




RĪGAS TEHNISKĀ  
UNIVERSITĀTE

**Artūrs Stepčenko**

# **NELINEĀRU UN NESTACIONĀRU NORMALIZĒTA VEĢETĀCIJAS INDEKSA LAIKA RINDU PROGNOZĒŠANAS SISTĒMAS IZSTRĀDĀŠANA**

Promocijas darba kopsavilkums



**RĪGAS TEHNISKĀ UNIVERSITĀTE**

Datorzinātnes un informācijas tehnoloģijas fakultāte

Informācijas tehnoloģijas institūts

**Artūrs Stepčenko**

Doktora studiju programmas “Informācijas tehnoloģija” doktorants

**NELINEĀRU UN NESTACIONĀRU  
NORMALIZĒTA VEGETĀCIJAS INDEKSA  
LAIKA RINDU PROGNOZĒŠANAS SISTĒMAS  
IZSTRĀDĀŠANA**

**Promocijas darba kopsavilkums**

Zinātniskie vadītāji:

profesors *Dr. habil. sc. comp.*

**ARKĀDIJS BORISOVS,**

profesore *Dr. sc. ing.*

**LUDMILA ALEKSEJEVA**

Zinātniskais konsultants

vadošais pētnieks *Dr. sc. ing.*

**JURIJS ČIŽOVS**

RTU Izdevniecība

Rīga 2019

Stepčenko, A. Nelineāru un nestacionāru normalizēta veģetācijas indeksa laika rindu prognozēšanas sistēmas izstrādāšana. Promocijas darba kopsavilkums. Rīga: RTU Izdevniecība, 2019. 46 lpp.

Iespiests saskaņā ar Informācijas tehnoloģijas institūta padomes sēdes 2019. gada 22. februāra lēmumu, protokols Nr. 12100-2/2.



Šis darbs izstrādāts ar Ventspils pilsētas domes atbalstu saskaņā ar nolikumu par mērķstipendijas piešķiršanu “Atbalsts doktora grāda pretendentiem Ventspils Augstskolā”.

**ISBN 978-9934-22-345-7 (print)**

**978-9934-22-346-4 (pdf)**

# PROMOCIJAS DARBS IZVIRZĪTS INŽENIERZINĀTŅU DOKTORA GRĀDA IEGŪŠANAI RĪGAS TEHNISKAJĀ UNIVERSITĀTĒ

Promocijas darbs inženierzinātņu doktora grāda iegūšanai tiek publiski aizstāvēts 2019. gada 7. oktobrī Rīgas Tehniskās universitātes Datorzinātnes un informācijas tehnoloģijas fakultātē, Sētas ielā 1, 202. auditorijā.

## OFICIĀLIE RECENZENTI

Profesors *Dr. habil. sc. ing.* Zigurds Markovičs,  
Rīgas Tehniskā universitāte

Profesors *Dr. sc. ing.* Egils Stalidzāns,  
Latvijas Lauksaimniecības universitāte, Latvija

Profesors *Dr. tech. sc.* Vadims Romaņuks,  
Polijas Jūras spēku akadēmija, Polija

## APSTIPRINĀJUMS

Apstiprinu, ka esmu izstrādājis šo promocijas darbu, kas iesniegts izskatīšanai Rīgas Tehniskajā universitātē inženierzinātņu doktora grāda iegūšanai. Promocijas darbs zinātniskā grāda iegūšanai nav iesniegts nevienā citā universitātē.

Artūrs Stepčenko ..... (paraksts)

Datums: .....

Promocijas darbs ir uzrakstīts latviešu valodā, tajā ir ievads, piecas nodaļas, secinājumi, literatūras saraksts, 36 attēli, 21 tabula, četri pielikumi, kopā 171 lappuse, ieskaitot pielikumus. Literatūras sarakstā ir 121 nosaukums.

# SATURS

VISPĀRĒJS DARBA RAKSTUROJUMS .....	5
Ievads .....	5
Tēmas aktualitāte.....	5
Darba mērķis un uzdevumi .....	5
Pētījuma objekts un priekšmets.....	6
Pētījuma hipotēzes.....	6
Pētījuma metodes .....	6
Darba zinātniskais jaunieguvums un vērtība.....	6
Darba praktiskais nozīmīgums .....	7
Aprobācija .....	7
Promocijas darba struktūra un saturs .....	8
1. NORMALIZĒTĀ VEĢETĀCIJAS INDEKSA LAIKA RINDAS UN TO ĪPAŠĪBAS .....	10
1.1. <i>NDVI</i> laika rindu prognozēšanas pētījumu analīze .....	10
1.2. Laika rindu prognozēšanas pētījumu ar signālu dekompozīciju analīze.....	11
1.3. Uzdevuma formāla nostādne .....	13
1.4. Prognozēšanas sistēmas konceptuālais apraksts .....	14
2. PROGNOZĒŠANAS SISTĒMAS IZSTRĀDĀŠANĀ IZMANTOJAMO METOŽU APSKATS .....	15
2.1. Variāciju apakšsignālu dekompozīcija.....	15
2.2. Fāžu telpas rekonstrukcija ar laika aiztures metodi.....	16
2.3. Pakāpeniskā regresijas analīze .....	16
2.4. Principiālo komponentu analīze .....	16
2.5. Mākslīgie neironu tīkli .....	17
3. APAKŠSIGNĀLA APROKSIMĀCIJAS PIEEJAS IZSTRĀDĀŠANA .....	18
3.1. Oriģinālās <i>VMD</i> metodes izmantošana <i>NDVI</i> laika rindu prognozēšanā.....	18
3.2. Variāciju apakšsignālu dekompozīcijas metodes modifikācija.....	19
3.3. Apakšsignāla vērtību tuvinātā aprēķināšana .....	22
4. PROGNOZĒŠANAS SISTĒMAS <i>NDVI FS</i> IZSTRĀDĀŠANA .....	26
4.1. Datu pirmapstrādes modulis.....	26
4.2. Mašīnmācīšanās modulis.....	28
5. IZSTRĀDĀTĀS PROGNOZĒŠANAS SISTĒMAS PRECIZITĀTES NOVĒRTĒŠANA.....	31
5.1. <i>NDVI</i> prognozēšana ar klasiskām metodēm.....	31
5.2. Eksperimentu ar prognozēšanas sistēmu <i>NDVI FS</i> raksturojums .....	31
5.3. Datu pirmapstrādes parametru un prognozēšanas modeļu pārņemšana .....	33
REZULTĀTI UN SECINĀJUMI.....	36
IZMANTOTĀS LITERATŪRAS SARAKSTS .....	38

# VISPĀRĒJS DARBA RAKSTUROJUMS

## Ievads

Veģetācijas prognozēšana ir cieši saistīta ar daudzām svarīgām starptautiskām problēmām, piemēram, globālo klimata izmaiņu un enerģijas izmantošanas monitoringu, dabas resursu patēriņa pārvaldību, invazīvo augu sugu izplatības prognozēšanu un apdraudēto augu sugu aizsardzību [7]. Datu apkopošana par Zemes virsmas veģetācijas pārklājumu parasti tiek veikta, izmantojot distancionālo zondēšanu. Distancionālā zondēšana ir attālināta Zemes virsmas novērošana ar aviācijas vai satelītu palīdzību, izmantojot dažādus sensorus [73]. No sensoriem tiek iegūti satelītattēli, kur no katra attēla mazākā elementa (pikseļa) var tikt iegūta laika rinda [107].

## Tēmas aktualitāte

Veģetācijas dzīves cikla analīze un prognozēšana ir būtiska, plānojot lauksaimniecības darbus, kā arī veicot lauksaimniecības kultūraugu augšanas monitoringu un prognozējot to ražību. Bieži praksē tiek izmantoti no satelītattēlu pikseļu vērtībām aprēķinātie veģetācijas indeksi, piemēram, normalizētais veģetācijas indekss (*NDVI*). Šī indeksa prognozēšana precīzajā lauksaimniecībā ļauj savlaicīgi noteikt problēmas, kas saistītas ar lauksaimniecības kultūru augšanu, un laikus pieņemt lēmumus par nepieciešamajiem pasākumiem, lai novērstu šīs problēmas.

## Darba mērķis un uzdevumi

Promocijas darba **mērķis** ir izstrādāt normalizēta veģetācijas indeksa laika rindu prognozēšanas sistēmu, kas balstīta uz signālu dekompozīciju un apakšsignāla aproksimācijas pieeju, specializētām datu pirmapstrādes metodēm, kā arī mašīnmācīšanās metodēm. Promocijas darba mērķa sasniegšanai ir nepieciešams atrisināt tālāk tekstā minētos **uzdevumus**.

1. Normalizēta veģetācijas indeksa laika rindu prognozēšanas metožu un sistēmu salīdzinošs pētījums, lai noteiktu to priekšrocības un iespējamus trūkumus, kas nosaka iegūto *NDVI* laika rindu prognozēšanas precizitāti.
2. Frekvenču analīzei izmantojamo signālu dekompozīcijas metožu salīdzinošs pētījums ar mērķi identificēt metodes, kas prognozēšanas uzdevumos nodrošina augstākas precizitātes sasniegšanu, kā arī noteikt to iespējamās nepilnības.
3. Apakšsignāla aproksimācijas pieejas izstrādāšana normalizēta veģetācijas indeksa laika rindu prognozēšanai.
4. Prognozēšanas sistēmas izstrādāšana, kas izmanto signālu dekompozīcijas metodē balstītu pieeju, datu pirmapstrādes un mašīnmācīšanās metodes.
5. Izstrādātās prognozēšanas sistēmas novērtēšana un precizitātes salīdzināšana ar citām prognozēšanas metodēm.

## Pētījuma objekts un priekšmets

Darba pētījuma **objekts** ir nelineāru un nestacionāru normalizēta veģetācijas indeksa laika rindu prognozēšanas process. Darba pētījuma **priekšmets** ir datu pirmapstrādes, signālu dekompozīcijas un prognozēšanas metodes, kas ir piemērotas nelineāru un nestacionāru normalizēta veģetācijas indeksa laika rindu prognozēšanai, un uz kuru bāzes tiek izstrādāta prognozēšanas sistēma.

## Pētījuma hipotēzes

Prognozēšanas sistēmas un apakšsignāla aproksimācijas pieejas izstrādāšanas laikā pārbaudei ir izvirzītas divas hipotēzes.

1. Normalizēta veģetācijas indeksa laika rindu prognozēšanas precizitāte paaugstinās, izmantojot darbā izstrādāto signālu dekompozīcijas metodē balstītu aproksimācijas pieeju.
2. Uz normalizēta veģetācijas indeksa laika rindas apmācītu prognozēšanas modeļi un iegūtos datu pirmapstrādes parametrus var izmantot citas līdzīgas *NDVI* laika rindas pirmapstrādei un prognozēšanai ar līdzvērtīgu precizitāti.

## Pētījuma metodes

Promocijas darba teorētiskajā izstrādē ir izmantotas šādas metožu klases: mašīnmācīšanās, lineārā algebra, digitālā signālu apstrāde, matemātiskā statistika un varbūtību teorija. Prognozēšanas sistēmas praktiskajai realizācijai tiek izmantota lietojumprogramma *MATLAB*.

## Darba zinātniskais jaunieguvums un vērtība

Promocijas darbā ir izstrādāta prognozēšanas sistēma, kas ļauj veikt normalizētā veģetācijas indeksa laika rindu īstermiņa prognozēšanu. Sistēmas izstrādes procesā ir izstrādātas vairākas jaunas pieejas, kā arī metožu un pieeju kopums, kas ir nepieciešams šādas sistēmas realizācijai un novērtēšanai.

1. Izstrādāta no modificētas variāciju apakšsignālu dekompozīcijas metodes iegūta apakšsignāla aproksimācijas pieeja, kas ļauj tuvināti aprēķināt apakšsignāla vērtības katrā laika solī, kur ir pieejami vēsturiskie novērojumi atbilstošajai normalizēta veģetācijas indeksa laika rindai.
2. Izstrādāts metožu un pieeju kopums, kas nodrošina augstas precizitātes normalizēta veģetācijas indeksa laika rindu īstermiņa prognozēšanu.
3. Izstrādāta datu pirmapstrādes parametru un prognozēšanas modeļu pārnesšanas pieeja, kas nodrošina citu normalizēta veģetācijas indeksa laika rindu prognozēšanu bez jaunas pirmapstrādes un apmācības, ja Eiklīda distance starp apmācībā izmantoto laika rindu un laika rindu, kur izmanto datu pirmapstrādes parametrus un prognozēšanas modeļi, ir pietiekami maza.

## Darba praktiskais nozīmīgums

Izstrādāta prognozēšanas sistēma, kas ļauj veikt normalizētā veģetācijas indeksa laika rindu īstermiņa prognozēšanu ar labu precizitāti, izmantojot no modificētas variāciju apakšsignālu dekompozīcijas metodes iegūta apakšsignāla aproksimācijas pieeju. Sistēmai ir divi lietojumu veidi precīzajā lauksaimniecībā.

1. Tā ir vajadzīga, lai varētu savlaicīgi noteikt, kādā apjomā ir nepieciešams izmantot barības vielas, tādējādi nodrošinot, ka nerodas papildu izmaksas.
2. Tā nodrošina iespēju izmantot normalizēta veģetācijas indeksa prognozes kultūraugu ražības modeļos un savlaicīgi aprēķināt ienākumus sagaidāmos.

## Aprobācija

Promocijas darbā veiktie pētījumi un to galvenie rezultāti ir prezentēti deviņās starptautiskajās zinātniskajās konferencēs.

1. International Conference on Aerospace Engineering, Applied Sciences, Information Technology, Electrical & Mechanical Engineering, Amsterdam, Netherlands, April 27–28, 2019.
2. 2nd International Conference on Research in Engineering and Fundamental Applied Sciences, Barcelona, Spain, April 20–21, 2019.
3. RTU 58th International Scientific Conference, Riga, Latvia, October 12–15, 2017.
4. 11th International Scientific and Practical Conference “Environment. Technology. Resources”, Rezekne, Latvia, June 15–17, 2017.
5. RTU 57th International Scientific Conference, Riga, Latvia, October 14–18, 2016.
6. 5th International Virtual Scientific Conference on Informatics and Management Sciences, Zilina, Slovakia, March 21–25, 2016.
7. 3rd Virtual Multidisciplinary Conference QUAESTI Zilina, Slovakia, December 7–11, 2015.
8. RTU 56th International Scientific Conference, Riga, Latvia, October 14–16, 2015.
9. 10th International Scientific and Practical Conference “Environment. Technology. Resources”, Rezekne, Latvia, June 18–20, 2015.

Promocijas darbā veiktie pētījumi un to rezultāti ir atspoguļoti astoņās publikācijās starptautiskajos zinātniskajos izdevumos.

1. Stepchenko, A. Land Cover Classification Based on MODIS Imagery Data Using Artificial Neural Networks. In: *Proceedings of the 11th International Scientific and Practical Conference “Environment. Technology. Resources”, June 15–17, 2017, Rezekne, Latvia*. Rezekne: Rezekne Academy of Technologies, 2017, pp. 159–164. Indexed in: **Scopus**.
2. Stepchenko, A., Chizhov, J., Aleksejeva, L., Tolujew, J. Nonlinear, Non-stationary and Seasonal Time Series Forecasting Using Different Methods Coupled with Data Preprocessing. *Procedia Computer Science*. 2016, vol. 104, pp. 578–585. Indexed in: **Scopus** and **Web of Science**. Cited: 2.



3. Stepchenko, A., Chizhov, J. Markov Chain Modelling for Short-Term NDVI Time Series Forecasting. *Information Technology and Management Science*. 2016, vol. 19, pp. 39–44. Indexed in: EBSCO, CSA/ProQuest and VINITI.
4. Stepchenko, A. NDVI Index Forecasting using a Layer Recurrent Neural Network Coupled with Stepwise Regression and the PCA. In: *Proceedings of the 5th Virtual International Conference of Informatics and Management Sciences, March 21–25, 2016, Zilina, Slovakia*. Zilina: EDIS-Publishing Institution of the University of Zilina, 2016, pp. 130-135. Indexed in: Google Scholar and Index Copernicus. Cited: 2.
5. Stepchenko, A. Normalized Difference Vegetation Index Forecasting using a Regularized Layer Recurrent Neural Network. In: *Proceedings of the 3rd Virtual Multidisciplinary Conference QUAESTI, December 7–11, 2015, Zilina, Slovakia*. Zilina: EDIS-Publishing Institution of the University of Zilina, 2015, pp. 261–266. Indexed in: Google Scholar.
6. Stepchenko, A., Chizhov, J. Applying Markov Chains for NDVI Time Series Forecasting of Latvian Regions. *Information Technology and Management Science*. 2015, vol. 18, pp. 57–61. Indexed in: EBSCO, CSA/ProQuest and VINITI. Cited: 2.
7. Stepchenko, A., Chizhov, J. NDVI Short-Term Forecasting Using Recurrent Neural Networks. In: *Proceedings of the 10th International Scientific and Practical Conference "Environment. Technology. Resources", June 18–20, 2015, Rezekne, Latvia*. Rezekne: Rezeknes Augstskola, 2015. Indexed in: **Scopus**. Cited: 2.
8. Stepchenko, A., Borisov, A. Methods of Forecasting Based on Artificial Neural Networks. *Information Technology and Management Science*. 2014, vol. 17, pp. 25–31. Indexed in: EBSCO, CSA/ProQuest and VINITI.

Promocijas darba rezultāti ir izstrādāti saistībā ar projektu "Aizaugušu lauksaimniecības platību un neinventarizētu meža zemju meža inventarizācijas rādītāju noteikšana, izmantojot tālzpētes metodes", ko īstenoja SIA "Meža nozares kompetences centrs", Ventspils Augstskola, Latvijas Valsts mežzinātnes institūts "Silava" un SIA "Mikrokods" (14.04.2014.–30.09.2015.).

Promocijas darbs izstrādāts ar Ventspils pilsētas domes atbalstu saskaņā ar nolikumu par mērķstipendijas piešķiršanu "Atbalsts doktora grāda pretendentiem Ventspils Augstskolā".

## **Promocijas darba struktūra un saturs**

Promocijas darbā ir ievads, piecas nodaļas, secinājumi, literatūras avotu saraksts un pielikumi. Darbs ir rakstīts latviešu valodā.

**Ievadā** ir pamatota izvēlētās tēmas aktualitāte, formulēts pētījumu mērķis un uzdevumi, izvirzītas hipotēzes, uzskaitītas promocijas darba izstrādē izmantotās zinātniskās metodes, aprakstīts pētījumu zinātniskais jaunieguvums un darbā iegūto rezultātu praktiskā vērtība, kā arī sniegts darba aprobācijas raksturojums.

**Pirmajā nodaļā** aprakstīti normalizēta veģetācijas indeksa teorētiskie pamati, kas iekļauj arī distancionālās zondēšanas un satelītattēlu pirmapstrādes pamatus, aprakstīta esošās

situācijas analīze, kas veltīta normalizēta veģetācijas indeksa prognozēšanai un signālu dekompozīcijas metožu izmantošanai laika rindu prognozēšanas uzdevumos.

**Otrajā nodaļā** aprakstītas datu pirmapstrādes metodes un laika rindu prognozēšanas metodes, kas izmantotas normalizēta veģetācijas indeksa laika rindu prognozēšanas sistēmas *NDVI FS* izstrādāšanā.

**Trešajā nodaļā** eksperimentāli pārbaudīta oriģinālās variāciju apakšsignālu dekompozīcijas metodes lietojamība normalizēta veģetācijas indeksa laika rindu prognozēšanas uzdevumā. Uz eksperimentu rezultātu analīzes pamata tiek izstrādāta modificēta variāciju apakšsignālu dekompozīcijas metode, kas arī tiek eksperimentāli pārbaudīta. Izstrādāta no modificētās variāciju apakšsignālu dekompozīcijas metodes iegūta apakšsignāla aproksimācijas pieeja.

**Ceturtajā nodaļā** piedāvāta prognozēšanas sistēma *NDVI FS*. Parādīta sistēmas arhitektūra, ko veido lietotāja saskarne, pirmapstrādes un mašīnmācīšanās moduļi, un datu krātuve. Parādīta moduļu un to veidojošo bloku skaitļošanas plūsma, dots katra bloka apraksts.

**Piektajā nodaļā** sniegts apraksts eksperimentiem ar izstrādāto sistēmu un iegūtajiem rezultātiem. Novērtēta sistēma ar aproksimācijas pieejas izmantošanu un bez šīs pieejas izmantošanas normalizēta veģetācijas indeksa laika rindu prognozēšanā. Sistēmas prognozēšanas precizitāte salīdzināta ar precizitāti, kas sasniegta, izmantojot klasiskās prognozēšanas metodes. Veikti pirmapstrādes parametru un prognozēšanas modeļu pārnesšanas eksperimenti.

**Pēdējā nodaļā** ietverti darbā sasniegtie rezultāti un secinājumi, kas balstīti uz veiktajiem eksperimentiem un piedāvātas prognozēšanas sistēmas *NDVI FS* izstrādāšanu un lietojumu.

# 1. NORMALIZĒTĀ VEĢĒTĀCIJAS INDEKSA LAIKA RINDAS UN TO ĪPAŠĪBAS

Nodaļā sniegts ieskats normalizēta veģētācijas indeksa (*Normalized Difference Vegetation Index, NDVI*) teorētiskajos pamatos un šī indeksa laika rindu prognozēšanā. Definēta prognozēšanas uzdevuma formālā nostādne. Apzinātas problēmas, kas saistītas ar *NDVI* laika rindu prognozēšanu un dekompozīcijas metožu izmantošanu dažādu laika rindu prognozēšanas uzdevumos. Tiek piedāvāta shēma ar laika rindas dekompozīciju, fāžu telpu rekonstrukciju, pazīmju atlasīšanu, pazīmju izvilkšanu un prognozēšanas metodes izmantošanu.

## 1.1. *NDVI* laika rindu prognozēšanas pētījumu analīze

Normalizētais veģētācijas indekss (*NDVI*) ir skaitlisks fotosintētiski aktīvas biomasas rādītājs [108], ko iegūst no multispektrāliem satelītattēliem (1.1. izteiksme):

$$NDVI = \frac{NIR - RED}{NIR + RED}, \quad (1.1.)$$

kur *NIR* – atstarošanas koeficienta vērtība tuvajā infrasarkanajā joslā;

*RED* – atstarošanas koeficienta vērtība redzamās gaismas sarkanajā joslā.

Darbā izmantotais pētījumu apgabals ir Ventspils novads. Lauksaimniecībā izmantojamā zeme Ventspils novadā aizņem 511 000 ha lielu platību jeb 20,9 % no novada teritorijas platības, savukārt mežu zemes aizņem 64 % no kopējās novada teritorijas [104]. Promocijas darba datu kopu veido 814 nogludināti *NDVI* attēli, kas iegūti no vidējās izšķirtspējas attēlveidošanas spektrometra *MODIS Terra* satelītattēliem ar telpisko izšķirtspēju 250 m, temporālo izšķirtspēju septiņas dienas un radiometrisko izšķirtspēju 16 biti. Šie attēli pārklāj Ventspils novada teritoriju. *NDVI* attēli tika lejupielādēti no Vīnes Dabas resursu un dabaszinātņu universitātes *MODIS* veģētācijas indeksu laika rindu datu apstrādes platformas, uz kuras arī tiek veikta *MODIS Terra NDVI* attēlu sagatavošana, kas iekļauj pikseļu vērtību nogludināšanu un trūkstošo vērtību aizpildīšanu, kas radušās mākoņu pārklājuma vai sliktu atmosfēras nosacījumu dēļ [106]. Katram pikselim tiek iegūta skalāra *NDVI* laika rinda.

Šajā promocijas darbā izmantotās normalizēta veģētācijas indeksa (*NDVI*) laika rindas ir nelineāras un nestacionāras laika rindas ar aditīva trokšņa un sezonālas komponentes elementiem [37]. Katrs laika rindas elements iegūts ar vienas nedēļas periodu. Katras *NDVI* laika rindas novērojumu skaits ir 814 un vērtību intervāls  $[-1; 1]$ .

Promocijas darbā tiek risināts prognozēšanas uzdevums, kur ir jāaprēķina *NDVI* laika rindas īstermiņa prognoze vienu nedēļu uz priekšu, izmantojot datu pirmapstrādes, frekvenču analīzei lietojamās signālu dekompozīcijas, lineārās algebras un mašīnmācīšanās metodes. Prognozēšanas precizitātes novērtēšanai tiek izmantotas šādas zaudējumu funkcijas: saknes vidējā kvadrātiskā kļūda (*Root Mean Square Error, RMSE*), virzienu simetrija (*Directional Symmetry, DS*) un pielāgotais determinācijas koeficients  $R_{adj}^2$ .

*NDVI* laika rindu prognozēšanas pētījumos [5], [13], [24], [38], [40], [60], [61] izmantoto metožu salīdzinājums pēc to piemērotības nelineāru, nestacionāru un trokšņainu laika rindu

prognozēšanai dots 1.1. tabulā. Apskatītajos pētījumos [5], [13], [24], [38], [40], [60], [61] ne vienmēr tiek sasniegta augsta prognozēšanas precizitāte. Tā ir atkarīga no dažādiem faktoriem, piemēram, no papildu datu izmantošanas. Vairākos pētījumos tika izmantoti papildu ieejas dati, piemēram, temperatūras vai nokrišņu dati.

1.1. tabula

*NDVI* laika rindu prognozēšanā izmantoto metožu salīdzinājums

Metodes un algoritmi Īpašības	<i>ARIMA</i> metode	Daudzparametru lineārā regresijas analīze	Vienvirziena neironu tīkli
Piemērotība nelineāru procesu modelēšanai	–	–	+
Piemērotība nestacionāru procesu modelēšanai	+	–	+
Robustums pret trokšņiem	–	–	+

Papildu datu iegūšana var būt sarežģīta, jo:

- ne vienmēr konkrētajam pikselim ir pieejami šie dati, biežāk tie ir pieejami par lieliem apgabaliem (vidējās vērtības novadā, rajonā utt.);
- papildu dati var būt maksas dati.

Praktiski visos apskatītajos pētījumos maz uzmanības tiek pievērsts datu pirmapstrādes posmam, netiek izmantotas tādas pirmapstrādes metožu grupas kā pazīmju atlasīšana (*feature selection*) un pazīmju izvilkšana (*feature extraction*), kas palīdz sagatavot laika rindu prognozēšanas uzdevumos ieejas datu kopu tā, lai tiktu paaugstināta prognozēšanas precizitāte.

Boksa–Dženkinsa automātiski regresējoša integrētā slīdošā vidējā (*Autoregressive Integrated Moving Average, ARIMA*) metode, kā arī lineārā regresijas analīze, kas tiek izmantota *NDVI* laika rindu prognozēšanai vairākos pētījumos, ir lineārās prognozēšanas metodes un nav robustas pret trokšņiem, savukārt *NDVI* laika rindas ir nelineāras un trokšņainas [37]. Turklāt piemērota *ARIMA* modeļa noteikšana ir laikietilpīga un resursus patērējoša procedūra.

## 1.2. Laika rindu prognozēšanas pētījumu ar signālu dekompozīciju analīze

Vairāku laika rindu prognozēšanas pētījumu analīze, kur tiek izmantotas dekompozīcijas metodes, ir dota 1.2. tabulā. Šajā tabulā kolonnas satur trīs dekompozīcijas metodes: veivletu dekompozīcijas metodi [33], [84], empīrisko apakšsignālu dekompozīcijas metodi [33], [34], [51], [64], [95] un variāciju apakšsignālu dekompozīcijas metodi [34], [51], [64], [84], [95], savukārt rindas satur attiecīgās prognozēšanas metodes, kas tiek izmantotas dažādos pētījumos. Turklāt katrā pētījumā tiek izmantotas divas no šīm laika rindu dekompozīcijas metodēm, tādā veidā nodrošinot prognozēšanas precizitātes salīdzināšanas iespēju: vispirms

prognozēšanas metode tiek izmantota kopā ar pirmo dekompozīcijas metodi, tad – ar otro dekompozīcijas metodi. Tai dekompozīcijas metodei, ko izmantojot tiek sasniegta augstākā prognozēšanas precizitāte, atbilstošā laukā, kur krustojas šī dekompozīcijas metode un atbilstošā prognozēšanas metode, tiek pielikts “+”, otrajai dekompozīcijas metodei, ko izmanto pētījumā, atbilstošajā laukā tiek pielikts “-”, kā redzams 1.2. tabulā. Trešā dekompozīcijas metode šajos pētījumos netiek izmantota.

1.2. tabula

Laika rindu prognozēšanā izmantoto dekompozīcijas metožu salīdzinājums

<b>Prognozēšanas metode</b> \ <b>Dekompozīcijas metode</b>	<b>Veivletu dekompozīcija</b>	<b>Empīriskā apakšsignālu dekompozīcija</b>	<b>Variāciju apakšsignālu dekompozīcija</b>
Vienvirziena neironu tīkls [33]	-	+	
Mazāko kvadrātu atbalsta vektoru mašīna, ekstrēmā apmācības mašīna [84]	-		+
Svērtā regularizētā ekstrēma apmācības mašīna [34]		-	+
Impulsu neironu tīkls [95]		-	+
Vispārējs regresijas neironu tīkls [51]		-	+
Daudzkodolu regularizēts pseidoinversais neironu tīkls [64]		-	+

Tādēļ lauks, kur krustojas trešā dekompozīcijas metode un atbilstošā prognozēšanas metode, tiek aizkrāsots ar pelēku krāsu. Ir redzams, ka visbiežāk augstākā laika rindu prognozēšanas precizitāte tiek sasniegta, izmantojot variāciju apakšsignālu dekompozīcijas (*Variational Mode Decomposition, VMD*) metodi.

Apskatītajos prognozēšanas pētījumos ar dekompozīcijas metožu izmantošanu daži autori [33], [95] lieto dekompozīcijas metodi visai ieejas laika rindai, un tikai tad tiek izveidotas apmācības un testa datu kopas, un tiek veikta prognozēšanas modeļa apmācība. Tomēr iegūtie rezultāti, kas parasti parāda augstu prognozēšanas precizitāti, no šādas pieejas izmantošanas neparāda patieso situāciju, jo tiek prognozēti tikai vēsturiskie novērojumi. Šajā gadījumā testa datu kopu veido daļa no šiem vēsturiskajiem novērojumiem, uz kuriem pirms tam tika lietota dekompozīcija [33], [95]. Līdz ar to nav iespējams noteikt, vai šie apmācītie prognozēšanas modeļi spēj ar līdzvērtīgu precizitāti prognozēt arī jaunas laika rindas vērtības, kas nāks klāt laika rindai aiz pēdējā vēsturisko novērojumu elementa.

Savukārt citi autori sadala ieejas laika rindu mazākos fragmentos atbilstoši kādam loga garumam un lieto dekompozīciju katram fragmentam atsevišķi [30], [34]. Praktiski tas nozīmē, ka dekompozīcija tiek lietota katram datu ierakstam no rekonstruētās fāžu telpas. Šādā veidā

signālu dekompozīcijas metodes, ko lieto frekvenču analīzei, var izmantot arī jaunu laika rindas vērtību prognozēšanai (to vērtību prognozēšanai, kas nāk pēc vēsturiskiem datiem).

Tomēr visu pētījumos apskatīto signālu dekompozīcijas metožu galvenais trūkums ir tas, ka to primārais uzdevums nav laika rindu dekompozīcijas veikšana prognozēšanas uzdevumu ietvaros. Pirmā problēma, ja *VMD* metodei ieejā padod visus vēsturiskos laika rindas novērojumus, ir, ka, aprēķinot apakšsignālu vērtības kādā laika solī, dekompozīcijas metodes izmanto visas ieejas laika rindas vērtības, tajā skaitā arī nākotnes novērojumu vērtības, skatoties pēc laika. Tādējādi, ja dekompozīcijas metode izmanto visus ieejas laika rindas vēsturiskos novērojumus, tad katru reizi, nākot klāt jaunam novērojumam, apakšsignālu vērtības ir jāpārrēķina vēlreiz, dekompozīcijas metodei padodot ieejā vēsturiskos novērojumus kopā ar jaunāko novērojumu, un visas iepriekš aprēķinātās apakšsignālu vērtības visos laika soļos mainās. Otrā problēma ir tā, ka, lietojot dekompozīcijas metodi visai ieejas laika rindai, pētījumos [33], [95] netiek pārbaudīts, vai ir iespējams prognozēt jaunu laika rindas vērtību ar līdzvērtīgu precizitāti, salīdzinot ar to, kas iegūta, prognozējot vēsturiskos *NDVI* novērojumus.

### 1.3. Uzdevuma formāla nostādne

Lai noteiktu procesa  $y = \{y(t), t = 1, 2, \dots, N\}$  vērtību laika brīdī  $t = N + 1$ , kur  $N$  ir vēsturisko novērojumu skaits, ir nepieciešams noteikt funkcionālu sakarību starp  $y = \{y(t)\}$  vēsturiskajām novērojumu vērtībām un nākotnes vērtībām, kā arī šai sakarībai ir jāņem vērā atvasinātā laika rinda  $u_1 = \{u_1(t)\}, u_2 = \{u_2(t)\}, \dots, u_K = \{u_K(t)\}$  vēsturisko vērtību ietekmi uz ieejas laika rindu (1.2. vienādojums):

$$\begin{aligned} y(t+1) = & f(y(t), y(t-1), \dots, y(t-m+1), u_1(t), u_1(t-1), \dots, \\ & u_1(t-m_1+1), \dots, u_K(t), u_K(t-1), \dots, u_K(t-m_K+1)) + \varepsilon(t), \end{aligned} \quad (1.2.)$$

kur  $y$  – ieejas laika rinda;

$K$  – atvasināto laika rindu skaits;

$u_1$  – pirmā atvasinātā laika rinda;

$u_K$  –  $K$ -tā atvasinātā laika rinda;

$m$  – loga garums, ko izmanto ieejas laika rindai;

$m_1$  – loga garums, ko izmanto pirmajai atvasinātajai laika rindai;

$m_K$  – loga garums, ko izmanto  $K$ -tai atvasinātajai laika rindai;

$t$  – laiks;

$\varepsilon$  – baltais troksnis.

Funkcionālā sakarība (1.2. vienādojums) ir prognozēšanas modelis. Ir nepieciešams iegūt tādu prognozēšanas modeli, kam saknes vidējās kvadrātiskās kļūdas (*RMSE*) vērtība starp patiesajām un prognozētajām laika rindas  $y = \{y(t)\}$  vērtībām ir minimāla.

## 1.4. Prognozēšanas sistēmas konceptuālais apraksts

Pamatojoties uz uzdevuma formālo nostādni, analizējamo datu struktūru un abiem literatūras apskatiem un analīzi, tiek piedāvāta prognozēšanas sistēmas konceptuālā shēma, kas ietver šādas metodes un pieejas:

- signālu apstrāde (laika rindas dekompozīcija);
- datu pirmapstrāde (fāžu telpu rekonstrukcija, datu kopu izveidošana, pazīmju atlasīšana un izvilksana);
- mašīnmācīšanās.

Balstoties uz veikto literatūras analīzi, ir izstrādātas prognozēšanas sistēmas **prasības**:

- 1) prognozēšanas sistēmai ieejā jāsaņem tikai *NDVI* laika rindas vēsturiskie dati;
- 2) jābūt izstrādātai pieejai, kas ļauj aproksimēt apakšsignālu vērtības katrā laika solī, kas nodrošina to, ka:
  - apakšsignālu vērtības ir pieejamas visiem laika soļiem, kur ir pieejami vēsturiskie normalizēta veģētācijas indeksa laika rindu novērojumi;
  - katrā laika solī apakšsignālu vērtības tiek iegūtas bez variāciju apakšsignālu dekompozīcijas metodes izmantošanas;
  - aprēķinot apakšsignālu vērtības katrā jaunā laika solī, iepriekšējos laika soļos aprēķinātās apakšsignālu vērtības nemainās;
- 3) prognozēšanas precizitātes uzlabošanai prognozēšanas modelim ir jābūt kombinētam:
  - ar datu pirmapstrādes metodēm (pazīmju atlasīšanas un izvilksanas metodēm);
  - ar piedāvāto apakšsignālu aproksimācijas pieeju.

Izstrādājot prognozēšanas sistēmu un balstoties uz izvirzītajām prasībām, pastāv vairāki pētījuma **ierobežojumi**.

1. Tiek analizētas un apstrādātas *NDVI* laika rindas, kur katra iegūta no viena pikseļa.
2. Tiek veikta tikai īstermiņa prognozēšana – vienu laika rindas vienību uz priekšu (promocijas darbā izmantotajiem *MODIS Terra NDVI* attēliem tās ir septiņas dienas).
3. Netiek izmantoti papildu dati (piemēram, gaisa temperatūras dati, nokrišņu dati, citi veģētācijas indeksi, zemes virsmas kategoriju dati).

Datu pirmapstrādē tiek piedāvāts izmantot dekompozīciju, lai iegūtu noteiktu skaitu apakšsignālu. Fāžu telpu rekonstrukcija var tikt izmantota, lai no visām laika rindām iegūtu sākotnējo datu kopu, kas tiek sadalīta, izveidojot vairākas ieejas datu kopas. Pazīmju atlasīšana var tikt izmantota, lai izslēgtu no datu kopām neinformatīvos atribūtus, kas var mazināt prognozēšanas precizitāti. Reducētās atribūtu kopas tiek transformētas pēc noteiktiem kritērijiem. Tālāk šīs datu kopas tiek padotas ieejā prognozēšanas metodei, kas, apmācoties uz šīm datu kopām, atrod funkcionālo sakarību (1.2. vienādojums), iegūstot prognozēšanas modeli, ko var izmantot jauno *NDVI* laika rindas vērtību prognozēšanai.

## 2. PROGNOZĒŠANAS SISTĒMAS IZSTRĀDĀŠANĀ IZMANTOJAMO METOŽU APSKATS

Nodaļā dots ieskats par prognozēšanas sistēmas izstrādāšanā lietojamajām datu pirmapstrādes un prognozēšanas metodēm. Viena no mūsdienu tendencēm, izstrādājot prognozēšanas sistēmas, ir dažādu metožu un pieeju kombinācija, parasti kombinējot dažādas datu pirmapstrādes metodes ar vienu vai vairākām laika rindu prognozēšanas metodēm [35], [80], [81], [85], [110]. Tas ļauj kompensēt atsevišķu metožu vai pieeju trūkumus un paaugstināt prognozēšanas precizitāti.

Atbilstoši literatūras analīzei par laika rindu dekompozīcijas metodi tiek piedāvāts izmantot variāciju apakšsignālu dekompozīcijas (*Variational Mode Decomposition, VMD*) metodi [118]. Lai skalāru *NDVI* laika rindu un iegūtos apakšsignālus sadalītu fragmentos pēc noteikta loga garuma un iegūtu sākotnējo datu kopu, var tikt izmantota fāžu telpas rekonstrukcija. Fāžu telpu rekonstrukcijai tiek piedāvāts izmantot populāro laika aiztures metodi [48]. Sākotnējā datu kopa tiek sadalīta apmācības, validācijas un testa datu kopās, kur katra no šīm kopām sastāv no atribūtu jeb pazīmju kopas un prognozējamā parametra.

Katrs atribūts šajās kopās ir par noteiktu laika soli nobīdīts *NDVI* laika rindas un apakšsignālu vērtības. Lai reducētu sākotnējās atribūtu kopas, atlasot tikai informatīvākos atribūtus, var izmantot pazīmju atlasīšanas metodes [26], [77]. Populāra pazīmju atlasīšanas metode, ko var lietot laika rindu prognozēšanas uzdevumos, ir pakāpeniskā regresijas analīze [99], ko tiek piedāvāts izmantot izstrādājamā sistēmā.

Ir svarīgi, lai atribūti savstarpēji lineāri nokorelētu un neapgrūtinātu prognozēšanas modeļa apmācību. Principiālo komponentu analīze (*Principal Component Analysis, PCA*) ir metode, ko bieži izmanto lineāri nekorelējošu atribūtu kopu iegūšanai [79]. Principiālo komponentu analīzes metodi tiek piedāvāts izmantot prognozēšanas sistēmā kā pazīmju izvilkšanas metodi.

Kā prognozēšanas metodi sistēmā tiek piedāvāts izmantot rekurento slāņu neironu tīklus (*Layer Recurrent Neural Network, LRNN*), pateicoties savām īpašībām prognozēt nelineāras, nestacionāras un trokšņainas laika rindas ar labu precizitāti [71].

### 2.1. Variāciju apakšsignālu dekompozīcija

Variāciju apakšsignālu dekompozīcijas modelī tiek pieņemts, ka reālo vērtību signāls  $f$  sastāv no vairākiem apakšsignāliem  $u_k$ , kur  $k = 1, \dots, K$ . Apakšsignāls jeb iekšējo svārstību funkcija (2.1. vienādojums) ir amplitūdas un frekvences modulētais (AM-FM) signāls [118]:

$$u_k(t) = A_k(t) \cos(\phi_k(t)); \quad (2.1)$$

where  $k$  – apakšsignāla numurs,  $k = 1, \dots, K$ , kur  $K$  ir apakšsignālu skaits

$A_k(t)$  –  $k$ -tā apakšsignāla amplitūda;

$\phi_k(t)$  –  $k$ -tā apakšsignāla fāze;

$t$  – laiks.



Jebkuram apakšsignālam frekvences  $\omega$  mainās nelielā diapazonā. Katram no  $K$  apakšsignāliem ir jābūt centrētam ap centra frekvenci  $\omega_k$ , kas tiek aprēķināta dekompozīcijas laikā. Lai aprēķinātu apakšsignālus, *VMD* algoritma ietvaros uzdevums ir minimizēt  $K$  apakšsignālu frekvenču joslu platumu summu ar nosacījumu, ka visu  $K$  apakšsignālu summa ir vienāda ar oriģinālo signālu [118]. Tātad nezināmie ir  $K$  apakšsignālu centra frekvences un  $K$  iekšējo svārstību funkcijas, kas ir centrētas pie šīm frekvencēm. Daži no nezināmajiem ir funkcijas, tāpēc *VMD* metodē tiek izmantoti variāciju aprēķini.

Lai iegūtu korektus rezultātus arī abos signāla galapunktos, izmantojot variāciju apakšsignālu dekompozīcijas algoritmu, oriģinālais signāls tiek paplašināts, izmantojot “spoguļošanu” [118]. Paplašinātais signāls ir divas reizes garāks par oriģinālo signālu, un tā garums ir  $T$ .

## 2.2. Fāžu telpas rekonstrukcija ar laika aiztures metodi

Fāžu telpa ir abstrakta telpa, kas attēlo visu sistēmas iespējamo stāvokļu kopu, kur katram iespējamajam sistēmas stāvoklim atbilst punkts fāžu telpā [11]. Haotiskām laika rindām izmanto fāžu telpas rekonstrukciju ar laika aiztures metodi pēc Takensa teorēmas [48]. Izmantojot Takensa teorēmu, haotisku un dinamisku sistēmu var attēlot ar aiztures vektoru palīdzību. Izmantojot fāžu telpas rekonstrukcijas metodi ar laika aizturi, ir nepieciešams atrast divu parametru – iegultās dimensijas  $m$  un laika aiztures  $\tau$  piemērotās vērtības. No šiem parametriem ir atkarīga laika rindu prognozēšanas precizitāte. Prognozēšanas uzdevuma formālajā nostādņē, meklējot funkcionālo sakarību (1.2. vienād.), kā loga garums  $m$  sākotnēji, pirms tiek veikta pazīmju atlasīšana, tiek izmantota rekonstruētās fāžu telpas dimensija.

## 2.3. Pakāpeniskā regresijas analīze

Pakāpeniskā regresijas analīze ir metode secīgai pazīmju atlasīšanai, kur pazīmes (jeb atribūti) tiek pievienoti multilineāram modelim un izņemti no tā automatisko procedūru rezultātā, pamatojoties uz atribūtu statistisko nozīmi regresijas analīzē [99].

Sākotnējais pakāpeniskās regresijas modelis neietver nevienu atribūtu. Tad katrā solī tiek aprēķināta  $F$  statistikas  $p$  vērtība, lai testētu modeļus ar noteiktiem atribūtiem [111]. Atribūts ar mazāko  $p$  vērtību, ja tā nepārsniedz noteikto pievienošanas sliekšni un ja tiek noraidīta nulles hipotēze, ka, pievienojot šo atribūtu modelim, tam varētu būt nulles koeficients, tiek pievienots modelim. No atribūtiem, kas jau ir modelī, atribūts ar lielāko  $p$  vērtību tiek izņemts no modeļa, ja atribūta  $p$  vērtība pārsniedz noteikto izņemšanas sliekšni un ja netiek noraidīta nulles hipotēze, ka šim atribūtam ir nulles koeficients. Tomēr pakāpeniskās regresijas analīze nav globāli optimāla, un iegūtais regresijas modelis var būt tikai lokāli optimāls [16].

## 2.4. Principiālo komponentu analīze

Principiālo komponentu analīze (*PCA*) ir statistiska pazīmju izvilkšanas metode, kas izmanto ortogonālu transformāciju, lai pārveidotu iespējami korelējošo ieejas datu (šajā darbā

atribūtu  $x_1, x_2, \dots, x_m$ ) kopu uz lineāri nekorelējošu datu kopu  $\hat{x}_1, \hat{x}_2, \dots, \hat{x}_p$ , kur  $m$  ir sākotnējās datu kopas dimensiju skaits, bet  $p$  ir principiālo komponentu skaits [79].

Pirmais solis *PCA* algoritmā ir normalizēt datus tā, lai katram atribūtam vidējā vērtība būtu nulle. Tad tiek aprēķinātas principiālās komponentes no normalizētiem datiem. No atribūtiem tiek aprēķināta paraugkopas kovariācijas matrica  $C$ , kurai, veicot īpašvērtību dekompozīciju, tiek iegūta īpašvektoru kopa  $M$  [96]. Principiālās komponentes  $\hat{x}$  tiek izvēlētas tādā veidā, ka pirmā principiālā komponente  $\hat{x}_1$  satur visvairāk dispersijas no oriģinālajiem datiem, otrā satur otro lielāko dispersijas, un turklāt tā lineāri nekorelē ar  $\hat{x}_1$  utt. [43].

## 2.5. Mākslīgie neironu tīkli

Mākslīgie neironu tīkli *ANN* ir mākslīgā intelekta paveids, kas mēģina imitēt bioloģisko neironu funkciju, pēc kuras strādā cilvēka smadzenes [85]. Viens no izplatītākajiem mākslīgo neironu tīklu modeļiem ir daudzslāņu perceptrons, kas iekļauj ieejas slāni, izejas slāni un vienu vai vairākus starpslāņus, ko sauc par slēptajiem slāņiem [85].

Darbā risināto prognozēšanas uzdevumu gadījumā izejas slānis satur vienu neironu, kas izejā dod laika rindas prognozēto vērtību. Katrs neirons katrā slānī saņem svērtās ieejas no iepriekšējā slāņa, šīs svērtās ieejas tiek summētas, izmantojot kombināciju funkciju. Šīs summēšanas rezultāts tiek padots kā arguments aktivizācijas funkcijai (piemēram, lineārai, loģistiskai vai hiperboliskā tangensa funkcijai [46]), kur šīs funkcijas vērtība ir neirona izeja, un tā tiek padota uz nākamo slāni [85].

Neironu tīkla apmācības mērķis ir samazināt globālo kļūdu, kas tiek aprēķināta, izmantojot kādu noteiktu mērķfunkciju. Viena no populārākajām un efektīvākajām nelineārās optimizācijas metodēm ir Levenberga–Markvardta kļūdas atgriezeniskās izplatīšanās algoritms ar Beijesa regularizāciju [85]. Beijesa regularizācija minimizē kļūdu un svaru kvadrātu lineāro kombināciju, kas izraisa to, ka neironu tīkla modelim ir mazāki svāri un konstantes, tas ļauj iegūt gludākas prognozes un samazina pārlietas pielāgotības (*overfitting*) iespēju prognozējamajiem datiem [23]. Kā minimizējama mērķfunkcija, izmantojot Beijesa regularizāciju, tiek lietota regularizēta vidējās kvadrātiskās kļūdas funkcija  $MSE_{reg}$  [23].

Rekurento slāņu neironu tīkli (*Layer Recurrent Neural Network, LRNN*) ir viens no dinamisko, rekurento neironu tīklu veidiem, kas tiek veidots uz daudzslāņu perceptrona bāzes, pievienojot atgriezeniskās saites [18], [71]. Šīs saites iziet no slēpto slāņu neironiem un nonāk konteksta slānī, kas uzglabā slēpto slāņu vērtības ar laika aizturi, tādējādi sniedzot vērtīgu informāciju par iepriekšējo ieejas vektoru, un tas nosaka *LRNN* tīkla galveno īpašību – secības iegaumēšanu [19].

### 3. APAKŠSIGNĀLA APROKSIMĀCIJAS PIEEJAS IZSTRĀDĀŠANA

Nodaļa veltīta variāciju apakšsignālu dekompozīcijas (*Variational Mode Decomposition, VMD*) metodes modifikācijas izstrādāšanai un no modificētās *VMD* metodes iegūta apakšsignāla aproksimācijas pieejas izstrādāšanai, kas ļauj tuvināti katrā laika solī aprēķināt apakšsignāla vērtības. Tiek veikta normalizēta veģetācijas indeksa (*Normalized Difference Vegetation Index, NDVI*) laika rindu prognozēšana, izmantojot no oriģinālās un modificētās *VMD* metodes iegūtos apakšsignālus.

#### 3.1. Oriģinālās *VMD* metodes izmantošana *NDVI* laika rindu prognozēšanā

Lai novērtētu oriģinālās variāciju apakšsignālu dekompozīcijas (*VMD*) metodes lietojamību *NDVI* laika rindu prognozēšanas uzdevumā, tiek veikti divi eksperimenti. Eksperimentos tiek izmantotas 100 *NDVI* laika rindas, kas izvēlētas nejauši, ģenerējot pikseļa rindas un kolonnas numurus *MODIS NDVI* attēlos. Katrs no abiem eksperimentiem tiek atkārtots 100 reižu katrai *NDVI* laika rindai atsevišķi.

Vispirms tiek pārbaudīta *NDVI* laika rindu prognozēšanas precizitāte, izmantojot oriģinālo *VMD* metodi visiem *NDVI* laika rindas vēsturiskiem novērojumiem, kā tas tiek darīts pētījumos [33], [95]. Eksperimentā *NDVI* laika rinda tiek padota ieejā *VMD* metodei, iegūstot noteiktu skaitu apakšsignālus. No *NDVI* laika rindas un visiem apakšsignāliem tiek izveidotas datu kopas, kas sastāv no atribūtu kopām un prognozējama parametra. Datu kopām tiek veikta pirmapstrāde, atlasot informatīvākos, lineāri nekorelējošos atribūtus. Pirmapstrādātās datu kopas tiek padotas ieejā rekurento slāņu neironu tīklam, kas iegūst prognozēšanas modeli. Eksperiments tiek atkārtots visām 100 laika rindām. Eksperimentā iegūto zaudējumu funkciju: saknes vidējās kvadrātiskās kļūdas (*Root Mean Square Error, RMSE*), virzienu simetrijas (*Directional Symmetry, DS*) un determinācijas koeficienta  $R^2$  vidējās vērtības no visām laika rindām dotas 3.1. tabulā.

Nākamajā eksperimentā tiek pārbaudīta *NDVI* laika rindu prognozēšanas precizitāte, izmantojot oriģinālo *VMD* metodi katram *NDVI* laika rindas fragmentam ar noteiktu loga garumu, kā tas tiek darīts pētījumos [30], [95]. *NDVI* laika rindu iedala fragmentos ar noteiktu loga garumu, iegūstot datu kopas, kas sastāv no atribūtu kopām un prognozējama parametra. Katrs atribūtu kopu datu ieraksts kā parametrs tiek padots ieejā *VMD* metodei, iegūstot paplašinātas atribūtu kopas. Atribūtu kopām tiek veikta pirmapstrāde – informatīvāko, lineāri nekorelējošu atribūtu kopu iegūšana. Pirmapstrādātās datu kopas tiek padotas ieejā rekurento slāņu neironu tīklam, kas veic apmācību uz šiem datiem, iegūstot prognozēšanas modeli. Eksperiments tiek atkārtots visām 100 laika rindām. Zaudējumu funkciju vidējās vērtības visām 100 laika rindām, kas ir iegūtas šajā eksperimentā, ir redzamas 3.1. tabulā.

Pirmajā eksperimentā iegūtās zaudējumu funkciju vidējās vērtības, kas parādītas 3.1. tabulā, uzrāda augstu prognozēšanas precizitāti uz apmācības un validācijas datu kopām, sasniedzot  $RMSE = 0,000027$  uz apmācības un  $RMSE = 0,000040$  uz validācijas kopas.

Zaudējumu funkciju vērtības eksperimentos ar oriģinālo *VMD* metodi

Datu kopa	Pirmais eksperiments			Otrais eksperiments		
	<i>RMSE</i>	<i>DS</i>	$R^2$	<i>RMSE</i>	<i>DS</i>	$R^2$
Apmācības datu kopa	0,000027	99,94 %	1,00	0,0013	97,53 %	0,99
Validācijas datu kopa	0,000040	99,99 %	1,00	0,0016	97,45 %	0,99
Testa datu kopa	0,046000	85,59 %	0,96	0,0011	97,69 %	0,99

Tas ir saistīts ar to, ka *VMD* metode, aprēķinot apakšsignālu vērtības katrā laika solī  $t$ , izmanto visas ieejas signāla vērtības. Respektīvi, katra apakšsignāla vērtība katrā laika solī  $t$  satur informāciju par *NDVI* laika rindas vērtībām gan nākamajos laika soļos, gan iepriekšējos. Lai arī pirms pirmā un pēc pēdējā *NDVI* laika rindas novērojuma būtu pieejami dati, oriģinālās *VMD* metodes autori izmanto signālu “spoguļošanu”, paplašinot laika rindu ar vērtībām no vēsturiskiem novērojumiem [118]. Savukārt otrajā eksperimentā aprēķinātās prognožu zaudējumu funkciju vidējās vērtības, kā var redzēt 3.1. tabulā, uzrāda stabilu prognozēšanas precizitāti uz visām trim datu kopām.

### 3.2. Variāciju apakšsignālu dekompozīcijas metodes modifikācija

Oriģinālajā *VMD* metodē tiek izmantots “spoguļošanas” algoritms [118]. Ja ieejas signāla garums ir  $N$ , tad tiek aprēķināts signāla viduspunkts: vesels skaitlis no  $N/2$ . No ieejas signāla tiek paņemti visi elementi no pirmā elementa līdz  $N/2$  elementam un apgrieztā secībā tiek pielikti priekšā ieejas signālam. Tālāk tiek paņemti visi elementi no  $N/(2+1)$  elementa līdz  $N$  elementam un apgrieztā secībā pielikti ieejas signāla beigās. Līdz ar to variāciju apakšsignālu dekompozīcijas metode strādā ar signālu, kura garums ir  $T$ . Tomēr paplašinātās laika rindas daļas arī dod savu ieguldījumu apakšsignālu skaitļošanas procesā, un līdz ar to arī ietekmē, kādas būs apakšsignālu vērtības laika soļos no  $t=1$  līdz  $t=N$ . Tas rada problēmas, ka, izstrādājot prognozēšanas modeļus, tie spēj ar augstu precizitāti prognozēt tikai vēsturiskos laika rindas novērojumus.

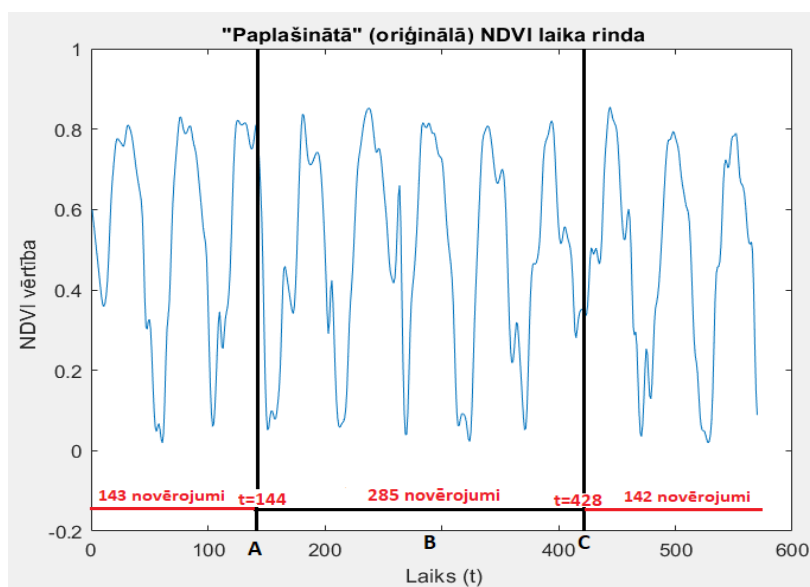
Lai atrisinātu “spoguļošanas” izraisīto problēmu, viens no variantiem ir neizmantot laika rindu paplašināšanu, bet tā vietā divreiz samazināt oriģinālā signāla novērojumu skaitu, ko ieejā saņem *VMD* metode. Ja visa oriģinālā laika rinda (kas tagad tiek izmantota kā paplašinātā laika rinda) ir ar novērojumu skaitu  $T$ , tad laika rindas vidusdaļa satur  $N$  novērojumus, un arī iegūtie apakšsignāli atbilst šiem  $N$  novērojumiem. Tagad paplašinājumu vietā atradīsies oriģinālās laika rindas reālie novērojumi, un apakšsignālu vērtības saturēs informāciju par patiesajām ieejas laika rindas vērtībām nākamajos laika soļos. Laika rindas sadalīšana “paplašinātajā” un “oriģinālajā” daļā parādīta 3.1. attēlā. Attiecīgi paplašinājums laika rindas sākumā ietvers novērojumus no pirmā novērojuma līdz punktam  $A$  (3.1. formula):

$$A = \frac{T}{4} + 1. \quad (3.1.)$$

Savukārt paplašinājums laika rindas beigās atbilst oriģinālās laika rindas novērojumiem no punkta  $C$  līdz pēdējam novērojumam (3.2. formula). Tādējādi tiek iegūts jaunās “oriģinālās”  $NDVI$  laika rindas beigu punkts  $C$ .

$$C = 3\frac{T}{4} + 1. \quad (3.2.)$$

Aprēķinātā “oriģinālās” (fragments  $AC$ ) un “paplašinātās” laika rindas proporcionalitāte atbilst oriģinālās un paplašinātās laika rindas proporcionalitātei, ko iegūst, izmantojot oriģinālo  $VMD$  metodi. Respektīvi, oriģinālās laika rindas garums ir puse no paplašinātās laika rindas garuma, turklāt paplašinātās vērtības atrodas abos oriģinālās laika rindas galos.



3.1. att.  $NDVI$  laika rindas sadalīšana “paplašinātajā” un “oriģinālajā” daļā.

Tomēr šāda modifikācija vēl nav izmantojama  $NDVI$  laika rindu jaunu vērtību prognozēšanai, jo iegūtās apakšsignālu vērtības ir pieejamas tikai ieejas laika rindas vidusdaļai, kā tas ir redzams 3.1. attēlā. Attiecīgi, arī laika rindas vērtība, ko var prognozēt vienu laiku soli uz priekšu, atradīsies aiz šīs vidusdaļas novērojumiem, laika solī  $t = N + 1$ , savukārt  $NDVI$  prognozēšanas uzdevumā ir nepieciešams prognozēt vērtību laika solī  $t = T + 1$ .

Tiek veikts eksperiments, kura mērķis ir pārbaudīt prognozēšanas precizitāti, izmantojot modificēto  $VMD$  metodi visiem  $NDVI$  laika rindas vēsturiskajiem novērojumiem. Eksperimentā tiek izmantotas 100  $NDVI$  laika rindas, kur katra laika rinda sākotnēji satur 814 novērojumus. Tiek paņemta katra laika rinda, un tiek veiktas vairākas iterācijas, kur vispirms tiek atlasīti pirmie 70 % novērojumu, no laika soļa  $t = 1$  līdz  $t = 570$ , kas kopā ir 570 novērojumi ( $T = 570$ ). Padodot atlasītos 570 novērojumus ieejā modificētajai  $VMD$  metodei, apakšsignāli tiek iegūti laika soļiem no  $t = 143$  līdz  $t = 428$ , kur katrs apakšsignāls satur 285 novērojumus ( $N = 285$ ). No  $NDVI$  laika rindas un iegūtajiem apakšsignāliem tiek rekonstruētas fāžu telpas, kas tiek

apvienotas vienotā datu kopā, kas savukārt tiek sadalīta apmācības, validācijas un testa datu kopās. Uz šīm kopām tiek veikta informatīvāko atribūtu atlasīšana, izmantojot pakāpenisko regresijas analīzi, un lineāri nekorelējošu atribūtu iegūšana, izmantojot principiālo komponentu analīzi. Pirmapstrādātas apmācības un validācijas datu kopas tiek padotas ieejā rekurento slāņu neironu tīklam, kas veic apmācību uz datiem.

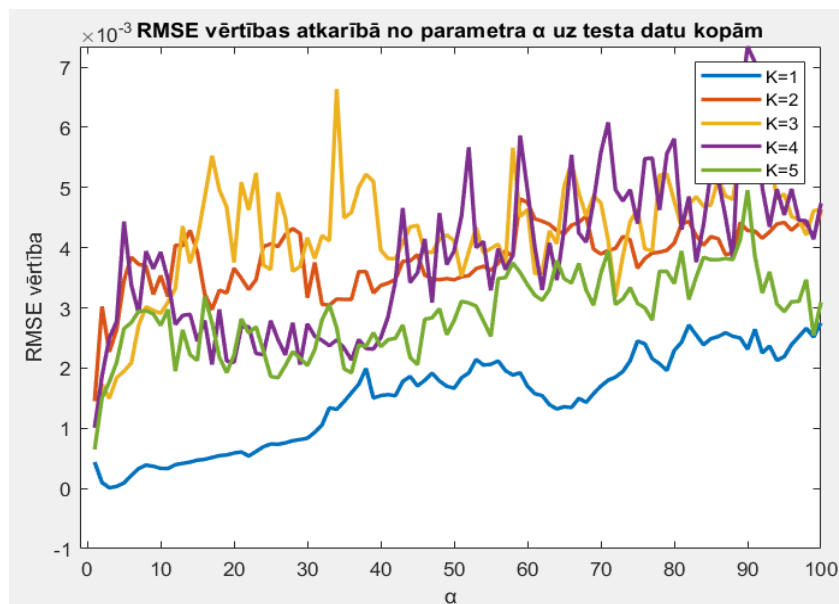
Kad prognozēšanas modelis ir iegūts, tas tiek izmantots, lai prognozētu *NDVI* laika rindas vērtību laika solī  $t = N + 1$ . Kad prognoze tiek iegūta, tālāk tiek paņemti nākamie 70 % novērojumu, un process atkārtojas. *NDVI* laika rindas novērojumi no  $t = N + 1$  līdz  $t = T$  veido testa datu kopu. Trešajā eksperimentā iegūtās zaudējumu funkciju vidējās vērtības no visām 100 *NDVI* laika rindām uz visām datu kopām ir redzamas 3.2. tabulā.

3.2. tabula

Eksperimentā ar modificēto *VMD* metodi iegūtās zaudējumu funkciju vērtības

Datu kopa	<i>RMSE</i>	<i>DS</i>	$R^2$
Apmācības datu kopa	0,000058	99,88 %	1,00
Validācijas datu kopa	0,000076	100 %	1,00
Testa datu kopa	0,000074	100 %	0,99

Atkarībā no apakšsignālu summas precizitāti regulējošā parametra  $\alpha$  pie dažāda apakšsignālu skaita  $K$  iegūtās *RMSE* vērtības redzamas 3.1. attēlā.



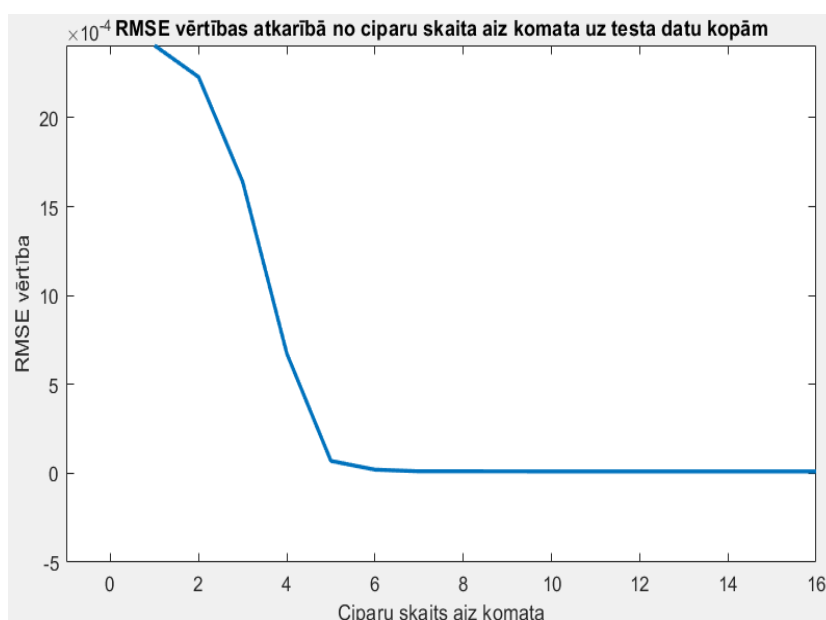
3.1. att. *RMSE* vērtības atkarībā no precizitātes parametra  $\alpha$ .

Analizējot 3.1. attēlu, tiek secināts, ka, pirmkārt, *RMSE* vērtībām ir tendence pieaugt, palielinoties apakšsignālu summas precizitāti regulējošā parametra  $\alpha$  vērtībām. Otrkārt, tiek secināts, kā viszemākās *RMSE* vērtības tiek sasniegtas, izmantojot tikai vienu apakšsignālu. Savukārt, analizējot 3.2. tabulu, var secināt, ka jaunu laika rindas vērtību (vienas vērtības uz

priekšu katrā novērojumu izlasē) prognozēšana pēc trešā eksperimenta uzrāda augstu precizitāti. Tomēr oriģinālās laika rindas reducēšanas dēļ prognozēšana ir iespējama tikai oriģinālās *NDVI* laika rindas vidusdaļā.

Ir nepieciešams arī veikt eksperimentu, lai novērtētu, kā mainās *RMSE* vērtības atkarībā no tā, cik ciparus aiz komata izmanto apakšsignāls. Viss eksperimenta apraksts sakrīt ar trešā eksperimenta aprakstu, izņemot to, ka apakšsignālam secīgi tiek atņemts noteikts skaits pēdējo ciparu. Ceturtajā eksperimentā iegūtās 16 vidējās *RMSE* vērtības pie dažāda apakšsignāla ciparu skaita aiz komata redzamas 3.2. attēlā.

Analizējot 3.2. attēlu, var secināt, ka *RMSE* vērtības strauji samazinās no viena līdz pieciem cipariem aiz komata. No sešiem cipariem līdz visiem 16 cipariem aiz komata *RMSE* vērtību izmaiņas ir nelielas. No viena līdz trim cipariem aiz komata vidējā *RMSE* vērtība svārstās starp 0,00164 un 0,0024. Ar četriem cipariem aiz komata tiek iegūta vidējā *RMSE* vērtība 0,00067.



3.2. att. *RMSE* vērtības atkarībā no apakšsignāla ciparu skaita aiz komata.

Otrajā eksperimentā tiek izmantota oriģinālā *VMD* metode, to lietojot katram *NDVI* laika rindas fragmentam, un uz testa datu kopām tiek iegūta vidējā *RMSE* vērtība 0,0011. Tādēļ, lai iegūtu augstāku *NDVI* laika rindu prognozēšanas precizitāti, aproksimētajām apakšsignālam tuvināti būtu jāiegūst vismaz četri pareizi cipari aiz komata, salīdzinot ar oriģinālo apakšsignālu, ko izejā dod modificēta *VMD* metode.

### 3.3. Apakšsignāla vērtību tuvinātā aprēķināšana

Lai varētu veikt *NDVI* laika rindu prognozēšanu, par atribūtiem izmantojot apakšsignāla vērtības, respektīvi, meklēt funkcionālo sakarību (1.2.), ir nepieciešams izstrādāt pieeju, kas ļauj tuvināti aprēķināt apakšsignāla vērtības jebkurā laika solī  $t$ . Šim nolūkam autors piedāvā

izmantojot lineāru vienādojumu sistēmu (*System of Linear Equations, LES*), risināšanu [55]. Lineāro vienādojumu sistēma var tikt pierakstīta matricu formā (3.3. vienād.):

$$Aw = b, \quad (3.3.)$$

kur  $A$  – koeficientu matrica ( $m \times n$ );  
 $b$  – brīvo locekļu vektors ( $m \times 1$ );  
 $w$  – mainīgo vektors ( $n \times 1$ );  
 $m$  – vienādojumu skaits;  
 $n$  – nezināmo skaits.

Lai iegūtu kvadrātisku koeficientu matricu  $A$ , var tikt izmantotas mašīnmācīšanās izmantotās kodola funkcijas (*kernel functions*). Kodola funkcija  $K$  nodrošina datu transformāciju no ievades telpas uz daudzu dimensiju atribūtu jeb pazīmju telpu [74]. Ja datu kopu, ko izmanto aproksimācijas algoritmā, veido apakšsignāls  $u$ , kura novērojumu skaits ir  $N$ , tad, padodot šo apakšsignālu kā vektoru lineārajai kodola funkcijai ar konstanti  $c = 0$  [25], tiek iegūta  $N \times N$  matrica (3.4. izteiksme):

$$K(u, u) = \begin{bmatrix} u(1)u(1) & u(1)u(2) & \dots & u(1)u(N) \\ u(2)u(1) & u(2)u(2) & \dots & u(2)u(N) \\ \dots & \dots & \dots & \dots \\ u(N)u(1) & u(N)u(2) & \dots & u(N)u(N) \end{bmatrix}. \quad (3.4.)$$

Atrisinot homogēno lineāro vienādojumu sistēmu [10] ar singulāro vērtību dekompozīcijas (*Singular Value Decomposition, SVD*) metodi, kur par koeficientu matricu tiek izmantota matrica (skat. 3.4.), tiek iegūta fundamentālu atrisinājumu sistēma  $x$ , kur šo lineāri neatkarīgo atrisinājumu kopu  $x$  apraksta matrica (3.5. izteiksme):

$$x = \begin{bmatrix} x_1(1) & x_1(2) & x_1(3) & \dots & x_1(N) \\ x_2(1) & x_2(2) & x_2(3) & \dots & x_2(N) \\ \dots & \dots & \dots & \dots & \dots \\ x_{N-1}(1) & x_{N-1}(2) & x_{N-1}(3) & \dots & x_{N-1}(N) \end{bmatrix}. \quad (3.5.)$$

Matricu (skat. 3.5.) veido  $N - 1$  lineāri neatkarīgi atrisinājumi un  $N$  mainīgie. Tagad var pārrakstīt lineārā kodola funkciju (skat. 3.4.) kā lineārā kodola funkciju, kas ieejā saņem datu kopu, kas sastāv no diviem vektoriem:  $NDVI$  laika rindas  $y$  ar  $N$  novērojumiem un apakšsignāla  $u$ , kā tas ir parādīts matricā (3.6. izteiksme):

$$K([yu], [yu]) = \begin{bmatrix} y(1)y(1) + u(1)u(1) & \dots & y(1)y(N) + u(1)u(N) \\ y(2)y(1) + u(2)u(1) & \dots & y(2)y(N) + u(2)u(N) \\ \dots & \dots & \dots \\ y(N)y(1) + u(N)u(1) & \dots & y(N)y(N) + u(N)u(N) \end{bmatrix}. \quad (3.6.)$$

Fundamentālu atrisinājumu sistēmā (3.5. izteiksme) ir par vienu atrisinājumu mazāk nekā nezināmo skaits. Ir nepieciešams iegūt vēl vienu vienādojumu – atrast pirmās nehomogēnās lineāro vienādojumu sistēmas partikulāru atrisinājumu  $w$ , kur kā koeficientu matrica  $A_1$  var tikt izmantota matrica (3.7. izteiksme):



$$A_1 = \begin{bmatrix} 1 & y(1)y(1)+u(1)u(1) & \dots & y(1)y(N-3)+u(1)u(N-3) & y(1) \\ 1 & y(2)y(1)+u(2)u(1) & \dots & y(2)y(N-3)+u(2)u(N-3) & y(2) \\ \dots & \dots & \dots & \dots & \dots \\ 1 & y(N)y(1)+u(N)u(1) & \dots & y(N)y(N-3)+u(N)u(N-3) & y(N) \end{bmatrix}. \quad (3.7.)$$

Matricas (skat. 3.7.) ar izmēriem  $N \times (N-1)$  pirmo atribūtu veido vieninieku vektors, bet, sākot no otrā atribūta līdz pirmspēdējam atribūtam, ir lineārās kodola funkcijas (skat. 3.6.) atbilstošie atribūti. Savukārt par atkarīgo parametru  $b$  tiek piedāvāts izmantot  $NDVI$  laika rindu  $y$ . Atrisinājums  $w$  tiek atrasts, izmantojot nelineāro mazāko kvadrātu metodi. Kā nelineārā funkcija tiek izmantota funkcija  $f$  (3.8. vienād.):

$$f = w(1) + \frac{\sqrt{S^2 + 1} - 1}{2} + S + yw(N); \quad (3.8.)$$

kur  $S$  – svērtā summa.

Svērtās summas elements laika solī  $t$  ir  $S(t)$ , kur  $t = 1, \dots, N$  (3.9. vienād.):

$$S(t) = w(2) + \sum_{i=2}^{N-2} A_1(t, i)w(j), j = 3, \dots, N-1. \quad (3.9.)$$

Pievienojot vektoru  $w$  pie fundamentālu atrisinājumu sistēmas, tiek iegūta koeficientu matrica  $A_2$  (3.10. izteiksme):

$$A_2 = \begin{bmatrix} x_1(1) & x_1(2) & \dots & x_1(N-2) & x_1(N-1) & x_1(N) \\ x_2(1) & x_2(2) & \dots & x_2(N-2) & x_2(N-1) & x_2(N) \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{N-1}(1) & x_{N-1}(2) & \dots & x_{N-1}(N-2) & x_{N-1}(N-1) & x_{N-1}(N) \\ w(3) & w(4) & \dots & 0 & 0 & 0 \end{bmatrix}. \quad (3.10.)$$

Brīvo locekļu vektors  $b_t$ , kas tiek izmantots otrajā nehomogēnajā lineāro vienādojumu sistēmā ( $LES$ ), attiecīgi arī sastāv no  $N$  elementiem. Vektora  $b_t(i)$  elementi laika solī  $t$ , kur  $i = 1, \dots, N-1$  tiek iegūti, izmantojot vienādojumu sistēmu (3.11. izteiksme):

$$b_t(i) = \begin{bmatrix} y(t)y(1)x_1(1) + y(t)y(2)x_1(2) + \dots + y(t)y(N)x_1(N) \\ y(t)y(1)x_2(1) + y(t)y(2)x_2(2) + \dots + y(t)y(N)x_2(N) \\ \dots \dots \dots \dots \dots \dots \dots \dots \\ y(t)y(1)x_{N-1}(1) + y(t)y(2)x_{N-1}(2) + \dots + y(t)y(N)x_{N-1}(N) \end{bmatrix}. \quad (3.11.)$$

Izmantojot partikulāro atrisinājumu  $w$  un brīvo locekļu vektoru  $b$ , var tikt tuvināti aprēķināta nezināmā svērtā summa  $\hat{S}$  (3.8. vienādojumā). Un vektora  $b_t(i)$  elements, kur  $i = N$ , tad tiek aprēķināts pēc vienādojuma (3.12. vienād.):

$$b_t(i) = \hat{S}(t) - w(2). \quad (3.12.)$$

Tādējādi katrā laika solī  $t$  atrisinot otro nehomogēno lineāro vienādojumu sistēmu ar koeficientu matricu  $A_2$  (3.10. izteiksme), un brīvo locekļu vektoru  $b_t$  (3.11. izteiksme) un (3.12. vienād.), izmantojot mazāko kvadrātu metodi, tiek iegūts otrās nehomogēnās lineāro vienādojumu sistēmas partikulārs atrisinājums  $w_t$ . Lai iegūtu apakšsignāla  $u$  tuvināto vērtību laika solī  $t$ , vispirms tiek izmantota izteiksme, kas ļauj iegūt  $N$  dažādas  $\hat{u}_i(t)$  vērtības, kur  $i = 1, \dots, N$  (3.13. izteiksme):

$$\hat{u}_i(t) = \frac{(w_t(i) - y(t)y(i))}{u(i)}. \quad (3.13.)$$

Un pa visiem  $i$  tiek aprēķināta vidējā vērtība (3.14. izteiksme):

$$\hat{u}(t) = \frac{\sum_{i=1}^N \hat{u}_i(t)}{N}. \quad (3.14.)$$

Iegūtais rezultāts (3.14. izteiksme) ir apakšsignāla  $u$  aproksimētā vērtība laika solī  $t$ . Atkarībā no otrajā nehomogēnajā lineāro vienādojumu sistēmā izmantotās koeficientu matricas  $A_2$  (skat. matricu (3.10.)) nosacītības skaitļa, iegūtās aproksimētās vērtības var būt ar dažādu precizitāti – ar dažādu ciparu skaitu, kas sakrīt ar oriģinālā apakšsignāla  $u$  cipariem. Izmantojot koeficientu matricas  $A_2$  nosacītības skaitli  $\text{cond}(A_2)$  var tikt aprēķināts aptuvenais ciparu skaits  $M$  (3.15. izteiksme), pa kādu samazinās precizitāte, iegūstot lineāro vienādojumu sistēmas atrisinājumu [100]:

$$M = \log_{10}(\text{cond}(A_2)). \quad (3.15.)$$

Otrs faktors, kas ietekmē aproksimētā apakšsignāla precizitāti, ir lineāro vienādojumu sistēmu atrisinājumu kļūdu lielumi. Šīs aproksimācijas pieejas izmantošanai tiek lietota četrkārtīga precizitāte (*quadruple precision*), kas aprēķinos izmanto 34 ciparus aiz komata.

## 4. PROGNOZĒŠANAS SISTĒMAS *NDVI FS* IZSTRĀDĀŠANA

Nodaļa veltīta *NDVI* laika rindu prognozēšanas sistēmas (*NDVI Forecasting System, NDVI FS*) izstrādāšanai. Prognozēšanas sistēma *NDVI FS* sastāv no lietotāja saskarnes, datu pirmapstrādes moduļa, mašīnmācīšanās moduļa un datu krātuves. Lietotāja saskarne atbild par pikseļa koordināšu ievadi, kā arī no modificētās *VMD* metodes iegūtā apakšsignāla aproksimācijas pieejas izvēli (izmantot vai neizmantot).

Uzsākot darbu, lietotājs, izmantojot atbilstošo saskarni, ievada sistēmā trīs nepieciešamo elementu vērtības:

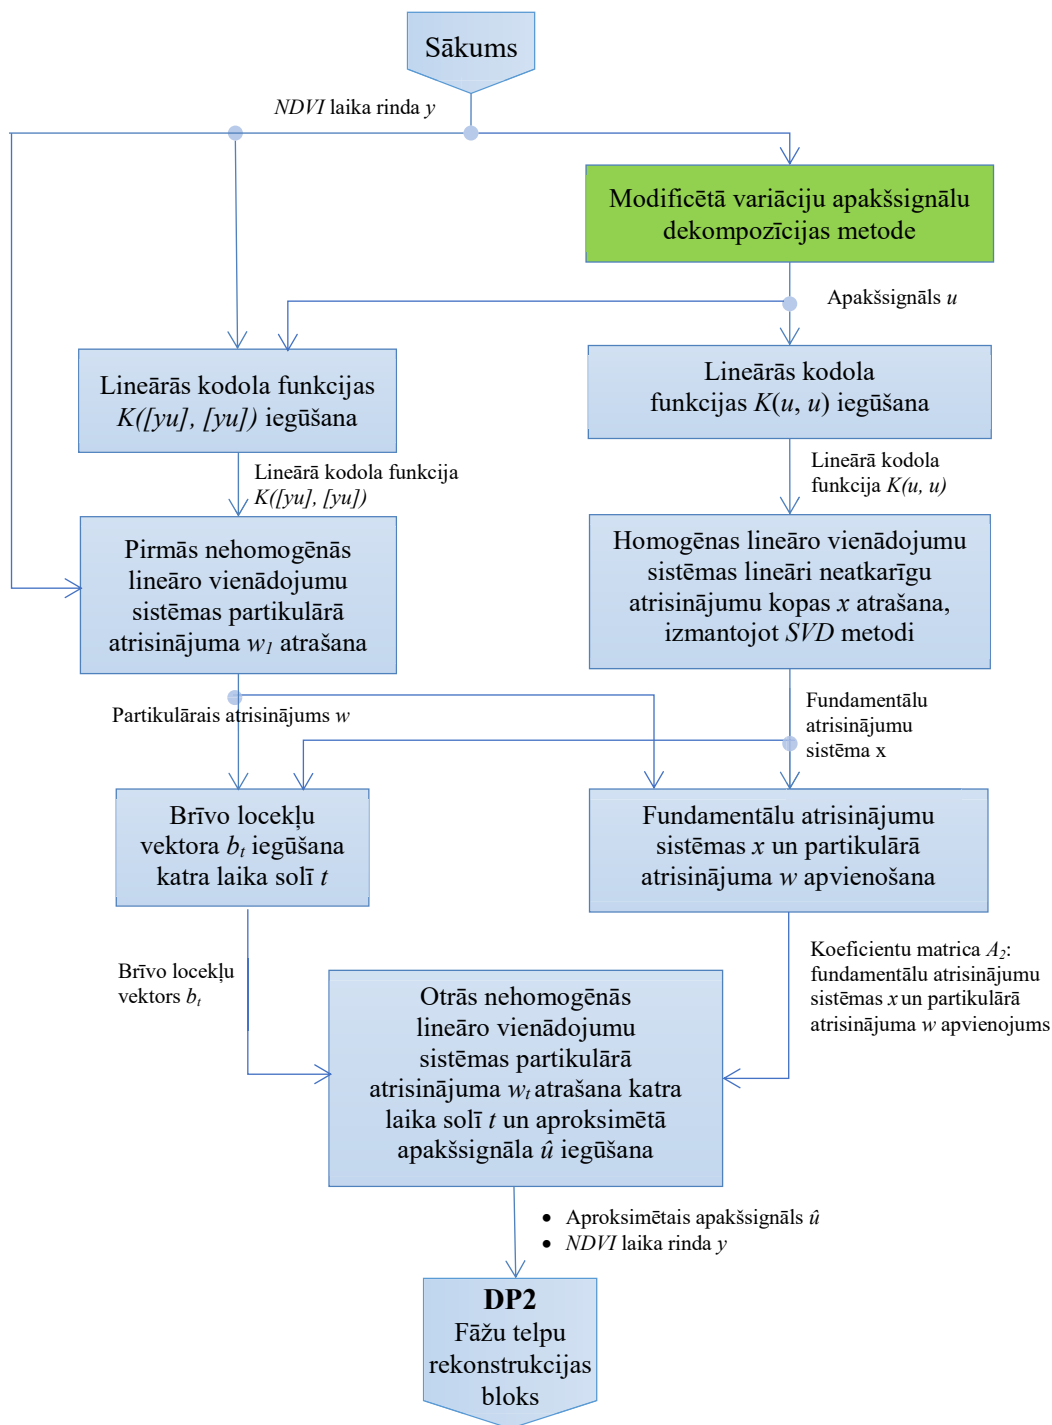
- koordināta *X* jeb ģeogrāfiskais garums *MODIS NDVI* attēlos atbilstoši šo attēlu koordinātu sistēmai;
- koordināta *Y* jeb ģeogrāfiskais platums *MODIS NDVI* attēlos atbilstoši šo attēlu koordinātu sistēmai;
- izvēles elementa vērtība (1: izmantot *VMD* apakšsignāla aproksimācijas pieeju, 0: neizmantot).

Datu pirmapstrādes modulī tiek veikta datu kopu izveidošana un to pirmapstrāde. Mašīnmācīšanās modulī tiek veikta prognozēšanas modeļa apmācība un *NDVI* laika rindas prognozēšana. Ja lietotāja izvēlētajai (atbilstoši ievadītājām pikseļa koordinātām) laika rindai nav pieejams prognozēšanas modelis un datu pirmapstrādes parametri datu krātuvē, tad konkrētajam pikselim tiek atlasītas visas pieejamās *NDVI* vēsturiskās vērtības, un tiek saglabātas ar komatiem atdalīto vērtību (*Comma-Separated Values, CSV*) datnē, iegūstot laika rindu. Šī laika rinda tiek padota datu pirmapstrādes modulim.

### 4.1. Datu pirmapstrādes modulis

Datu pirmapstrādes modulī blokā “DP1” tiek veikta *NDVI* laika rindas dekompozīcija, izmantojot modificēto variāciju apakšsignālu dekompozīcijas metodi un iegūtā apakšsignāla aproksimāciju, ja lietotājs to ir izvēlējis (skat. 4.1. attēlu).

- Abām laika rindām (vai tikai *NDVI* laika rindai, ja lietotājs nav izvēlējis apakšsignāla aproksimāciju) tiek rekonstruētas fāžu telpas blokā “DP2”, izmantojot laika aiztures metodi.
- Datu kopu izveidošanas blokā fāžu telpas tiek apvienotas (ja ir divas fāžu telpas), un tad sadalītas apmācības (70 % no ierakstiem), validācijas (15 % no ierakstiem) un testa (15 % no datu ierakstiem) datu kopās. Katra datu kopa tiek iedalīta atribūtu kopā un prognozējamajā parametrā.
- Blokā “DP3” no visām kopām tiek atlasīti informatīvākie atribūti, izmantojot pakāpenisko regresijas analīzi, un tiek iegūtas lineāri nekorelējošu atribūtu kopas, izmantojot principiālo komponentu analīzi.



4.1. att. Apakšsignāla aproksimācijas bloks “DP1”.

Tagad iegūtās pirmapstrādātas apmācības, validācijas un testa datu kopas ir datu pirmapstrādes moduļa izeja, kas tiek padota ieejā mašīnmācīšanās modulim. Visi nepieciešamie datu pirmapstrādes parametri: koeficientu matrica  $A_2$ ; partikulārais atrisinājums  $w$ ; informatīvāko atribūtu indeksi; atribūtu vidējās vērtības un īpašvektoru kopa  $M$  tiek saglabāti datu krātuvē, ar unikālo identifikatoru sasaistot tos ar konkrēto *NDVI* laika rindu.

## 4.2. Mašīnmācīšanās modulis

Mašīnmācīšanās moduli veido divas komponentes: apmācības bloks un prognozēšanas bloks. Ieejā modulis saņem pirmapstrādātas apmācības, validācijas un testa datu kopas no datu pirmapstrādes moduļa. Savukārt moduļa izejā ir iegūta prognoze, kas tiek izsniegta lietotājam.

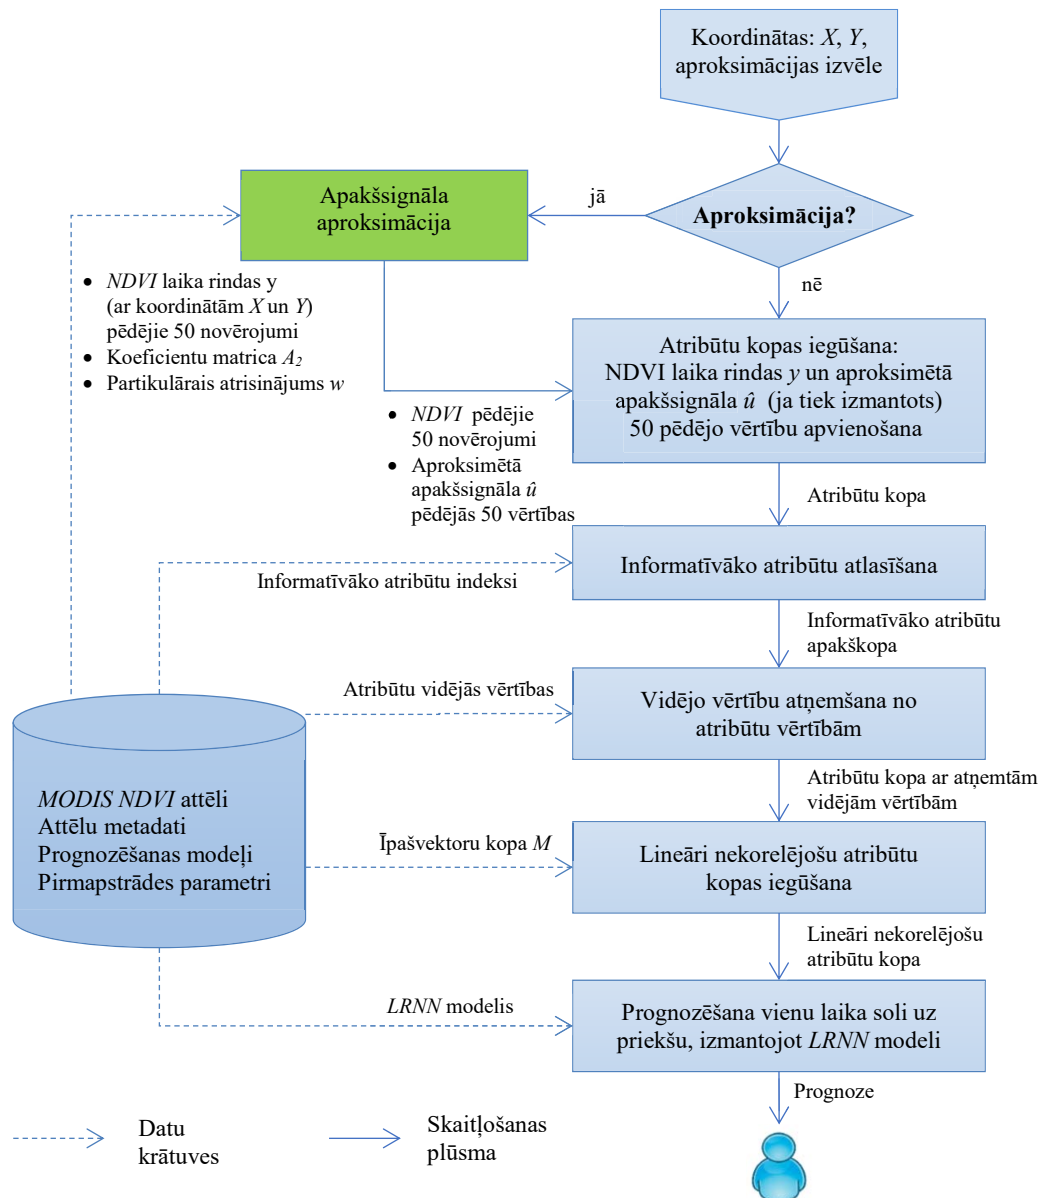
Apmācības blokā rekurento slāņu neironu tīkls (*LRNN*) veic apmācību uz apmācības datu kopas, novērtējot saknes vidējo kvadrātisko kļūdu (*RMSE*) vērtību uz validācijas datu kopas. Kā piemērotākais *LRNN* prognozēšanas modelis tiek izvēlēts tas, kuram tiek sasniegta mazākā zaudējumu funkcijas *RMSE* vērtība.

- Ar atrasto labāko prognozēšanas modeli tiek veikta īstermiņa prognozēšana uz apmācības, validācijas un testa datu kopu prognozējamā parametra, un tiek novērtētas zaudējumu funkciju *RMSE*, virzienu simetrijas (*DS*) un pielāgota determinācijas koeficienta  $R_{adj}^2$  vērtības uz katras no šīm kopām.
- Kad tiek atrasts piemērotākais *LRNN* prognozēšanas modelis, tad šī *LRNN* modeļa parametri (svari un konstantes) tiek saglabāti datu krātuvē, pēc unikāla identifikatora sasaistot tos ar iepriekš saglabātajiem datu pirmapstrādes parametriem, tādējādi iegūstot konkrētajai *NDVI* laika rindai piemērotāko prognozēšanas modeli un datu pirmapstrādes parametrus. Bloka izejā ir prognozēšanas modelis.
- Kad prognozēšanas modelis ir iegūts, to var izmantot *NDVI* laika rindas jaunu vērtību prognozēšanai, to veicot *NDVI* laika rindu prognozēšanas blokā (skat. 4.2. att.). Pēc noteikta laika perioda, kas *MODIS NDVI* attēlu gadījumā ir septiņas dienas, prognozēšanas process var tikt atkārtots.

Sistēmas *NDVI FS* praktiskā realizācija lietojumprogrammas veidā tiek veikta, izmantojot augsta līmeņa programmēšanas valodu *MATLAB*. Sistēma tiek realizēta, izmantojot savstarpēji saistītu *MATLAB* funkciju (gan iebūvēto, gan autora izstrādāto) kopumu un skriptu biznesa loģikas nodrošināšanai, rakstzīmju orientēto lietotāja saskarni un datu krātuvē. Skripts tiek izmantots, lai uzsāktu sistēmas darbu un noteiktā secībā izsauktu visas nepieciešamās funkcijas, sākot ar lietotāja parametru ievadīšanu. Datu krātuve tiek realizēta datu failu veidā, kas tiek glabāti lietotāja datu nesējā.

Sistēmas biznesa loģika ietver noteiktas *NDVI* laika rindas īstermiņa prognozes aprēķināšanu, izmantojot lietotāja ievadītos datus, datu krātuvē esošos *MODIS NDVI* attēlus, kā arī noteiktus algoritmus. Biznesa loģikas nodrošināšanai tiek izmantota virkne dažādu *MATLAB* funkciju, gan iebūvēto, gan autora izstrādāto. Izstrādātajā sistēmā *NDVI FS* visa datu pirmapstrāde, *LRNN* modeļa apmācība un laika rindas prognozēšana ir pilnībā automatizēta.

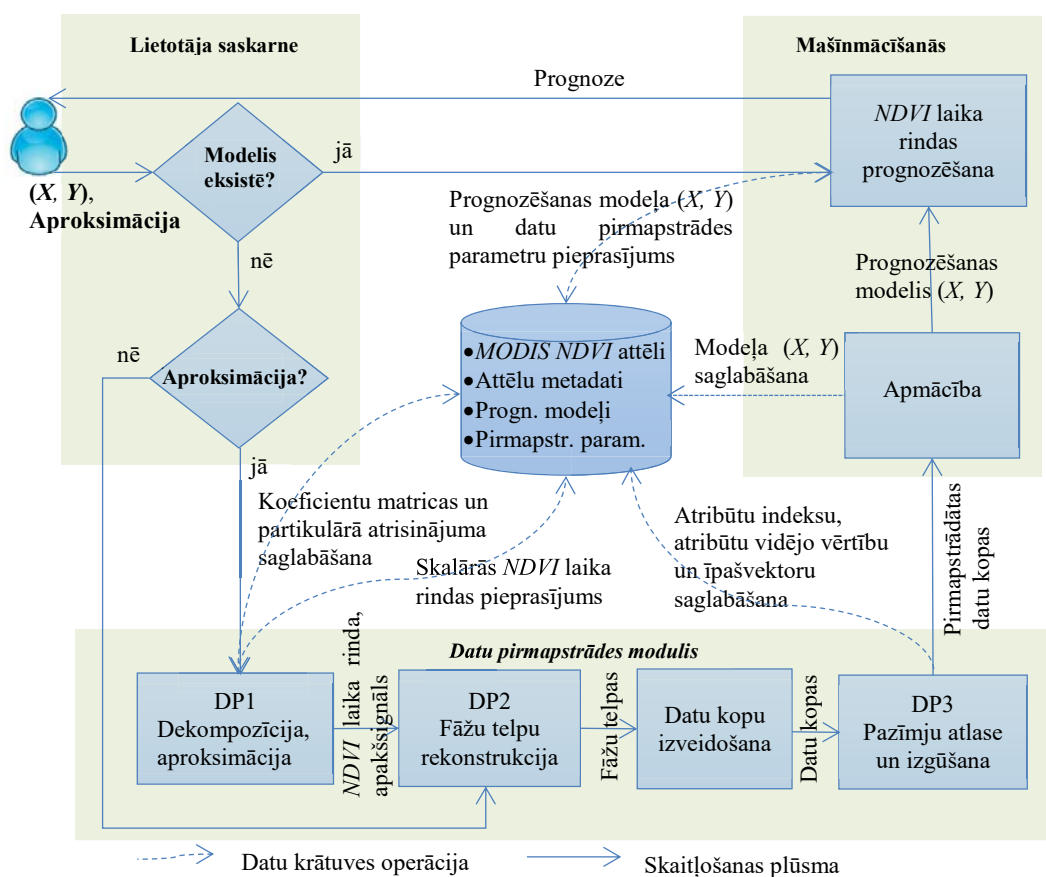
Apakšsignāla aproksimācijas pieejas izstrādāšana, datu pirmapstrādes parametru piemēroto vērtību meklēšana, kā arī rekurento slāņu neironu tīkla parametru piemēroto vērtību meklēšana tiek realizēta, izmantojot autora izstrādātas *MATLAB* funkcijas. Modificētās *VMD* metodes *vmd modified* koda izstrādāšana tiek veikta, par pamatu izmantojot oriģinālās *VMD* metodes *MATLAB* funkciju [119].



4.2. att. Prognozēšanas bloks.

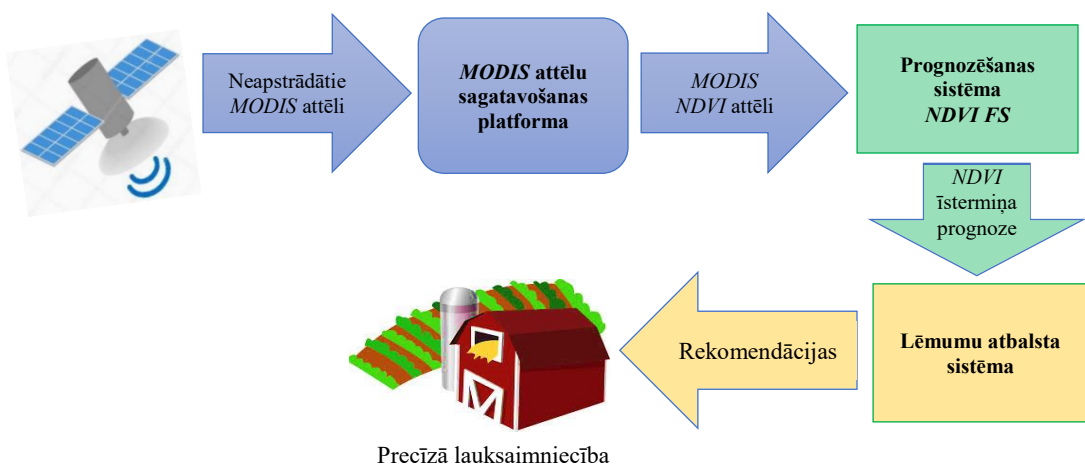
Darba autors apakšsignāla aproksimācijas pieejas funkcijas kodu izstrādā, izmantojot *MATLAB* iebūvētas funkcijas *null*, *lsqcurvefit* un *lsqlin*. Pakāpeniskās regresijas analīzes veikšanai tiek izmantota iebūvētā funkcija *stepwisefit*. Fāžu telpas rekonstrukcija ar laika aiztures metodi tiek realizēta ar funkcijas *phasespace* palīdzību [54]. *PCA* analīze tiek veikta, izmantojot *MATLAB* dimensiju skaita reducēšanas rīku [58]. Iebūvētā funkcija *layrecnet* tiek izmantota rekurento slāņu neironu tīkla (*LRNN*) modeļa apmācībai.

Prognozēšanas sistēmas *NDVI FS* arhitektūra, skaitļošanas plūsma un datu krātuves operācijas ir parādīta 4.3. attēlā. Sistēma ieejā saņem *MODIS NDVI* attēlus no kādas *MODIS* attēlu sagatavošanas platformas. Izejā sistēma *NDVI FS* izsniedz lietotāja (piemēram, lauksaimnieka) izvēlētās *NDVI* laika rindas īstermiņa prognozi.



4.3. att. NDVI laika rindu prognozēšanas sistēma NDVI FS.

Tādējādi izstrādātā prognozēšanas sistēma NDVI FS ir tas posms precīzajā lauksaimniecībā, kas nodrošina ieejas datus lēmumu atbalsta sistēmai (skat. 4.4. attēlu).



4.4. att. Izstrādātā sistēma NDVI FS precīzajā lauksaimniecībā.

Uz NDVI indeksa prognozes pamata lēmumu atbalsta sistēma pieņem noteiktus lēmumus un izsniedz rekomendācijas lauksaimniekiem.

## 5. IZSTRĀDĀTĀS PROGNOZĒŠANAS SISTĒMAS PRECIZITĀTES NOVĒRTĒŠANA

Nodaļa veltīta eksperimentiem ar izstrādāto prognozēšanas sistēmu *NDVI FS*. Tiek novērtēta sistēma ar aproksimācijas pieejas izmantošanu un bez šīs pieejas izmantošanas, kā arī sistēmas precizitāte tiek salīdzināta ar citu metožu precizitāti. Katrs eksperiments tiek atkārtots 100 reižu, katru reizi ņemot citu *NDVI* laika rindu.

### 5.1. *NDVI* prognozēšana ar klasiskām metodēm

Tiek veikti trīs eksperimenti, kuros tiek izmantotas klasiskās prognozēšanas metodes. Viena eksperimenta mērķis ir izpētīt vienkāršā slīdošā vidējā precizitāti *NDVI* laika rindu prognozēšanas uzdevumā. Eksperimentā *NDVI* laika rindai tiek rekonstruēta fāžu telpa ar dažādiem dimensijas  $m$  lielumiem. Fāžu telpas dimensija  $m$  tiek meklēta intervālā [1; 50], laika aizture  $\tau = 1$ . Par piemēroto dimensiju  $m$  un attiecīgi par vienkāršā slīdošā vidējā periodu tiek uzskatīta tā vērtība, pie kuras tiek sasniegta minimālā zaudējumu funkcijas *RMSE* vērtība.

Nākamā eksperimenta mērķis ir izpētīt nepārtrauktu stāvokļu kopas Markova ķēžu precizitāti *NDVI* laika rindu prognozēšanas uzdevumā. Darba autors eksperimentu ar diskrētā laika, diskrētās stāvokļu kopas Markova ķēžu izmantošanu *NDVI* laika rindu prognozēšanā ir aprakstījis pētījumā [91], bet  $m$ -tās kārtas diskrētā laika, nepārtrauktu stāvokļu kopas Markova ķēžu izmantošana *NDVI* laika rindu prognozēšanā ir aprakstīta darba autora pētījumā [93]. Eksperimentā tiek izmantota nepārtrauktu stāvokļu kopas Markova ķēdes ar atmiņu  $m$ . Tiek izmantota  $m$ -tās kārtas Markova ķēde, tāpēc pēdējie  $m$  stāvokļi jeb pēdējie  $m$  laika rindas novērojumi tiek izmantoti, lai prognozētu nākamo stāvokli. Šī Markova ķēdes  $m$  stāvokļu kombinācija izveido vektoru, kas formāli ir identisks stāvokļa vektoram rekonstruētajā fāžu telpā.

Lai prognozētu nākamo laika rindas vērtību starp pēdējo aiztures vektoru fāžu telpā un visiem pārējiem aiztures vektoriem, tiek aprēķināta Eiklīda distance. Tiem aiztures vektoriem, ar kuriem Eiklīda distance ir pietiekami maza, tiek paņemtas nākamās laika rindas vērtības, kas seko aiz šī vektora, un prognoze tiek iegūta kā visu šo nākamo vērtību vidējā vērtība.

Pēdējā eksperimenta mērķis ir izpētīt automatiski regresējoša integrētā slīdošā vidējā (*ARIMA*) metodes precizitāti *NDVI* laika rindu prognozēšanas uzdevumā. Eksperimentā, izmantojot *NDVI* laika rindas datus, tiek apmācīti *ARIMA*( $p, d, q$ ) modeļi, kur  $p$  ir autoregresīvā polinoma kārtā,  $d$  – diferencu operatora kārtā,  $q$  – slīdošā vidējā polinoma kārtā. Tiek izveidoti modeļi ar dažādām  $p$ ,  $d$  un  $q$  vērtībām. Par piemērotām tiek izvēlētas tās  $p$ ,  $d$  un  $q$  vērtības, pie kurām *RMSE* vērtība starp prognozētajām un novērotajām testa datu kopas vērtībām ir minimāla.

### 5.2. Eksperimentu ar prognozēšanas sistēmu *NDVI FS* raksturojums

Izstrādātās prognozēšanas sistēmas *NDVI FS* precizitātes novērtēšanai tiek veikti divi eksperimenti. Darba autors eksperimentu ar Elmana rekurento neironu tīklu izmantošanu



*NDVI* laika rindu prognozēšanai ir aprakstījis pētījumā [92], eksperiments ar *LRNN* izmantošanu *NDVI* laika rindu prognozēšanai ir aprakstīts autora pētījumā [87], bet prognozēšanas sistēmas, kura neizmanto uz *VMD* balstīto aproksimācijas pieeju, pielietošana *NDVI* laika rindu prognozēšanai ir aprakstīta autora pētījumos [88], [94].

Viena eksperimenta mērķis ir izpētīt *NDVI* prognozēšanas sistēmas precizitāti *NDVI* laika rindu prognozēšanas uzdevumā, neizmantojot no modificētās *VMD* metodes iegūtā apakšsignāla aproksimācijas pieeju. Eksperiments tiek atkārtots 100 reižu.

- Normalizēta veģetācijas indeksa laika rindai tiek iegūta fāžu telpa ar dimensiju  $m = 50$  un laika aizturi  $\tau = 1$ , un tādējādi tiek iegūta datu kopa, kas tiek iedalīta divās daļās: atribūtu kopā un prognozējamajā parametrā. Gan atribūtu kopa, gan prognozējamais parametrs tiek iedalīti trīs daļās, iegūstot apmācības, validācijas un testa datu kopas.
- No katras atribūtu kopas tiek atlasīti informatīvākie atribūti, izmantojot pakāpenisko regresijas analīzi, un, izmantojot principiālo komponentu analīzi, tiek iegūtas lineāri nekorelējošu atribūtu kopas.
- Pirmapstrādātas apmācības un validācijas datu kopas tiek padotas ieejā rekurento slāņu neironu tīklam, kas veic apmācību un iegūst prognozēšanas modeli.

Nākamā eksperimenta mērķis ir izpētīt *NDVI* prognozēšanas sistēmas precizitāti *NDVI* laika rindu prognozēšanas uzdevumā, izmantojot no modificētās *VMD* metodes iegūtā apakšsignāla aproksimācijas pieeju.

- Izmantojot izstrādāto variāciju apakšsignālu dekompozīcijas (*VMD*) metodes modifikāciju, tiek iegūts normalizēta veģetācijas indeksa laika rindas apakšsignāls, kas tiek tuvināti aprēķināts ar izstrādāto apakšsignāla aproksimācijas pieeju. Apakšsignālam tiek rekonstruēta fāžu telpa ar  $m = 50$  un laika aizturi  $\tau = 1$ , tāpat arī *NDVI* laika rindai tiek rekonstruēta fāžu telpa ar šiem pašiem parametriem.
- Fāžu telpas tiek apvienotas, iegūstot datu kopu, kas tiek iedalīta divās daļās: atribūtu kopā un prognozējamajā parametrā. Atribūtu kopa un prognozējamais parametrs tiek iedalīti trīs daļās, iegūstot apmācības, validācijas un testa datu kopas.
- No visām atribūtu kopām tiek atlasīti informatīvākie atribūti, izmantojot pakāpenisko regresijas analīzi, un, izmantojot principiālo komponentu analīzi, tiek iegūtas lineāri nekorelējošu atribūtu kopas.
- Pirmapstrādātas apmācības un validācijas datu kopas saņem ieejā rekurento slāņu neironu tīkls, kas veic apmācību uz šiem datiem, iegūstot prognozēšanas modeli.

Piecos eksperimentos iegūtās triju zaudējumu funkciju – saknes vidējās kvadrātiskās kļūdas *RMSE*; virzienu simetrijas *DS* un pielāgotā determinācijas koeficienta  $R_{adj}^2$  – vidējās vērtības uz testa datu kopām dotas 5.1. tabulā. Prognozēšanas metodes un sistēmas 5.1. tabulā ir sakārtotas proporcionāli vidējo *RMSE* vērtību kritumam jeb prognozēšanas precizitātes pieaugumam.

Zaudējumu funkciju vidējas vērtības

Prognozēšanas metode vai sistēma	<i>RMSE</i>	<i>DS</i>	$R_{adj}^2$
Vienkāršais slidošais vidējais	0,0442	93,40 %	0,94
Diskrētā laika, nepārtrauktu stāvokļu kopas <i>m</i> -tās kārtas Markova ķēde	0,0214	83,76 %	0,90
Automātiski regresējošs integrēts slidošais vidējais	0,0108	93,85 %	0,96
Izstrādātā <i>NDVI FS</i> bez aproksimācijas pieejas	0,0012	97,28 %	<b>0,99</b>
Izstrādātā <i>NDVI FS</i> ar aproksimācijas pieeju	<b>0,0009</b>	<b>98,80 %</b>	<b>0,99</b>

No 5.1. tabulas tabulas tiek secināts, ka augstāko prognozēšanas precizitāti uzrāda izstrādātā *NDVI FS*, izmantojot no modificētās variāciju apakšsignālu dekompozīcijas metodes iegūtā apakšsignāla aproksimācijas pieeju ( $RMSE = 0,0009$ ,  $DS = 98,90\%$  un pielāgotais  $R_{adj}^2 = 0,99$ ).

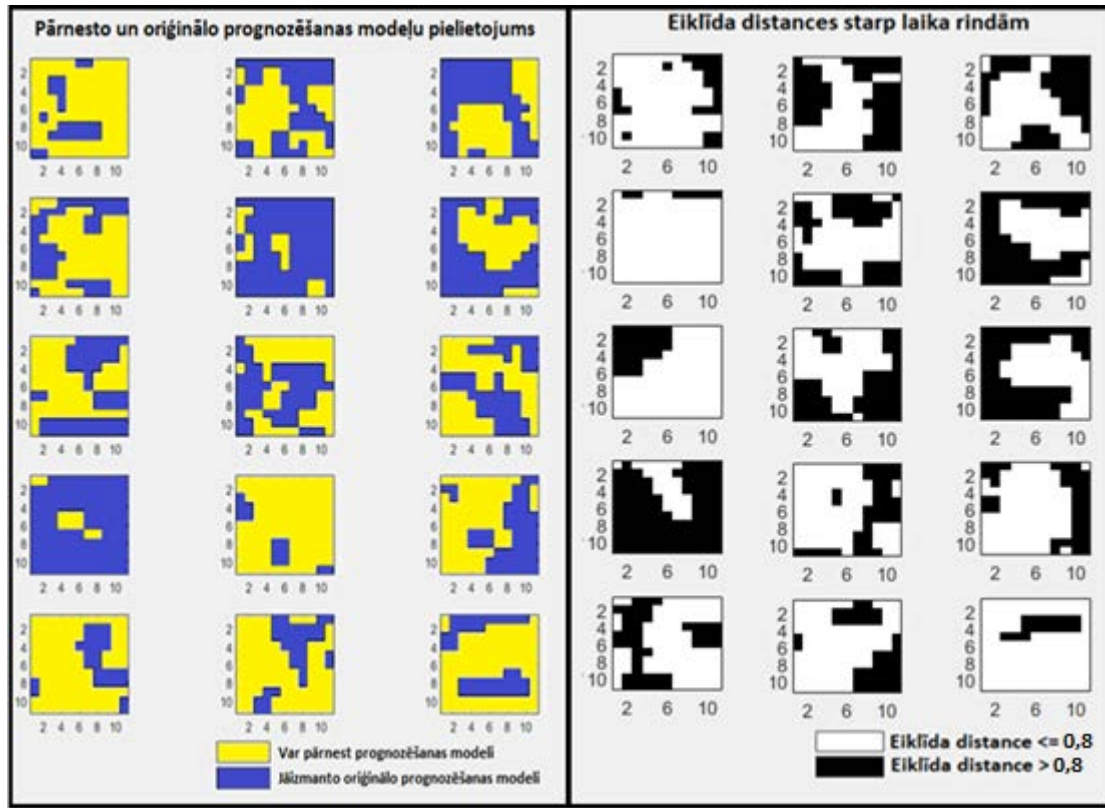
### 5.3. Datu pirmapstrādes parametru un prognozēšanas modeļu pārņemšana

Ar datu pirmapstrādes parametru un modeļu pārņemšanu tiek veikti divi eksperimenti. Viena eksperimenta mērķis ir izpētīt prognozēšanas modeļu pārņemšanu uz kaimiņu pikseļu *NDVI* laika rindām, veicot to prognozēšanu bez jaunas apmācības un neizmantojot apakšsignāla aproksimācijas pieeju.

- Kad uz nejauši izvēlētas *NDVI* laika rindas ir veikta datu pirmapstrāde un apmācība, izmantojot izstrādāto *NDVI FS* bez aproksimācijas pieejas, tiek saglabāti visi nepieciešamie parametri un modelis.
- Ap šai *NDVI* laika rindai atbilstošo pikseli satelītattēlā tiek novilkts režģis ar rādiusu  $r = 5$ . Tādējādi apkārt izvēlētas *NDVI* laika rindas atbilstošajam pikselim tiek novilkts  $11 \times 11$  pikseļu liels režģis, kurā bez centrālā pikseļa vēl ir 120 pikseļu.
- Katram no šiem kaimiņu pikseļiem tiek iegūtas 120 *NDVI* laika rindas, un katra no šīm laika rindām vispirms tiek pirmapstrādāta un prognozēta, izmantojot no apmācībā izmantotās laika rindas iegūtos datu pirmapstrādes parametrus un prognozēšanas modeli, un tiek aprēķinātas *RMSE* vērtības.
- Tad uz katras no šīm laika rindām tiek individuāli iegūti datu pirmapstrādes parametri un prognozēšanas modelis, tiek iegūtas prognozes un aprēķinātas *RMSE* vērtības.

Katrai laika rindai tiek salīdzinātas abas *RMSE* vērtības. Eksperiments tiek atkārtots 100 reižu, katru reizi prognozējot 120 laika rindas. Pirmajos 15 eksperimentos iegūtie rezultāti redzami 5.1. attēlā. Kā redzams 5.1. attēla kreisajā pusē, tiek iegūts binārais attēls, kur ar dzeltenu krāsu (vērtība viens) ir attēloti tie pikseļi, kur var izmantot pārnestos datu pirmapstrādes parametrus un prognozēšanas modeli uz konkrētā pikseļa laika rindas. Ar zilo

krāsu (vērtība nulle) tiek attēloti tie pikseļi, kur ir jāizmanto uz šīs laika rindas individuāli iegūtos datu pirmapstrādes parametrus un oriģinālo prognozēšanas modeli.



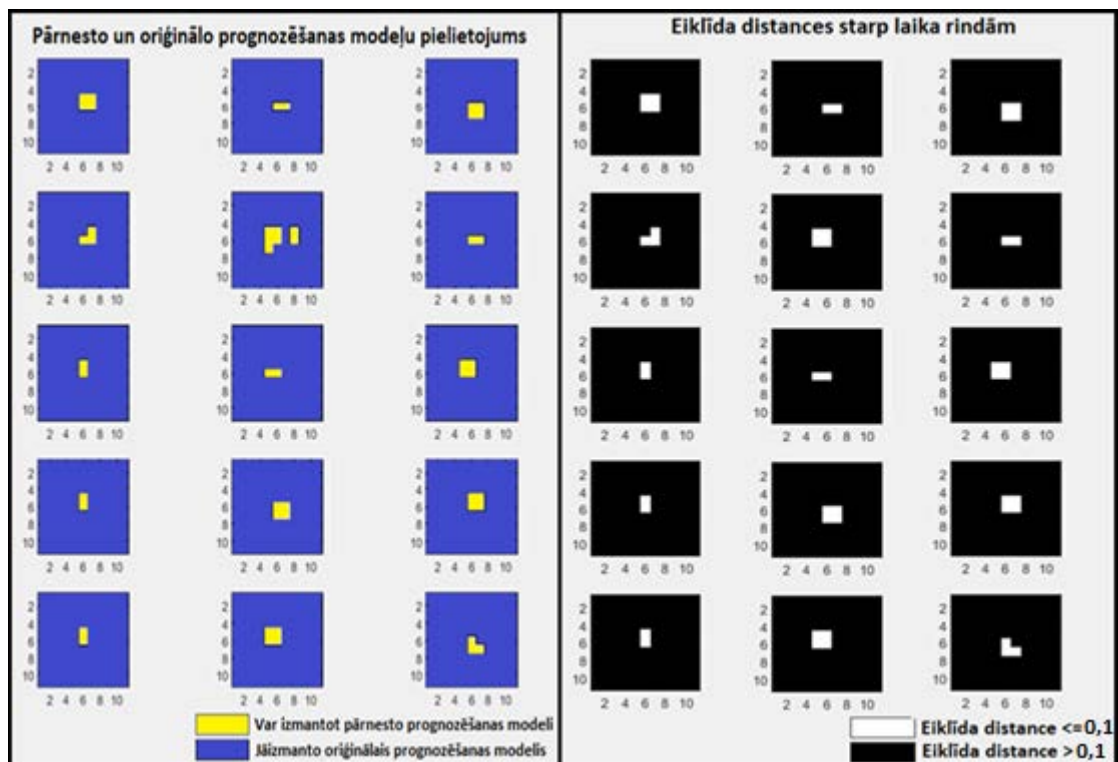
5.1. att. Prognozēšanas modeļa lietojums bez aproksimācijas pieejas.

Savukārt 5.1. attēla labajā pusē ir dotas Eiklīda distances ar sliekšni 0,8. Eiklīda distances ir aprēķinātas starp centrālo laika rindu un visām pārējām laika rindām. Analizējot 5.1. attēlu, tiek secināts, ka pārnesot pirmapstrādes parametrus un prognozēšanas modeli un veicot prognozēšanu, var iegūt līdzvērtīgu *RMSE* vērtību, ja starp apmācībā izmantoto laika rindu un laika rindu, kur tiek lietoti pārņestie parametri un modeļi, Eiklīda distance ir mazāka vai vienāda ar sliekšņa vērtību 0,8.

Nākamā eksperimenta mērķis ir izpētīt prognozēšanas modeļu pārņemšanu uz kaimiņu pikseļu *NDVI* laika rindām, veicot to prognozēšanu bez jaunas apmācības un izmantojot apakšsignāla aproksimācijas pieeju.

- Satelītattēlā tiek novilkts  $11 \times 11$  pikseļu režģis (kopā 121 pikselis), kur centrālais pikselis ir tas, uz kura *NDVI* laika rindas tiek veikta pirmapstrāde un apmācība.
- Katra no 120 laika rindām tiek pirmapstrādāta un prognozēta, vispirms izmantojot pārņestos parametrus un modeļus, kas iegūti uz centrālā pikseļa *NDVI* laika rindas, un tad, izmantojot individuāli uz katras laika rindas iegūtos parametrus un modeļus, abos gadījumos novērtējot iegūtās *RMSE* vērtības starp novēroto un prognozēto *NDVI* laika rindu.

Eksperiments tiek atkārtots 100 reizi, katru reizi prognozējot 120 laika rindas. Eksperimenta rezultāti pirmajiem 15 gadījumiem redzami 5.2. attēlā.



5.2. att. Prognozēšanas modeļa lietojums ar aproksimācijas pieeju.

Arī 5.2. attēla kreisajā pusē ir binārais attēls, kur ar dzelteni krāsu atzīmēti tie pikseļi, kur var pārņest datu pirmapstrādes parametrus un prognozēšanas modeli, ar zilo krāsu parādīti tie pikseļi, kur to izdarīt nevar. Savukārt 5.2. attēla labajā pusē ir Eiklīda distancu binārais attēls ar sliekšni 0,1, kur Eiklīda distancēs aprēķinātas starp centrālo laika rindu un visām citām laika rindām. Analizējot 5.2. attēlu, tiek secināts, ka pirmapstrādes parametrus un prognozēšanas modeli, kas iegūti uz centrālā pikseļa normalizēta veģētācijas indeksa laika rindas, var izmantot citu *NDVI* laika rindu prognozēšanai ar līdzvērtīgu *RMSE* vērtību, ja starp apmācībā izmantoto laika rindu un laika rindu, kur tiek lietoti pārņestie parametri un modeļi, Eiklīda distance ir mazāka vai vienāda ar sliekšņa vērtību 0,1.

## REZULTĀTI UN SECINĀJUMI

Promocijas darbā ir izstrādāta NDVI indeksa laika rindu prognozēšanas sistēma NDVI FS, kas nodrošina īstermiņa veģetācijas izmaiņu dinamikas prognozes, kas ir vitāli svarīgas precīzajā lauksaimniecībā. Izstrādātā prognozēšanas sistēma tiek novērtēta, izmantojot autora piedāvāto aproksimācijas pieeju, un bez šīs pieejas, lai pārbaudītu pirmo izvirzīto hipotēzi. Lai pārbaudītu otro izvirzīto hipotēzi, tika veikti modeļu pārnesšanas eksperimenti, uz vienas NDVI laika rindas iegūtos parametrus un modeli izmantojot citu pikseļu NDVI laika rindu prognozēšanai. Atrisinot promocijas darbā izvirzītos uzdevumus, iegūtie galvenie rezultāti ir šādi.

1. Veikta zinātniskās literatūras analīze par normalizēta veģetācijas indeksa laika rindu prognozēšanu. Definētas prasības un pamatota prognozēšanas metodes izvēle izstrādājamajai sistēmai.
2. Veikta zinātniskās literatūras analīze par laika rindu prognozēšanu, izmantojot dažādas signālu dekompozīcijas metodes, ko lieto frekvenču analīzei. Pamatota dekompozīcijas metodes izvēle NDVI laika rindu prognozēšanas uzdevumā un no tās iegūto apakšsignālu aproksimācijas nepieciešamība.
3. Izstrādāta no modificētās variāciju apakšsignālu dekompozīcijas metodes iegūtā apakšsignāla aproksimācijas pieeja, kas ļauj iegūt tuvinātas apakšsignāla vērtības visiem tiem laika soļiem, kuriem ir pieejami vēsturiskie normalizēta veģetācijas indeksa novērojumi.
4. Izstrādāta normalizēta veģetācijas indeksa laika rindu prognozēšanas sistēma, kas balstās uz specializētu metožu un pieeju kopumu. Tas ļauj paaugstināt prognozēšanas precizitāti, neizmantojot papildu ieejas datus, piemēram, gaisa temperatūras, nokrišņu daudzuma un zemes virsmas kategoriju datus, kā arī citus veģetācijas indeksus. Viss sistēmā implementētais datu pirmapstrādes process, LRNN modeļa apmācība un laika rindas prognozēšana ir pilnībā automatizēta.
5. Veikta izstrādātās sistēmas NDVI FS novērtēšana, tās precizitāte, gan izmantojot, gan neizmantojot apakšsignāla aproksimācijas pieeju, ir salīdzināta ar vienkāršā slīdošā vidējā, diskrētā laika, nepārtrauktu stāvokļu kopas *m-tās* kārtas Markova ķēžu un automātiski regresējoša integrētā slīdošā vidējā sasniegto precizitāti NDVI laika rindu prognozēšanā.
6. Izstrādāta pieeja apmācīta prognozēšanas modeļa un atbilstošo datu pirmsapstrādes parametru pārnesšanai uz teritoriju, kur nav pieejami prognozēšanas modeļi. Iegūtā prognozēšanas precizitāte daudzos gadījumos ir līdzvērtīga ar rezultātiem, ko sniedz uz konkrētās normalizēta veģetācijas indeksa laika rindas datiem apmācītais prognozēšanas modelis.

Promocijas darba izstrādāšanas gaitā ir iegūti šādi **secinājumi**.

1. Normalizēta veģetācijas indeksa laika rindu prognozēšanas pētījumos nepietiekami tiek izmantotas datu pirmapstrādes metodes, kas bieži vien neļauj sasniegt augstu prognozēšanas precizitāti.

2. Izstrādātā prognozēšanas sistēma veic normalizēta veģetācijas indeksa laika rindas jaunās vērtības īstermiņa prognozi, ieejā izmantojot tikai *NDVI* vēsturiskās vērtības.
3. Izstrādātā pieeja aproksimē no variāciju apakšsignālu dekompozīcijas metodes iegūto apakšsignālu jebkurā laika solī, kur ir pieejamas vēsturiskās normalizēta veģetācijas indeksa laika rindas vērtības, un tas ļauj izmantot šo tuvināti aprēķināto apakšsignālu jaunu *NDVI* laika rindas vērtību prognozēšanai.
4. Aproksimētā apakšsignāla precizitāte ir atkarīga gan no otrās nehomogēnās lineāro vienādojumu sistēmas koeficientu matricas nosacītības skaitļa lieluma, gan no lineāro vienādojumu sistēmu atrisinājumu kļūdas lieluma.
5. Prognozēšanas precizitāte, izmantojot izstrādāto sistēmu un autora piedāvāto apakšsignāla aproksimācijas pieeju, ir augstāka nekā, neizmantojot šo pieeju, kas apstiprina darbā izvirzīto pirmo hipotēzi.
6. Prognozēšanas sistēmas *NDVI FS* sasniegtā normalizēta veģetācijas indeksa laika rindu prognozēšanas precizitāte, gan izmantojot, gan neizmantojot autora piedāvāto aproksimācijas pieeju, ir augstāka nekā precizitāte, kas ir sasniegta, prognozējot *NDVI* laika rindas ar vienkāršo slīdošo vidējo, diskrētā laika, nepārtrauktu stāvokļu kopas  $m$ -tās kārtas Markova ķēdēm un automātiski regresējošo integrēto slīdošo vidējo.
7. Izmantojot prognozēšanas sistēmu *NDVI FS* un veicot apmācību uz kādas *NDVI* laika rindas, var tikt iegūti datu pirmapstrādes parametri un prognozēšanas modelis, ko var izmantot citas *NDVI* laika rindas prognozēšanai ar līdzvērtīgu precizitāti, salīdzinot ar precizitāti, ko var sasniegt, prognozējot šo laika rindu ar individuāli iegūtiem datu pirmapstrādes parametriem un prognozēšanas modeli, ja Eiklīda distance starp šīm abām laika rindām ir mazāka vai vienāda ar kādu noteiktu sliekšni. Tas apstiprina darbā izvirzīto otro hipotēzi.
8. Izstrādātā sistēma *NDVI FS* bez aproksimācijas pieejas izmantošanas var tikt lietota, ja nepieciešams prognozēt normalizēta veģetācijas indeksa laika rindu vērtības lielam zemes virsmas apgabalam salīdzinoši īsā laika posmā, kur ir pieļaujama neliela prognozēšanas precizitātes samazināšanās.
9. Izstrādātā sistēma *NDVI FS* ar aproksimācijas pieejas izmantošanu var tikt lietota, ja nepieciešamas normalizēta veģetācijas indeksa laika rindu prognozes ar augstāku precizitāti, bet salīdzinoši nelieliem zemes virsmas apgabaliem.

Turpmākie pētījumi ir saistīti ar datu pirmapstrādes parametru un prognozēšanas modeļu pārvešanas pieejas attīstīšanu, definējot stingrākus pārvešanas nosacījumus un uzlabojot aproksimācijas pieeju.

## IZMANTOTĀS LITERATŪRAS SARAKSTS

1. Adhikari, R., Agrawal, R. K. *An Introductory Study on Time series Modeling and Forecasting*. Germany: LAP Lambert Academic Publishing, 2013. 76 pp.
2. ADVANPIX. *Multiprecision Computing Toolbox* [online]. [viewed 2 March 2019]. Available from: <https://www.advanpix.com/>.
3. Ahmed, D., Elkettan, Y., Kasem, A. Application of Statistical Methods of Time-Series for Estimating and Forecasting the Wheat Series in Yemen (Production and Import). *American J. Applied Mathematics*. 2016, vol. 4, no. 3, pp. 124–131.
4. Allisy-Roberts, P., Williams, J. *Farr's Physics for Medical Imaging*. 2<sup>nd</sup> ed. Saunders Ltd, 2007. 216 p.
5. Asoka, A., Mishra, V. Prediction of Vegetation Anomalies to Improve Food Security and Water Management in India. *Geophysical Research Letters*. 2015, vol. 42, no. 13, pp. 5290–5298.
6. Atsalakis, G. S., Skiadas, C. H., Nezis, D. Forecasting Chaotic Time Series by a Neural Network. In: *Proc. of the 1<sup>st</sup> Chaotic Modeling and Simulation Intern. Conf., June 3–6, 2008, Chania, Greece*. Chania: CRC Press, 2008, pp. 77–82.
7. Badamasi, M. M., Yelwa, S. A., AbdulRahim, M. A., Noma, S. S. NDVI Threshold Classification and Change Detection of Vegetation Cover at the Falgore Game Reserve in Kano State, Nigeria. *Sokoto J. of the Social Sciences*. 2015, vol. 2, no. 2, pp. 174–194.
8. Bell, A. A., Seiler, C., Kaftan, J. N., Aach, T. Noise in High Dynamic Range Imaging. In: *Proc. of 15<sup>th</sup> IEEE Intern. Conf. on Image Processing*, October 12–15, 2008, San Diego, USA. IEEE, 2008, pp. 561–564.
9. Bortolot, Z. J., Wynne, R. H. Estimating Forest Biomass Using Small Footprint LiDAR Data: An Individual Tree-Based Approach That Incorporates Training Data. *ISPRS J. of Photogrammetry and Remote Sensing*. 2005, vol. 59, no. 6, pp. 342–360.
10. Bronson, R., Costa, G. B. *Linear Algebra: An Introduction*. 2<sup>nd</sup> ed. USA: Academic Press, 2007. 520 p.
11. Chakrabarti, G., Sen, C. *Anatomy of Global Stock Market Crashes*. Springer India, 2012. 62 p.
12. Choi, G., Oh, H. S., Kim, D. Enhancement of Variational Mode Decomposition with Missing Values. *Signal Processing*. 2018, vol. 142, pp. 75–86.
13. Clements, N., Sarkar, S., Wei, W. Multiplicative Spatio-Temporal Models For Remotely Sensed Normalized Difference Vegetation Index Data. *J. of International Energy Policy*. 2014, vol. 3, no. 1, pp. 1–14.
14. Coulibaly, P., Baldwin, C. K. Nonstationary Hydrological Time Series Forecasting Using Nonlinear Dynamic Methods. *J. of Hydrology*. 2005, vol. 307, no. 1, pp. 164–174.
15. Crone, S. F. Prediction of White Noise Time Series Using Artificial Neural Networks and Asymmetric Cost Functions. In: *Proc. of the Intern. Joint Conf. on Neural Networks*, July 20–24, 2003, Portland, USA. IEEE, 2003, 3582 p.
16. Draper, N. R., Smith, H. *Applied Regression Analysis*. 3<sup>rd</sup> ed. Hoboken, New Jersey: Wiley, 1998. 736 p.

17. Du, R., Yang, H. An Improved Weighted Moving Average Methods Based on Transferring Weights for an Analytical Process Data. *The Open Automation and Control Systems Journal*. 2014, vol. 6, pp. 1886–1890.
18. El-Sharkh, M. Y., Rahman, M. A. Forecasting Electricity Demand Using Dynamic Artificial Neural Network Model. In: *Proc. of the 2012 Intern. Conf. on Industrial Engineering and Operations Management, July 3–6, 2012, Istanbul, Turkey*. 2012, pp. 1691–1694.
19. Elman, J. L. Finding Structure in Time. *Cognitive Science*. 1990, vol. 14, no. 2, pp. 179–211.
20. Elsner, J. B. Predicting Time Series Using a Neural Network as a Method of Distinguishing Chaos from Noise. *J. of Physics A: Mathematical and General*. 1999, vol. 25, no. 4, pp. 843–850.
21. Fan, J., Yao, Q. *Nonlinear Time Series: Nonparametric and Parametric Methods*. New York: Springer, 2003. 552 p.
22. Fattahi, S., Ravandi, S. A. H., Taheri, S. M. Two-Way Prediction of Cotton Yarn Properties and Fiber Properties using Multivariate Multiple Regression. *J. of the Textile Institute*. 2011, vol. 102, no. 10, pp. 849–856.
23. Fernandez, M., Caballero, J., Fernandez, L., Sarai, A. Genetic Algorithm Optimization in Drug Design QSAR: Bayesian-regularized Genetic Neural Networks (BRGNN) and Genetic Algorithm-optimized Support Vectors Machines (GA-SVM). *Molecular Diversity*. 2011, vol. 15, no. 1, pp. 269–289.
24. Fernández-Mansoa, A., Quintanob, C., Fernández-Mansoa, O. Forecast of NDVI in Coniferous Areas using Temporal ARIMA Analysis and Climatic Data at a Regional Scale. *Int. J. Remote Sensing*. 2011, vol. 32, no. 6, pp. 1595–1617.
25. Fletcher, T., Redpath, F., Alessandro, J. D. Machine Learning in FX Carry Basket Prediction. In: *Proc. of the World Congress on Engineering, vol. II, July 1–3, 2009, London, United Kingdom*. Newswood Limited, 2009, pp. 1371–1375.
26. Foresti, L., Tuia, D., Timonin, V., Kanevski, M. Time Series Input Selection using Multiple Kernel Learning. In: *Proc. of the 18<sup>th</sup> European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2010), April 28–30, 2010, Bruges, Belgium*. D-side Publishing, 2010, pp. 123–128.
27. Gallaher, D., Campbell, G. G., Meier, W., Moses, J., Wingo, D. The Process of Bringing Dark Data to Light: The Rescue of the Early Nimbus Satellite Data. *GeoResJ*. 2015, vol. 6, pp. 124–134.
28. Geoimage. *Satellite Overview* [online]. [viewed 2 March 2019]. Available from: <https://www.geoimage.com.au/>.
29. Grinchenko, N. N., Baranchikov, A. I., Tokarev, A. V. Terrain Objects Edge Detection in Noisy GPS Images. In: *ITM Web of Conferences: 6<sup>th</sup> Seminar on Industrial Control Systems: Analysis, Modeling and Computation, February 25–26, 2016, Moscow, Russia*. EDP Sciences, 2016, article no. 03004.
30. Haykal, V., Cardot, H., Ragot, N. A Combination of Variational Mode Decomposition with Neural Networks on Household Electricity Consumption Forecast. In: *Proc. of*



- Intern. Work-Conf. on Time Series (ITISE 2017), September 18–20, 2017, Granada, Spain.* Granada: Godel Impresiones Digitales S. L., 2017, pp. 740–752.
31. Hazledine, S., Sun, J., Wysham, D., Downie, J. A., Oldroyd, G. E. D., Morris, R. J. Nonlinear Time Series Analysis of Nodulation Factor Induced Calcium Oscillations: Evidence for Deterministic Chaos? *PLoS ONE*. 2009, vol. 4, no. 8, p. e6637.
  32. Hossain, A., Nasser, M. Recurrent Support and Relevance Vector Machines Based Model with Application to Forecasting Volatility of Financial Returns. *Journal of Intelligent Learning Systems and Applications*. 2011, vol. 3, pp. 230–241.
  33. Huang, D., Wu, Z. Forecasting Outpatient Visits using Empirical Mode Decomposition Coupled with Back-Propagation Artificial Neural Networks Optimized by Particle Swarm Optimization. *PLOS One*. 2017, vol. 12, no. 2, p. e0172539.
  34. Huang, N., Yuan, C., Cai, G., Xing, E. Hybrid Short Term Wind Speed Forecasting Using Variational Mode Decomposition and a Weighted Regularized Extreme Learning Machine. *Energies*. 2016, vol. 9, no. 12, pp. 1–19.
  35. Huang, S. C., Hsieh, C. H. Wavelet-based Relevance Vector Regression Model Coupled with Phase Space Reconstruction for Exchange Rate Forecasting. *Int. J. Innovative Computing, Information and Control*. 2012, vol. 8, no. 3, pp. 1917–1930.
  36. Huete, A. R. *Environmental Monitoring and Characterization*. Academic Press, 2004. 410 p.
  37. Jensen, J. R. *Introductory Digital Image Processing: A Remote Sensing Perspective*. 3<sup>rd</sup> ed. Upper Saddle River, N.J.: Pearson/Prentice Hall, 2005. 526 p.
  38. Ji, L., Peters, A. J. Forecasting Vegetation Greenness with Satellite and Climate Data. *IEEE Geoscience and Remote Sensing Letters*. 2004, vol. 1, no. 1, pp. 3–6.
  39. Joo, J. M. Diversity and Temporality of Chaotic Events. *Industrial Data*. 2016, vol. 19, no. 1, pp. 125–130.
  40. Kang, L., Di, L., Deng, M. Forecasting Vegetation Index Based on Vegetation-Meteorological Factor Interactions with Artificial Neural Network. In: *Proc. of the 5th Intern. Conf. on Agro-Geoinformatics (Agro-Geoinformatics 2016), July 18–20, 2016, Tianjin, China*. Tianjin: IEEE, 2016, pp. 1–6.
  41. Kantz, H., Holstein, D., Ragwitz, M., Vitanov, N. K. Markov Chain Model for Turbulent Wind Speed Data. *Physica A: Statistical Mechanics and its Applications*. 2004, vol. 342, no. 1–2, pp. 315–321.
  42. Karaca, E., Durmaz, B., Aktug, H., Yildiz, T., Guducu, C., Irgi, M., Gulcihan, M., Koksall, C., Ozkinay, F., Gunduz, C., Cogulu, O. Erratum to: The Genotoxic Effect of Radiofrequency Waves on Mouse Brain. *J. of Neuro-Oncology*. 2012, vol. 107, no. 3, pp. 665–671.
  43. Kay, S. M. *Fundamentals of Statistical Signal Processing: Estimation Theory*. Upper Saddle River, New Jersey, USA: Prentice-Hall, 1993. 608 p.
  44. Kayri, M. Predictive Abilities of Bayesian Regularization and Levenberg-Marquardt Algorithms in Artificial Neural Networks: A Comparative Empirical Study on Social Data. *Mathematical and Computational Applications*. 2016, vol. 21, no. 20, pp. 1–11.
  45. Khan, M. J., Yousaf, A., Khurshid, K., Abbas, A., Shafait, F. Automated Forgery

- Detection in Multispectral Document Images Using Fuzzy Clustering. In: *Proc. of 13<sup>th</sup> IAPR Intern. Workshop on Document Analysis Systems (DAS), April 24–27, 2018, Vienna, Austria*. IEEE, 2018, pp. 393–398.
46. Khashei, M., Bijari, M. An Artificial Neural Network (p, d, q) Model for Timeseries Forecasting. *Expert Systems with Applications*. 2010, vol. 37, no. 1, pp. 479–489.
  47. Kim, T. Y., Oh, K. J., Kim, C., Do, J. D. Artificial Neural Networks for Non-stationary Time Series. *Neurocomputing*. 2004, vol. 61, pp. 439–447.
  48. Klapetek, P. *Quantitative Data Processing in Scanning Probe Microscopy. SPM Applications for Nanometrology*. 2<sup>nd</sup> ed. Elsevier, 2018. 416 p.
  49. Klikova, B., Raidl, A. Reconstruction of Phase Space of Dynamical Systems Using Method of Time Delay. In: *WDS'11 Proceedings of Contributed Papers, Part III, May 31–June 3, 2011, Prague, Czech Republic*. Prague: Matfyzpress, 2011, pp. 83–87.
  50. Kochura, Y. P., Stirenko, S., Alienin, O., Novotarskiy, M., Gordienko, Y. G. Performance Analysis of Open Source Machine Learning Frameworks for Various Parameters in Single-Threaded and Multi-Threaded Modes. In: *Proc. of CSIT 2017: Advances in Intelligent Systems and Computing II, September 5–8, 2017, Lviv, Ukraine*. Springer, Cham, 2017, pp. 243–256.
  51. Lahmiri, S. A Variational Mode Decomposition Approach for Analysis and Forecasting of Economic and Financial Time Series. *Expert Systems with Applications*. 2016, vol. 55, pp. 268–273.
  52. Lau, K. T., Guo1, W., Kiernan, B., Slater, C., Diamond, D. Non-Linear Carbon Dioxide Determination using Infrared Gas Sensors and Neural Networks with Bayesian Regularization. *Sensors and Actuators B: Chemical*. 2009, vol. 136, no. 1, pp. 242–247.
  53. Leine, R., Wouw, N. V. D. *Stability and Convergence of Mechanical Systems with Unilateral Constraints*. Berlin: Springer, 2008. 236 p.
  54. Leontitsis, A. *Chaotic Systems Toolbox* [online]. [viewed 2 March 2019]. Available from: <https://se.mathworks.com/matlabcentral/fileexchange/1597-chaotic-systems-toolbox>.
  55. Li, Z. C., Chiend, C. S., Huang, H. T. Effective Condition Number for Finite Difference Method. *J. Computational and Applied Mathematics*. 2007, vol. 198, no. 1, pp. 208–235.
  56. Li, Y., Voos, H., Darouach, M., Hua, C. An Application of Linear algebra Theory in Networked Control Systems: Stochastic Cyber-Attacks Detection Approach. *IMA J. of Mathematical Control and Information*. 2016, vol. 33, no. 4, pp. 1081–1102.
  57. Lindgren, A. C., Johnson, M. T., Povinelli, R. J. Speech Recognition using Reconstructed Phase Space Features. In: *Proc. of the IEEE Intern. Conf. on Acoustics, Speech, and Signal Processing (ICASSP '03), April 6–10, 2003, Hong Kong, China*. IEEE, 2003, pp. 60–63.
  58. Liu, Z. Chaotic Time Series Analysis. *Mathematical Problems in Engineering*. 2010, vol. 2010, Article ID 720190, 31 p.
  59. Maaten, L. V. D. *Matlab Toolbox for Dimensionality Reduction*. [online]. [viewed 2 March 2019]. Available from: <https://lvdmaaten.github.io/drtoolbox/>.
  60. Manobavan, M., Lucas, N. S., Boyd, D. S., Petfor, N. Forecasting the Interannual

- Trends in Terrestrial Vegetation Dynamics using Time Series Modelling Techniques. In: *ForestSAT Symposium, August 5–9, 2002, Heriot Watt University, Edinburgh, United Kingdom*. London: Kingston University Publishing, 2002, pp. 1–7.
61. Marj, A. F. Agricultural Drought Forecasting using Satellite Images, Climate Indices and Artificial Neural Network. *Int. J. Remote Sensing*. 2011, vol. 32, no. 24, pp. 9707–9719.
  62. Mitrea, C. A., Lee, C. K. M., Wu, Z. A Comparison between Neural Networks and Traditional Forecasting Methods: A Case Study. *Int. J. Engineering Business Management*. 2009, vol. 1, no. 2, pp. 19–24.
  63. Nai, W., Liu, L., Wang, S., Dong, D. An EMD-SARIMA-Based Modeling Approach for Air Traffic Forecasting. *Algorithms*. 2017, vol. 10, no. 4, article no. 139.
  64. Naik, J., Dash, S., Dash, P. K., Bisoi, R. Short Term Wind Power Forecasting using Hybrid Variational Mode Decomposition and Multi-Kernel Regularized Pseudo Inverse Neural Network. *Renewable Energy*. 2018, vol. 118, pp. 180–212.
  65. NASA. *Landsat Science* [online]. [viewed 2 March 2019]. Available from: <https://landsat.gsfc.nasa.gov>.
  66. NASA. *LP DAAC. Land Process Distributed Active Archive Center* [online]. [viewed 2 March 2019]. Available from: <https://lpdaac.usgs.gov/>.
  67. NASA. *MODIS. Moderate Resolution Imaging Spectroradiometer Data* [online]. [viewed 2 March 2019]. Available from: <https://modis.gsfc.nasa.gov/>.
  68. Neumann, A., Krawczyk, H., Borg, E., Fichtelmann, B. Towards Operational Monitoring of the Baltic Sea by Remote Sensing. In: *Baltcoast 2004 – Managing the Baltic Sea, April 26-28, 2004, Rostock-Warnemünde, Germany*. Rostock-Warnemünde: EUCC, 2004, pp. 211–218.
  69. Ng’andwe, P., Mwitwa, J., Muimba-Kankolongo, A. *Forest Policy, Economics, and Markets in Zambia, 1st ed.* Academic Press, 2015. 186 p.
  70. Niaki, S. T. A., Hoseinzade, S. Forecasting S&P Index using Artificial Neural Networks and Design of Experiments. *J. of Industrial Engineering International*. 2013, vol. 9, no. 1. Available from: <http://www.jiei-tsb.com/cjntent/9/1/1>.
  71. Nordin, F. H., Nagi, F. H., Abidin, A. A. Z. Comparison Study of Computational Parameter Values between LRN and NARX in Identifying Nonlinear Systems. *Turkish Journal of Electrical Engineering and Computer Sciences*. 2013, vol. 21, no. 4, pp. 1151–1165.
  72. Oyafuso, M., Carvalho, F. C., Takeshita, T., etc. Development and In Vitro Evaluation of Lyotropic Liquid Crystals for the Controlled Release of Dexamethasone. *Polymers*. 2017, vol. 9, no. 8, pp. 330–346.
  73. Panigrahi, N. *Computing in Geographic Information Systems*. CRC Press, 2014. 303 p.
  74. Parikh, K. S., Shah, T. P. Support Vector Machine – A Large Margin Classifier to Diagnose Skin Illnesses. *Procedia Technology*. 2016, vol. 23, pp. 369–375.
  75. Plessis, L. D., Xu, R., Damelin, S., Sears, M., Wunsch, D. C. Reducing Dimensionality of Hyperspectral Data with Diffusion Maps and Clustering with K-means and Fuzzy ART. *Int. J. Systems, Control and Communications*. 2011, vol. 3, no. 3, pp. 232–251.
  76. Ram, R., Patra, S., Mohanty, M. N. Application of Variational Mode Decomposition on

- Speech Enhancement. In: *Proc. of the 2nd Intern. Conf. on Research in Intelligent and Computing in Engineering, March 24–26, 2017, Gopeshwar, Uttrakhand, India.* Warsaw: Polskie Towarzystwo Informatyczne, 2017, pp. 293–296.
77. Ribeiro, G. H. T., Neto, P. S. G. de M., Cavalcanti, G. D. C., Tsang, I. R. Lag Selection for Time Series Forecasting using Particle Swarm Optimization. In: *The 2011 Intern. Joint Conf. on Neural Networks (IJCNN), July 31–August 5, 2011, San Jose, CA, USA.* IEEE, 2011, pp. 2437–2444.
  78. Sahebjalal, E., Dashtekian, K. Analysis of Land Use-Land Covers Changes using Normalized Difference Vegetation Index (NDVI) Differencing and Classification Methods. *African J. Agricultural Research.* 2013, vol. 8, no. 37, pp. 4614–4622.
  79. Saleh, J. M., Hoyle, B. S. Improved Neural Network Performance Using Principal Component Analysis on Matlab. *Intern. J. of The Computer, the Internet and Management.* 2008, vol. 16, no. 2, pp. 1–8.
  80. Sallehuddin, R., Shamsuddin, S. M. H., Hashim, S. Z. M., Abraham, A. Forecasting Time Series Data Using Hybrid Grey Relational Artificial Neural Network and Auto Regressive Integrated Moving Average Model. *Neural Network World.* 2007, vol. 17, no. 6, pp. 573–605.
  81. Sallehudin, R., Shamsuddin, S. M. H., Hashim, S. Z. M., Abraham, A. Hybrid Grey Relational Artificial Neural Network and Auto Regressive Integrated Moving Average Model for Forecasting Time-Series Data. *Applied Artificial Intelligence.* 2009, vol. 23, no. 5, pp. 443–486.
  82. Satellite Imaging Corporation. *Satellite Sensors* [online]. [viewed 2 March 2019]. Available from: <https://www.satimagingcorp.com/>.
  83. Seelan, S. K., Laguette, S., Casady, G. M., Seielstad, G. Remote Sensing Applications for Precision Agriculture: A Learning Community Approach. *Remote Sensing of Environment.* 2003, vol. 88, no. 1, pp. 157–169.
  84. Seo, Y., Kim, S., Singh, V. P. Machine Learning Models Coupled with Variational Mode Decomposition: A New Approach for Modeling Daily Rainfall-Runoff. *Atmosphere.* 2018, vol. 9, no. 7, pp. 251–277.
  85. Shabri, A., Samsudin, R. Daily Crude Oil Price Forecasting Using Hybridizing Wavelet and Artificial Neural Network Model. *Mathematical Problems in Engineering.* 2014, vol. 1, pp. 1–10.
  86. Soloviev, V., Sapsin, V., Chabenko, D. Markov Chains Application to The Financial-Economic Time Series Prediction. *Computer Modelling and New Technologies.* 2011, vol. 14, no. 3, pp. 16–20.
  87. Stepchenko, A. Normalized Difference Vegetation Index Forecasting using a Regularized Layer Recurrent Neural Network. In: *Proc. of the 3<sup>rd</sup> Virtual Multidisciplinary Conf. QUAESTI, December 7–11, 2015, Zilina, Slovakia.* Zilina: EDIS-Publishing Institution of the University of Zilina, 2015, pp. 261–266.
  88. Stepchenko, A. NDVI Index Forecasting using a Layer Recurrent Neural Network Coupled with Stepwise Regression and the PCA. In: *Proc. of the 5<sup>th</sup> Virtual Intern. Conf. of Informatics and Management Sciences, March 21–25, 2016, Zilina, Slovakia.*

- Zilina: EDIS-Publishing Institution of the University of Zilina, 2016, pp. 130–135.
89. Stepchenko, A. Land Cover Classification Based on MODIS Imagery Data Using Artificial Neural Networks. In: *Proc. of the 11<sup>th</sup> Intern. Scientific and Practical Conf. "Environment. Technology. Resources"*, June 15–17, 2017, Rezekne, Latvia. Rezekne: Rezekne Academy of Technologies, 2017, pp. 159–164.
  90. Stepchenko, A., Borisov, A. Methods of Forecasting Based on Artificial Neural Networks. *Information Technology and Management Science*. 2014, vol. 17, pp. 25–31.
  91. Stepchenko, A., Chizhov, J. Applying Markov Chains for NDVI Time Series Forecasting of Latvian Regions. *Information Technology and Management Science*. 2015, vol. 18, pp. 57–61.
  92. Stepchenko, A., Chizhov, J. NDVI Short-Term Forecasting Using Recurrent Neural Networks. In: *Proc. of the 10<sup>th</sup> Intern. Scientific and Practical Conf. "Environment. Technology. Resources"*, June 18–20, 2015, Rezekne, Latvia. Rezekne: Rezeknes Augstskola, 2015, pp. 180–185.
  93. Stepchenko, A., Chizhov, J. Markov Chain Modelling for Short-Term NDVI Time Series Forecasting. *Information Technology and Management Science*. 2016, vol. 19, pp. 39–44.
  94. Stepchenko, A., Chizhov, J., Aleksejeva, L., Tolujew, J. Nonlinear, Non-stationary and Seasonal Time Series Forecasting Using Different Methods Coupled with Data Preprocessing. *Procedia Computer Science*. 2016, vol. 104, pp. 578–585.
  95. Sun, G., Chen, T., Wei, Z., Sun, Y., Zang, H., Chen, S. A Carbon Price Forecasting Model Based on Variational Mode Decomposition and Spiking Neural Networks. *Energies*. 2016, vol. 9, no. 1, pp. 1–16.
  96. Susac, M. Z., Sarlija, N., Pfeifer, S. Combining PCA Analysis and Artificial Neural Networks in Modelling Entrepreneurial Intentions of Students. *Croatian Operational Research Review*. 2013, vol. 4, no. 1, pp. 306–317.
  97. Šāvelis, Rolands. *Signālu diskretizācijas un atjaunošanas paņēmieni izpēte*. Promocijas darbs. Rīga: [RTU], 2013. 132 lpp.
  98. Teal, R., Tubana, B., Girma, K., Freeman, K. W., et al. In-Season Prediction of Corn Grain Yield Potential Using Normalized Difference Vegetation Index. *Agronomy Journal*. 2006, vol. 98, no. 6, pp. 1488–1494. ISSN 0002-1962.
  99. Templ, M., Kowarik, A., Filzmoser, P. Iterative Stepwise Regression Imputation using Standard and Robust Methods. *Computational Statistics & Data Analysis*. 2011, vol. 55, no. 10, pp. 2793–2806.
  100. Trefethen, L. N., Bau III, D. *Numerical Linear Algebra*. SIAM, 1997. 361 p.
  101. Vaidyanathan, S. Analysis, Control, and Synchronization of a 3-D Novel Jerk Chaotic System with Two Quadratic Nonlinearities. *Kyungpook Mathematical Journal*. 2015, vol. 55, no. 3, pp. 563–586.
  102. Valters, Gatis. *FPGA Implementation of Parametrical Orthogonal Transform-Based Experimental DSP Devices*. Promocijas darbs. Rīga: [RTU], 2012. 180 lpp.
  103. Vasermanis E., Šķiltere D., Krasts J. *Prognozēšanas metodes*. Rīga: Latvijas Universitāte, 2004. 121 lpp.

104. Ventspils novada pašvaldība. Ventspils novada teritorijas plānojums [tiešsaiste]. [skatīts 2019. g. 2. martā]. Pieejams: [http://www.ventspilsnovads.lv/images/stories/Teritorijas%20planojumi/2016/Paskaidrojuma\\_raksts.pdf](http://www.ventspilsnovads.lv/images/stories/Teritorijas%20planojumi/2016/Paskaidrojuma_raksts.pdf).
105. Vilde, A., Ruciņš, Ā., Viesturs, D. *Globālās Pozicionēšanas Tehnoloģijas Lauksaimniecībā*. Jelgava: LLU Lauksaimniecības tehnikas zinātniskais institūts, 2008. 47 lpp.
106. Vuolo, F., Mattiuzzi, M., Klisch, A., Atzberger, C. Data Service Platform for MODIS NDVI Time Series Pre-Processing at BOKU Vienna: Current Status and Future Perspectives. In: *Proc. of SPIE – Earth Resources and Environmental Remote Sensing/GIS Applications III, September 25–27, 2012, Edinburgh, United Kingdom*. Vol. 8538. SPIE Press, 2012, p. 85380A.
107. Wafi, A. F. *Historical Land Use/Land Cover Classification Using Remote Sensing. A Case Study of the Euphrates River Basin in Syria*. Heidelberg: Springer, 2013. 204 p.
108. Wang, Y. *Remote Sensing of Coastal Environments (Remote Sensing Applications Series)*. 1<sup>st</sup> ed. CRC Press, 2009. 458 p.
109. Xanthopoulou, G., Salamanis, A., Kehagias, D., Antoniou, I., Bratsas, C., Tzovaras, D. Forecasting Power Output of Photovoltaic Systems Using Linear, Non-Linear and Enhanced Models. In: *Proc. of Intern. Work-Conference on Time Series (ITISE 2017), September 18–20, 2017, Granada, Spain*. Vol. 1. Godel Impresiones Digitales S.L., 2017, pp. 129–140.
110. Yan, Q., Wang, S., Li, B. Forecasting Uranium Resource Price Prediction by Extreme Learning Machine with Empirical Mode Decomposition and Phase Space Reconstruction. *Discrete Dynamics in Nature and Society*. 2014, vol. 5, pp. 1–10.
111. Yusof, Z. M., Abdullah, S., Soaad, S., Yahaya, S. S. S. Comparing the Performance of Modified Ft Statistic with ANOVA and Kruskal Wallis Test. *Applied Mathematics & Information Sciences*. 2013, vol. 7, no. 2L, pp. 403–408.
112. Zhang, G. P. Time Series Forecasting using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. 2003, vol. 50, pp. 159–175.
113. Zhang, G., Patuwo, B. E., Hu, M. Y. Forecasting with Artificial Neural Networks: The State of the Art. *Int. J. Forecasting*. 1998, vol. 14, no. 1, pp. 35–62.
114. Zhang, G. P., Patuwo, B. E., Hu, M. Y. A Simulation Study of Artificial Neural Networks for Nonlinear Time-Series Forecasting. *Computers & Operations Research*. 2001, vol. 28, no. 4, pp. 381–396.
115. Zhang, H., Liang, J., Chai, Z. Stock Prediction Based on Phase Space Reconstruction and Echo State Networks. *J. Algorithms & Computational Technology*. 2013, vol. 7, no. 1, pp. 87–100.
116. Zhang, J. S., Xiao, X. C. Predicting Chaotic Time Series Using Recurrent Neural Network. *Chinese Physics Letters*. 2008, vol. 17, no. 2, pp. 88–90.
117. Zhao, J. H., Dong, Z. Y., Xu, Z. Effective Feature Preprocessing for Time Series Forecasting. In: *Proc. of the 2nd Intern. Conf. on Advanced Data Mining and Applications, ADMA 2006, August 14–16, 2006, Xi'an, China*. Springer, 2006, pp. 769–781.

118. Zosso, D., Dragomiretskiy, K. Variational Mode Decomposition. *IEEE Transactions on Signal Processing*. 2013, vol. 62, no. 3, pp. 531–544.
119. Zosso, D. *Variational Mode Decomposition* [online]. 2013 [viewed 2 March 2019]. Available from: <https://se.mathworks.com/matlabcentral/fileexchange/44765-variational-mode-decomposition>.
120. GIS-Lab. *NDVI – теория и практика* [tiešsaiste]. [skatīts 2019 g. 2. martā]. Pieejams: <http://gis-lab.info/qa/ndvi.html>.
121. GIS-Lab. *NDVI – теория и [практика]* [tiešsaiste]. [skatīts 2019. g. 2. martā]. Pieejams: <http://gis-lab.info/qa/ndvi2.html>.