



Nr. 24-00-COLA1601-000010

*“Ģeotelpisko datu apstrādes algoritmu pielietošana plantāciju mežu veselības stāvokļa un oglekļa piesaistes prognozēšanai”*

## **Pētījumam pieejamo datu slāņu novērtēšana un pielietošanas iespējas stādījumu augšanas gaitas un vitalitātes izpētei**

### **Literatūras apskats**

Ģeotelpisko slāņu dati ar mašīnmācīšanās algoritmu palīdzību ir plaši izmantoti, lai prognozētu un kartētu dažādus parametrus. Piemēram, Āzijas, Eiropas un ASV valstīs, kur pielietota līdzīga metodika, ir izstrādāti veiksmīgi pētījumi par koku augšanas gaitas prognozēšanas modelēšanu, koku sugu areāla izmaiņām klimata pārmaiņu rezultātā, kā arī atsevišķu scenāriju simulācijām pie konkrēti mainīgiem apstākļiem (Liang & Zhou, 2010; Nakao et al., 2022; Saha et al., 2022a, 2022b).

Meža nozarē mašīnmācīšanās algoritmi ir plaši izmantoti koku sugu kartēšanas uzlabošanai. Sugu klasifikācijai, koku augstuma, koku vainagu, veģetācijas virsmas u.c. modeļu izstrādei dati no attālās mērīšanas tehnoloģijas (LiDAR) ir plaši izmantoti, taču bieži vien ir nepieciešams integrēt citus datu avotus, lai iegūtu precīzākus rezultātus. Papildinājumus, piemēram, ar koku telpisko izvietojumu, koku vainagu blīvumu un formu, izmanto, lai uzlabotu modeļu precizitāti. Jaunākajos pētījumos aizvien vairāk uzmanības pievērsts vairāku avotu attālās izpētes datu apvienošanai, lai uzlabotu klasifikācijas precizitāti. Īpaši kalnainos reģionos un tropu klimatiskajos mežos augstums virs jūras līmeņa un nogāzes slīpums būtiski ietekmē temperatūras un ienākošās saules gaismas intensitāti reģionā. Šie faktori ietekmē koku sugu izplatību. Tāpēc algoritmu ievadei datu kombinācijās ir iekļauti arī tādi elementi kā reljefs, nogāzes slīpums un temperatūra (Valizadeh et al., 2023; Guo et al., 2024).

Somijas pētījumā, modelējot sugu areāla izmaiņas un to pielāgošanās spēju klimata pārmaiņām, pēc līdzīgas metodikas ir izveidoti parastās priedes augšanas gaitas un saglabāšanās modeļi ģenētiski uzlabotam un neuzlabotam materiālam. Noskaidrots, ka optimālie apstākļi koku izdzīvošanai var būtiski atšķirties atkarībā no teritorijas augstuma virs jūras līmeņa un ģeogrāfiskā platuma grādiem, savukārt koku augšanas apstākļi mainās atkarībā no ģeogrāfiskā platuma grādiem un vidējās mēneša temperatūras (Berlin et al., 2016).

Ģeotelpisko datu, satelītattēlu, LiDAR un citu attālās izpētes radaru izmantošana kombinācijā ar mašīnmācīšanos ir sniegusi daudzsoļus rezultātus arī konkrēti koku vitalitātes un augšanas gaitas prognozēšanai. Tomēr līdz šim šāda veida metodika lielākoties ir izmantota attālā meža un pilsētas vides monitoringa precizitātes uzlabošanai. Vairāku ģeotelpisko un satelītattēlu datu kombināciju ievade spēj būtiski uzlabot augšanas gaitas un vitalitātes modeļa uzticamības līmeni. Āzijas valstīs ir iegūtas atziņas, ka koku vitalitātes modeļa precizitāti būtiski uzlabo papildināšana ar manuāli ievāktiem datiem lauka apstākļos. Šāda veida metodiku attīstīšanai ir potenciāls laikus prognozēt mežaudžu un atsevišķu koku

veselības stāvokli, kā arī kukaiņu postījumus, tādējādi paredzot riskus un laicīgi tos novēršot (Choi et al., 2021; van den Dool & Bidwai, 2023; Mičko et al., 2024).

Izmantojot mašīnmācīšanās metodes kopā ar attālās izpētes un valsts meža inventarizācijas datiem, pētīta organisko augšņu izplatība un oglekļa saturs Latvijā. Klasificējot vairāk nekā 24 000 augsnes zondēšanas mērījumu atsevišķās kūdras slāņa biezuma kategorijās, pētnieki izstrādāja mašīnmācīšanās modeli, kas precīzi klasificē organiskā slāņa biezumu. Modeļa izveidei integrētie dati sastāvēja no dažādiem slāņu avotiem – gaisa lāzerskenēšanas, digitālajiem augstuma modeļiem, ūdens dziļuma kartēm, mitro teritoriju kartēm un vēsturiskajiem datiem par organiskajām augsnēm (Ivanovs et al., 2024).

### **Datu slāņu apraksts**

Pētījuma veikšanai ir pieejams plašs attālās izpētes datu klāsts, dažādi kartogrāfiskie materiāli un klimatiskie dati no novērojumu stacijām. Attālās izpētes datus ar dažādām tehnoloģijām, kuras iedala aktīvajos un pasīvajos sensoros. Aktīvie sensori raida signālu pret pētāmo objektu un saņem atstaroto signālu, tādējādi veicot novērojumus un aprēķinus, kamēr pasīvie sensori paļaujas uz paļaujas uz citu objektu radīto signālu, piemēram Saules izstaroto gaismu, un tikai uztver no pētāmā objekta nākošo atstarojumu. Tāpat ir pieejami dažādi vēsturiskie karšu slāņi, kuri, atkarībā no to telpiskās izšķirtspējas, sniedz informāciju par laikā nemainīgām vai maz mainīgām lietām, piemēram par augsnes struktūru un tekstūru, tās cilmiezi un ķīmiskajām īpašībām. Pētījumā plānojam izmantot arī klimatiskos datus no Latvijas vides, ģeoloģijas un meteoroloģijas centra (LVĢMC) novērojumu stacijām analizējot temperatūras, nokrišņu un citu pieejamo informāciju. Īss apraksts par datu slāņiem, kurus plānojam izmantot šī pētījuma laikā:

- Aktīvie sensori
  - Aerolāzerskenēšanas dati (ALS), kurus nodrošina Latvijas ģeotelpiskā informācijas aģentūra (LĢIA). Izmantojot šos datus esam radījuši vairākus karšu slāņus, kuri varētu palīdzēt prognozēt stādījumu augšanas gaitu un vitalitāti:
    - Reljefs (Augstums virs jūras līmeņa) – sniedz informāciju par teritorijas augstumu virs jūras līmeņa;
    - Normalizēts augstums – normalizēts reljefa modelis, norāda uz lokāliem Zemes virsmas paaugstinājumiem un pazeminājumiem;
    - Nogāzes slīpums – norāda uz Zemes virsmas slīpumu, grādos;
    - Mitro vietu karte – prognožu karte, kurā prognozēts augsnes piesātinājums ar ūdeni;
    - Gruntsūdens dziļuma kartes – prognozēts gruntsūdens līmenis. Aprēķini veikti balstoties uz zināmu ūdens objektu ūdens līmeni un reljefa īpašībām;
    - Kūdras slāņa biezuma karte – prognozēts kūdras slāņa biezums klasēs 0, 1–20 un 21–70 cm biezumā;
- Pasīvie sensori
  - Sentinel-2 satelītainas – multispektrāli optiskie dati ar horizontālo izšķirtspēju 10 metri. Izmantojami zemes virsmas klasifikācijai, dažādu veģetācijas indeksu ģenerēšanai u.c. mērķiem;

- Citi kartogrāfiskie materiāli
  - Vēsturiskās augšņu kartes – digitalizētas vēsturiskās augšņu kartēšanas dati mērogā 1:10 000 no pagājušā gadsimta 60-ajiem līdz 90-ajiem gadiem. Pieejama informācija par augsnes tipu un granulometrisko sastāvu;
  - Kvartāra nogulumu karte – Kvartāra nogulumu karte mērogā 1:200 000. Norāda uz augsnes cilmiezi;
  - Ķīmisko elementu kartes – dati no Latvijas ģeokīmiskā atlanta (2003);
- Klimata dati
  - Minimālās, vidējās un maksimālās temperatūras pa mēnešiem – temperatūra ietekmē augu fotosintēzi un elpošanu, augu augšanu, ūdens cirkulāciju, stresu un citus faktorus. Minimālās un maksimālās temperatūras var bojāt augu audus, veicināt atūdeņošanos un citus apstākļus, kas apgrūtina to izdzīvošanu;
  - Nokrišņu daudzums pa mēnešiem – nokrišņu apjoms ietekmē augiem pieejamo ūdens daudzumu un augu spēju izmantot barības vielas. Ūdens trūkums vai arī pārlietu liels daudzums var radīt stresu;
  - Veģetācijas sezonas garums – gada periods, kad noris augu augšana un attīstība. Rādītāju aprēķināsim no temperatūras datiem;
  - Kontinentalitāte – attālums līdz jūrai.

### Literatūras saraksts

Berlin, M., Persson, T., Jansson, G., Haapanen, M., Ruotsalainen, S., Barring, L., & Andersson Gull, B. (2016). Scots pine transfer effect models for growth and survival in Sweden and Finland. *Silva Fennica*, 50(3). <https://doi.org/10.14214/sf.1562>

Choi, Y., Chung, H. I., Lim, C.-H., Lee, J.-H., Choi, W. Il, & Jeon, S. W. (2021). Multi-Model Approaches to the Spatialization of Tree Vitality Surveys: Constructing a National Tree Vitality Map. *Forests*, 12(8), 1009. <https://doi.org/10.3390/f12081009>

Guo, H., Boonprong, S., Wang, S., Zhang, Z., Liang, W., Xu, M., Yang, X., Wang, K., Li, J., Gao, X., Yang, Y., Hu, R., Zhang, Y., & Cao, C. (2024). Dominant Tree Species Mapping Using Machine Learning Based on Multi-Temporal and Multi-Source Data. *Remote Sensing*, 16(24), 4674. <https://doi.org/10.3390/rs16244674>

Ivanovs, J., Haberl, A., & Melniks, R. (2024). Modeling Geospatial Distribution of Peat Layer Thickness Using Machine Learning and Aerial Laser Scanning Data. *Land*, 13(4), 466. <https://doi.org/10.3390/land13040466>

Liang, J., & Zhou, M. (2010). A geospatial model of forest dynamics with controlled trend surface. *Ecological Modelling*, 221(19), 2339–2352. <https://doi.org/10.1016/j.ecolmodel.2010.06.016>

Mičko, K., Staš, J., & Junáková, N. (2024). Tree Vitality Assessment Using Computer Vision and Determination of Vegetation Spectral Indices (pp. 122–132). [https://doi.org/10.1007/978-3-031-75329-9\\_14](https://doi.org/10.1007/978-3-031-75329-9_14)

Nakao, K., Kabeya, D., Awaya, Y., Yamasaki, S., Tsuyama, I., Yamagawa, H., Miyamoto, K., & Araki, M. G. (2022). Assessing the regional-scale distribution of height growth of *Cryptomeria japonica* stands using airborne LiDAR, forest GIS database and machine learning. *Forest Ecology and Management*, 506, 119953. <https://doi.org/10.1016/j.foreco.2021.119953>

Saha, R., Baranval, N. K., Das, I. C., Kumaranchat, V. K., & Reddy, K. S. (2022a). Application of Machine Learning and Geospatial Techniques for Groundwater Potential Mapping. *Journal of the Indian Society of Remote Sensing*, 50(10), 1995–2010. <https://doi.org/10.1007/s12524-022-01582-z>

Saha, R., Baranval, N. K., Das, I. C., Kumaranchat, V. K., & Reddy, K. S. (2022b). Application of Machine Learning and Geospatial Techniques for Groundwater Potential Mapping. *Journal of the Indian Society of Remote Sensing*, 50(10), 1995–2010. <https://doi.org/10.1007/s12524-022-01582-z>

Valizadeh, E., Asadi, H., Jaafari, A., & Tafazoli, M. (2023). Machine learning prediction of tree species diversity using forest structure and environmental factors: a case study from the Hyrcanian forest, Iran. *Environmental Monitoring and Assessment*, 195(11), 1334. <https://doi.org/10.1007/s10661-023-11969-1>

van den Dool, G., & Bidwai, D. (2023). Integrated Approach for Tree Health Prediction in Reforestation Using Satellite Data and Meteorological Parameters. *ECRS 2023*, 15982. <https://doi.org/10.3390/ECRS2023-15982>