

Lāsma Ratnika

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

Promocijas darba kopsavilkums



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 darba kopsavilkums

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

Konsultants
Dr. sc. ing.
RIMS JANELIUKŠTIS

RTU Izdevniecība
Rīga 2026

Ratnika, L. Adaptīva segmentētas regresijas metode ārējās vides faktoru ietekmes samazināšanai būvju dinamisko parametru ilgtermiņa tehniskā monitoringa datos. Promocijas darba kopsavilkums. Rīga: RTU Izdevniecība, 2026. 66 lpp.

Publicēts saskaņā ar promocijas padomes “RTU-P-06” 2026. gada 7. maija lēmumu, protokols Nr.04030-9.6/8.

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.



NACIONĀLAIS
ATTĪSTĪBAS
PLĀNS 2020



EIROPAS SAVIENĪBA
Eiropas Sociālais
fonds

IEGULDĪJUMS TAVĀ NĀKOTNĒ

Vāka attēls no *www.shutterstock.com*.

<https://doi.org/10.7250/9789934373480>

ISBN 978-9934-37-348-0 (pdf)

PROMOCIJAS DARBS IZVIRZĪTS ZINĀTNES DOKTORA GRĀDA IEGŪŠANAI RĪGAS TEHNISKAJĀ UNIVERSITĀTĒ

Promocijas darbs zinātnes doktora (*Ph. D.*) grāda iegūšanai tiek publiski aizstāvēts 2026. gada 9. oktobrī plkst. 14.00 Rīgas Tehniskās universitātes Būvniecības un mašīnzinību fakultātē, Ķīpsalas ielā 6A, 453. auditorijā.

OFICIĀLIE RECENZENTI

Vadošā pētniece *Dr. sc. ing. Karīna Buka-Vaivade*,
Rīgas Tehniskā universitāte

Profesors *Dr. sc. ing. Darius Bacinskas*,
Viļņas Ģedimīna tehniskā universitāte, Lietuva

Asociētais profesors *Dr. sc. ing. Andrea Belleri*,
Bergamo Universitāte, Itālija

APSTIPRINĀJUMS

Apstiprinu, ka esmu izstrādājusi šo promocijas darbu, kas iesniegts izskatīšanai Rīgas Tehniskajā universitātē zinātnes doktora (*Ph. D.*) grāda iegūšanai. Promocijas darbs zinātniskā grāda iegūšanai nav iesniegts nevienā citā universitātē.

Lāsma Ratnika(paraksts)

Datums:

Promocijas darbs ir uzrakstīts latviešu valodā, tajā ir darba vispārējs raksturojums, četras nodaļas, secinājumi, literatūras saraksts, 74 attēli, astoņas tabulas, kopā 127 lappuses. Izmantojamās literatūras sarakstā ir 210 avoti.

SATURS

DARBA VISPĀRĒJS RAKSTUROJUMS	5
Tēmas aktualitāte.....	5
Darba mērķis un uzdevumi	6
Pētījuma zinātniskā novitāte.....	6
Promocijas darba praktiskais nozīmīgums	7
Pētīšanas metodika un izmantotie materiāli.....	8
Pētījuma teorētiskais un metodoloģiskais pamats	9
Pētījuma ierobežojumi.....	10
Aizstāvēšanai izvirzītie darba rezultāti	10
Darba aprobācija un publikācijas	11
Darba saturs un apjoms	12
PROMOCIJAS DARBA SATURS	13
1. Esošā ēku fonda novērtējums un tehniskā stāvokļa monitoringa sistēmas nepieciešamība	13
2. Mašīnmācīšanās metožu integrācija konstrukciju tehniskā stāvokļa monitoringā.....	21
3. Metode ārējās vides faktoru ietekmes samazināšanai konstrukciju pašsvārstību frekvenču monitoringa datos	27
4. Ārējās vides faktoru ietekmes samazināšanas metodes validācija.....	33
SECINĀJUMI	55
LITERATŪRAS AVOTI	57

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 ne bojāto 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. Tilta 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 atkarotāmību 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 datos 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 novērtējumus par konstrukcijas tehnisko stāvokli, nevis periodiski veiktas vizuālās pārbaudes rezultātos. Tas veicina pāreju no tradicionālās datos 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 rāmim 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. Tiltā 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 rimšanas 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 norādīti turpmāk.

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 vienotu 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 pieeja 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 ārējās vides faktoru ietekmes samazināšanas metodes efektivitāte. Promocijas darba noslēgumā apkopoti galvenie secinājumi.

PROMOCIJAS DARBA SATURS


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

Jaunu ēku būvniecības skaita rādītājs ilgstoši ir kalpojis kā būtisks atskaite 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. Lai gan kopš 2021. gada kopējā būvniecības aktivitāte samazinās, tomēr novērojamas būtiskas pārmaiņas būvniecības struktūrā, pieaugot pieprasījumam pēc dzīvojamām ēkām, īpaši daudzdzīvokļu jeb divu vai vairāku dzīvokļu ēku būvniecībai [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 pārbūves 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 (1.1. 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.



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

Liels 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 dzīvojamie ēku veidi [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 otrās un trešās grupas publiskām un daudzstāvu daudzdzīvokļu dzīvojamām ēkām tehniskā apsekošana ir jāveic periodiski ne retāk kā reizi 10 gados [2]. Līdz ar to normatīvs nosaka, ka, piemēram, ēkām, kuru apsekošana veikta 2019. gadā, nākamā tehniskā apsekošana ir paredzēta tikai pēc 10 gadiem, 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 sistemātisku apkopi [10].

Konstrukciju tehniskā stāvokļa monitorings (*Structural Health Monitoring, SHM*) 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. Konstrukciju tehniskā stāvokļa monitoringa mērķis ir apkopot pietiekamu informāciju par bojājumiem, lai nodrošinātu atbilstošus novēršanas pasākumus un atjaunotu konstrukcijas, nodrošinot ēkas lietotāju drošību. Bojājumu noteikšana tiek veikta

secīgi, sākot ar bojājumu konstatēšanu un turpinot ar tā lokalizāciju, apjoma novērtēšanu un bojājumu attīstības prognozēšanu [11].

Būvēm, kas sasniegušas vai tuvojas vidējam kalpošanas ilgumam, ir ieteicams veikt periodisku vai ilgtermiņa konstrukciju tehniskā stāvokļa monitoringu, lai nodrošinātu drošu ekspluatāciju un pagarinātu to kalpošanas laiku. Līdzīga pieeja ir būtiska arī vēsturisko ēku uzturēšanā, kur monitorings ļautu objektīvi novērtēt konstrukciju tehnisko stāvokli un plānot tehniskās apkopes un restaurācijas darbus [12].

Konstrukcijām bez uzstādītām monitoringa sistēmām uzticamība ekspluatācijas laikā samazinās, jo bojājumi netiek savlaicīgi konstatēti, savukārt uzturēšanas izmaksas pieaug. Savukārt konstrukcijām ar uzstādītām monitoringa sistēmām bojājumi tiek identificēti agrīnā stadijā, saglabājot augstu uzticamības līmeni un stabilas, zemākas uzturēšanas izmaksas [10]. Papildus tam monitoringa dati ļauj precizēt slodžu iedarbību un konstrukcijas nestspēju, samazinot nenoteiktību drošuma novērtējumā un nodrošinot pamatotāku lēmumu pieņemšanu par konstrukciju tehnisko apkopi [13].

Mūsdienās 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]. Šīs metodes nodrošina lokālu bojājumu identificēšanu ar augstu ticamību, tomēr to lietojumam ir nepieciešamas iepriekšējās zināšanas par bojājuma atrašanās vietu un veidu [14]. 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 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. Pēdējos gados strauji pieaugoša interese par konstrukciju tehniskā stāvokļa monitoringu ir saistīta ar nepieciešamību nodrošināt cilvēku drošību, pagarināt būvju ekspluatācijas laiku un optimizēt konstrukciju uzturēšanas izmaksas, balstoties faktiskajā tehniskajā stāvoklī. Līdz ar to konstrukciju tehniskā stāvokļa monitorings kļūst par būtisku instrumentu ilgtspējīgas būvniecības un drošas infrastruktūras attīstībā [15].

Vizuālās konstrukciju tehniskā stāvokļa pārbaudes metodes ir ierobežotas lielu un sarežģītu būvju konstrukciju bojājumu identificēšanā, jo tās nenodrošina kvantitatīvu bojājumu novērtējumu un nespēj uzticami raksturot konstrukcijas kopējo tehnisko stāvokli, īpaši gadījumos, kad bojājumi atrodas grūti pieejamās vai neredzamās vietās. Lai noteiktu konstrukciju bojājumus šādām būvēm, tika izstrādāta svārstībās balstīta metode, kurā konstrukciju svārstības tiek ierosinātas ar apkārtējā vidē esošiem ierosinātajiem, ārēju ierosinātāju vai iebūvētiem mehānismiem [14]. Apkārtējās vides ierosinātāji, piemēram, vējš vai intensīvas satiksmes ierosinātas svārstības, salīdzinot ar piespiedu svārstību ierosinātajiem, ir ekonomiski izdevīgāki, lai nodrošinātu nepārtrauktu ilgtermiņa konstrukciju monitoringu [16].

Apkārtējās vides svārstību ierosinātāju ierosmes signāls mainās gan pēc amplitūdas, gan arī pēc ierosmes frekvenču spektra [16], tāpēc konstrukciju dinamisko īpašību noteikšanai šādos apstākļos bieži tiek izmantota operacionālā modālā analīze (OMA), kas nodrošina iespēju identificēt konstrukcijas dinamiskos parametrus reālos ekspluatācijas apstākļos, neizmantojot kontrolētu ierosinātāju [17]. OMA balstās pieņēmumā par nejaušu, plaša spektra ierosmi [18], savukārt eksperimentālā modālā analīze (EMA) nodrošina augstu precizitāti kontrolētos apstākļos. Tomēr EMA praktiska lietošana lielām būvēm ir ierobežota, jo tās lietošanai ir nepieciešams specifiskas iekārtas, jānodrošina piekļuve konstrukcijām, kā arī tās ieviešana ir saistīta ar ievērojamām izmaksām [19]. Tāpēc OMA ir kļuvusi par galveno metodi lielu būvju dinamiskās uzvedības novērtēšanai [20].

Konstrukciju tehniskā stāvokļa monitorings, kas balstās konstrukciju dinamisko parametru izmaiņās, ēkām un inženierbūvēm tiek pētīts jau kopš pagājušā gadsimta 80. gadu sākuma [15]. Konstrukciju svārstībās balstītas metodes pamatprincipu var izskaidrot ar to, ka dinamiskie parametri, piemēram, pašsvārstību frekvences, pašsvārstību formas un svārstību rimšanas koeficienti, ir atkarīgi no konstrukcijas masas un stinguma un bojājumi izraisa šo parametru izmaiņas [14]. Konstrukciju bojājumu identificēšanai visbiežāk tiek izmantotas tieši pašsvārstību frekvenču izmaiņas, jo tās ir vieglāk noteikt, mērījumu kļūda parasti ir mazāka par 1 % [21] un to noteikšanai nepieciešams mazāks sensoru skaits nekā svārstību formu analīzei [14].

Salīdzinot ar vizuālās pārbaudes un nesagraujošās testēšanas metodēm, svārstībās balstītas metodes nodrošina globālu konstrukcijas tehniskā stāvokļa novērtējumu bez iepriekšējas bojājumu atrašanās vietas noteikšanas, nepieprasa sensoru izvietojumu bojājuma tuvumā un ļauj izmantot ierobežotu sensoru skaitu pat lielās un sarežģītās būvēs [22]. Tomēr šīs metodes praktisko lietojumu ierobežo salīdzinoši zemā jutība pret lokāliem bojājumiem, mērījumu nenoteiktība augstāku svārstību formu gadījumā, lielais monitoringa datu apjoms un būtiskā ārējās vides un ekspluatācijas faktoru ietekme uz konstrukciju dinamiskajiem parametriem [14].

Svārstībās balstīta nesošo konstrukciju tehniskā stāvokļa monitoringa pieejas informatīvā kapacitāte ir atkarīga no spējas precīzi identificēt dominējošās pašsvārstību formas izmērtajā frekvenču diapazonā. Taču praksē šo identificēšanu apgrūtina tuvu novietotu pašsvārstību formu savstarpējā saistība un atsevišķu svārstību formu nošķiršana [23], kā arī ar mērījumu datu ieguvī saistītie traucējumi un daļējs datu zudums [24]. Līdz ar to svārstībās 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 [25].

1993. gadā *Rytter* pirmo reizi izstrādāja konstrukciju bojājumu noteikšanas shēmu, kas ietvēra bojājumu konstatēšanu, lokalizāciju, pakāpes novērtēšanu un prognozēšanu [26]. Šī shēma balstās hierarhiskā pieejā, kur katram nākamajam līmenim ir nepieciešama iepriekšējā līmeņa informācija, un augstāku līmeņu analīzei parasti ir nepieciešami analītiskie modeļi vai arī konstrukcijas datu piemēri, kas atbilst dažāda līmeņa bojājuma pakāpēm [15].

Konstrukciju tehniskā stāvokļa monitoringa procesa rezultāts ir atjaunota informācija par konstrukciju spēju turpināt pildīt tās funkcijas, ņemot vērā konstrukcijas nolietojumu un

iespējamos bojājumus ārējās vides apstākļu ietekmē. Monitoringa process ietver ekspluatācijas apstākļu noteikšanu un monitoringa mērķu definēšanu, datu iegūšanu un apstrādi, pazīmju atlasī, kā arī statistisko modeļu izstrādi bojājumu identificēšanai un to pakāpes noteikšanai. 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 [27].

Konstrukciju bojājumu noteikšana balstās esošā stāvokļa salīdzināšanā ar references jeb nebojātas konstrukcijas stāvokli, lai identificētu statistiski nozīmīgas izmaiņas dinamiskajos parametros [15]. Ja references stāvoklis nav precīzi definēts, tad bojājumu noteikšanas rezultāti var kļūt nenoteikti, īpaši parametru nelielu izmaiņu gadījumā. Līdz ar to bojājumu identificēšana tiek formulēta kā statistiska lēmuma pieņemšanas problēma, kuras precizitāte ir cieši saistīta ar datu kvalitāti un izmantoto novērtēšanas metožu piemērotību [28].

Svārstībās 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*).

Konstrukciju tehniskā stāvokļa monitoringā izmantotos sensoru mērījumus var iedalīt kinemātiskajos, mehāniskajos un apkārtējās vides iedarbības mērījumos [29].

Sensori ir viena no būtiskākajām monitoringa sistēmas sastāvdaļām, jo iegūto datu kvalitāte tieši ietekmē dinamisko parametru noteikšanas precizitāti. Konstrukciju monitoringā visbiežāk tiek izmantoti piezoelektriskie, optiskās šķiedras un mikroelektromagnētiskie (*MEMS, Micro-Electro-Mechanical Systems*) sensori [14], no kuriem *MEMS* sensori pēdējos gados ir kļuvuši par visbiežāk izmantotajām ierīcēm konstrukciju tehniskā stāvokļa monitoringā. *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 [30].

Lai izvēlētos atbilstošu sensoru konstrukciju tehniskā stāvokļa monitoringam, ir svarīgi ņemt vērā arī katra sensora ražotāja norādītās specifiskās īpašības un veiktspēju. Sensoriem, kas tiek izmantoti ēku un inženierbūvju konstrukciju tehniskā stāvokļa monitoringam, ir jābūt ar lielu jutību un zemu trokšņu līmeni [31].

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, kas ļauj uzlabot signāla un trokšņa attiecību un nodrošināt stabilāku pašsvārstību frekvenču identificēšanu ilgtermiņa konstrukciju monitoringa apstākļos [32].

Svārstību mērījumiem tiek pieņemts, ka ir nepieciešams izmantot augstas kvalitātes sensorus. Tomēr pēdējā laikā ir notikusi pāreja no retāk izvietotu augstas kvalitātes sensoru izmantošanu uz lielāku skaitu izkliedēti izvietotu zemākas kvalitātes un lētāku sensoru izmantošanu. Piemēram, izmantojot viedtālruņus, ir iespējams noteikt konstrukcijas svārstības ar akselerometra aplikāciju. Viedtālruņos iebūvētie sensori ir zemas kvalitātes, tāpēc trokšņu

slāpēšana tiek panākta, izmantojot augstfrekvences filtrēšanu. Filtrēšana uzlabo sistēmas darbības efektivitāti, samazinot integrēto troksni. Tomēr tā rada arī risku, ka no signāla tiek izņemta būtiska informācija [33]. Sākot no 2015. gada, atsevišķos pētījumos tiltu konstrukciju monitoringā mērījumi tiek iegūti arī, izmantojot viedtālruņos iebūvētos sensorus [34].

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 [35].

Īpašību iegūšanas procesu var iedalīt divās lielākās kategorijās – datos balstītu un modeļos balstītu īpašību iegūšana. Papildus šīm divām metodēm tiek izmantota arī viļņu izplatīšanās procesā un mehāniskajā impedancē balstīta metode, kas ir datos balstītas metodes apakškopas. Tomēr tās nav izmantojamas masīvām civilām ēkām un inženierbūvēm, bet tās biežāk tiek izmantotas aeronautikā un automašīnu ražošanā kā kvalitātes kontroles rīks [1].

Modeļos balstītās metodes pamatā ir galīgo elementu modeļa izveide un modālās analīzes veikšana, lai noteiktu konstrukcijas dinamiskos parametrus. Konstrukciju tehniskā stāvokļa monitorings tiek veikts, analizējot modeļa parametru izmaiņas vai prognožu kļūdas modeļa izejas datus, kas ļauj identificēt konstrukciju bojājumus. Šī pieeja ir īpaši piemērota gadījumos ar ierobežotu monitoringa datu apjomu, tomēr tās praktisko lietojumu būtiski ietekmē ārējo vides apstākļu mainīgums un nepieciešamība nodrošināt augstu galīgā elementa modeļa precizitāti [1]. Galīgo elementu modeļi tiek izmantoti sensoru tīkla projektēšanā, bojājumu simulācijai un datos balstītu algoritmu kontrolētai apmācībai [36]. Modeļa precizitāte tiek uzlabota, izmantojot modeļu atjaunināšanas pieejas, pielāgojot masas un stinguma matricas [37]. Dinamisko parametru izmaiņu kvantitatīva analīze ekspluatācijas un ārējo vides apstākļu ietekmē ir būtiska gan bojājumu novērtēšanai, gan analītisko modeļu kalibrēšanai [38].

Datos balstītās metodes tieši izmanto mērījumu signālu analīzi un ietver pazīmju iegūšanu un lēmumu pieņemšanu par konstrukcijas tehnisko stāvokli [46]. Pazīmju iegūšana var tikt veikta laika frekvenču vai laika un frekvenču apgabalā, kā arī izmantojot mašīnmācīšanās algoritmus, kas ļauj apstrādāt sarežģītus signālus un identificēt bojājumu izraisītās izmaiņas konstrukciju dinamiskajos parametros.

Ņemot vērā abu metožu priekšrocības un trūkumus, jaunākajos pētījumos arvien biežāk tiek izmantotas hibrīdmetodes, kas apvieno modeļos un datos balstītu pieeju priekšrocības un uzlabo konstrukciju bojājumu identificēšanas precizitāti mainīgos ārējās vides un ekspluatācijas apstākļos [40].

Ēku konstrukciju tehniskā stāvokļa monitoringa nepieciešamība ir pierādīta un pamatota vairākos pētījumos, tomēr tā ieviešana reālām ēku konstrukcijām, kas ir pakļautas ārējiem vides apstākļiem, ir izaicinoša un joprojām ir nepieciešama papildu izpēte [12], lai šo metodi lietotu 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 [41].


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, kas ir stacionāri, ir jāņem vērā apkārtējās vides mainīgums [1].

Pētījumos 1996. gadā [42] un 1998. gadā [43] tika sniegts plašs literatūras pārskaits par svārstībās balstītu konstrukciju bojājumu noteikšanas metodēm, vienlaikus konstatējot, ka lielākā daļa no tiem balstās iepriekš izveidotos analītiskajos modeļos. Kā arī pētījumi galvenokārt tika veikti laboratorijas apstākļos, un netika analizēti konstrukciju dinamiskie parametri mainīgos ārējās vides apstākļos [44].

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 [14].

Ārējie vides apstākļi ietver vēju, temperatūru, mitrumu un sniegu. Savukārt ekspluatācijas apstākļi ietver apkārtējās slodzes apstākļus, darbības ātrumu un masas slodzi. Realitātē konstrukcijas vienlaikus tiek pakļautas dažādiem ekspluatācijas un ārējās vides apstākļiem [45]. 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 [46].

Lielākā uzmanība konstrukciju tehniskā stāvokļa monitoringa izpētē tiek pievērsta ārējās vides temperatūras un vēja radīto slodžu un ietekmju izpētei (1.2. att.). Citi ietekmes faktori, piemēram, mitrums un robežnosacījumu izmaiņu ietekme, tiek apskatīti retāk [41].



1.2. att. Dažādu ārējo ietekmes faktoru sadalījums, kuru ietekme tiek pētīta konstrukciju tehniskā stāvokļa monitoringa izpētē zinātniskajās publikācijās [41].

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 statistiski 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 [47].

Ilgtermiņa tehniskā stāvokļa monitoringa pētījumi liecina, ka ārējās gaisa temperatūras ietekmē konstrukciju pašsvārstību frekvenču relatīvās izmaiņas var sasniegt vairāk nekā 1 %, kas potenciāli var noslēpt bojājumu izraisītās dinamisko parametru izmaiņas [48]. Milānas katedrāles un Prāgas TV torņa monitoringa datu rezultātu apstiprināja, ka ārējā gaisa temperatūra ir dominējošais faktors konstrukciju dinamisko īpašību izmaiņās, savukārt relatīvais mitrums un vēja ietekme ir mazāka [49]. Līdzīga tendence novērota arī Kampobasso pilsētas “*Cardarelli*” slimnīcas konstrukciju tehniskā stāvokļa monitoringā, kur frekvenču izmaiņas tika skaidrotas ar to, ka abus ēkas blokus sadala šuve, un, paaugstinoties temperatūrai, attālums starp blokiem termiskās izplešanās rezultātā samazinās, rezultātā bloku savstarpējā sasaiste rada zināmu stinguma pieaugumu ēkas garenvirzienā [50].

Ārējie vides apstākļi, kas varētu ietekmēt ēkas dinamiskos parametrus, ir arī gruntsūdens līmenis [51]. Līmeņa izmaiņas ietekmē atmosfēras nokrišņu daudzums, gaisa temperatūra, iežu litoloģiskais sastāvs un drenēšanas pakāpe [52]. 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 [53].

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 [54]. Augsnes veids arī var būt faktors, kas ietekmē ēkas svārstību formu un pat modificē to, radot vertikālās svārstības [55]. Augsnes ietekme uz ēkas dinamiskajiem parametriem tiek izvērtēta, izmantojot elastīgas pamatu konstrukcijas analīzi. Elastīgās pamatu atsperes ir atkarīgas no grunts tipa, slāņu biezuma, gruntsūdens līmeņa un iežu dziļuma [56].

2. Mašīnmācīšanās metožu integrācija konstrukciju tehniskā stāvokļa monitoringā

Konstrukciju tehniskā stāvokļa monitoringa speciālisti šobrīd pievērš arvien vairāk uzmanības mākslīgā intelekta izmantošanas iespējām, lai paaugstinātu ēku un inženierbūvju stāvokļa novērtēšanas un tehniskās apkopes automatizācijas līmeni, izmantojot patstāvīgu, precīzu un stabilu monitoringa datu apstrādi [57].

Fengs un Bahngs jau 1999. gadā [58], 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 lietošana dažādās pētniecības nozarēs joprojām tiek aktīvi pētīta, lai uzlabotu mācīšanās procesu, galveno uzmanību pievēršot datu dimensiju samazināšanai [59]. 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 iegūtajos datos, ir viena no aktuālākajām problēmām.

Aizvien vairāk ir nepieciešams izmantot jaunās tehnoloģijas, lai automatizētu datu novērtēšanas procesus un uzlabotu šo novērtēšanas procesu objektivitāti [60]. Lai sistēma, kas atrodas mainīgā vidē, būtu automatizēta un inteliģenta, 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 [61].

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 [62].

Automatizēto metožu galvenais pieņēmums ir tas, ka bojājumi – plaisas, pakāpenisks konstrukcijas nolietojums, ir raksturīgas datu anomālijas jeb novirzes no normālā stāvokļa, ko var atpazīt. Ja datu analizē tiek konstatētas iespējamās novirzes, konstrukciju bojājumu lokalizācijai, bojājuma veidam un pakāpei var izmantot īpaši izstrādātus algoritmus [63].

Mašīnmācīšanās algoritmu mērķis ir noteikt statistisko struktūru datos [64] 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 [65].

Pamatojoties uz literatūru, kas tika publicēta aptuveni 20 gadu laikā līdz 2007. gadam, pētījumā [66] tika formulētas septiņas aksiomas, kas nosaka bojājumu noteikšanas pamatprincipus. Aksiomas nosaka, ka konstrukcijās vienmēr pastāv materiālu trūkumi vai defekti, bet bojājumu novērtēšana ir iespējama tikai tad, ja salīdzina divus sistēmas stāvokļus. Sensori bojājumus tieši nemēra, līdz ar to bojājumu identificēšanai ir nepieciešama pazīmju iegūšana no mērījumu datiem, izmantojot signālu apstrādi un statistiskās metodes. Bojājuma konstatēšanu un atrašanās vietu iespējams noteikt, izmantojot nekontrolēto mācīšanas veidu, bet bojājuma veida un pakāpes noteikšanai ir nepieciešama kontrolēta mācīšanās. Vienlaikus bojājumu noteikšanas jutība ir saistīta ar trokšņa ietekmi, ārējo vides un ekspluatācijas apstākļu mainīgumu, sensoru sistēmas laika un telpas mērogu, kā arī ierosmes frekvenču diapazonu, kas nosaka identificējamo bojājumu apjomu. Šīs aksiomas kļuva par nozīmīgu pamatu turpmākajiem pētījumiem konstrukciju tehniskā stāvokļa monitoringa un mašīnmācīšanās metožu integrācijai [66].

Lielākā daļa teorētisko darbu mašīnmācīšanās jomā ir koncentrēti uz vispārīgu mācīšanās metožu izveidi, raksturošanu un analīzi, akcentējot metodes vispārīgumu un efektivitātes analīzi [67].

Mašīnmācīšanās algoritmus var iedalīt četrās grupās: uzraudzītas, neuzraudzītas, daļēji uzraudzītas un padziļinātās mācīšanās algoritmi.


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].

Mašīnmācīšanās algoritms, ko nepieciešams izmantot attiecīgajam konstrukciju tehniskā stāvokļa monitoringa uzdevumam, ir atkarīgs no spējas veikt uzraudzītu vai neuzraudzītu mācīšanos [68].

Uzraudzītā mācīšanās balstās marķētā mācību datu kopā un izmanto klasifikācijas metodes, lai iegūtu sakarību starp novērojumiem un to attiecīgajiem izejas datu marķējumiem, nodrošinot jaunu, iepriekš neatpazītu datu klasificēšanu.

Daļēji uzraudzītās mašīnmācīšanās algoritmi tiek izmantoti gadījumos, kad ir pieejams ierobežots marķēto datu apjoms. Algoritmos tiek izmantota marķēto datu informācija, savukārt nemarķētie dati tiek izmantoti, lai papildus ierobežotu klasifikācijas algoritmu [69].

Savukārt **neuzraudzītā mācīšanās** tiek izmantota gadījumos, kad ievades datiem nav pieejami marķieri. Metode mēģina klasificēt ievades datus, pamatojoties uz to līdzību. Šādos gadījumos algoritmi grupē līdzīgus novērojumus klasteros vai identificē anomālijas, lai noteiktu datu punktus, kas būtiski atšķiras un var liecināt par konstrukcijas bojājumiem, trokšņiem vai ārējās vides ietekmi [70]. Visbiežāk anomāliju noteikšanas metodes paredz, ka normālais stāvoklis veido vienu klasi vai grupu un punkti ārpus klases robežas tiek apzīmēti kā jaunumi vai anomālijas (2.1. att.). Ja dati veido vairākas grupas dažādu nebojātu vai bojātu apstākļu dēļ, tad par atbilstošāko metodi tiek uzskatīta klasteru analīze.



2.1. att. Novitāšu noteikšanas metodes: a) vienas klases novitātes noteikšanas metode;
b) vairāku klašu novitātes noteikšanas jeb klasteru analīze [71].

Padziļinātās mašīnmācīšanās algoritmi spēj automātiski veikt pazīmju iegūšanu un apgūt hierarhiskas, augsta līmeņa pazīmes, kas ļauj efektīvi risināt sarežģītus uzdevumus, sadalot tos lielā skaitā vienkāršu problēmu [65].

Mašīnmācīšanās algoritmi attiecīgai problēmsituācijai tiek izvēlēti pēc vairākiem kritērijiem. Daži no faktoriem, kas ietekmē algoritma izvēli, ir, piemēram, apmācības datu skaits, paredzamais apmācības laiks un precizitātes pakāpe [1].

Mašīnmācīšanās metodes algoritma izvēlē noteicošais faktors ir arī sasniedzamais rezultāts – konstrukciju monitoringa bojājumu identifikācijas līmenis. Izvēloties mašīnmācīšanās metodi, ir jāņem vērā katras metodes ierobežojumi un konstrukciju tehniskā stāvokļa monitoringa prasības attiecībā uz bojājumu identificēšanas līmeni un ekspluatācijas apstākļiem [40].

Pamata mākslīgie neironu tīkli (*ANN, Artificial Neural Network*) konstrukciju monitoringā tiek izmantoti datu reprezentāciju apgūšanai un dimensiju samazināšanā, bieži balstoties uzraudzītā mācīšanās procesā ar nebojāta stāvokļa datiem, lai identificētu novirzes un iespējamus bojājumus. Klasiskajiem *ANN* raksturīga vienkārša struktūra ar nelielu skaitu slēpto slāņu. Šādus tīklus visbiežāk izmanto datu dimensiju samazināšanai.

Konvolūcijas neironu tīkls (*CNN, Convolutional Neural Network*) ir padziļinātās mācīšanās pieeja, kas, izmantojot konvolūcijas filtrus, automātiski identificē nozīmīgākās pazīmes datos. *CNN* visbiežāk tiek izmantoti datu analīzei ar tīklveida struktūru un lokālu telpisku korelāciju.

Atbalsta vektoru mehānismu (*SVM*) metode tiek plaši izmantota klasifikācijas un regresijas uzdevumos, nosakot optimālu robežvirsmu starp datu klasēm un nosakot gan lineāras, gan nelineāras sakarības starp datiem, izmantojot dažādas kodolfunkcijas [40].

Galveno komponentu analīze (*PCA, Principal Component Analysis*) tiek izmantota datu dimensiju samazināšanai, saglabājot tikai būtiskāko informāciju no sākotnējiem datiem un uzlabojot apmācības efektivitāti, samazinot sensoru datu apstrādes laiku [40], [72]. Nelineāru sakarību analīzei tiek lietota kodola galveno komponentu analīze (*KPCA, Kernel Principal Component Analysis*), kas ļauj efektīvi apstrādāt sarežģītas datu struktūras [73].

Ārējie vides ietekmes faktori konstrukcijas dinamiskās īpašības spēj ietekmēt dažādi, piemēram, samazināt vai palielināt pašvārstību frekvences. Lai uzlabotu konstrukciju monitoringa precizitāti un uzticamību, ārējo vides faktoru ietekmes samazināšanai tiek izmantoti dažādi mašīnmācīšanās algoritmi [41]. 2.1. tabulā apkopoti vairāki mašīnmācīšanās algoritmi, to lietojums un konkrētais ārējās vides ietekmes faktors, kura ietekme attiecīgi ir analizēta šajā pētījumā.

Publikācijās izmantotie mašīnmācīšanās algoritmi ārējo vides faktoru ietekmes samazināšanai

Algoritma nosaukums	Lietojums	Analizētais un koriģētais ārējās vides faktors
Galveno komponentu analīze (<i>PCA</i>)	Izmantojot ar <i>PCA</i> transformētus ārējās vides parametrus, saliktais ansambļa mācīšanās modelis precīzāk prognozēja dinamisko parametru atkarību no ārējās vides apstākļiem, ļaujot netieši kompensēt ārējās vides ietekmi, analizējot prognozēšanas atlikumus [74].	Ārējā gaisa temperatūra, mitrums, vēja ātrums, vēja virziens, virsmas temperatūra
Autoregresīvie modeļi (<i>ARX</i> , <i>Autoregressive Models with Exogenous Inputs</i>)	Autoregresīvie modeļi (<i>ARX</i>) tika izmantoti, lai modelētu Z24 tilta pašsvārstību frekvenču izmaiņas, vienlaikus ņemot vērā ārējās gaisa temperatūras svārstības [75].	Ārējā gaisa temperatūra
Gausa procesa regresija (<i>GPR</i> , <i>Gaussian Process Regression</i>)	<i>GPR</i> algoritms tika izmantots, lai prognozētu vēja ģeneratoru lāpstiņu pašsvārstību frekvences, vienlaikus ņemot vērā ārējās vides svārstības [76].	Ārējā gaisa temperatūra
Galveno komponentu analīze (<i>PCA</i>) un metaapmācība (<i>MAML</i> , <i>Model-Agnostic Meta-Learning</i>)	<i>PCA</i> tika izmantota, lai no frekvenču datiem noņemtu dažas mazāk nozīmīgās izmaiņas. <i>MAML</i> tika izmantota, lai pielāgotu modeļus dažādām vidēm un konstrukcijām, ļaujot uzlabot sistēmas spēju pielāgoties ārējās vides variācijām [77].	Ārējā gaisa temperatūra
Konvolūcijas neironu tīkli (<i>CNN</i>) un Gausa jauktie modeļi (<i>GMM</i>)	Tā vietā, lai tieši atdalītu konkrētus vides parametrus, <i>GMM</i> apguva <i>CNN</i> iegūto pazīmju statistiskos sadalījumus, ļaujot modelim filtrēt vides ietekmi un koncentrēties uz konstrukciju bojājumu noteikšanu [78].	Ārējā gaisa temperatūra
Bajesa modeļa atjaunināšana	Metode tika izmantota, lai pusautomātiski pielāgotu temperatūras korekcijas funkciju, lai samazinātu temperatūras izraisītās kļūdas [79].	Ārējā gaisa temperatūra
Modeļos balstīta pieeja	Temperatūras modelēšana tika integrēta skaitliskajā modelī, lai atšķirtu bojājumu no apkārtējās vides izraisītām izmaiņām [80].	Ārējā gaisa temperatūra

Metode, kurā ārējās vides faktoru dimensijas samazināšanai tiek izmantota **galveno komponentu analīze (*PCA*)** un dinamisko parametru prognozēšanai – saliktā ansambļa mācīšanās pieeja [74], balstās datos balstītā ārējās vides ietekmes netiešā samazināšanā, analizējot prognozēšanas atlikumus starp mērītajām un prognozētajām pašsvārstību frekvenču vērtībām.

Metode ļauj vienlaikus ņemt vērā vairākus ārējās vides faktorus un aprakstīt nelineāras sakarības, taču tās efektivitāte ir atkarīga no apmācības datu kvalitātes, pieņēmuma par sakarību

nemainību laikā. Metodes interpretējamība ir ierobežota, un tās validācijai tika izmantoti pilna mēroga režģa konstrukciju īstermiņa monitoringa dati, kurā netika novērotas pēkšņas ārējo vides faktoru vērtību izmaiņas [74].

Metode, kas balstās datos balstītā ārējās vides faktoru ietekmes samazināšanā, izmantojot **autoregresīvos modeļus (ARX)** [75], apraksta konstrukcijas pašsvārstību frekvenču izmaiņas kā ārējās gaisa temperatūras funkciju, izmantojot ilgtermiņa monitoringa datus, kas iegūti ar automātisko modālo analīzi (*AMA, Automated Modal Analysis*). Ārējās vides ietekme tiek netieši kompensēta, analizējot prognozēšanas atlikumus starp mērītajām un *ARX* modeļa prognozētajām pašsvārstību frekvenču vērtībām.

Metode tika validēta, izmantojot pilna mēroga tilta konstrukciju ilgtermiņa monitoringa datus, kas apliecina tās piemērojamību arī citām inženierbūvēm mainīgos ārējās gaisa temperatūras apstākļos. Tomēr analizē ietekmes samazināšanai tika izmantotas tikai pozitīvas temperatūras vērtības, neņemot vērā konstrukcijas dinamisko parametru izmaiņas, ja ārējā gaisa temperatūra ir negatīva, kā arī metode balstās empīriskos modeļos ar ierobežotu interpretējamību.

Metode, kurā tiek izmantota **Gausa procesa regresija (GPR)** [76], balstās ārējās vides faktoru netiešā samazināšanā, modelējot relatīvās sakarības starp nomināli identisku konstrukcijas elementu dinamiskajiem parametriem. Pieņemot, ka ārējās vides ietekme uz šādiem elementiem ir līdzīga, GPR tiek izmantota funkcionālas sakarības modelēšanai divu elementu dinamiskajiem parametriem, un ārējās vides ietekme tiek kompensēta, analizējot prognozēšanas atlikumus.

Metodes priekšrocība ir nelineāru sakarību modelēšana ar nenoteiktības novērtējumu, savukārt tās ierobežojumi ir saistīti ar piemērojamību tikai nomināli identiskiem elementiem, pieņēmumu par līdzīgu ārējās vides ietekmi un augstu atkarību no nebojātā stāvokļa apmācības datu kvalitātes.

Metode, kurā tiek izmantota **metaapmācība (MAML)** un **galveno komponentu analīze (PCA)** [77], balstās ārējās gaisa temperatūras ietekmes netiešā samazināšanā, modelējot konstrukcijas dinamisko reakciju kā temperatūras funkciju.

Augstas dimensijas dinamiskie dati tiek samazināti, izmantojot galveno komponentu analīzi (*PCA*), savukārt metaapmācības algoritms (*MAML*) tiek apmācīts, izmantojot skaitliski simulētus galīgo elementu modeļus ar dažādiem temperatūras un stinguma scenārijiem. Metode ļauj netieši samazināt ārējās gaisa temperatūras ietekmi arī ierobežota datu apjoma gadījumā, taču tā analizē tikai temperatūras ietekmes faktoru un ir validēta uz skaitliski simulētiem konstrukciju modeļiem, kas ierobežo tās tiešu piemērošanu ēkām un inženierbūvēm reālos mainīgos ārējās vides apstākļos.

Metode, kurā tiek izmantoti **konvolūcijas neironu tīkli (CNN)** un **Gausa jauktie modeļi** [78], balstās automātiskā pazīmju iegūšanā no mērījumu signāliem un ārējās gaisa temperatūras ietekmes netiešā samazināšanā, aprakstot pazīmju sadalījumu ar Gausa jaukto modeli (*GMM*). Ārējās gaisa temperatūras ietekme tiek modelēta statistiski, salīdzinot references un monitoringa stāvokļa sadalījumus ar Kullbeka-Leiblera (*KL, Kullback-Leibler*) diverģenci.

Metodes priekšrocība ir ārējās gaisa temperatūras ietekmes samazināšana bez tiešas ārējās vides faktora mērīšanas monitoringa laikā. Savukārt metodes ierobežojumi ir saistīti ar lielu

apmācības datu nepieciešamību, ierobežotu interpretējamību un validāciju laboratorijas apstākļos uz nepilna mēroga konstrukcijām.

Metodē, kurā tiek izmantota **Bajesa modeļa atjaunināšana** [79], ārējās gaisa temperatūras ietekme tiek modelēta kā temperatūras atkarīga mērījumu sistēmas pārnese funkcija, ko izmanto tiešai mērījumu korekcijai. Ārējās gaisa temperatūras ietekme tiek aprakstīta ar empīrisku otrās kārtas polinomu, kura koeficienti tiek adaptīvi atjaunināti, izmantojot Bajesa modeļa atjaunināšanu.

Metode nodrošina tiešu un interpretējamu ārējās gaisa temperatūras ietekmes kompensāciju ar spēju adaptēties temperatūras izmaiņām novērojumu periodā. Savukārt metodes ierobežojumi saistīti ar to, ka tiek analizēta tikai ārējās gaisa temperatūras ietekme, tās praktiskai ieviešanai nepieciešama kontrolēta temperatūras kalibrācija, un metode ir validēta laboratorijas apstākļos uz nepilna mēroga eksperimentālās sistēmas.

Metodē, kurā tiek izmantota **modeļos balstīta** ārējās vides faktoru ietekmes samazināšana [80], ārējās gaisa temperatūras ietekme tiek tieši integrēta galīgo elementu modelī, vienlaikus modelējot gan temperatūras, gan bojājumu izraisītās izmaiņas konstrukciju dinamiskajos parametros. Temperatūras ietekme tiek ievērtēta, modelējot materiāla elastības moduļa un termiskās izplešanās atkarību no temperatūras, līdz ar to nodrošinot fizikāli pamatotu ārējās vides ietekmes nodalīšanu bez tiešas mērījumu signālu korekcijas.


Metodes galvenā priekšrocība ir augsta rezultātu interpretējamība un fizikāli pamatota ārējās gaisa temperatūras ietekmes samazināšana. Savukārt metodes ierobežojumi saistīti ar to, ka tiek analizēta tikai ārējās gaisa temperatūras ietekme, augstu atkarību no precīza galīgo elementu modeļa pieejamības, kā arī validāciju, kas veikta, izmantojot skaitliski ģenerētus datus.

Analizētās ārējās vides faktoru ietekmes samazināšanas metodes ļauj būtiski samazināt ārējās vides izraisīto dinamisko parametru izmaiņas, saglabājot jutību pret konstrukciju bojājumiem. Tomēr to praktisko lietojumu bieži ierobežo pieņēmumi par ārējās vides nemainīgumu, apmācības datu kvalitāte un apjoms, ierobežota interpretējamība, kā arī tas, ka lielākajā daļā pētījumu tiek analizēti tikai ārējās gaisa temperatūras ietekme un validācija balstās īstermiņa vai simulētos monitoringa datus.

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 [81]. 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 lietojamību 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 ar astoņiem secīgiem posmiem (3.1. att.), kas ļauj iegūt stabilas un salīdzināmas pašsvārstību frekvenču vērtības un uzlabot bojājumu identificēšanu. Metode nodrošina ārējās vides faktoru kvantificēšanu un korekciju aprēķinu, ir praktiski lietojama un integrējama monitoringa sistēmas algoritmos, kā arī sniedz iespēju pielāgoties sezonālajām klimata izmaiņām.



3.1. att. Ārējās vides ietekmes samazināšanas metodes 1.–8. posms.

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.

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 un 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 [82].

Atbalsta vektora regresija (*SVR*) ir atbalsta vektora mašīnmācīšanās algoritma (*SVM*) paplašinājums regresijas uzdevumiem, kas ļauj modelēt nelineāras sakarības, izmantojot Gausa jeb radiālās bāzes (*RBF*) kodolfunkciju [83] un pieļaujot kontrolētas novirzes ārpus noviržu noteiktā tolerances intervāla [84].

Gadījuma meža regresija (*RF*) ir ansambļa mācīšanās metode, kas apvieno vairākus lēmumu kokus, apmācītus uz nejauši atlasītiem datu apakšparaugiem un mainīgo apakškopām, nodrošinot stabilas prognozes un samazinot pārprielāgošanās risku [85].

Lineārā regresija (*LR*) pieņem lineāru sakarību starp pašsvārstību frekvencēm un ārējās vides faktoriem, minimizējot vidējo kvadrātisko kļūdu. Metode ir piemērota gadījumos ar aptuveni lineāru ietekmi [86].

Lēmumu koku regresija (*DT*) sadala datu telpu reģionos ar raksturīgām prognozēm, minimizējot kļūdu katrā reģionā. Taču metodes precizitāte var samazināties sarežģītu nelineāru sakarību gadījumā [87].

Gradientu palielināšanas regresija (*XGBoost*) ir ansambļa mācīšanās metode, kas secīgi uzlabo lēmumu kokus, ierobežojot modeļa sarežģītību un samazinot pārprielāgošanās risku ar regularizāciju [88].

Gausa procesu regresija (*GPR*) ir neparametriska metode, kas modelē nelineāras sakarības, izmantojot Gausa procesa modeli ar noteiktu kovariācijas struktūru, un ļauj kvantitatīvi novērtēt prognožu nenoteiktību [89].

Bajesa regresija (*BR*) šajā gadījumā balstās *GPR* ar automatizētās atbilstības noteikšanas (*ARD, Automatic Relevance Determination*) *Matern 5/2* kodolfunkcijā, kas piešķir katram ievades parametram atsevišķu garuma mēroga parametru un nodrošina precīzas prognozes ar nenoteiktības kvantitatīvu novērtējumu [90].

Lai nodrošinātu katra modeļa optimālu pielāgošanu datiem, tiek izmantota **Bajesa optimizācija**, kas automātiski meklē labākos modeļu hiperparametrus, uzlabojot prognozēto pašsvārstību frekvenču atbilstību novērotajiem datiem, ņemot vērā ārējās vides faktorus.

Optimizācijas procesā tiek izveidots varbūtību modelis par mērķa funkcijas vērtību sadalījumu, izmantojot Gausa procesa regresiju (GPR) kā aizstājējfunkciju, kas ļauj novērtēt gan prognozes vidējo vērtību, gan prognozes varianci [90].

Bajesa optimizācija tiek lietota katrai regresijas metodei, veicot 30 hiperparametru testus, lai atrastu optimālos hiperparametrus (*SVR* – regulēšanas parametrs un kodolfunkcijas parametrs; *RF* – lēmumu koku skaits, maksimālais sadalījumu skaits, minimālais lapas izmērs un minimālais paraugu skaits mezglā pirms sadalīšanas; *XGBoost* – mācīšanās ātrums, gradienta palielināšanas koku skaits, maksimālais sadalījuma skaits, minimālais lapas izmērs; *GPR* – kodolfunkcijas tips, garuma mērogs un signāla variance; *BR* – *ARD* garuma vērtība; *DT* – maksimālais sadalījumu skaits un minimālais lapas izmērs).

Optimizācijas problēma tiek formulēta kā hiperparametru vektora izvēle, kas minimizē vidējo kvadrātisko kļūdu (*MSE*). Nākamā hiperparametru kombinācija tiek izvēlēta, izmantojot paredzamā uzlabojuma plus funkciju (*EI+*), ņemot vērā gan iespējamo prognozes kļūdu samazinājumu, gan ar to saistīto nenoteiktību [91].

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: determinācijas koeficients (R^2 , *Coefficient of Determination*), vidējā kvadrātiskā kļūda (*RMSE*, *Root Mean Squared Error*), vidējā absolūtā kļūda (*MAE*, *Mean Absolute Error*) un vidējā procentuālā absolūtā kļūda (*MAPE*, *Mean Absolute Percentage Error*).

R^2 vērtība raksturo, kādu daļu no atkarīgā mainīgā dispersijas skaidro modelis ($R^2 = 1$ – pilnīga atbilstība, $R^2 = 0$ – modelis nav labāks par vidējo prognozi, $R^2 < 0$ – sliktāks par vidējo prognozi). *RMSE* un *MAE* raksturo vidējo prognozes kļūdu, savukārt *MAPE* izsaka kļūdu procentuālā izteiksmē. Zemākas *RMSE*, *MAE* un *MAPE* vērtības liecina par augstāku modeļa precizitāti [87].

Katram no modeļiem tiek aprēķināts **saliktās efektivitātes rādītājs** (*CPM*, *Composite Performance Metric*), kas apvieno R^2 , *RMSE*, *MAE* un *MAPE* vērtības, lai sniegtu vienotu rādītāju, pēc kura var salīdzināt dažādu regresijas modeļu vispārējo precizitāti. *CPM* tiek aprēķināts pēc 3.1. formulas:

$$CPM = M_{norm}(RMSE) + M_{norm}(MAE) + M_{norm}(MAPE) - M_{norm}(R^2), \quad (3.1)$$

kur $M_{norm}(M_m)$ nozīmē, ka attiecīgais rādītājs tiek normalizēts pēc 3.2. formulas:

$$M_{norm}(M_m) = \frac{M_m - \mu_M}{\sigma_M + \varepsilon}, \quad (3.2)$$

kur M_m – konkrētā modeļa rādītāja *RMSE*, *MAE*, *MAPE* vai R^2 vērtība; μ_M – attiecīgā rādītāja vidējā vērtība, kas tiek aprēķināta starp visiem modeļiem analizētajā frekvencē; σ_M – attiecīgā rādītāja standartnovirze; ε – ļoti maza konstante, kas pievienota, lai izvairītos no dalīšanas ar nulli un uzlabotu skaitlisko stabilitāti [92].

Zemāka *CPM* vērtība liecina par labāku modeļa veiktspēju. Ārējo vides faktoru segmentu noteikšanai tiek izvēlēts modelis ar zemāko vidējo *CPM* vērtību.

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 pārprielāgošanas riska [93]. Pašsvārstību frekvenču korekcija tiek veikta katram segmentam atsevišķi, kur segmentu robežas tiek noteiktas automātiski, izmantojot izvēlēto regresijas modeļa daļējās atkarības diagrammas (*PDP*, *Partial Dependence Plots*) līknes. *PDP* raksturo prognozēto frekvenču izmaiņas atkarībā tikai no viena izvēlēta ārējās vides faktora, saglabājot pārējo parametru faktiskās vērtības visā datu kopā. Daļējās 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:

$$f_{PDP(x_j)} = \frac{1}{N} \sum_{n=1}^N f(x_j, X_{-j}^n), \quad (3.3)$$

kur x_j – analizējamā ārējās vides faktora vērtība; X_{-j}^n – pārējo apkārtējās vides ietekmes faktoru faktiskās vērtības n -tajam datu novērojumam; N – monitoringa novērojumu skaits [94].

Pēc 3. posmā veiktās regresijas modeļu novērtēšanas tiek izvēlēts modelis ar zemāko *CPM* vērtību. Izmantojot šo modeli, tiek noteiktas vidējās *PDP* vērtības visām pašsvārstību frekvencēm un no tām iegūta vidējā *PDP* funkcija. Iegūtā vidējā funkcija tiek papildus izlīdzināta, izmantojot Gausa procesa regresiju, lai iegūtu vienmērīgu un stabilu sakarības aprakstu. Izlīdzināšana ir būtiska, jo tā nodrošina, ka segmentu robežas tiek noteiktas no kopīgās ārējās vides ietekmes faktora un pašsvārstību frekvences sakarības, nevis lokālām novirzēm [90].

Segmentu maiņas punktu noteikšanai tiek izmantota *Matlab* komanda *findchangepts*, kas atrod tās ārējo vides parametru vērtības c_1 , c_2 , kurās mainās *PDP* līknes lineārā tendence un funkcija vislabāk sadalās trīs lineārās daļās. Segmentu maiņas punkti tiek izvēlēti, minimizējot kopējo atlikumu kvadrātu summu. Kad maiņas punkti ir atrasti, ārējās vides faktoru vērtību diapazons tiek sadalīts trīs intervālos:

$$(-\infty, c_1), [c_1, c_2], [c_2, +\infty). \quad (3.4)$$

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 . Katrā segmentā tiek novērtēti visi septiņi regresijas modeļi, aprēķinot R^2 , *RMSE*, *MAE*, *MAPE* un saliktās efektivitātes rādītāju (*CPM*). Par labāko katrā segmentā tiek izvēlēts modelis ar zemāko *CPM* vērtību, kas tiek izmantots samazinātas vērtības daļējās atkarības diagrammas (*PDP*) veidošanai katrai pašsvārstību frekvencei f_i un katram ārējās vides faktoram x_j . Samazinātu vērtību daļējās

atkarības diagramma (*PDP*) tiek veidota diskrētā režģī, kur katram ārējās vides faktora punktam tiek aprēķināta atbilstošā prognozētā pašsvārstību frekvences vērtība, pārējos faktorus fiksējot to vidējās vērtībās.

Optimālais režģa punktu skaits G_i katrai pašsvārstību frekvencei tiek noteikts, izmantojot iteratīvu režģa meklēšanas procesu ar konverģences kritēriju. Diskrēto vērtību kvalitāte tiek novērtēta, aprēķinot vidējo kvadrātisko kļūdu *MSE*. Pēc katra režģa aprēķina diskrētās daļējas atkarības diagrammu (*PDP*) vērtības tiek interpolētas faktiskajās ārējās vides faktora vērtībās un aprēķināta vidējā kvadrātiskā kļūda starp faktisko un prognozēto pašsvārstību frekvenci. Ja vidējās kvadrātiskās kļūdas (*MSE*) izmaiņas starp diviem secīgiem režģiem ir mazāka par toleranci ε , tiek noteikts optimālais režģa punktu skaits. Optimizācijas procesā tiek izmantots minimālais režģa punktu skaits $G_{min} = 50$, maksimālais $G_{max} = 500$ un režģa palielināšanas solis $\Delta G = 50$. Optimāli izvēlēta diskretizācija nodrošina, ka interpolētā *PDP* līkne precīzi atspoguļo ārējās vides faktora ietekmi un tiek izmantota turpmākai pašsvārstību frekvenču korekcijai.

Ārējās vides faktoru ietekmes samazināšanas metodes **6. posmā** katrai pašsvārstību frekvences f_i vērtībai un katram ārējās vides ietekmes faktoram x_j tiek izmantotas segmentētās diskrētās daļējas atkarības (*PDP*) vērtības, kas tiek interpolētas pie faktiskās ārējās vides faktora vērtības attiecīgajā segmentā. Lai izvairītos no ekstrapolācijas, ārējās vides faktora vērtība tiek ierobežota ar segmenta režģa minimālo vai maksimālo robežvērtību [95].

Pēc tam tiek aprēķināta interpolētā daļējas atkarības diagrammas (*PDP*) vērtība pie attiecīgā ārējās vides faktora vērtības. Interpolācijai tiek izmantota gabalu veida kubiskā Hermīta interpolācija (*PCHIP*, *Piecewise Cubic Hermite Interpolation Polynomial*), kas veido gludu, nepārtrauktu interpolācijas līkni, saglabājot sākotnējo datu vienmērīgu izmaiņu raksturu un neieviešot mākslīgas lokālas svārstības starp režģa punktiem [96].

Aprēķinu rezultātā tiek iegūta ietekmes izmaiņu matrica:

$$\Delta(n, s, j, i) = \hat{f}_{i,j,s}^{PDP}(n) - \hat{f}_{i,j,s}^{PDP}(\bar{x}_{j,s}), \quad (3.5)$$

kur $\hat{f}_{i,j,s}^{PDP}(n)$ – interpolētā daļējas atkarības diagrammas (*PDP*) vērtība pie faktiskās $x_j(n)$; $\bar{x}_{j,s}$ – segmenta režģa vidējā vērtība; $\hat{f}_{i,j,s}^{PDP}(\bar{x}_{j,s})$ – segmenta vidējās vērtības līmeņa vērtība [88]. 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 [97].

Ārējās vides faktoru ietekmes samazināšanas metodes **7. posmā** katrai pašsvārstību frekvencei tiek noteikts nenegatīvs ietekmes īpatsvaru vektors w_i . Vispirms tiek definēta daļējas atkarības diagrammas (*PDP*) ietekmju matrica, kurā apkopota katra ārējās vides faktora un segmenta relatīvā ietekme vienotā optimizācijas līmenī [98]. No ietekmes matricas D_i tiek izvēlēti tikai tie segmenti, kuros pietiekami bieži parādās nenulles ietekme, izmantojot minimālā pārklājuma kritēriju ($\rho = 0,05$). Lai nodrošinātu salīdzināmību starp segmentiem ar ļoti atšķirīgiem mērogiem, izvēlētajiem segmentiem tiek veikta robusta mērogošana, izmantojot starpkvartīļu diapazonu (*IQR*) [99].

Ietekmes īpatsvari tiek noteikti, risinot regularizētu nenegatīvu mazāko kvadrātu optimizācijas uzdevumu, kur katras pašsvārstību frekvences novirze no tās vidējās vērtības tiek aprakstīta kā segmentēto ārējās vides ietekmes komponentu lineāra kombinācija, bet Tihonova

regularizācija samazina pārpilnāšanās risku. Pēc optimizācijas īpatsvari tiek “atgriezti” sākotnējā mērogā (atceļot starpkvartīļu diapazonu (*IQR*, *Interquartile Range*) mērogošanu) un ievietoti pilnā īpatsvaru vektorā w_i . Lai nodrošinātu interpretējamību, īpatsvari tiek normalizēti.

Kopējā segmentētā ārējās vides ietekme katrā novērojumā tiek noteikta, summējot visu attiecīgās pašsvārstību frekvences segmentēto ārējās vides ietekmes komponentu vērtības, katru no tām reizinot ar aprēķināto ietekmes īpatsvaru.

Koriģētā pašsvārstību frekvences vērtība pēc 7. posma tiek aprēķināta pēc 3.6. formulas:

$$f_{PDP}(n, i) = f(n, i) - \hat{e}_i^{PDP}(n) = f(n, i) - \sum_p w_i(p) \times D_i(n, p). \quad (3.6)$$

Šajā solī tiek ņemta 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 [75].

Lai novērtētu atlikušās nelineārās vai sarežģītas vides ietekmes, ārējās vides faktoru ietekmes samazināšanas metodes **8. posmā**, izmantojot koriģētās vērtības $f_{PDP}(n, i)$, tiek trenēti papildu regresijas metodes (*LSBoost*, *GPR*, *SVR* un *Bagging*, (*Bootstrap Aggregating*)). *LSBoost* un *Bagging* ļauj aprakstīt lokālas nelineāras sakarības un vienlaikus paaugstina prognožu stabilitāti [88]. *GPR* nodrošina atlikušās ietekmes modelēšanu, izmantojot varbūtības sadalījumu [90]. Savukārt *SVR* ir piemērota gadījumos, kad atlikušās ietekmes ir vājākas, bet saglabā sistemātisku raksturu [84]. Līdz ar to šo metožu izmantošana pēc sākotnējās korekcijas ļauj papildus samazināt ārējās vides faktoru un ekspluatācijas apstākļu ietekmi, vienlaikus samazinot pārpilnāšanās risku [45].

Katrai metodei tiek aprēķināta laika un bloku krosvalidācijas *MSE*, izvēloties modeli ar zemāko *MSE* vērtību. No segmentētās *PDP* koriģētās frekvences vērtības tiek atņemta šī modeļa prognozētā atlikusī ārējās vides ietekme, iegūstot starpposma koriģētu pašsvārstības frekvences vērtību ar samazinātu segmentēto un nelineāro ietekmi, saglabājot sezonālo (ilgtermiņa periodiskā) ietekmi.

Nākamajā solī tiek veikta sezonālītātes ņemšana ar harmonisko regresiju. Sezonālā komponente tiek novērtēta ar mazāko kvadrātu metodi, un sezonāli koriģēta pašsvārstību frekvence tiek aprēķināta, izmantojot 3.7. formulu:

$$f_{corr}(n, i) = f_2(n, i) - SK(n, i) + \overline{SK(i)}, \quad (3.7)$$

kur $f_2(n, i)$ – koriģētā pašsvārstību frekvence konkrētajā novērojuma rindā pēc ārējās vides faktoru ietekmes korekcijas; $SK(n, i)$ – sezonālās komponentes vērtība n -tajam novērojumam un i -tajai pašsvārstību frekvencei; $\overline{SK(i)}$ – sezonālās komponentes vidējā vērtība, kas nodrošina koriģētās pašsvārstību frekvences vidējā līmeņa saglabāšanu [100].

Iegūtās frekvenču vērtības pēc sezonālās ietekmes ņemšanas vairs nesatur atkārtotas gada laika svārstības, kas uzlabo konstrukciju bojājumu noteikšanas jutību. Ja sezonālā ietekme netiek ņemta, periodiskas izmaiņas dominē atlikušajos datos, samazinot monitoringa sistēmas spēju identificēt bojājumus [101].


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 *Filomena Delli Castelli* tilta. Šajā darbā tika izmantoti pētījumā [102] analogi iegūtie *Filomena Delli Castelli* tilta monitoringa dati, jo šī tilta konstrukcijām kopš pētījuma veikšanas tiek veikts nepārtraukts konstrukciju dinamisko datu monitorings. Savukārt koka rāmja konstrukciju monitoringa dati, kas iepriekš analizēti pētījumā [103] ārējo vides apstākļu ietekmē, šajā darbā tiek atkārtoti analizēti, izmantojot izstrādāto ārējās vides faktoru ietekmes samazināšanas metodi.

Eksperimentālie 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 705 mm × 584 mm, rāmja kopējais augstums – 1,2 m (4.1. a) att.). Kā koka rāmja galvenie nesošie elementi tika izmantoti 15 mm × 15 mm koka līstes kā rāmja nesošās kolonnas un 4 mm bieza kokšķiedras plāksne kā rāmja pārseguma plātne.

Divstāvu koka rāim tika veidoti dažādas pakāpes bojājumi, kas izraisīja noturības un/vai masas izmaiņas (4.1. b) att.). Šajā darbā ar terminu “bojājums” tiek apzīmēta robežnosacījumu maiņa, kas ietekmē savienojumu stingumu un konstrukcijas dinamiskos parametrus, ne tikai degradāciju. Bojāto konstrukciju dati tika iegūti laika posmā no 2022. gada 2. septembra līdz 2022. gada 27. oktobrim.

Eksperimentā koka rāmis tika novietots 4,5 km no Baltijas jūras un 10 m attālumā no piebraucamā ceļa, līdz ar to nodrošinot mainīgus apkārtējās vides apstākļus un blakus esošās satiksmes ietekmi. Ziemā koka konstrukciju rāim tika pārklāts pagaidu jumts, kas novērsa sniega slodzes ietekmi. Eksperimenta laikā koka rāmis tika pasargāts no tiešas vēja iedarbības, līdz ar to vējš šajā gadījumā netiek iekļauts ārējo vides ietekmes faktoru analizē.



4.1. att. Eksperimentālā koka rāmja: a) modeļa shēma; b) modeļa bojājumu apraksts un pakāpe.

Mērījumiem tika izmantoti seši *Dytran IEPE* pjezoelektriskie paātrinājuma sensori (*DY 3191A1*, 10 V/g, darbības diapazons no $-51\text{ }^{\circ}\text{C}$ līdz $121\text{ }^{\circ}\text{C}$), savienoti ar dinamisko signālu pārveidotāju *DT9857E* (izejas diapazons $\pm 10\text{ V}$) ar 15 m gariem poliuretāna, 2-pin(F) signālu kabeļiem. Sensori tika izvietoti trīs savienojumu stūros divos horizontālajos virzienos – x un y virzienā. Katra sensora svars ir aptuveni 800 g. Lai nodrošinātu koka rāmja stabilitāti, rāmja stūros tika piestiprināta 1,6 kg papildu masa. Eksperimenta gaitā tika veikti nepārtraukti datu mērījumi ar nolasīšanas frekvenci $f_s = 400\text{ Hz}$.

Meteoroloģiskie dati eksperimenta laikā tika iegūti no tuvākās meteoroloģiskās stacijas, ietverot ārējo gaisa temperatūru, relatīvo mitrumu un nokrišņu daudzumu. Ārējā gaisa temperatūra novērojumu periodā mainījās no aptuveni $-15\text{ }^{\circ}\text{C}$ ziemas mēnešos līdz pat $+30\text{ }^{\circ}\text{C}$ vasaras mēnešos. Relatīvais mitrums mainījās no 30 % līdz 100 % un lielākā daļu novērojumu atradās diapazonā virs 60 % ar augstākām vērtībām ziemas mēnešos. Ziemas periodā nokrišņu daudzums bija minimāls, savukārt vasarā nokrišņi sasniedza maksimumu, īpaši jūlijā ar nokrišņu daudzumus no 20 mm līdz 25 mm stundā.

Eksperimentā iegūtie paātrinājuma signāli tika sadalīti pa 30 minūšu porcijām. Pēc tam šīs laika rindas tika atdalītas, filtrētas frekvenču joslās, pēc tam pamatdati izmantoti īpašvērtību sistēmas realizācijas algoritmā (*ERA, Eigensystem Realization Algorithm*), lai noteiktu koka rāmja pirmās sešas svārstību formas frekvences: šķērsvirziena f_1 , garenvirziena f_2 un vērpes f_3 frekvenču formas pirmajai lieces un vērpes svārstību formai, kā arī šķērsvirziena f_4 , garenvirziena f_5 un vērpes f_6 frekvenču formas otrajai lieces un vērpes svārstību formai.


Pirmajām trīs pašsvārstību frekvencēm ziemas mēnešos novērojamas izteiktas svārstības, kam seko pakāpenisks samazinājums līdz pavasarim un relatīvi stabils periods līdz pirmajam bojājumam. Pēc konstrukcijas bojājumiem visas trīs pirmās pašsvārstību frekvenču vērtības kļūst nestabilas, un lielākās izmaiņas novērojamas pēc konstrukciju bojājuma Nr. 5. Otrajām trīs pašsvārstību frekvencēm arī ir novērojami svārstību periodi ziemas mēnešos, un līdz bojājumam Nr. 1 sākuma periodam frekvenču vērtību zonu var uzskatīt kā stabilu ar mazāk izteiktām svārstībām. Augstākajām frekvencēm pēc konstrukciju bojājumiem raksturīgas lielākas amplitūdas un izteiktāki vērtību kritumi. Savukārt f_4 frekvences uzrāda mazākas svārstības un pakāpenisku samazinājumu.

Lai novērtētu, vai pašsvārstību frekvenču dati atbilst normālsadalījumam, katrai frekvencei tika analizēts empīriskais sadalījums un salīdzināts ar teorētisko normālā sadalījuma varbūtības blīvuma funkciju, kas aprēķināta, izmantojot attiecīgās frekvences vidējo vērtību un standartnovirzi. Rezultāti liecina, ka visu sešu pašsvārstību frekvenču sadalījumi būtiski atšķiras no normālsadalījuma. Datu sadalījumi vairumā gadījumu ir asimetriski, tiem ir augstāka blīvuma apgabali, kas liecina par nevienmērīgiem sadalījuma apgabaliem.

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, šķērso Saline upi un 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 ir tērauda un betona kompozītmateriāla daudzslāņu tilts, tā kopējais garums ir 188,6 m, platums – no 19,2 m līdz 22,8 m (4.2. att.). Tilta nesošās


konstrukcijas ir 1,2 m augstas dubulta T veida sijas, kas savienotas ar dubulta T veida šķērssijām ar mainīgu augstumu no 0,8 m līdz 1,2 m. Tilta klāju veido 25 cm bieza dzelzsbetona plātne. Tilta pilonu konstrukcijas sastāv no četrām slīpām tērauda caurulēm, kuru diametrs ir 1,9 m, kas apakšējā daļā 16 m augstumā ir aizpildītas ar betonu. Katra pilona pamats ir balstīts uz 35 m gariem urbtajiem pāļiem, kuru diametrs ir 1,2 m. Krasta balstu pamatus veido 16 urbti pāļi, kuru diametrs ir 1,2 m, kas izvietoti trīs šķērsrindās. Uz pāļiem tiek balstīta taisnstūra formas 1,4 m bieza pamatu plātne, kuras izmērs plānā ir 10,3 m × 16,3 m [104].



4.2. att. *Filomena Delli Castelli* tilta konstruktīvā shēmas un galvenie izmēri: (a) sānskats un plāna shēma [104].

Eksperimenta laikā tika noteikta ārējā gaisa temperatūra, relatīvais mitrums, vēja ātrums un vēja virziens. Monitoringa periodā ārējā gaisa temperatūra mainījās no aptuveni 0 °C ziemas mēnešos līdz pat +30 °C vasaras mēnešos. Relatīvais mitrums visā novērojumu periodā saglabājās galvenokārt virs 60 %. Vēja ātrums mainījās no 0 līdz aptuveni 20 m/s ar vidējo vērtību aptuveni 6 m/s, dominējot dienvidrietumu virzienam.

Dinamisko parametru noteikšanai tika izmantoti 20 *PCB* un *B&K* tipa pjezoelektriskie sensori, no kuriem 16 izvietoti uz tilta klāja un četri – uz abiem dzelzsbetona piloniem vanšu enkurojuma līmenī (4.3. 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 vienlaikus. Datu iegūšanas vadībai un datu uzglabāšanai tika izmantots portatīvais dators ar *LabVIEW* lietojumprogrammu. Eksperimenta laikā iegūtie svārstību paātrinājumu mērījumu dati tika nolasīti ar nolasīšanas frekvenci $f_s = 100$ Hz, sadalīti pa 30 minūšu porcijām, filtrēti frekvenču joslās, un pašsvārstību frekvenču noteikšanai tika izmantota kovarianci balstīta stohastiskās apakštelpas identifikācijas metode (*SSI-COV*) [104].



4.3. att. *Filomena Delli Castelli* tilta sensoru izvietošanas shēma [104].


Tika noteiktas tilta pirmās sešas svārstību formas frekvences – pirmā klāja lieces f_1 un pirmā klāja vērpes f_2 , otrā klāja lieces f_3 , otrā klāja vērpes f_4 un f_5 , kā arī trešā klāja lieces f_6 svārstību formai. Pirmajām trīs pašsvārstību frekvencēm novērojamas nelielas sezonālās svārstības ar frekvenču vērtību pieaugumu ziemas mēnešos un nelielu vērtību samazinājumu vasaras mēnešos. Savukārt otrās trīs pašsvārstību frekvences saglabā nemainīgu vidējo frekvenču vērtību līmeni visā novērojumu periodā. Visām frekvencēm novērojami atsevišķi īslaicīgi vērtību kritumi un pieaugumi, taču izteikta ilgtermiņa frekvenču vērtību pieauguma vai samazinājuma tendence nav novērojama.

Pašsvārstību frekvenču sadalījuma analīze liecina, ka zemāko frekvenču f_1 un f_2 dati ir salīdzinoši simetriski un tuvināti normālajam sadalījumam. Savukārt frekvencēm no f_3 līdz f_6 novērojama izteikta datu sadalījuma asimetrija un vairāki lokāli maksimumi, kas liecina par neviendabīgu un no normālsadalījuma būtiski atšķirīgu datu sadalījumu monitoringa periodā.

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. Regresijas funkciju izvēle ir balstīta pakāpeniskā modeļu sarežģītības palielināšanā, lai saglabātu rezultātu fizikālo interpretējamību un izvairītos no datu pārprielāgošanās riska [94]. Lineārais modelis ļauj pārbaudīt pieņēmumu par proporcionālu sakarību starp ārējās vides faktoriem un pašsvārstību frekvencēm [105], savukārt kvadrātiskais modelis spēj precīzāk aprakstīt paraboliskas nelineāras sakarības, identificējot lokālus ekstrēmums vai simetriskas izmaiņas [106]. Modeļu koeficienti tika noteikti, izmantojot *Matlab* komandu *polyfit* pirmās un otrās pakāpes polinomiem.

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 Bajesa informācijas kritērijā (*BIC*, *Bayesian Information Criterion*) [107]. Šis kritērijs ļauj salīdzināt modeļus ar atšķirīgu parametru skaitu, vienlaikus 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 [108]. Regresijas modeļu salīdzināšanai tika analizēta *BIC* starpība, kur pozitīva ΔBIC vērtība norāda kvadrātiskā (nelineārā) modeļa piemērotību, savukārt negatīva – lineārā modeļa piemērotību datu aprakstīšanai [109]. Regresijas modeļu pielāgošanās kvalitātes raksturošanai tika izmantots koriģētais determinācijas koeficients ($Adj R^2$, *Adjusted Coefficient of Determination*), kas ņem vērā gan modeļa piemērotību datiem, gan neatkarīgo mainīgo skaitu. Augstāka $Adj R^2$ vērtība liecina par labāku modeļa atbilstību un spēcīgāku sakarību starp ārējās vides parametru un pašsvārstību frekvenci [86].

Koka rāmja gadījumā tika analizētas pašsvārstību frekvenču un ārējās gaisa temperatūras, relatīvā mitruma un nokrišņu daudzuma sakarības. Katras pašsvārstību frekvences un ārējās gaisa temperatūras sakarības redzamas grafikos (4.4. att.) kopā ar lineārā un kvadrātiskā modeļa piemērotības rādītājiem – koriģēto determinācijas koeficientu $Adj R^2$ un Bajesa informācijas kritēriju starpību ΔBIC . Relatīvā mitruma un nokrišņu daudzuma ietekme uz pašsvārstību frekvencēm tika analizēta un attēlota grafiski analogi, izvērtējot abu modeļu piemērotību, izmantojot $Adj R^2$ un ΔBIC katrai pašsvārstību frekvencei.



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

Koka rāmja pašsvārstību frekvenču un ārējās gaisa temperatūras analīze parāda, ka frekvenču vērtības samazinās, pieaugot temperatūras vērtībai. Lineārais modelis raksturo kopējo tendenci ar vidēji augstām koriģētā determinācijas koeficienta $Adj R^2$ vērtībām, taču zemākas Bajesa informācijas kritērija (BIC) vērtības kvadrātiskajam modelim norāda, ka nelineārais modelis sniedz statistiski pamatotu uzlabojumu datu aprakstā. Relatīvā mitruma gadījumā 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, kas liecina par statistiski pamatotu nelineārā modeļa priekšrocību. Savukārt nokrišņu daudzuma gadījumā nav novērojama būtiska statistiska sakarība visā analizētajā frekvenču diapazonā, ko apstiprina ļoti zemās $Adj R^2$ vērtības un nelielās ΔBIC vērtības.

Filomena Delli Castelli tilta gadījumā tika analizētas pašsvārstību frekvenču un ārējās gaisa temperatūras, relatīvā mitruma un vēja ātruma sakarības.

Vēja ātruma ietekmes analīzē uz pašsvārstību frekvencēm papildus tiek ņemta vērā vēja virziena ietekme attiecībā pret būves orientāciju. 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 [110].


Vēja komponentes tiek aprēķinātas, izmantojot sakarības:

$$V_g = V \times \cos(\Delta\theta) \text{ un } V_{sk} = V \times \sin(\Delta\theta), \quad (4.1)$$

kur V – vēja ātrums attiecīgajā novērojumu brīdī; $\Delta\theta$ – 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 [111].

Katras pašsvārstību frekvences un ārējās gaisa temperatūras sakarības redzamas grafikos (4.5. att.) kopā ar lineārā un kvadrātiskā modeļa piemērotības rādītājiem – koriģēto determinācijas koeficientu $Adj R^2$ un Bajesa informācijas kritēriju starpību ΔBIC . Relatīvā mitruma un vēja ātruma sakarību ietekme uz pašsvārstību frekvencēm tika analizēta un attēlota grafiski analogi, līdzīgi izvērtējot abu modeļu piemērotību, izmantojot $Adj R^2$ un ΔBIC katrai pašsvārstību frekvencei.




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

Filomena Delli Castelli tilta gadījumā, pieaugot ārējai gaisa temperatūrai, pašsvārstību frekvenču vērtības samazinās. Lineārais modelis atspoguļo frekvenču samazināšanās virzienu, taču koriģētā determinācijas koeficienta $Adj R^2$ vērtības lielākajai daļai pašsvārstību frekvenču ir zemas. Kvadrātiskais modelis atsevišķos gadījumos uzrāda nedaudz augstāku $Adj R^2$ vērtību un zemāku Bajesa informācijas kritēriju (BIC) vērtību, tomēr tā piemērotība nav statistiski pamatota visā attiecīgo frekvenču vērtību diapazonā. Relatīvā mitruma un vēja komponentu ietekme uz pašsvārstību frekvenču vērtībām ir neliela, un kopējā sakarības tendence ir vāji izteikta. 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, kā arī vēja komponentu un pašsvārstību frekvenču vērtību izmaiņu sakarību.

Kopumā gan koka rāmja, gan *Filomena Delli Castelli* tilta pašsvārstību frekvenču sakarības ar ārējās vides faktoriem liecina, ka ietekme var būt gan vāji, gan izteikti nelineāra. Rezultāti apliecina, ka vienkāršots lineārs pieņēmums nav pietiekams precīzai pašsvārstību frekvenču vērtību izmaiņu novērtēšanai. Līdz ar to konstrukciju bojājumu identificēšanai ir nepieciešams izmantot nelineārus modeļus.

Ārējās vides faktoru ietekmes novērtējumā 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. Augsta savstarpēja korelācija starp pašsvārstību frekvencēm norāda, ka tās līdzīgi reaģē uz ārējās vides apstākļu izmaiņām, savukārt zema korelācija liecina, ka dažādas frekvences reaģē neatkarīgi vai atšķirīgi, kas var būt svarīgi konstrukcijas dinamikas analizē un tās izmaiņu interpretācijā [75].

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 (4.6. att.). Pīrsona lineāro koeficientu vērtības tuvu nullei liecina par vāju lineāru sakarību, savukārt vērtības tuvu viens – par spēcīgu lineāru sakarību [112].



4.6. att. Koka rāmja (a) un *Filomena Delli Castelli* tilta (b) pašsvārstību frekvenču un ārējo vides ietekmes faktoru savstarpējie Pīrsona lineārie korelācijas koeficienti.

Koka rāmja gadījumā starp visām pašsvārstību frekvencēm pastāv ļoti augstas savstarpējās korelācijas vērtības, īpaši starp zemākajām frekvencēm f1, f2 un f3. Savukārt starp zemākajām un augstākajām pašsvārstību frekvencēm vērojama nedaudz zemāka, tomēr joprojām spēcīga korelācija.

Filomena Delli Castelli tilta gadījumā pašsvārstību 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.

Starp ārējo gaisa temperatūru un relatīvo mitrumu abos gadījumos ir novērojama spēcīgākā negatīvā savstarpējā korelācija. Tas nozīmē, ka, pieaugot ārējai gaisa temperatūrai, relatīvais mitrums parasti samazinās. Koka rāmja gadījumā vāja korelācija ir starp nokrišņu daudzumu un visiem pārējiem faktoriem, savukārt *Filomena Delli Castelli* tilta gadījumā novērojama

negatīva 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 un atkarībā no faktora rakstura novērojams gan frekvenču pieaugums, gan samazinājums ar atšķirīgu ietekmes intensitāti dažādos diapazonos. Tas norāda, ka katra faktora ietekmi uz konstrukciju dinamiskajām īpašībām var analizēt individuāli, ņemot vērā to, ka spēcīgas savstarpējās mijiedarbības nav novērojamas.

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 to spējā modelēt sarežģītas nelineāras un nehomogēnas sakarības starp ārējās vides faktoriem un konstrukciju pašsvārstību frekvencēm, vienlaikus nodrošinot augstu vispārināšanas spēju un samazinātu pārpilnāšanās risku [85]. Regularizācijas mehānismi *XGBoost* struktūrā saglabā modeļa stabilitāti un ļauj kvantitatīvi novērtēt atsevišķu ārējās vides faktoru ietekmi [113]. *RF* algoritms efektīvi apstrādā augstas dimensijas datu kopas un būtiski samazina pārpilnāšanās risku [85], savukārt GPR algoritms nodrošina augstu prognožu precizitāti un prognožu nenoteiktības kvantitatīvu novērtējumu [90].

Visu modeļu apmācībai un iegūto rezultātu izvērtēšanai tika izmantota kārta krosvalidācija ar parametra vērtību $k = 5$, sadalot datu kopas 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 analīzē [114].

Ārējo vides faktoru ietekmes analīzes rezultāti tika apkopoti kopējā izmaiņu grafikā un ietekmes matricā. Katrā ārējās vides faktora kopējā ietekme uz attiecīgo pašsvārstību frekvenci tika noteikta, izmantojot regresijas modeļa aprēķināto prognozēto frekvences vērtību pie analizējamā ārējās vides faktora minimālās un maksimālās vērtības tā novērojumu diapazonā, bet pārējos ārējās vides faktorus saglabājot konstanti to vidējo vērtību līmenī. Par ietekmes lielumu tika pieņemta šo divu prognozēto pašsvārstību frekvences vērtību starpība [90].

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.

Pašsvārstību frekvenču savstarpējai salīdzināmībai tika analizēta arī relatīvā kopējā ietekme, nosakot absolūtās izmaiņas īpatsvaru attiecībā pret attiecīgās pašsvārstību frekvences vidējo vērtību analizētajā periodā un iegūto attiecību izsakot procentos. 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 [19].


Gradientu palielināšanas regresijas (*XGBoost*) gadījumā tika izmantota *Matlab* komanda *fitrensemble*, kas veido regresijas modeli, balstoties mazāko kvadrātu palielināšanas (*LSBoost*)

algoritmā. Tika veikta hiperparametru optimizācija (mācību ciklu skaits, mācīšanās ātrums, maksimālais sadalījumu skaits, minimālais lapu izmērs), izmantojot iegūšanas funkciju *AcquisitionFunctionName*, lai samazinātu kļūdu un pārpelāģošanās risku. Galaprognoze tika aprēķināta kā visu iterāciju laikā izveidoto lēmumu koku svērtā summa [94].

Gadījuma meža regresijas algoritma (RF) gadījumā prognoze tika noteikta kā visu koku prognožu vidējā vērtība. Hiperparametri (lēmumu koku skaits, minimālais lapu izmērs, mainīgo skaits, ko izmantot katrā dalīšanas solī) tika optimizēti, izmantojot *Matlab fitrensemble* komandu [115].

Gausa procesa regresijas (GPR) metodē pašsvārstību frekvenču atkarība no ārējiem vides faktoriem tika modelēta kā Gausa process, izmantojot *Matlab* komandu *fitrgp* ar automātisku hiperparametru optimizāciju (garuma mērogs, trokšņa variācijas parametra vērtība, bāzes funkcija). Modeļa apmācība un hiperparametru optimizācija tika veikta netieši, minimizējot negatīvo logaritmiskās ticamības funkciju (*NLL*, *Negative Log-Likelihood*) [90].


Koka rāmja gadījumā tika analizēta ārējās gaisa temperatūras un relatīva mitruma ietekme uz visām sešām pašsvārstību frekvencēm. Ārējās vides faktoru ietekme uz pašsvārstību frekvencēm, izmantojot *XGBoost* metodi, redzama grafikos (4.7. att.), atsevišķi norādot absolūto (Hz) un relatīvo (%) ietekmi. *RF* un *GPR* algoritmu rezultāti tika analizēti un attēloti grafiski analogi, salīdzinot iegūtās absolūtās un relatīvās ietekmes vērtības katrai pašsvārstību frekvencei.



4.7. att. Ārējās vides faktoru ietekme uz koka rāmja pašsvārstību frekvencēm, izmantojot *XGBoost* metodi (1 – ārējā gaisa temperatūra (°C), 2 – relatīvais mitrums (%)).

Analizējot ārējo vides faktoru absolūto un relatīvo ietekmi uz koka rāmja pašsvārstību frekvencēm, iegūtie rezultāti liecina par līdzīgām vispārējām tendencēm. Ārējā gaisa temperatūra visās metodēs uzrāda vislielāko negatīvo ietekmi uz pašsvārstību frekvencēm, savukārt relatīvais mitrums visās metodēs uzrāda mērenu pozitīvu absolūto ietekmi uz pašsvārstību frekvencēm.

Filomena Delli Castelli tilta gadījumā arī tika analizēta ārējās gaisa temperatūras, relatīva mitruma, vēja garenvirziena un šķērsvirziena komponentu ietekme uz visām sešām pašsvārstību frekvencēm. Ārējās gaisa temperatūras ietekme uz pašsvārstību frekvencēm, izmantojot *XGBoost* metodi, redzama grafikos (4.8. att.), atsevišķi norādot absolūto (Hz) un relatīvo (%) ietekmi. Līdzīgi arī *RF* un *GPR* algoritmu rezultāti tika analizēti un attēloti grafiski, salīdzinot iegūtās absolūtās un relatīvās ietekmes vērtības katrai pašsvārstību frekvencei.



4.8. att. Ārējās vides faktoru ietekme uz *Filomena Delli Castelli* tilta pašsvārstību frekvencēm, izmantojot *XGBoost* metodi (1 – ārējā gaisa temperatūra (°C), 2 – relatīvais mitrums (%), 3 – vēja garenvirziena komponente V_g , (m/s), 4 – vēja šķērsvirziena komponente V_{sk} (m/s)).

Analizējot ārējo vides faktoru ietekmi uz tilta pašsvārstību frekvencēm, 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.

Lai analizētu **koka rāmja** konstrukciju pašsvārstību frekvenču izmaiņu raksturu daudzdimensiju 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 [116].

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 mediānu un interkvartīlu diapazonā (*IQR*). Šī metode tiek izvēlēta, jo pašsvārstību frekvenču datiem nav izteikts normālsadalījums un datu kopā iespējami atsevišķi novirzes punkti [117].

Lai noteiktu nebojātā stāvokļa datu sadalījumu, tiek aprēķināts vidējais vektors μ visām pašsvārstību frekvencēm [75]. Atsevišķiem algoritmiem papildus tiek aprēķināta kovariances matrica, lai raksturotu, kā frekvences kopīgi mainās laikā, un tas ļauj ņemt vērā to savstarpējo korelāciju, nevis analizēt katru pašsvārstību frekvenci atsevišķi. Ja frekvences sistemātiski pieaug vai samazinās vienlaikus, tad šīs sakarības tiek tieši atspoguļotas kovariances matricā [118].

Mahalanobisa distances algoritms ir neuzraudzītās mašīnmācīšanās anomāliju noteikšanas metode, kas novērtē novērojuma attālumu no nebojātā stāvokļa datu kopas daudzdimensiju telpā, ņemot vērā parametru savstarpējo korelāciju un dispersijas raksturu [119]. Mahalanobisa distances algoritma sākumā tiek noteikts nebojātā stāvokļa bojājumu jutīgo pazīmju vidējais vektors μ un kovariācijas matrica S . Pēc šo lielumu iegūšanas tiek aprēķināta Mahalanobisa distance visiem datu punktiem, kas raksturo novirzi no nebojātā datu sadalījuma daudzdimensiju telpā. Anomāliju noteikšanai tiek noteikta augšējās kontroles robeža (*UCL, Upper Control Limit*), kas balstīta H_1 kvadrāta sadalījumā un izvēlētajā pieļaujamā viltus trauksmju līmenī $PFA = 0,05$ (*Probability of False Alarm*). Pašsvārstību frekvenču vērtības ar Mahalanobisa distanci, kas pārsniedz *UCL*, tiek uzskatītas par anomālijām.

Galveno komponentu analīze (PCA) konstrukciju bojājumu noteikšanai balstās dimensiju samazināšanā, identificējot datu struktūras galvenās iezīmes. *PCA* transformē sākotnējos datus uz jaunu ortogonālo telpu, kur galvenās komponentes ir savstarpēji neatkarīgas un maksimizē datu dispersiju. *PCA* pamatā ir kovariācijas matricas diagonalizācija, kas ļauj iegūt īpašvērtības un īpašvektorus [120]. Katras galvenās komponentes nozīmīgumu nosaka tās izskaidrotās dispersijas attiecība, kas parāda, cik lielu daļu no kopējās datu dispersijas konkrētā komponente izskaidro. Bojājumu noteikšanas optimizācijai tiek izmantota režģa meklēšana, izvēloties saglabātās variācijas līmeni (90 %, 95 %, 99 %) un nozīmīguma līmeni α (0,01, 0,05, 0,1) Hotellinga T^2 statistikas robežvērtības aprēķināšanai. Ja T^2 pārsniedz robežvērtību, novērojums tiek klasificēts kā bojājums [121].

Vienklases atbalsta vektora (OC-SVM) mašīnmācīšanās algoritms tiek izmantots anomāliju jeb noviržu noteikšanai datu kopās, kurās lielākā daļa datu ir nebojātas konstrukcijas dati un tikai daļa datu ir novirzes. Algoritms apmācības fāzē mācās definēt normālo datu robežu un pēc tam klasificē jaunus novērojumus kā normālus vai anomālijas. Nelineāru sakarību modelēšanai tiek izmantota radiālās bāzes kodolfunkcija (*RBF, Radial Basis Function*). Hiperparametri (γ un ν) tiek noteikti ar Bajesa optimizāciju, 30 iterāciju laikā maksimizējot sabalansēto precizitāti [91]. Anomālijas tiek noteiktas, balstoties lēmumu funkcijas vērtībā un definētā robežā. Šajā gadījumā robeža tiek definēta kā 5 % kvantile, un punkti zem šīs robežas tiek klasificēti kā anomālijas.


Gausa jauktā modeļa (GMM) metode pieņem, ka nebojātā stāvokļa pašsvārstību frekvenču dati veido daudzdimensiju sadalījumu, ko iespējams pietiekami precīzi aproksimēt ar K daudzdimensiju normālsadalījumiem, kur katra komponentei ir savs svārs, vidējais vektors un kovariācijas matrica, kas raksturo savstarpējās sakarības starp pašsvārstību frekvencēm. Būtiskas novirzes no šī sadalījuma tiek interpretētas kā iespējamās anomālijas. Pēc *GMM* apmācības katram novērojumam x_i tiek aprēķināta negatīvā logaritmiskā ticamība (*NLL*). Jo lielāka *NLL* vērtība, jo mazāka varbūtība, ka novērojums atbilst nebojātā stāvokļa konstrukcijas datiem [122]. Parametri (komponentu skaits $K = 1, 2, 3$ un nozīmīguma līmenis $\alpha = 0,01, 0,05, 0,1$) tiek izvēlēti ar režģveida meklēšanu, balstoties sabalansētajā precizitātē. Pēc optimālā modeļa noteikšanas tiek aprēķināta klasifikācijas robežvērtība τ , izmantojot $(100 \% \cdot (1 - \alpha))$ procentpunktu no *NLL* sadalījuma. Novērojumi ar *NLL* vērtību virs šīs robežas tiek klasificēti kā anomālijas.

Mahalanobisa distances algoritma, *PCA*, *OC-SVM* un *GMM* metožu **novērojumu klasifikācija** balstās noteiktā robežvērtībā, kas nosaka, vai novērojums atbilst nebojātam konstrukcijas stāvoklim vai tiek uzskatīts par novirzi. Pārāk zems robežsliekšnis palielina kļūdaini pozitīvo gadījumu skaitu, savukārt pārāk augsts robežsliekšnis palielina kļūdaini negatīvo gadījumu skaitu.

Divu klasifikatoru problēmuzdevumam katrs novērojums var tikt klasificēts kā patiesi pozitīvs (*TP*, *True Positive*), kļūdaini pozitīvs (*FP*, *False Positive*), patiesi negatīvs (*TN*, *True Negative*) vai kļūdaini negatīvs (*FN*, *False Negative*).

Izmantoto metožu klasifikācijas efektivitātes novērtēšanai tiek aprēķināta **sabalansētā precizitāte**, analizējot pareizi klasificēto un kļūdaini klasificēto gadījumu skaitu. Sabalansētās precizitātes noteikšanai tiek izmantoti divi galvenie kritēriji – sensitivitāte un specifitāte. Sensitivitāte raksturo pareizi identificēto bojājumu īpatsvaru ($TP/(TP+FN)$), savukārt specifitāte raksturo pareizi identificēto ne bojāto gadījumu īpatsvaru ($TN/(TN+FP)$). Ņemot vērā to, ka ne bojāto un bojāto datu skaits nav līdzīgs, tiek noteikta sabalansētā precizitāte, kas nodrošina, ka modelis tiek vērtēts vienmērīgi neatkarīgi no klašu disproporcijas [116].

Mahalanobisa distances algoritma, galveno komponentu analīzes (*PCA*), vienklašu 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 4.8. attēlā.




4.9. 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 pašvārstību frekvences.

Mahalanobisa distances algoritms nodrošināja 70 % sabalansēto precizitāti, pareizi identificējot lielāko daļu nebojāto datu. Tomēr kļūdaini negatīvo gadījumu skaits (464) un kļūdaini pozitīvo gadījumu skaits (404) bija salīdzinoši liels, galvenokārt ziemas mēnešos. *PCA* metodes rezultāti uzrādīja zemāku sabalansēto precizitāti (65 %) un lielāku kļūdaini pozitīvo (422) un kļūdaini negatīvo (535) gadījumu skaitu, kas liecina par metodes zemāku spēju identificēt konstrukcijas bojājumus un samazina monitoringa sistēmas efektivitāti. *OC-SVM* metode nodrošināja 74 % sabalansēto precizitāti. Kļūdaini pozitīvie rezultāti (202) galvenokārt koncentrējas ziemas periodā, savukārt kļūdaini negatīvo gadījumu skaits nepārsniedza 410. *GMM* metode sasniedza 70 % sabalansēto precizitāti, kas liecina par mēreni labu spēju atšķirt nebojātās un bojātās konstrukcijas datus. Tomēr tika identificēti 377 kļūdaini pozitīvi un 467 kļūdaini negatīvi gadījumi, īpaši ziemas mēnešos.

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 izmaiņas bieži tiek kļūdaini interpretētas kā konstrukciju bojājumu, palielinot viltus trauksmju skaitu.

Mahalanobisa distances algoritma kļūdaini pozitīvo punktu atrašanās ārējo vides faktoru izmaiņu laika grafikos redzama 4.10. attēlā. *PCA*, *OC-SVM* un *GMM* metodes kļūdaini pozitīvo rezultātu izvietojums tika analizēts un attēlots grafiski analogi, norādot konkrētus periodus un ekstrēmas vērtības, kuros dominējošā ārējās vides faktora izmaiņas tiek interpretētas kā konstrukcijas bojājums.




4.10. att. Mahalanobisa distances algoritma kļūdaini pozitīvo rezultātu izvietojums ārējās vides faktoru izmaiņu grafikos.

Kļūdaini pozitīvie rezultāti visām metodēm 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. Liels anomāliju blīvums ir arī pie augsta relatīvā mitruma līmeņa, galvenokārt 80 %. Tomēr atsevišķi kļūdaini pozitīvie datu punkti atrodas visā novērojumu periodā un neatbilst maksimālajām vai minimālajām ārējā vides faktora vērtībām kādā no laika posmiem.

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 pašsvārstību frekvenču vērtības.


Koka rāmja ārējās vides faktoru ietekmes samazināšanas metodes **1. posmā** pašsvārstību frekvenču un ārējās vides faktoru vērtības tika apvienoti vienā datu kopā pēc mērījumu laika norādēm. 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 (4.11. att.) visu ārējās vides faktoru (ārējās gaisa temperatūras, relatīvā mitruma) un pašsvārstību frekvenču sakarības modelēšanai.



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

Metodes **4. posmā** tiek izvēlēts *XGBoost* regresijas modelis, kas uzrādīja viszemāko globālo *CPM* vērtību, lai noteiktu segmentu robežas. Ārējās gaisa temperatūras un relatīvā mitruma ietekmes segmenti apkopoti 4.12. attēlā.




4.12. 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 $+4,09$ °C, un virs $+4,09$ °C. Relatīvā mitruma ietekmes robežas tiek definētas: līdz 52,05 %, no 52,05 % līdz 84,14 % un virs 84,14 %.

Iegūtie maiņas punkti atspoguļo būtiskas izmaiņas koka rāmja dinamiskajā reakcijā un sakrīt ar citos pētījumos minēto robežvērtību -5 °C. Šī temperatūras vērtība bieži tiek izmantota kā robežvērtība ekspluatācijas un testēšanas standartos [123]. Savukārt relatīvā mitruma ietekmes segmentu maiņas punktu vērtības ir ļoti tuvas *LVS EN 1995-1-1:2005* noteiktajām koka konstrukciju lietojamības klašu robežvērtībām (zem 65 %, no 65 % līdz 85 %, virs 85 %).

Metodes **5. posmā** tiek noteikti atsevišķi regresijas modeļi katrā 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 apkopoti 4.13. attēlā.



4.13. att. *PDP* līknes koka rāmja pašsvārstību frekvencēm ārējās gaisa temperatūras ietekmē.

Kopējā tendence visos *PDP* grafikos liecina par skaidru negatīvu korelāciju starp ārējo gaisa temperatūru un pašsvārstību frekvencēm – frekvenču vērtība pazeminās, pieaugot gaisa temperatūrai (4.13. att.). Līdz $-2,14\text{ }^{\circ}\text{C}$ frekvenču vērtības pakāpeniski pieaug, bet segmentā no $-2,14\text{ }^{\circ}\text{C}$ līdz $+4,09\text{ }^{\circ}\text{C}$ novērojams straujš vērtību kritums un visu septiņu regresijas modeļu prognozes šajā zonā savstarpēji pārklājas. Virs $+4,09\text{ }^{\circ}\text{C}$ parādās izteiktākas nelineārās atšķirības gan starp modeļiem, gan starp pašsvārstību frekvencēm.

Regresijas modeļu *CPM* vērtības ārējās gaisa temperatūras un pašsvārstību frekvenču sakarības modelēšanai atsevišķos segmentos apkopotas 4.14. 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		
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		

4.14. att. *CPM* vērtības regresijas modeļiem ārējās vides temperatūras segmentos līdz $-2,14\text{ }^{\circ}\text{C}$, no $-2,14\text{ }^{\circ}\text{C}$ līdz $4,09\text{ }^{\circ}\text{C}$ un virs $4,09\text{ }^{\circ}\text{C}$ koka rāmja monitoringa datos.

Ārējās gaisa temperatūras ietekmes analīze liecina, ka regresijas modeļu veikspēja būtiski atšķiras atsevišķos segmentos. Lineārā regresija (LR) visos segmentos uzrāda zemāko

precizitāti, savukārt nelineārie modeļi sasniedz zemākas vidējās *CPM* vērtības, apliecinot to labāku pielāgošanos datiem.

Relatīvā mitruma un pašsvārstību frekvenču sakarību *PDP* grafiki kopā ar segmentu robežām, kā arī regresijas modeļu *CPM* vērtības sakarības modelēšanai atsevišķos segmentos tika analizētas un attēlotas grafiski analogi ārējās gaisa temperatūras ietekmes analīzei.

Relatīvā mitruma gadījumā 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. Regresijas modeļu *CPM* vērtības liecina, ka prognozēšanas precizitāte ir nevienmērīga un būtiski atkarīga gan no mitruma diapazona, gan no izvēlētajās metodes.


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

- 1) Bajesa regresijas (BR) metodi – ārējās vides temperatūras segmentā līdz $-2,14^{\circ}\text{C}$, relatīvā mitruma segmentā no 0 % līdz 52,05 %;
- 2) *XGBoost* metodi – ārējās vides temperatūras segmentā no $-2,14^{\circ}\text{C}$ 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, ārējās gaisa temperatūras gadījumā pašsvārstību frekvencēm f_1 , f_3 un f_4 ir 400 punkti, f_2 ir 150, savukārt f_6 ir 500 punkti. Relatīvā mitruma gadījumā f_1 , f_5 un f_6 ir nepieciešami 500 punkti, f_2 ir 150, bet f_3 ir 350 punkti. 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.


Uz šīm koriģētām pašsvārstību frekvenču vērtībām tika trenēti papildu regresijas modeļi – *LSBoost*, GPR, *SVR* un *Bagging*, lai novērtētu atlikušās nelineārās ietekmes sakarības. Tika izvēlēts modelis ar zemāko *MSE*, un galakorekcija 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.

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 (4.15. att.).



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

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 garensvirziena komponentes V_g un vēja šķērsvirziena komponentes V_{sk} ietekmes segmenti apkopoti 4.16. attēlā.




4.16. att. *XGBoost* metodes PDP līkne ārējās gaisa temperatūras (a), relatīvā mitruma (b), vēja garensvirziena 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 $+11,11\text{ }^{\circ}\text{C}$, no $+11,11\text{ }^{\circ}\text{C}$ līdz $+24,35\text{ }^{\circ}\text{C}$, un virs $+24,35\text{ }^{\circ}\text{C}$. Relatīvā mitruma ietekmei tika definēti šādi segmenti: līdz $59,73\text{ }\%$, no $59,73\text{ }\%$ līdz $72,20\text{ }\%$, un virs $72,20\text{ }\%$. Vēja garensvirziena komponentes V_g ietekmei tika definēti segmenti: līdz $-14,09\text{ m/s}$, no $-14,09\text{ m/s}$ līdz $4,11\text{ m/s}$, un virs $4,11\text{ m/s}$. Vēja šķērsvirziena komponentes V_{sk} ietekmei tika definēti segmenti: līdz $-3,14\text{ m/s}$, no $-3,14\text{ m/s}$ līdz $14,17\text{ m/s}$, un virs $14,17\text{ m/s}$.

Metodes **5. posmā** tiek noteikti atsevišķi regresijas modeļi katrā 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 apkopoti 4.17. attēlā.



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

Kopējā tendence visos *PDP* grafikos (4.17. att.) liecina par 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 modeļēšanai atsevišķos segmentos apkopotas 4.18. 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.dev.	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

4.18. 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 *Filomena Delli Castelli* tilta monitoringa datos.

Ārējās gaisa temperatūras ietekmes analīze liecina, ka lineārās regresijas (LR) modelis uzrāda visaugstākās *CPM* vērtības, savukārt nelineārie modeļi sasniedz zemākas *CPM* vērtības, līdzīgi kā koka rāmja gadījumā.

Relatīvā mitruma, vēja garenvirziena komponentes V_g , vēja šķērsvirziena komponentes V_{sk} un pašsvārstību frekvenču sakarību *PDP* grafiki kopā ar segmentu robežām, kā arī regresijas modeļu *CPM* vērtības sakarības modelēšanai atsevišķos segmentos tika analizētas un attēlotas grafiski analogi ārējās gaisa temperatūras ietekmes analīzei.

Relatīvā mitruma gadījumā pašsvārstību frekvenču vērtības pieaug, palielinoties relatīvajam mitrumam. 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.

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.

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.

Apkopojot visus *CPM* vērtību rezultātus no visiem septiņiem regresijas modeļiem, zemākās *CPM* vērtības katram ārējās vides ietekmes faktoram visos segmentos tika iegūtas, izmantojot *XGBoost* metodi. Izmantojot šo regresijas metodi, 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, ārējās gaisa temperatūras, relatīvā mitruma, kā arī vēja garenvirziena komponentes V_g un vēja šķērsvirziena komponentes V_{sk} gadījumā visām pašsvārstību frekvencēm 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.


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 konstrukciju dinamisko parametru analīzē. Metodes tika pielāgotas koka rāmja monitoringa datiem. Katras metodes ietvaros tika analizēta un samazināta tikai publikācijā norādītā ārējās vides faktora ietekme.

Publikācijās analizēto ārējās vides ietekmes samazināšanas metožu salīdzinājums, izmantojot visas sešas koka rāmja pašsvārstību frekvences, parādīja būtiskas atšķirības bojājumu noteikšanas efektivitātē. Galveno komponentu analīzes (PCA) [74] un Bajesa modeļa atjaunināšanas [79] pieejas nodrošina augstāku sabalansēto precizitāti (līdz 0,72 un 0,74), savukārt autoregresīvo modeļu [75] gadījumā tā nepārsniedz 0,52.

Līdz ar to 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, kā arī kļūdaini pozitīvo un kļūdaini negatīvo rezultātu skaits (4.19. 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.

Pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas būtiski uzlabojās visu metožu sabalansētā precizitāte un samazinājās kļūdaini pozitīvo un kļūdaini negatīvo gadījumu skaits. Visas metodes pēc korekcijas pilnībā identificēja konstrukciju bojājumu datus, sākot no 2. pakāpes un daļēji arī 1. pakāpes bojājumu datiem, kas pirms tam tika klasificēti kā pilnībā nebojātās konstrukcijas dati.



4.19. 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 algoritma kļūdaini pozitīvo punktu atrašanās ārējo vides faktoru izmaiņu laika grafikos pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas redzama 4.20. attēlā. *PCA*, *OC-SVM* un *GMM* metodes kļūdaini pozitīvo rezultātu izvietojums tika analizēts un attēlots grafiski analogi līdzīgi kā pirms ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas.



4.20. att. Mahalanobisa distances algoritma 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, var secināt, ka Mahalanobisa distances algoritma, *OC-SVM*, *PCA* un *GMM* metodes identificētās anomālijas ir izkļaidētas visā novērojumu periodā un nav izteikti koncentrētas zemas ārējās gaisa temperatūras un augsta relatīvā mitruma līmeņa vērtību periodos.


Salīdzinot kļūdaini pozitīvo un kļūdaini negatīvo rezultātu datu skaita izmaiņas pirms un pēc ārējo vides ietekmes faktoru korekcijas, *PCA* un *OC-SVM* metode vislabāk novērsa viltus trauksmju rezultātus, īpaši ziemas periodā. Savukārt kļūdaini negatīvo rezultātu datu skaitu visvairāk samazināja *PCA* metode, bet vismazāk – *GMM* metode.



4.21. att. Sabalansētās precizitātes salīdzinājums izmantotajām metodēm.

Salīdzinot visu četru metožu efektivitāti, pirms ārējās vides ietekmes faktoru samazināšanas katrā metodē 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 novērtētu ārējās vides faktoru ietekmes samazināšanas metodes efektivitāti, **koka rāmja** un **Filomena Delli Castelli tilta** pašsvārstību frekvencēm tika analizētas frekvenču izmaiņas Δf , salīdzinātas frekvenču laika rindas pirms un pēc korekcijas, kā arī noteikti variācijas koeficienti (*CV*, *Coefficient of Variation*), kas redzami 4.22. attēlā.



4.22. att. Variācijas koeficienta CV salīdzinājums koka rāmja (a) un *Filemonā Delli Castelli* tilta (b) pašsvārstību frekvencēm.

Pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas koka rāmja gadījumā 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 liecina par stabilu korekcijas ietekmi. Savukārt augstāko pašsvārstību frekvenču f_4 , f_5 un f_6 gadījumā mediāna joprojām saglabājas tuvu nullei, bet ar nedaudz lielāku izkliedi, neieviešot sistemātisku nobīdi. Pēc korekcijas pašsvārstību frekvenču laika rindas kļūst vienmērīgākas, samazinās gan kopējā vērtību izkliede, gan īstermiņa lokālās svārstības. Variācijas koeficientu CV salīdzinājums pirms un pēc pašsvārstību frekvenču vērtību korekcijas parāda būtisku frekvenču vērtību svārstību visām sešām koka rāmja pašsvārstību frekvencēm. Tas apliecina, ka ārējās vides faktoru ietekmes samazināšanas metode efektīvi stabilizē koka rāmja konstrukciju pašsvārstību frekvenču vērtības un uzlabo datu piemērotību turpmākai konstrukciju tehniskā stāvokļa novērtēšanai un bojājumu identificēšanai.

Pēc ārējās vides faktoru ietekmes samazināšanas metodes piemērošanas tilta gadījumā 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. Tilta 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, bet augstākajām pašsvārstību frekvencēm f_4 , f_5 un f_6 novērojama lielāka Δf izkliede, ko raksturo plašāks starpkvartīļu apgabals (IQR) un atsevišķas lokālas novirzes. Variācijas koeficientu CV iegūtie rezultāti apstiprina, ka ārējās vides faktoru ietekmes samazināšanas metode efektīvi koriģē tilta pašsvārstību frekvenču vērtības, samazinot frekvenču vērtību izkliedi novērojumu periodā.

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 diskrešu 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 kļūdaini 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 izkļedes 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 datos 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] 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.

- [12] 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.
- [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] Hua-Peng Chen, *Structural Health Monitoring of Large Civil Engineering Structures*. John Wiley & Sons Limited, 2018.
- [15] 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.
- [16] 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.
- [17] 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.
- [18] R. Brincker un C. Ventura, *Introduction to operational modal analysis*. John Wiley & Sons, Ltd, United Kingdom, 2015.
- [19] D. J. Ewins, *Modal testing : theory, practice, and application*. Baldock: Research Studies Press, 2000.
- [20] 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, jül. 2022, doi: 10.1177/14759217211036880.
- [21] 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.
- [22] 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.
- [23] 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.
- [24] 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.

- [25] 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.
- [26] Rytter A., “Vibrational based inspection of civil engineering structures”, *PhD Thesis, Dept. of Building Technology and Structural Engineering. Aalborg University*, 1993.
- [27] 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.
- [28] 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.
- [29] 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.
- [30] 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.
- [31] 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.
- [32] 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>.
- [33] 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.
- [34] 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.
- [35] 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.
- [36] 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.
- [37] 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.

- [38] 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.
- [39] 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.
- [40] 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.
- [41] 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.
- [42] 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.
- [43] 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.
- [44] H. Sohn, C. R. Farrar, F. Hemez, un J. Czarnecki, “A Review of Structural Health Monitoring Literature 1996–2001”, Los Alamos National Laboratory, 2004.
- [45] 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.
- [46] S. Maas, V. H. Nguyen, T. Kebabci, S. Schommer, un A. Zührke, “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.
- [47] 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.
- [48] 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.
- [49] 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.

- [50] 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.
- [51] 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.
- [52] Latvijas Vides ģeoloģijas un meteoroloģijas centrs, "Pārskats par virszemes un pazemes ūdeņu stāvokli 2016. gadā", Rīga, 2018.
- [53] 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.
- [54] 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.
- [55] D. Z. Gravett, C. Murlas, 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: 10.1016/j.soildyn.2021.106656.
- [56] NEHRP Consultants Joint Venture, "Soil-Structure Interaction for Building Structures", National Institute of Standards and Technology, Gaithersburg, sept. 2012.
- [57] 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.
- [58] 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).
- [59] 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.
- [60] 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.
- [61] T. Oladipupo, "Introduction to Machine Learning", no *New Advances in Machine Learning*, InTech, 2010. doi: 10.5772/9394.
- [62] 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.

- [63] 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.
- [64] 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.
- [65] 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.
- [66] 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.
- [67] 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.
- [68] 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.
- [69] 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.
- [70] 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.
- [71] K. Eltouny, 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.
- [72] 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.
- [73] 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.
- [74] 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.

- [75] 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.
- [76] 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.
- [77] 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.
- [78] 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.
- [79] 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.
- [80] 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.
- [81] 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.
- [82] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006.
- [83] 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.
- [84] 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.
- [85] L. Breiman, “Random Forests”, *Mach. Learn.*, sēj. 45, nr. 1, lpp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [86] D. C. Montgomery, E. A. Peck, un G. G. Vining, *Introduction to Linear Regression Analysis*. no Wiley Series in Probability and Statistics. Wiley, 2013.

- [87] 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.
- [88] J. H. Friedman, “Greedy Function Approximation: A Gradient Boosting Machine”, *The Annals of Statistics*, sēj. 29, nr. 5, lpp. 1189–1232, 2001.
- [89] 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.
- [90] C. Edward. Rasmussen un C. K. I. Williams, *Gaussian processes for machine learning*. MIT Press, 2006.
- [91] 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.
- [92] 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>.
- [93] 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.
- [94] 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.
- [95] 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.
- [96] 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.
- [97] 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.
- [98] A. M. Yan un J. C. Golinval, “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.
- [99] A. Saltelli u. c., *Global Sensitivity Analysis: The Primer*. Wiley, 2008. [Tiešsaiste]. Pieejams: <https://books.google.lv/books?id=wAssmt2vumgC>.
- [100] 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.

- [101] 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.
- [102] 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.
- [103] 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. Mendler, & M. Aenlle-Lopez (Eds.), 2022, lpp. 286–293.
- [104] 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.
- [105] 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.
- [106] G. A. F. Seber un A. J. Lee, *Linear Regression Analysis*. no Wiley Series in Probability and Statistics. Wiley, 2012.
- [107] I. A. Hernández-González un E. García-Macías, “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.
- [108] 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.
- [109] 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>
- [110] 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.
- [111] 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.
- [112] 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.

- [113] 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.
- [114] 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.
- [115] M. Kuhn un K. Johnson, *Applied Predictive Modeling*. no SpringerLink: Bücher. Springer New York, 2013.
- [116] 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.
- [117] 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.
- [118] D. C. Montgomery un G. C. Runger, *Applied Statistics and Probability for Engineers*. Wiley, 2017.
- [119] 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.
- [120] 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.
- [121] 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.
- [122] C. C. Aggarwal, “Outlier Analysis”, *Outlier Analysis*, 2017, doi: 10.1007/978-3-319-47578-3.
- [123] 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=AfmBOopE629yiHFVkvIb9flqrs-a2aulStAGhZKjSZcnpD_pYXEJn1lg.



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.