 90%. Līdz ar to pēc ārējās vides faktoru ietekmes samazināšanas OC-SVM metode spēja pilnībā identificēt konstrukciju bojājumu, sākot ar 2.pakāpes bojājumu un daļēji identificēt arī 1.pakāpes bojājuma datus, kurus pirms tam klasificēja pilnībā kā nebojātās konstrukcijas datus.

Gausa jauktā modeļa (GMM) analīzē, pēc ārējās vides faktoru ietekmes samazināšanas metodes, būtiski samazinājās kļūdaini pozitīvo rezultātu skaits līdz 134 un kļūdaini negatīvo datu skaits līdz 224. Savukārt metodes sabalansētā precizitāte pieauga līdz 0.86 jeb 86%. Līdzīgi kā pārējām metodēm, pēc ārējās vides faktoru ietekmes samazināšanas, GMM metode spēja pilnībā identificēt konstrukciju bojājumus, sākot ar 2.pakāpes bojājumu un daļēji identificēt arī 1.pakāpes bojājuma datus.



4.46.att. Mahalanobisa distances algoritma (a) un PCA metodes (b) kļūdaini pozitīvo rezultātu izvietojums ārējo vides ietekmes faktoru izmaiņu grafikā pēc pašsvārstību frekvenču vērtību korekcijas.



4.47.att. OC-SVM metodes (c) un GMM metodes (d) kļūdaini pozitīvo rezultātu izvietojums ārējo vides ietekmes faktoru izmaiņu grafikā pēc pašsvārstību frekvenču vērtību korekcijas.

Apkopojot un analizējot kļūdaini pozitīvos gadījumus jeb viltus trauksmes pēc pašsvārstību frekvenču vērtību korekcijas ārējo vides faktoru izmaiņu grafikos (4.46.att., 4.47.att.), var secināt, ka Mahalanobisa distancēs algoritma, OC-SVM, PCA un GMM metodes identificētās anomālijas ir izkliedētas visā novērojumu periodā un nav izteikti koncentrētas zemas ārējās gaisa temperatūras un augsta relatīvā mitruma līmeņa vērtību periodos.


Ārējās vides faktoru ietekmes samazināšanas metodes iegūtie rezultāti **koka rāmja** pašsvārstību frekvenču vērtību korekcijai liecina, ka ārējo vides ietekmes faktoru korekcija būtiski samazina kļūdaini pozitīvo un kļūdaini negatīvo rezultātu skaitu, līdz ar to uzlabojot visu analizēto metožu efektivitāti. Iegūtie kļūdaini pozitīvie un kļūdaini negatīvie rezultāti pirms un pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas apkopoti 4.6.tabulā.

4.6.tabula

Rezultātu salīdzinājums dažādiem konstrukciju bojājumu noteikšanas algoritmiem

	Mahalanobisa distancēs algoritms	PCA metode	OC-SVM metode	GMM metode
Kļūdaini pozitīvo datu punktu skaits				
Pirms korekcijas	404	422	202	377
Pēc korekcijas	148	48	76	134
Kļūdaini negatīvo datu punktu skaits				
Pirms korekcijas	464	535	410	467
Pēc korekcijas	195	77	166	224

Analizējot kļūdaini pozitīvo un kļūdaini negatīvo rezultātu datu skaita izmaiņas pirms un pēc ārējo vides ietekmes faktoru korekcijas (4.6.tab.) koka rāmja monitoringa periodā, var secināt, ka OC-SVM un PCA metode vislabāk novērsa kļūdaini pozitīvo jeb viltus trauksmju rezultātus, kas šajā gadījumā bija izteikti koncentrēti ziemas periodā. Savukārt, kļūdaini negatīvo rezultātu datu skaits jeb neidentificēto konstrukciju bojājumu skaits visvairāk tika samazināts, izmantojot PCA metodi un vismazāk – izmantojot GMM metodi.




4.48.att. Sabalansētās precizitātes salīdzinājums izmantotajām metodēm.

Salīdzinot visu četru metožu efektivitāti (4.48.att.), ārējās vides ietekmes faktoru samazināšana vidēji paaugstināja sabalansēto precizitāti no 70% līdz 90%. Pirms ārējās vides ietekmes faktoru samazināšanas katrā no metodēm sabalansētās precizitātes rādītāji atšķīrās un variēja no 65% līdz 74%. Savukārt, pēc ārējās vides ietekmes faktoru samazināšanas sabalansētās precizitātes rādītāji visām metodēm variēja no 86% līdz 95%. Vislielākais sabalansētās precizitātes uzlabojums tika novērots PCA metodei, savukārt viszemākais tika iegūts izmantojot GMM metodi.


Lai papildus novērtētu ārējās vides faktoru ietekmes samazināšanas metodes efektivitāti, **koka rāmja** pašsvārstību frekvencēm tika veikta frekvenču vērtību izmaiņu analīze, kurā aprēķinātas frekvenču izmaiņas Δf , salīdzinātas frekvenču laika rindas pirms un pēc korekcijas (4.50.att.), kā arī noteikti variācijas koeficienti (*CV*, *Coefficient of Variation*) (4.51.att.). Pašsvārstību frekvenču laika rindu grafiki ļauj vizuāli analizēt korekcijas ietekmi visā monitoringa periodā un izmaiņu apjoms Δf tiek attēlots kastu diagrammās (4.49.att.). Pašsvārstību frekvenču vērtību izmaiņa Δf raksturo, cik lielā mērā korekcijas metode maina frekvenču vērtības katrā mērījuma brīdī. Kastu diagrammas vizuāli parāda Δf sadalījumu, ļaujot novērtēt, vai korekcija rada stabilu un vienmērīgu ietekmi visām pašsvārstību frekvencēm.

Koka rāmja pašsvārstību frekvenču vērtību izmaiņu sadalījums pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas visām sešām pašsvārstību frekvencēm apkopots 4.48.attēlā.



4.49.att. Koka rāmja pašsvārstību frekvenču izmaiņu sadalījums pēc korekcijas.


Analizējot koka rāmja pašsvārstību frekvenču izmaiņu sadalījumu pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas var secināt, ka pirmajām trim pašsvārstību frekvencēm f_1 , f_2 un f_3 izmaiņas ir nelielas un vienmērīgas, ar mediānas vērtībām tuvu nullei, kas norāda uz stabilu korekcijas ietekmi. Savukārt augstāko pašsvārstību frekvenču f_4 , f_5 un f_6 gadījumā mediāna joprojām saglabājas tuvu nullei, tomēr novērojama nedaudz lielāka izkliede ap šo vērtību, kas norāda uz korekcijas ietekmes pieaugumu, neieviešot sistemātisku nobīdi.



4.50.att. Koka rāmja pašsvārstību frekvences f_1 – f_6 izmaiņas monitoringa periodā.

Analizējot koka rāmja pašsvārstību frekvenču vērtības pirms un pēc korekcijas (4.50.att.), var secināt, ka korekcijas metode būtiski samazina frekvenču vērtību izkliedi un sezonālā rakstura svārstības visā monitoringa periodā. Pēc korekcijas pašsvārstību frekvenču laika rindas kļūst vienmērīgākas, samazinās gan kopējā vērtību izkliede, gan īstermiņa lokālās svārstības. Īpaši izteikta korekcijas ietekme novērojama pirmajām trim pašsvārstību frekvencēm. Augstākām pašsvārstību frekvencēm korekcijas efekts ir tikai nedaudz mazāk, tomēr arī šīm frekvenču vērtībām ir novērojama būtiska svārstību amplitūdu samazināšanās.


Variācijas koeficients CV tiek noteikts kā frekvenču standartnovirzes attiecība pret to vidējo vērtību un tiek izteikts procentos. Variācijas koeficients raksturo relatīvo izkliedi un ļauj salīdzināt frekvences ar atšķirīgām vidējām vērtībām. Mazāks CV norāda uz mazākām svārstībām un stabilākām frekvenču vērtībām [188]. Ja pēc korekcijas CV vērtība ir mazāka nekā CV vērtība pirms korekcijas, tas liecina, ka ārējās vides ietekmes samazināšanas metode ir efektīvi stabilizējusi frekvenču vērtības. Grafikā (4.51.att.) vizuāli tiek salīdzinātas koka rāmja pašsvārstību frekvenču CV vērtības pirms un pēc korekcijas, norādot korekcijas metodes rezultātu katrai pašsvārstību frekvencei atsevišķi.



4.51.att. Variācijas koeficienta *CV* salīdzinājums koka rāmja pašsvārstību frekvencēm.

Variācijas koeficientu *CV* salīdzinājums pirms un pēc pašsvārstību frekvenču vērtību korekcijas (4.51.att.) parāda būtisku frekvenču vērtību svārstību samazinājumu pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas. Visām sešām pašsvārstību frekvencēm *CV* vērtības pēc korekcijas ir ievērojami mazākas nekā pirms korekcijas. Iegūtie rezultāti apliecina, ka ārējās vides faktoru ietekmes samazināšanas metode efektīvi stabilizē koka rāmja konstrukciju pašsvārstību frekvenču vērtības, būtiski samazinot frekvenču izkliedi un uzlabojot datu piemērotību turpmākai konstrukciju tehniskā stāvokļa novērtēšanai un bojājumu identificēšanai.


Lai novērtētu vai ārējās vides faktoru ietekmes samazināšanas metode efektīvi koriģē **Filomena Delli Castelli tilta** pašsvārstību frekvenču monitoringa vērtības, arī tika veikta frekvenču izmaiņu analīze, kurā tika salīdzinātas frekvenču laika rindas pirms un pēc korekcijas (4.52.att.), aprēķinātas frekvenču izmaiņas Δf (4.53.att.), kā arī noteikti variācijas koeficienti *CV* (4.54.att.).



4.52.att. Tilta pašsvārstību frekvences $f_1 - f_6$ izmaiņas monitoringa periodā.

Analizējot tilta konstrukciju pašsvārstību frekvenču vērtības pirms un pēc korekcijas (4.52.att.), var secināt, ka tikai f_1 un f_2 pašsvārstību frekvencēm korekcijas metode būtiski maina frekvenču vērtību svārstības novērojumu periodā. Pārējām pašsvārstību frekvencēm vērtību izmaiņas ir minimālas. Laika rindu grafikos novērojams, ka pēc frekvenču korekcijas vērtības kļūst vienmērīgas ar mazāk izteiktām lokālām svārstībām un sezonālās ietekmes efektiem.


Tilta pašsvārstību frekvenču vērtību izmaiņu sadalījums pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas visām sešām pašsvārstību frekvencēm apkopots 4.53.attēlā.



4.53.att. Tilta pašsvārstību frekvenču izmaiņu sadalījums pēc korekcijas.

Kastu diagrammas rezultāti (4.53.att.) norāda, ka frekvenču izmaiņu sadalījums pēc korekcijas nav vienmērīgs visām pašsvārstību frekvencēm. Zemākajām frekvencēm f_1 , f_2 un f_3 izmaiņu vērtības Δf koncentrējas ap nulli, norādot, ka korekcijas metode šajās frekvencēs rada tikai nelielas svārstības un saglabā stabilu frekvenču vērtību līmeni visā novērojumu periodā. Savukārt augstākajām pašsvārstību frekvencēm f_4 , f_5 un f_6 novērojama lielāka Δf izkliede, ko raksturo plašāks starpkvartīļu apgabals (IQR) un atsevišķas lokālas novirzes.

Tilta pašsvārstību frekvenču izmaiņām pirms un pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas grafikā (4.54.att.) tiek salīdzinātas CV vērtības, norādot korekcijas metodes rezultātu katrai pašsvārstību frekvencei atsevišķi.



4.54.att. Variācijas koeficienta CV salīdzinājums tilta pašsvārstību frekvencēm.

Variācijas koeficientu CV iegūtie rezultāti pirms un pēc ārējās vides faktoru ietekmes samazināšanas parāda skaidru frekvenču svārstību samazinājumu pēc korekcijas veikšanas. Zemākajām pašsvārstību frekvencēm f_1 , f_2 un f_3 CV vērtības pēc korekcijas ir būtiski mazākas nekā pirms korekcijas, kas norāda uz stabilāku un mazāk mainīgu frekvenču vērtību izkliedi novērojumu periodā. Iegūtie rezultāti apstiprina, ka ārējās vides faktoru ietekmes samazināšanas metode efektīvi koriģē tilta pašsvārstību frekvenču vērtības, samazinot frekvenču vērtību izkliedi novērojumu periodā. Ietekmes samazināšanas metode spēj nodrošināt stabilas un precīzas frekvenču vērtību izmaiņas, uzlabojot datu interpretāciju konstrukciju bojājumu noteikšanas metodēm.

Secinājumi

Promocijas darbā tika izstrādāta un aprobēta jauna, adaptīva metode būvju nesošo konstrukciju tehniskā stāvokļa monitoringam, kas ļauj kompensēt mainīgo ārējo vides faktoru ietekmi un palielināt bojājumu noteikšanas precizitāti. Metode balstās vairāku mašīnmācīšanās algoritmu kombinētā lietojumā un segmentētā ārējās vides faktoru ietekmes modelēšanā, kas nodrošina būtiski augstāku konstrukciju bojājumu noteikšanas precizitāti un samazina viltus trauksmju risku. Metode tika pārbaudīta, izmantojot divstāvu koka rāmja un Filomena Delli Castelli tilta konstrukciju ilgtermiņa monitoringa datus, pierādot tās praktisko lietojamību dažādu būvju konstrukcijām.

Divstāvu koka rāmja un Filomena Delli Castelli tilta konstrukciju eksperimentāli iegūto dinamisko monitoringa datu analīze skaidri norādīja, ka būvju pašsvārstību frekvenču vērtības būtiski ietekmē ārējie vides faktori, piemēram, ārējā gaisa temperatūra, relatīvais mitrums un vējš.

Tika apkopoti galvenie secinājumi.

- 1) Tika konstatēts, ka ārējo vides faktoru ietekmes apjoms un raksturs uz konstrukciju pašsvārstību frekvencēm ir izteikti nelineārs un mainīgs dažādos sezonālajos periodos. Šī iemesla dēļ identificēto pašsvārstību frekvenču datu segmentācija nodrošina ievērojami precīzāku ietekmes samazināšanu, ņemot vērā vienotu metodes lietojumu katram diapazonam atsevišķi.
- 2) Ārējās vides faktoru ietekmes samazināšanas metodes pieeja kombinē vairāku regresijas modeļu adaptīvu izvēli ar fiziski pamatotu segmentāciju katram ārējās vides ietekmes faktoram atsevišķi. Saliktās efektivitātes rādītāja (*CPM*) vērtību aprēķins liecināja par būtisku atšķirību starp modeļu efektivitāti, pamatojot nepieciešamību piemērot ārējās vides faktora ietekmes segmentiem dažādus regresijas modeļus atkarībā no konkrētā diapazona rakstura.
- 3) Daļējas atkarības diagrammas (*PDP*) katrai pašsvārstību frekvencei un katram ārējās vides ietekmes faktoram skaidri norādīja, ka lineārā regresija (*LR*) sniedz tikai vispārīgu tendenci par pašsvārstību frekvenču izmaiņām atkarībā no ārējās vides faktora izmaiņām. Nelineārie regresijas modeļi spēja labāk pielāgoties un aprakstīt pašsvārstību frekvenču izmaiņas, tomēr arī šajā gadījumā precizitāte bija atkarīga no izvēlēta modeļa. Augstāko precizitāti ārējās vides faktoru ietekmes un pašsvārstību frekvenču izmaiņu sakarības modelēšanai sasniedza *XGBoost* un *Bajesa* regresija (*BR*) koka rāmja gadījumā un *XGBoost* regresija tilta gadījumā.
- 4) Metodes piemērošanas rezultātā tiek iegūta diskrētu daļējas atkarības diagrammu (*PDP*) vērtību kopa, kas apkopo būtiskāko informāciju par ārējās vides ietekmi uz pašsvārstību frekvenču vērtībām. Šāda pieeja ļauj aizstāt liela apjoma mācību datu kopu ar samazinātu, strukturētu references datu kopu, būtiski samazinot uzglabājamo datu apjomu, vienlaikus saglabājot augstu korekcijas precizitāti.
- 5) Pētījuma rezultāti apstiprināja, ka izstrādātā metode būtiski uzlabo konstrukciju bojājumu noteikšanas algoritmu precizitāti. Pirms frekvenču vērtību korekcijas

Mahalanobisa distances algoritms, PCA, OC-SVM un GMM metodes uzrādīja plašu klūdaini pozitīvo un negatīvo rezultātu izkliedi, īpaši ziemas periodā.

- 6) Pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas koka rāmja pašsvārstību frekvenču monitoringa datiem Mahalanobisa distances algoritma sabalansētā precizitāte palielinājās no 70 % līdz 87 %, PCA metodes sabalansētā precizitāte palielinājās no 65 % līdz 95 %, savukārt OC-SVM un GMM metožu sabalansētā precizitāte pēc korekcijas palielinājās no 74 % līdz 90 % un no 70 % līdz 86 %. Iegūtie rezultāti apstiprina, ka pēc ārējās vides ietekmes samazināšanas metodes piemērošanas pašsvārstību frekvenču monitoringa datiem mašīnmācīšanās algoritmi spēj nošķirt ārējās vides izraisītās izmaiņas no faktiskajām konstrukciju bojājumu pazīmēm, būtiski uzlabojot bojājumu noteikšanas ticamību.
- 7) Pēc ārējās vides ietekmes samazināšanas metodes piemērošanas tilta pašsvārstību frekvencēm tika novērots būtisks frekvenču vērtību izkļiedes samazinājums zemākajām frekvencēm. Variācijas koeficienta *CV* samazinājums visām pašsvārstību frekvencēm apstiprina, ka metode efektīvi kompensē ārējo vides faktoru ietekmes radītās svārstības.

Lai nodrošinātu konstrukciju bojājumu noteikšanas uzticamību un precīzu konstrukciju tehniskā stāvokļa novērtēšanu, monitoringa sistēmas ieviešanai praksē ir jāievēro vairāki būtiski priekšnosacījumi.

- 1) Lai nodrošinātu pilnīgu un reprezentatīvu datu ieguvu, monitoringa sistēmās ir nepieciešams integrēt vairākus sensorus, piemēram, akselerometrus, ārējā gaisa temperatūras, relatīva mitruma, vēja ātruma sensorus.
- 2) Monitoringa iekārtas ir periodiski jāpārbauda un jākalibrē, lai nodrošinātu augstu mērījumu precizitāti, lai novērstu pašu sensoru bojājumus.
- 3) Mērierīces ir jānovieto konstrukcijas kritiskajos punktos, lai iegūtu detalizētus datus par konstrukcijas svārstībām dažādos virzienos un punktos.
- 4) Lai iegūtu ticamus un reprezentatīvus rezultātus par dinamisko parametru izmaiņām, ir nepieciešams veikt monitoringu vismaz viena gada garumā, kas ļauj novērot sezonālās svārstības.

Promocijas darbs sniedz nozīmīgu ieguldījumu būvkonstrukciju tehniskā stāvokļa monitoringā, nodrošinot racionālu resursu izmantošanu. Metodes praktiskā lietojamība nodrošina iespēju plānot uzturēšanas un atjaunošanas darbus, balstoties kvantitatīvos konstrukcijas tehniskā stāvokļa novērtējumos, nevis periodiskos vizuālo pārbaūžu rezultātos. Izstrādātā pieeja veicina pāreju no tradicionālās datus balstītas būvju uzturēšanas prakses, kas ir būtiska ilgtspējīgas būvniecības un ekspluatācijas stratēģijas sastāvdaļa.

Izstrādātās metodes validācija balstīta vienkāršotā divstāvu koka rāmja modelī ar pielāgotām frekvencēm un viena tilta ilgtermiņa monitoringa datus, kas ierobežo rezultātu vispārināmību uz sarežģītām reālām konstrukcijām. Bojājumi tika simulēti nesagraujoši, neietverot neatgriezeniskus defektu. Metodes efektivitāte ir atkarīga no augstas kvalitātes un nepārtrauktiem monitoringa datiem, kas praksē ne vienmēr ir nodrošināti. Pētījumā tika ņemti vērā tikai galvenie ārējās vides faktori, tāpēc reālos objektos var būt nepieciešama paplašināta ietekmju kopa un papildu korekcijas.

Literatūras avoti

- [1] A. Malekloo, E. Ozer, M. AlHamaydeh, un M. Girolami, "Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights", 2022. gada 1. jūlijā, *SAGE Publications Ltd*. doi: 10.1177/14759217211036880.
- [2] Ministru kabineta 2021.gada 15.jūnija noteikumi Nr. 384, "Būvju tehniskās apsekošanas būvnormatīvs LBN 405-21". Skatīts: 2023. gada 24. oktobrī. [Tiešsaiste]. Pieejams: <https://likumi.lv/ta/id/324221-buvju-tehniskas-apsekosanas-buvnormativs-lbn-405-21>
- [3] Centrālā statistikas pārvalde, "Jaunbūvju skaita indekss (2021=100) – Ēku veids, Koriģēšana un Laika periods". Skatīts: 2025. gada 25. februārī. [Tiešsaiste]. Pieejams: <https://data.stat.gov.lv>
- [4] Rīgas valstspilsētas pašvaldība, "Teritorijas plānojumi". Skatīts: 2025. gada 24. maijā. [Tiešsaiste]. Pieejams: <https://georiga.lv/portal/apps/webappviewer/index.html?id=8c4e85a205444317bcbe094b42ef6aa5&locale=lv>
- [5] "Ministru kabineta 2024.gada 18.jūnija noteikumi Nr. 364, "Būvkonstrukciju projektēšanas būvnormatīvs LBN 217-24 """. Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://likumi.lv/ta/id/352913-buvkonstrukciju-projektesanas-buvnormativs-lbn-217-24>
- [6] Rīgas valstspilsētas pašvaldība, "Pilsētvide". Skatīts: 2025. gada 24. maijā. [Tiešsaiste]. Pieejams: <https://georiga.lv/portal/apps/webappviewer/index.html?id=06a659346b5446509311676b7219b4ed&locale=lv>
- [7] Rīgas domes Pilsētas attīstības departaments, "Vēsture". Skatīts: 2023. gada 24. oktobrī. [Tiešsaiste]. Pieejams: <https://www.rdpad.lv/departaments/vesture/>
- [8] Ministru kabineta 2010.gada 28.septembra noteikumi Nr.907, "Noteikumi par dzīvojamās mājas apsekošanu, tehnisko apkopi un kārtējo remontu". Skatīts: 2023. gada 24. oktobrī. [Tiešsaiste]. Pieejams: <https://likumi.lv/ta/id/218831-noteikumi-par-dzivojamas-majas-apsekosanu-tehnisko-apkopi-un-kartejo-remontu>
- [9] European Commission, "New rules for greener and smarter buildings will increase quality of life for all Europeans". Skatīts: 2025. gada 19. maijā. [Tiešsaiste]. Pieejams: https://commission.europa.eu/news/new-rules-greener-and-smarter-buildings-will-increase-quality-life-all-europeans-2019-04-15_en
- [10] S. Chandrasekaran, *Structural Health Monitoring with Application to Offshore Structures*. World Scientific, 2019. doi: 10.1142/11302.
- [11] C. R. Farrar, S. W. Doebling, un D. A. Nix, "Vibration-based structural damage identification", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 359, nr. 1778, lpp. 131–149, 2001, doi: 10.1098/rsta.2000.0717.

- [12] K. Worden un J. M. Dulieu-Barton, "An Overview of Intelligent Fault Detection in Systems and Structures", *Struct. Health Monit.*, sēj. 3, nr. 1, lpp. 85–98, 2004, doi: 10.1177/1475921704041866.
- [13] D. M. Frangopol, "Life-Cycle performance, management, and optimisation of structural systems under uncertainty: Accomplishments and challenges", *Structure and Infrastructure Engineering*, sēj. 7, nr. 6, lpp. 389–413, 2011, doi: 10.1080/15732471003594427.
- [14] Z. Jiawei, "The Application of Structural Health Monitoring in Different Engineering Fields", no *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, janv. 2021. doi: 10.1088/1755-1315/643/1/012164.
- [15] Hua-Peng Chen, *Structural Health Monitoring of Large Civil Engineering Structures*. John Wiley & Sons Limited, 2018.
- [16] "Scopus, Analyze search results: Structural Health Monitoring". Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [17] "Scopus, Analyze search results: Structural Health Monitoring and Buildings". Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [18] "Scopus, Analyze search results: Structural Health Monitoring and Buildings and Vibration". Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [19] "Scopus, Analyze search results: Structural Health Monitoring and Bridges". Skatīts: 2025. gada 22. novembrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [20] "Scopus, Analyze search results: Structural Health Monitoring and Bridges and Vibration". Skatīts: 2025. gada 22. novembrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [21] C. R. Farrar un K. Worden, "An introduction to structural health monitoring", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 365, nr. 1851, lpp. 303–315, 2007, doi: 10.1098/rsta.2006.1928.
- [22] E. Peter Carden un J. M. W. Brownjohn, "ARMA modelled time-series classification for structural health monitoring of civil infrastructure", *Mech. Syst. Signal Process.*, sēj. 22, nr. 2, lpp. 295–314, febr. 2008, doi: 10.1016/j.ymssp.2007.07.003.
- [23] A. Pierdicca, F. Clementi, P. Mezzapelle, A. Fortunati, un S. Lenci, "One-year monitoring of a reinforced concrete school building: Evolution of dynamic behavior during retrofitting works", no *Procedia Engineering*, Elsevier Ltd, 2017, lpp. 2238–2243. doi: 10.1016/j.proeng.2017.09.206.
- [24] R. Brincker un C. Ventura, *Introduction to operational modal analysis*. John Wiley & Sons, Ltd, United Kingdom, 2015.
- [25] D. J. Ewins, *Modal testing : theory, practice, and application*. Baldock: Research Studies Press, 2000.

- [26] A. Malekloo, E. Ozer, M. AlHamaydeh, un M. Girolami, "Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights", *Struct. Health Monit.*, sēj. 21, nr. 4, lpp. 1906–1955, jūl. 2022, doi: 10.1177/14759217211036880.
- [27] J. Humar, A. Bagchi, un H. Xu, "Performance of vibration-based techniques for the identification of structural damage", *Struct. Health Monit.*, sēj. 5, nr. 3, lpp. 215–241, sept. 2006, doi: 10.1177/1475921706067738.
- [28] H. P. Chen, "Nonlinear perturbation theory for structural dynamic systems", *AIAA Journal*, sēj. 43, nr. 11, lpp. 2412–2421, 2005, doi: 10.2514/1.15207.
- [29] K. He un W. D. Zhu, "Structural damage detection using changes in natural frequencies: Theory and applications", *J. Phys. Conf. Ser.*, sēj. 305, nr. 1, 2011, doi: 10.1088/1742-6596/305/1/012054.
- [30] S. W. Doebling, C. R. Farrar, un M. B. Prime, "A summary review of vibration-based damage identification methods", *Shock and Vibration Digest*, sēj. 30, nr. 2, lpp. 91–105, 1998, doi: 10.1177/058310249803000201.
- [31] Y. Zhuang, J. Qin, B. Chen, C. Dong, C. Xue, un S. M. Easa, "Data Loss Reconstruction Method for a Bridge Weigh-in-Motion System Using Generative Adversarial Networks", *Sensors*, sēj. 22, nr. 3, febr. 2022, doi: 10.3390/s22030858.
- [32] A. M. Belostotsky un P. A. Akimov, "Adaptive Finite Element Models Coupled with Structural Health Monitoring Systems for Unique Buildings", no *Procedia Engineering*, Elsevier Ltd, 2016, lpp. 83–88. doi: 10.1016/j.proeng.2016.08.084.
- [33] C. Michel, P. Guéguen, un P. Y. Bard, "Dynamic parameters of structures extracted from ambient vibration measurements: An aid for the seismic vulnerability assessment of existing buildings in moderate seismic hazard regions", *Soil Dynamics and Earthquake Engineering*, sēj. 28, nr. 8, lpp. 593–604, aug. 2008, doi: 10.1016/j.soildyn.2007.10.002.
- [34] Rytter A., "Vibrational based inspection of civil engineering structures", *PhD Thesis, Dept. of Building Technology and Structural Engineering. Aalborg University*, 1993.
- [35] C. R. Farrar, G. Park, D. W. Allen, un M. D. Todd, "Sensor network paradigms for structural health monitoring", *Struct. Control Health Monit.*, sēj. 13, nr. 1, lpp. 210–225, janv. 2006, doi: 10.1002/stc.125.
- [36] E. Figueiredo, G. Park, J. Figueiras, C. Farrar, un K. Worden, "Structural health monitoring algorithm comparisons using standard data sets", United States, 2009. doi: 10.2172/961604.
- [37] K. Eltoumy, M. Gomaa, un X. Liang, "Unsupervised Learning Methods for Data-Driven Vibration-Based Structural Health Monitoring: A Review", *Sensors*, sēj. 23, nr. 6, mar. 2023, doi: 10.3390/s23063290.
- [38] K. Worden, H. Sohn, un C. R. Farrar, "Novelty detection in a changing environment: Regression and interpolation approaches", *J. Sound Vib.*, sēj. 258, nr. 4, lpp. 741–761, 2002, doi: 10.1006/jsvi.2002.5148.

- [39] C. R. Farrar un N. A. J. Lieven, "Damage prognosis: The future of structural health monitoring", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 365, nr. 1851, lpp. 623–632, febr. 2007, doi: 10.1098/rsta.2006.1927.
- [40] A. Moreno-Gomez, C. A. Perez-Ramirez, A. Dominguez-Gonzalez, M. Valtierra-Rodriguez, O. Chavez-Alegria, un J. P. Amezcuita-Sanchez, "Sensors Used in Structural Health Monitoring", *Archives of Computational Methods in Engineering*, sēj. 25, nr. 4, lpp. 901–918, nov. 2018, doi: 10.1007/s11831-017-9217-4.
- [41] V. Gattulli, M. Lepidi, un F. Potenza, "Dynamic testing and health monitoring of historic and modern civil structures in Italy", *Structural Monitoring and Maintenance*, sēj. 3, nr. 1, lpp. 71–90, mar. 2016, doi: 10.12989/smm.2016.3.1.071.
- [42] F. Mohd-Yasin, D. J. Nagel, un C. E. Korman, "Noise in MEMS", *Meas. Sci. Technol.*, sēj. 21, nr. 1, 2010, doi: 10.1088/0957-0233/21/1/012001.
- [43] Derek K. Shaeffer, "MEMS Inertial Sensors: A Tutorial Overview", *IEEE Communications Magazine*, sēj. 51, nr. 4, lpp. 100–109, 2013, doi: 10.1109/MCOM.2013.6495768.
- [44] F. Cartiaux un J. Semiao, "The Challenges of long-time high-sampled Structural Health Monitoring: a practical Feedback", *ce/papers*, sēj. 6, nr. 5, lpp. 292–301, sept. 2023, doi: 10.1002/cepa.2081.
- [45] S. Kavitha, R. Joseph Daniel, un K. Sumangala, "High performance MEMS accelerometers for concrete SHM applications and comparison with COTS accelerometers", *Mech. Syst. Signal Process.*, sēj. 66–67, lpp. 410–424, 2016, doi: 10.1016/j.ymssp.2015.06.005.
- [46] Dytran Instruments, "Model 3191A1 High Sensitivity IEPE Piezoelectric Accelerometer – Performance Specifications", Chatsworth, USA, jūn. 2018. [Tiešsaiste]. Pieejams: www.dytran.com
- [47] Vijay K. Varadan, K. J. Vinoy, un S. Gopalakrishnan, *Smart Material Systems and MEMS: Design and Development Methodologies*. Chichester: John Wiley & Sons Ltd, 2006.
- [48] S. Beeby, G. Ensell, M. Kraft, un N. White, *MEMS Mechanical Sensors*, sēj. 282. Artech House, 2004. [Tiešsaiste]. Pieejams: <https://api.semanticscholar.org/CorpusID:109095910>
- [49] R. Pallás-Areny un J. G. Webster, *Sensors and Signal Conditioning*, sēj. 608. John Wiley & Sons, 2012. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=BDmQDQAAQBAJ>
- [50] A. Ibrahim, A. Eltawil, Y. Na, un S. El-Tawil, "A Machine Learning Approach for Structural Health Monitoring Using Noisy Data Sets", *IEEE Transactions on Automation Science and Engineering*, sēj. 17, nr. 2, lpp. 900–908, apr. 2020, doi: 10.1109/TASE.2019.2950958.

- [51] E. Figueiredo, I. Moldovan, P. Alves, H. Rebelo, un L. Souza, "Smartphone Application for Structural Health Monitoring of Bridges", *Sensors*, sēj. 22, nr. 21, nov. 2022, doi: 10.3390/s22218483.
- [52] J. P. Amezquita-Sanchez un H. Adeli, "Signal Processing Techniques for Vibration-Based Health Monitoring of Smart Structures", *Archives of Computational Methods in Engineering*, sēj. 23, nr. 1, lpp. 1–15, mar. 2016, doi: 10.1007/s11831-014-9135-7.
- [53] G. Chandrashekar un F. Sahin, "A survey on feature selection methods", *Computers and Electrical Engineering*, sēj. 40, nr. 1, lpp. 16–28, janv. 2014, doi: 10.1016/j.compeleceng.2013.11.024.
- [54] D. Goyal un B. S. Pabla, "The Vibration Monitoring Methods and Signal Processing Techniques for Structural Health Monitoring: A Review", *Archives of Computational Methods in Engineering*, sēj. 23, nr. 4, lpp. 585–594, dec. 2016, doi: 10.1007/s11831-015-9145-0.
- [55] Y. Zou, L. Tong, un G. P. Steven, "Vibration-based model-dependent damage (delamination) identification and health monitoring for composite structures - a review", *J. Sound Vib.*, sēj. 230, nr. 2, lpp. 357–378, febr. 2000, doi: 10.1006/jsvi.1999.2624.
- [56] E. Figueiredo, I. Moldovan, A. Santos, P. Campos, un J. C. W. A. Costa, "Finite Element–Based Machine-Learning Approach to Detect Damage in Bridges under Operational and Environmental Variations", *Journal of Bridge Engineering*, sēj. 24, nr. 7, jül. 2019, doi: 10.1061/(asce)be.1943-5592.0001432.
- [57] A. S. Kompalka un S. Reese, "Finite Element Model Updating for Damage Localisation and Quantification Using Experimental Modal Data", *Key Eng. Mater.*, sēj. 293–294, lpp. 297–304, sept. 2005, doi: 10.4028/www.scientific.net/kem.293-294.297.
- [58] W. H. Chen *u.c.*, "Theoretical and experimental modal analysis of the Guangzhou New TV Tower", *Eng. Struct.*, sēj. 33, nr. 12, lpp. 3628–3646, dec. 2011, doi: 10.1016/j.engstruct.2011.07.028.
- [59] R. I. Levin, T. P. Waters, un N. A. J. Lieven, "Required Precision and Valid Methodologies for Dynamic Finite Element Model Updating", *J. Vib. Acoust.*, sēj. 120, nr. 3, lpp. 733–741, jül. 1998, doi: 10.1115/1.2893891.
- [60] R.I.Levin un N.A.J.Lieven, "Dynamic finite element model updating using simulated annealing and genetic algorithms", *Mech. Syst. Signal Process.*, sēj. 12, nr. 1, lpp. 91–120, 1998.
- [61] J. E. Mottershead un M. I. Friswell, "Model Updating In Structural Dynamics: A Survey", *J. Sound Vib.*, sēj. 167, nr. 2, lpp. 347–375, okt. 1993, doi: 10.1006/JSVI.1993.1340.
- [62] S. Alampalli, "Effects of testing, analysis, damage, and environment on modal parameters", *Mech. Syst. Signal Process.*, sēj. 14, nr. 1, lpp. 63–74, 2000, doi: 10.1006/mssp.1999.1271.

- [63] A. Gomez-Cabrera un P. J. Escamilla-Ambrosio, "Review of Machine-Learning Techniques Applied to Structural Health Monitoring Systems for Building and Bridge Structures", *Applied Sciences*, sēj. 12, nr. 21, nov. 2022, doi: 10.3390/app122110754.
- [64] R.-T. Wu un M. R. Jahanshahi, "Data fusion approaches for structural health monitoring and system identification: Past, present, and future", *Struct. Health Monit.*, sēj. 19, nr. 2, lpp. 552–586, sept. 2018, doi: 10.1177/1475921718798769.
- [65] A. Keshmiry, S. Hassani, M. Mousavi, un U. Dackermann, "Effects of Environmental and Operational Conditions on Structural Health Monitoring and Non-Destructive Testing: A Systematic Review", 2023. gada 1. aprīlī, *MDPI*. doi: 10.3390/buildings13040918.
- [66] S. W. Doebling, C. Farrar, M. Prime, un D. W. Shevitz, "Damage Identification and Health Monitoring of Structural and Mechanical Systems From Changes in their Vibration Characteristics: A Literature Review", *Technical Report No. LA-13070-MS*, sēj. 30, mai. 1996, doi: 10.2172/249299.
- [67] S. Doebling, C. Farrar, M. Prime, un D. Shevitz, "A Review of Damage Identification Methods that Examine Changes in Dynamic Properties", *Shock and Vibration Digest*, sēj. 30, lpp. 91–105, janv. 1998.
- [68] H. Sohn, C. R. Farrar, F. Hemez, un J. Czarnecki, "A Review of Structural Health Monitoring Literature 1996 – 2001", Los Alamos National Laboratory, 2004.
- [69] "Scopus, Analyze search results: Structural Health Monitoring and Buildings and Environmental Factors". Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [70] "Scopus, Analyze search results: Structural Health Monitoring and Buildings and Environmental Factors and Vibration". Skatīts: 2025. gada 2. oktobrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [71] "Scopus, Analyze search results: Structural Health Monitoring and Bridges and Environmental Factors". Skatīts: 2025. gada 22. novembrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [72] "Scopus, Analyze search results: Structural Health Monitoring and Bridges and Environmental Factors and Vibration". Skatīts: 2025. gada 22. novembrī. [Tiešsaiste]. Pieejams: <https://www.scopus.com>
- [73] H. Sohn, "Effects of environmental and operational variability on structural health monitoring", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 365, nr. 1851, lpp. 539–560, dec. 2006, doi: 10.1098/rsta.2006.1935.
- [74] K. V. Yuen un S. C. Kuok, "Ambient interference in long-term monitoring of buildings", *Eng. Struct.*, sēj. 32, nr. 8, lpp. 2379–2386, 2010, doi: 10.1016/j.engstruct.2010.04.012.
- [75] S. Maas, V. H. Nguyen, T. Kebig, S. Schommer, un A. Zürbes, "Comparison of different excitation- and data sampling-methods in structural health monitoring", *Civil Engineering Design*, sēj. 1, nr. 1, lpp. 10–16, mar. 2019, doi: 10.1002/cend.201800002.

- [76] S. Hassani un U. Dackermann, "A Systematic Review of Advanced Sensor Technologies for Non-Destructive Testing and Structural Health Monitoring", *Sensors*, sēj. 23, nr. 4, febr. 2023, doi: 10.3390/s23042204.
- [77] Y. Q. Ni, X. G. Hua, K. Q. Fan, un J. M. Ko, "Correlating modal properties with temperature using long-term monitoring data and support vector machine technique", *Eng. Struct.*, sēj. 27, nr. 12 SPEC. ISS., lpp. 1762–1773, 2005, doi: 10.1016/j.engstruct.2005.02.020.
- [78] C. Gentile, A. Ruccolo, un F. Canali, "Continuous monitoring of the Milan Cathedral: dynamic characteristics and vibration-based SHM", *J. Civ. Struct. Health Monit.*, sēj. 9, nr. 5, lpp. 671–688, nov. 2019, doi: 10.1007/s13349-019-00361-8.
- [79] M. Pirner un O. Fischer, "Monitoring stresses in GRP extension of the Prague TV tower", *Proc. DAMAS 97: structural damage assessment using advanced signal processing procedures*, University of Sheffield, lpp. 451–460, 1997.
- [80] D. Gargaro, C. Rainieri, un G. Fabbrocino, "Structural and seismic monitoring of the "cardarelli" Hospital in Campobasso", *Procedia Eng.*, sēj. 199, lpp. 936–941, 2017, doi: 10.1016/j.proeng.2017.09.244.
- [81] D. Boggs un J. Dragovich, "The Nature of Wind Loads and Dynamic Response", *ACI Symposium Publication*, sēj. 240, lpp. 15–44, 2006, doi: 10.14359/18290.
- [82] L. Ratnika, L. Gaile, un N. I. Vatin, "Impact of Groundwater Level Change on Natural Frequencies of RC Buildings", *Buildings*, sēj. 11, nr. 7, 2021, doi: 10.3390/buildings11070265.
- [83] Latvijas Vides ģeoloģijas un meteoroloģijas centrs, "Pārskats par virszemes un pazemes ūdeņu stāvokli 2016.gadā", Rīga, 2018.
- [84] Rethati L., "Geotechnical Effects of Changes in Groundwater Level", no *Groundwater and Seepage Problems: Proceedings of the 10th International Conference on Soil Mechanics and Foundation Engineering*, Stockholm, 1981, lpp. 471–477.
- [85] F. Butt un P. Omenzetter, "Long term seismic response monitoring and finite element modeling of a concrete building considering soil flexibility and non-structural components", *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2011*, sēj. 7981, nr. 1, lpp. 79811X, 2011, doi: 10.1117/12.880147.
- [86] D. Z. Gravett, C. Mourlas, V.-L. Taljaard, N. Bakas, G. Markou, un M. Papadrakakis, "New fundamental period formulae for soil-reinforced concrete structures interaction using machine learning algorithms and ANNs", *Soil Dynamics and Earthquake Engineering*, sēj. 144, lpp. 106656, 2021, doi: <https://doi.org/10.1016/j.soildyn.2021.106656>.
- [87] NEHRP Consultants Joint Venture, "Soil-Structure Interaction for Building Structures", National Institute of Standards and Technology, Gaithersburg, sept. 2012.
- [88] T. G. Mondal un G. Chen, "Artificial intelligence in civil infrastructure health monitoring—Historical perspectives, current trends, and future visions", *Front. Built Environ.*, sēj. 8, sept. 2022, doi: 10.3389/fbuil.2022.1007886.

- [89] M. Q. Feng un E. Y. Bahng, "Damage Assessment of Jacketed RC Columns Using Vibration Tests", *Journal of Structural Engineering*, sēj. 125, nr. 3, lpp. 265–271, 1999, doi: 10.1061/(ASCE)0733-9445(1999)125:3(265).
- [90] I. Arel, D. Rose, un T. Karnowski, "Deep machine learning-A new frontier in artificial intelligence research", *IEEE Comput. Intell. Mag.*, sēj. 5, nr. 4, lpp. 13–18, nov. 2010, doi: 10.1109/MCI.2010.938364.
- [91] M. J. Rosales un R. Liyanapathirana, "Data driven innovations in structural health monitoring", no *Journal of Physics: Conference Series*, Institute of Physics Publishing, jūn. 2017. doi: 10.1088/1742-6596/842/1/012012.
- [92] T. Oladipupo, "Introduction to Machine Learning", no *New Advances in Machine Learning*, InTech, 2010. doi: 10.5772/9394.
- [93] S. Samudra, M. Barbosh, un A. Sadhu, "Machine Learning-Assisted Improved Anomaly Detection for Structural Health Monitoring", *Sensors*, sēj. 23, nr. 7, apr. 2023, doi: 10.3390/s23073365.
- [94] R. Boccagna, M. Bottini, M. Petracca, A. Amelio, un G. Camata, "Unsupervised Deep Learning for Structural Health Monitoring", *Big Data and Cognitive Computing*, sēj. 7, nr. 2, jūn. 2023, doi: 10.3390/bdcc7020099.
- [95] G. Mesnil u.c., "Unsupervised and Transfer Learning Challenge: a Deep Learning Approach", no *Proceedings of ICML Workshop on Unsupervised and Transfer Learning*, I. Guyon, G. Dror, V. Lemaire, G. Taylor, un D. Silver, Red., no *Proceedings of Machine Learning Research*, vol. 27. Bellevue, Washington, USA: PMLR, jūl. 2012, lpp. 97–110.
- [96] O. Avci, O. Abdeljaber, S. Kiranyaz, M. Hussein, M. Gabbouj, un D. J. Inman, "A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications", *Mech. Syst. Signal Process.*, sēj. 147, janv. 2021, doi: 10.1016/j.ymssp.2020.107077.
- [97] K. Worden, C. R. Farrar, G. Manson, un G. Park, "The fundamental axioms of structural health monitoring", *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 463, nr. 2082, lpp. 1639–1664, 2007, doi: 10.1098/rspa.2007.1834.
- [98] J. G. Carbonell, R. S. Michalski, un T. M. Mitchell, "Machine Learning: A Historical and Methodological Analysis", *AI Mag.*, sēj. 4, nr. 3, lpp. 69, sept. 1983, doi: 10.1609/aimag.v4i3.406.
- [99] E. Figueiredo, G. Park, C. R. Farrar, K. Worden, un J. Figueiras, "Machine learning algorithms for damage detection under operational and environmental variability", *Struct. Health Monit.*, sēj. 10, nr. 6, lpp. 559–572, nov. 2011, doi: 10.1177/1475921710388971.
- [100] W. Nick, K. Asamene, G. Bullock, A. Esterline, un M. Sundaresan, "A Study of Machine Learning Techniques for Detecting and Classifying Structural Damage", *Int. J. Mach. Learn. Comput.*, sēj. 5, nr. 4, lpp. 313–318, aug. 2015, doi: 10.7763/ijmlc.2015.v5.526.

- [101] L. Bull, K. Worden, G. Manson, un N. Dervilis, "Active learning for semi-supervised structural health monitoring", *J. Sound Vib.*, sēj. 437, lpp. 373–388, dec. 2018, doi: 10.1016/j.jsv.2018.08.040.
- [102] D. A. Tibaduiza, L. E. Mujica, un J. Rodellar, "Damage classification in structural health monitoring using principal component analysis and self-organizing maps", *Struct. Control Health Monit.*, sēj. 20, nr. 10, lpp. 1303–1316, okt. 2013, doi: 10.1002/stc.1540.
- [103] Y. Hamishebahar, H. Z. Li, un H. Guan, "Application of machine learning algorithms in structural health monitoring research", no *Lecture Notes in Civil Engineering*, Springer Science and Business Media Deutschland GmbH, 2021, lpp. 219–228. doi: 10.1007/978-981-15-8079-6_21.
- [104] B. Schölkopf, A. Smola, un K.-R. Müller, "Nonlinear Component Analysis as a Kernel Eigenvalue Problem", *Neural Comput.*, sēj. 10, nr. 5, lpp. 1299–1319, 1998, doi: 10.1162/089976698300017467.
- [105] A. Santos, E. Figueiredo, M. F. M. Silva, C. S. Sales, un J. C. W. A. Costa, "Machine learning algorithms for damage detection: Kernel-based approaches", *J. Sound Vib.*, sēj. 363, lpp. 584–599, febr. 2016, doi: 10.1016/j.jsv.2015.11.008.
- [106] S. J. Pan, I. W. Tsang, J. T. Kwok, un Q. Yang, "Domain adaptation via transfer component analysis", *IEEE Trans. Neural Netw.*, sēj. 22, nr. 2, lpp. 199–210, febr. 2011, doi: 10.1109/TNN.2010.2091281.
- [107] Q. Han, Q. Ma, D. Dang, un J. Xu, "Modal Parameters Prediction and Damage Detection of Space Grid Structure under Environmental Effects Using Stacked Ensemble Learning", *Struct. Control Health Monit.*, sēj. 2023, 2023, doi: 10.1155/2023/5687265.
- [108] B. Peeters un G. De Roeck, "One year monitoring of the Z24-bridge: Environmental influences versus damage events", no *Proceedings of the International Modal Analysis Conference - IMAC*, 2000.
- [109] K. Chandrasekhar, N. Stevanovic, E. J. Cross, N. Dervilis, un K. Worden, "Damage detection in operational wind turbine blades using a new approach based on machine learning", *Renew. Energy*, sēj. 168, lpp. 1249–1264, janv. 2021, doi: 10.1016/j.renene.2020.12.119.
- [110] G. Tsialiamanis, N. Dervilis, D. J. Wagg, un K. Worden, "A Meta-Learning Approach to Population-Based Modelling of Structures", no *Data Science in Engineering, Volume 10*, R. Madarshahian un F. Hemez, Red., Cham: Springer Nature Switzerland, 2023, lpp. 63–71.
- [111] S. Sawant, S. Patil, J. Thalapil, S. Banerjee, un S. Tallur, "Environmental variation compensated damage classification and localization in ultrasonic guided wave SHM using self-learned features and Gaussian mixture models", nov. 2021, doi: 10.1088/1361-665X/ac5ce3.
- [112] J. H. Bartels, M. Kitahara, S. Marx, un M. Beer, "Environmental influence on structural health monitoring systems", no *Life-Cycle of Structures and Infrastructure Systems - Proceedings of the 8th International Symposium on Life-Cycle Civil Engineering*,

IALCCE 2023, CRC Press/Balkema, 2023, lpp. 662–669. doi: 10.1201/9781003323020-80.

- [113] M.-S. Huang, M. Gül, un H.-P. Zhu, "Vibration-Based Structural Damage Identification under Varying Temperature Effects", *J. Aerosp. Eng.*, sēj. 31, nr. 3, mai. 2018, doi: 10.1061/(asce)as.1943-5525.0000829.
- [114] R. Janeliukstis, L. Ratnika, L. Gaile, un S. Rucevskis, "Environmental Factors in Structural Health Monitoring—Analysis and Removal of Effects from Resonance Frequencies", *Journal of Sensor and Actuator Networks*, sēj. 14, nr. 2, apr. 2025, doi: 10.3390/jsan14020033.
- [115] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006.
- [116] A. J. Smola un B. Schölkopf, "A tutorial on support vector regression", *Stat. Comput.*, sēj. 14, nr. 3, lpp. 199–222, aug. 2004, doi: 10.1023/B:STCO.0000035301.49549.88/METRICS.
- [117] B. Schölkopf un A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. The MIT Press, 2001. doi: 10.7551/mitpress/4175.001.0001.
- [118] N. Cristianini un J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge: Cambridge University Press, 2000. doi: DOI: 10.1017/CBO9780511801389.
- [119] L. Breiman, "Random Forests", *Mach. Learn.*, sēj. 45, nr. 1, lpp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [120] D. C. Montgomery, E. A. Peck, un G. G. Vining, *Introduction to Linear Regression Analysis*. no Wiley Series in Probability and Statistics. Wiley, 2013.
- [121] D. Chicco, M. J. Warrens, un G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation", *PeerJ Comput. Sci.*, sēj. 7, lpp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [122] J. H. Friedman, "Greedy Function Approximation: A Gradient Boosting Machine", *The Annals of Statistics*, sēj. 29, nr. 5, lpp. 1189–1232, 2001.
- [123] C. Edward. Rasmussen un C. K. I. . Williams, *Gaussian processes for machine learning*. MIT Press, 2006.
- [124] J. Snoek, H. Larochelle, un R. P. Adams, "Practical Bayesian optimization of machine learning algorithms", no *Proceedings of the 26th International Conference on Neural Information Processing Systems - Volume 2*, no NIPS'12. Red Hook, NY, USA: Curran Associates Inc., 2012, lpp. 2951–2959.
- [125] T. Hastie, R. Tibshirani, un J. H. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. no Springer series in statistics. Springer, 2009.

- [126] A. Botchkarev, "A new typology design of performance metrics to measure errors in machine learning regression algorithms", *Interdisciplinary Journal of Information, Knowledge, and Management*, sēj. 14, lpp. 45–76, 2019, doi: 10.28945/4184.
- [127] Data Science Stack Exchange, "Potential Sign Issues in a Composite Performance Metric for Model Selection". Skatīts: 2025. gada 28. jūlijā. [Tiešsaiste]. Pieejams: <https://datascience.stackexchange.com/questions/130072/potential-sign-issues-in-a-composite-performance-metric-for-model-selection>
- [128] O. Das, "Prediction of the natural frequencies of various beams using regression machine learning models", *Sigma Journal of Engineering and Natural Sciences*, sēj. 41, nr. 2, lpp. 302–321, apr. 2023, doi: 10.14744/sigma.2023.00040.
- [129] D. Sivori, M. G. B. Merani, F. Bocchi, D. Spina, un S. Cattari, "Environmental effects on the experimental modal parameters of masonry buildings: experiences from the Italian Seismic Observatory of Structures (OSS) network", *J. Civ. Struct. Health Monit.*, sēj. 15, nr. 2, lpp. 307–331, febr. 2025, doi: 10.1007/s13349-024-00847-0.
- [130] Z. Wang, D. H. Yang, T. H. Yi, G. H. Zhang, un J. G. Han, "Eliminating environmental and operational effects on structural modal frequency: A comprehensive review", 2022. gada 1. novembrī, *John Wiley and Sons Ltd*. doi: 10.1002/stc.3073.
- [131] S. C. Kuok, K. V. Yuen, S. Roberts, un M. A. Girolami, "Propagative broad learning for nonparametric modeling of ambient effects on structural health indicators", *Struct. Health Monit.*, sēj. 20, nr. 4, lpp. 1409–1427, jūl. 2021, doi: 10.1177/1475921720916923.
- [132] J. Li, X. Meng, L. Hu, un Y. Bao, "Quantifying the Impact of Environment Loads on Displacements in a Suspension Bridge with a Data-Driven Approach", *Sensors*, sēj. 24, nr. 6, mar. 2024, doi: 10.3390/s24061877.
- [133] I. Santos-Vila, R. Soto, E. Vega, B. Crawford, un A. Peña, "Damage Detection on Real Bridges Using Machine Learning Techniques: A Systematic Review", 2025. gada 1. augustā, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app15168884.
- [134] M. Haggag, M. K. Ismail, un W. El-Dakhkhni, "An interpretable machine learning approach for predicting the capacity and failure mode of reinforced concrete columns", *Advances in Structural Engineering*, sēj. 28, nr. 2, lpp. 246–263, 2025, doi: 10.1177/13694332241281546.
- [135] S. Mangalathu, K. Karthikeyan, D. C. Feng, un J. S. Jeon, "Machine-learning interpretability techniques for seismic performance assessment of infrastructure systems", *Eng. Struct.*, sēj. 250, janv. 2022, doi: 10.1016/j.engstruct.2021.112883.
- [136] C. Molnar, *Interpretable Machine Learning A Guide for Making Black Box Models Explainable*. Leanpub, 2019.
- [137] A. Anastasiou un S. Loizidou, "Data-adaptive structural change-point detection via isolation", *Stat. Comput.*, sēj. 35, nr. 5, okt. 2025, doi: 10.1007/s11222-025-10643-5.

- [138] P. Fearnhead un D. Grose, "cpop: Detecting Changes in Piecewise-Linear Signals", *J. Stat. Softw.*, sēj. 109, nr. 7, lpp. 1–30, mai. 2024, doi: 10.18637/jss.v109.i07.
- [139] H. Garg, K. Yang, A. G. Cohn, D. Borman, S. V. Nanukuttan, un P. A. M. Basheer, "Automated Piecewise Linear Regression for Analyzing Structural Health Monitoring Data", *ACI Mater. J.*, sēj. 121, nr. 2, lpp. 93–104, apr. 2024, doi: 10.14359/51740370.
- [140] B. M. Greenwell, "pdp: An R Package for Constructing Partial Dependence Plots", *R J.*, sēj. 9, lpp. 421, 2017, [Tiešsaiste]. Pieejams: <https://api.semanticscholar.org/CorpusID:52254631>
- [141] G. James, D. Witten, T. Hastie, un R. Tibshirani, *An Introduction to Statistical Learning: with Applications in R*. Springer Publishing Company, Incorporated, 2014.
- [142] D. W. Apley un J. Zhu, "Visualizing the effects of predictor variables in black box supervised learning models", *J. R. Stat. Soc. Series B Stat. Methodol.*, sēj. 82, nr. 4, lpp. 1059–1086, sept. 2020, doi: 10.1111/rssb.12377.
- [143] M. Jambulkar, S. Ojha, A. Shelke, un A. Habib, "Autonomous defect estimation in aluminum plate and prognosis through stochastic process modeling", *Sci. Rep.*, sēj. 15, nr. 1, dec. 2025, doi: 10.1038/s41598-025-13189-8.
- [144] N. Antary, M. H. Trauth, un N. Marwan, "Interpolation and sampling effects on recurrence quantification measures", *Chaos: An Interdisciplinary Journal of Nonlinear Science*, sēj. 33, nr. 10, lpp. 103105, okt. 2023, doi: 10.1063/5.0167413.
- [145] B. M. Greenwell, B. C. Boehmke, un A. J. McCarthy, "A Simple and Effective Model-Based Variable Importance Measure", *ArXiv*, sēj. abs/1805.04755, 2018.
- [146] A. M. Yan un J. C. Golinvál, "Null subspace-based damage detection of structures using vibration measurements", *Mech. Syst. Signal Process.*, sēj. 20, nr. 3, lpp. 611–626, apr. 2006, doi: 10.1016/j.ymssp.2005.04.010.
- [147] A. Saltelli u.c., *Global Sensitivity Analysis: The Primer*. Wiley, 2008. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=wAssmt2vumgC>
- [148] P. J. Huber un E. M. Ronchetti, *Robust Statistics*. no Wiley Series in Probability and Statistics. Wiley, 2011. [Tiešsaiste]. Pieejams: https://books.google.lv/books?id=j1OhquR_j88C
- [149] J. Kullaa, "Distinguishing between sensor fault, structural damage, and environmental or operational effects in structural health monitoring", *Mech. Syst. Signal Process.*, sēj. 25, nr. 8, lpp. 2976–2989, nov. 2011, doi: 10.1016/j.ymssp.2011.05.017.
- [150] C. Bergmeir, R. J. Hyndman, un J. M. Benítez, "Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation", *Int. J. Forecast.*, sēj. 32, nr. 2, lpp. 303–312, apr. 2016, doi: 10.1016/j.ijforecast.2015.07.002.
- [151] C. R. Farrar un K. Worden, *Structural Health Monitoring: A Machine Learning Perspective*. 2012. doi: 10.1002/9781118443118.

- [152] C. Chatfield, *The Analysis of Time Series: An Introduction, Sixth Edition*. no Chapman & Hall/CRC Texts in Statistical Science. CRC Press, 2016. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=qKzyAbdaDFAC>
- [153] R. J. Hyndman un G. Athanasopoulos, *Forecasting: Principles and Practice*. OTexts, 2014. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=nmTQwAEACAAJ>
- [154] A. Dokumentov un R. J. Hyndman, "STR: Seasonal-Trend Decomposition Using Regression", *INFORMS Journal on Data Science*, sēj. 1, nr. 1, lpp. 50–62, apr. 2022, doi: 10.1287/ijds.2021.0004.
- [155] V. Nicoletti, L. Amico, R. Martini, S. Carbonari, F. Gara, un F. Dezi, "The Monitoring System of the New Filomena Delli Castelli Cable-Stayed Bridge", no *Experimental Vibration Analysis for Civil Engineering Structures*, M. P. Limongelli, P. F. Giordano, S. Quqa, C. Gentile, un A. Cigada, Red., Cham: Springer Nature Switzerland, 2023, lpp. 401–411.
- [156] L. Gaile, S. Amador, R. Brincker, L. Gaile, un S. Amador, "Initial Results from the Continuous Monitoring Campaign of a Wooden Frame Specimen", no *Proceedings of the 9th International Operational Modal Analysis Conference (IOMAC)*, In C. E. Ventura, M. Motamedi, A. Mandler, & M. Aenlle-Lopez (Eds.), 2022, lpp. 286–293.
- [157] R. D. Innocenzi, V. Nicoletti, D. Arezzo, S. Carbonari, F. Gara, un L. Dezi, "A Good Practice for the Proof Testing of Cable-Stayed Bridges", *Applied Sciences (Switzerland)*, sēj. 12, nr. 7, apr. 2022, doi: 10.3390/app12073547.
- [158] Douglas C. Montgomery, Elizabeth A. Peck, un G. Geoffrey Vining, *Introduction to Linear Regression Analysis*, 6-ā red., sēj. 704. John Wiley & Sons, 2021.
- [159] C. Larsson, O. Abdeljaber, Å. Bolmsvik, un M. Dorn, "Long-term analysis of the environmental effects on the global dynamic properties of a hybrid timber-concrete building", *Eng. Struct.*, sēj. 268, okt. 2022, doi: 10.1016/j.engstruct.2022.114726.
- [160] Q. Han, Q. Ma, J. Xu, un M. Liu, "Structural health monitoring research under varying temperature condition: a review", *J. Civ. Struct. Health Monit.*, sēj. 11, nr. 1, lpp. 149–173, febr. 2021, doi: 10.1007/s13349-020-00444-x.
- [161] G. A. F. Seber un A. J. Lee, *Linear Regression Analysis*. no Wiley Series in Probability and Statistics. Wiley, 2012.
- [162] M. Jordan, J. Kleinberg, un B. Schölkopf, *Pattern Recognition and Machine Learning*, sēj. 4. Springer, 2006.
- [163] F. E. Harrell, *Regression Modeling Strategies: With Applications to Linear Models, Logistic and Ordinal Regression, and Survival Analysis*. no Springer Series in Statistics. Springer International Publishing, 2015.
- [164] I. A. Hernández-González un E. García-Macias, "Towards a comprehensive damage identification of structures through populations of competing models", *Eng. Comput.*, sēj. 40, nr. 5, lpp. 3157–3174, okt. 2024, doi: 10.1007/s00366-024-01972-6.
- [165] J. Zhang, Y. Yang, un J. Ding, "Information criteria for model selection", 2023. gada 1. septembrī, *John Wiley and Sons Inc.* doi: 10.1002/wics.1607.

- [166] S. Xu, M. A. R. Ferreira, un A. N. Tegge, "What is in the model? A Comparison of variable selection criteria and model search approaches", okt. 2025, [Tiešsaiste]. Pieejams: <http://arxiv.org/abs/2510.02628>
- [167] M. H. Kutner, *Applied Linear Statistical Models*, 5-ā red., sēj. 1396. no McGrwa-Hill international edition, vol. 1396. McGraw-Hill Irwin, 2005. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=0xqCAAAACAAJ>
- [168] E. Simiu un D. H. Yeo, *Wind Effects on Structures: Modern Structural Design for Wind*. Wiley, 2019. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=60WCDwAAQBAJ>
- [169] B. Morais da Costa, J. Wang, J. B. Jakobsen, O. A. Øiseth, un J. þór Snæbjörnsson, "Bridge buffeting by skew winds: A quasi-steady case study", *Journal of Wind Engineering and Industrial Aerodynamics*, sēj. 227, aug. 2022, doi: 10.1016/j.jweia.2022.105068.
- [170] A. Fenerci un O. Øiseth, "Strong wind characteristics and dynamic response of a long-span suspension bridge during a storm", *Journal of Wind Engineering and Industrial Aerodynamics*, sēj. 172, lpp. 116–138, janv. 2018, doi: 10.1016/j.jweia.2017.10.030.
- [171] V. Plevris, G. Solorzano, N. P. Bakas, un M. E. A. Ben Seghier, "Investigation of performance metrics in regression analysis and machine learning-based prediction models", no *World Congress in Computational Mechanics and ECCOMAS Congress*, Scipedia S.L., 2022. doi: 10.23967/eccomas.2022.155.
- [172] C. Bentéjac, A. Csörgö, un G. Martínez-Muñoz, "A comparative analysis of gradient boosting algorithms", *Artif. Intell. Rev.*, sēj. 54, nr. 3, lpp. 1937–1967, 2021, doi: 10.1007/s10462-020-09896-5.
- [173] T. Chen un C. Guestrin, "XGBoost: A scalable tree boosting system", no *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, aug. 2016, lpp. 785–794. doi: 10.1145/2939672.2939785.
- [174] L. Su, G. Guo, un Y. Li, "Vibration monitoring of wind turbine tower based on XGBoost", no *Journal of Physics: Conference Series*, IOP Publishing Ltd, jūn. 2021. doi: 10.1088/1742-6596/1948/1/012075.
- [175] Á. Presno Vélez, Z. Fernández Muñiz, un J. L. Fernández Martínez, "Advancing Structural Health Monitoring with Deep Belief Network-Based Classification", *Mathematics*, sēj. 13, nr. 9, mai. 2025, doi: 10.3390/math13091435.
- [176] O. E. Esu, Y. Wang, un M. K. Chryssanthopoulos, "A baseline-free method for damage identification in pipes from local vibration mode pair frequencies", *Struct. Health Monit.*, sēj. 21, nr. 5, lpp. 2152–2189, sept. 2022, doi: 10.1177/14759217211052335.
- [177] S. Arlot un A. Celisse, "A survey of cross-validation procedures for model selection", *Stat. Surv.*, sēj. 4, lpp. 40–79, 2010, doi: 10.1214/09-SS054.

- [178] Carlo. Rainieri un Giovanni. Fabbrocino, *Operational Modal Analysis of Civil Engineering Structures : An Introduction and Guide for Applications*, 1st ed. 2014. New York, NY: Springer New York, 2014. doi: 10.1007/978-1-4939-0767-0.
- [179] K. P. . Murphy, *Machine learning : a probabilistic perspective*. MIT Press, 2012.
- [180] M. Kuhn un K. Johnson, *Applied Predictive Modeling*. no SpringerLink : Bücher. Springer New York, 2013.
- [181] S. Weisberg, *Applied Linear Regression*. no Wiley Series in Probability and Statistics. Wiley, 2014.
- [182] A. Zheng un A. Casari, *Feature Engineering for Machine Learning: Principles and Techniques for Data Scientists*, 1st red. O'Reilly Media, Inc., 2018.
- [183] S. Möller, C. Jonscher, T. Griebmann, un R. Rolfes, "Comparing Gaussian process enhanced grey-box approaches to detect damage in unknown environmental conditions due to climate change", *Struct. Health Monit.*, sēj. 24, nr. 4, lpp. 2338–2364, jūl. 2025, doi: 10.1177/14759217241313375.
- [184] Z. Shao un M. Kumral, "Implementing Gaussian process modelling in predictive maintenance of mining machineries", *Mining Technology: Transactions of the Institutions of Mining and Metallurgy*, sēj. 133, nr. 4, lpp. 348–368, dec. 2024, doi: 10.1177/25726668241275434.
- [185] K. Worden un G. Manson, "The application of machine learning to structural health monitoring", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 365, nr. 1851, lpp. 515–537, febr. 2007, doi: 10.1098/RSTA.2006.1938,.
- [186] L. B. V. de Amorim, G. D. C. Cavalcanti, un R. M. O. Cruz, "The choice of scaling technique matters for classification performance", dec. 2022, doi: 10.1016/j.asoc.2022.109924.
- [187] M. M. Ahsan, M. A. P. Mahmud, P. K. Saha, K. D. Gupta, un Z. Siddique, "Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance", *Technologies (Basel)*, sēj. 9, nr. 3, sept. 2021, doi: 10.3390/technologies9030052.
- [188] D. C. Montgomery un G. C. Runger, *Applied Statistics and Probability for Engineers*. Wiley, 2017.
- [189] W. C. Lai, T. P. Chang, J. J. Wang, C. W. Kan, un W. W. Chen, "An evaluation of Mahalanobis Distance and grey relational analysis for crack pattern in concrete structures", *Comput. Mater. Sci.*, sēj. 65, lpp. 115–121, dec. 2012, doi: 10.1016/J.COMMATSCI.2012.07.002.
- [190] H. Cao u.c., "End milling tool breakage detection using lifting scheme and Mahalanobis distance", *Int. J. Mach. Tools Manuf.*, sēj. 48, nr. 2, lpp. 141–151, febr. 2008, doi: 10.1016/J.IJMACHTOOLS.2007.09.001.
- [191] S. M. Ji u.c., "Method of monitoring wearing and breakage states of cutting tools based on Mahalanobis distance features", *J. Mater. Process. Technol.*, sēj. 129, nr. 1–3, lpp. 114–117, okt. 2002, doi: 10.1016/S0924-0136(02)00587-3.

- [192] R. De Maesschalck, D. Jouan-Rimbaud, un D. L. Massart, "The Mahalanobis distance", *Chemometrics and Intelligent Laboratory Systems*, sēj. 50, nr. 1, lpp. 1–18, janv. 2000, doi: 10.1016/S0169-7439(99)00047-7.
- [193] D. C. Montgomery, *Introduction to Statistical Quality Control*. Wiley, 2020. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=oh7zDwAAQBAJ>
- [194] C. Huber-Carol, N. Balakrishnan, M. Nikulin, un M. Mesbah, *Goodness-of-Fit Tests and Model Validity*. no Statistics for Industry and Technology. Birkhäuser Boston, 2012.
- [195] I. T. Jolliffe un J. Cadima, "Principal component analysis: a review and recent developments", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 374, nr. 2065, apr. 2016, doi: 10.1098/RSTA.2015.0202.
- [196] J. Edward. Jackson un J. W. & Sons., *A user's guide to principal components*. no Wiley series in probability and mathematical statistics. Applied probability and statistics. New York: Wiley Interscience Publication, 2004. doi: 10.1002/0471725331.
- [197] I. T. Jolliffe un J. Cadima, "Principal component analysis: a review and recent developments", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, sēj. 374, nr. 2065, apr. 2016, doi: 10.1098/RSTA.2015.0202.
- [198] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, un R. C. Williamson, "Estimating the Support of a High-Dimensional Distribution", *Neural Comput.*, sēj. 13, nr. 7, lpp. 1443–1471, jūl. 2001, doi: 10.1162/089976601750264965.
- [199] C. C. Aggarwal, "Outlier Analysis", *Outlier Analysis*, 2017, doi: 10.1007/978-3-319-47578-3.
- [200] G. J. McLachlan un D. Peel, *Finite Mixture Models*. no Wiley Series in Probability and Statistics. Wiley, 2004.
- [201] K. H. Brodersen, C. S. Ong, K. E. Stephan, un J. M. Buhmann, "The balanced accuracy and its posterior distribution", *Proceedings - International Conference on Pattern Recognition*, lpp. 3121–3124, 2010, doi: 10.1109/ICPR.2010.764.
- [202] M. Gul un F. Necati Catbas, "Statistical pattern recognition for Structural Health Monitoring using time series modeling: Theory and experimental verifications", *Mech. Syst. Signal Process.*, sēj. 23, nr. 7, lpp. 2192–2204, okt. 2009, doi: 10.1016/j.ymssp.2009.02.013.
- [203] A. Deraemaeker un K. Worden, "A comparison of linear approaches to filter out environmental effects in structural health monitoring", *Mech. Syst. Signal Process.*, sēj. 105, lpp. 1–15, mai. 2018, doi: 10.1016/j.ymssp.2017.11.045.
- [204] E. Figueiredo un J. Brownjohn, "Three decades of statistical pattern recognition paradigm for SHM of bridges", *Struct. Health Monit.*, sēj. 21, nr. 6, lpp. 3018–3054, nov. 2022, doi: 10.1177/14759217221075241.
- [205] T. Fawcett, "An introduction to ROC analysis", *Pattern Recognit. Lett.*, sēj. 27, nr. 8, lpp. 861–874, jūn. 2006, doi: 10.1016/J.PATREC.2005.10.010.

- [206] P. P. Kärenlampi, P. Tynjälä, un P. Ström, "Phase transformations of wood cell wall water", *Journal of Wood Science*, sēj. 51, nr. 2, lpp. 118–123, apr. 2005, doi: 10.1007/s10086-004-0630-6.
- [207] European Committee for Standardization (CEN), "EN 15425:2023 - Adhesives - One component polyurethane (PUR) for load-bearing timber structures -". Skatīts: 2025. gada 18. aprīlī. [Tiešsaiste]. Pieejams: https://standards.iteh.ai/catalog/standards/cen/9dab2ba7-06b2-4c18-af22-e644265e9d4f/en-15425-2023?srltid=AfmBOopE629yiHFVkJb9flqrs-a2aulStAGhZKjSZcnpD_pYXEJn1lg
- [208] S. Gao, X. Wang, un L. Wang, "Effect of Temperature and Moisture State Changes on Modulus of Elasticity of Red Pine Small Clear Wood", no *Proceedings of the 18th International Nondestructive Testing and Evaluation of Wood Symposium*, Madison, 2013.
- [209] U.S. Forest Service un F. Products Laboratory, "Wood Handbook, Wood as an Engineering Material", Madison, 2010.
- [210] C. Sala, E. Robles, A. Gumowska, A. Wronka, un G. Kowaluk, "Influence of Moisture Content on the Mechanical Properties of Selected Wood-based Composites", *Bioresources*, sēj. 15, lpp. 5503–5513, mai. 2020, doi: 10.15376/biores.15.3.5503-5513.



Lāsma Ratnika dzimusi 1993. gada 1. aprīlī Rēzeknes novadā. Rīgas Tehniskās universitātes (RTU) Būvniecības inženierzinātņu fakultātē (BIF) ieguvusi inženiera kvalifikāciju un profesionālo bakalaura grādu (2019) un profesionālā maģistra grādu (2020) būvniecībā. Profesionālo karjeru saistījusi ar būvkonstrukciju projektēšanu un paralēli iesaistījusies zinātniskajā pētniecībā RTU BIF Būvkonstrukciju inženierzinātņu institūtā, strādājot zinātniskās asistentes amatā. Zinātniskā darbība saistīta ar konstrukciju tehniskā stāvokļa monitoringu un konstrukciju dinamisko īpašību izpēti.