


Artūrs Ķempelis

**MAŠĪNMĀCĪŠANĀS BALSTĪTA
MĒRĪJUMU NOVĒRTĒŠANAS PIEEJA
PRECĪZAJAI LAUKSAIMNIECĪBAI**

Promocijas darba kopsavilkums



RĪGAS TEHNISKĀ UNIVERSITĀTE

Datorzinātnes, informācijas tehnoloģijas un enerģētikas fakultāte

Informācijas tehnoloģijas institūts

Artūrs Ķempelis

Doktora studiju programmas “Datorzinātne un informācijas tehnoloģija” doktorants

MAŠĪNMĀCĪŠANĀS BALSTĪTA MĒRĪJUMU NOVĒRTĒŠANAS PIEEJA PRECĪZAJAI LAUKSAIMNIECĪBAI

Promocijas darba kopsavilkums

Zinātniskie vadītāji

asociētais profesors *Dr. sc. ing.*

ANDREJS ROMĀNOVS

Dr. sc. ing.

ANTONS PATĻINS

RTU Izdevniecība

Rīga 2026

Ķempelis, A. Mašīnmācīšanās balstīta mērījumu novērtēšanas pieeja precīzajai lauksaimniecībai. Promocijas darba kopsavilkums. – Rīga: RTU Izdevniecība, 2026. – 52 lpp.

Publicēts saskaņā ar promocijas padomes “RTU P-07” 2026. gada 31. marta lēmumu, protokols Nr. 04030-9.7/5.

Vāka attēla autors Artūrs Ķempelis.

<https://doi.org/10.7250/9789934373176>

ISBN 978-9934-37-317-6 (pdf)

PROMOCIJAS DARBS IZVIRZĪTS ZINĀTNES DOKTORA GRĀDA IEGŪŠANAI RĪGAS TEHNISKAJĀ UNIVERSITĀTĒ

Promocijas darbs zinātnes doktora (*Ph. D.*) grāda iegūšanai tiek publiski aizstāvēts 2026. gada 3. jūlijā plkst. 12.00 Rīgas Tehniskās universitātes Datorzinātnes, informācijas tehnoloģijas un enerģētikas fakultātē, Zundas krastmalā 10, 206. telpā.

OFICIĀLIE RECENZENTI

Profesors *Dr. sc. ing.* Agris Ņikitenko,
Rīgas Tehniskā universitāte

Profesors *Dr. sc. ing.* Vitālijs Komašilovs,
Latvijas Biozinātņu un tehnoloģiju universitāte, Latvija

Emeritētais profesors *Dr. sc. ing.* Izzet Kale,
Vestminsteres Universitāte, Apvienotā Karaliste

APSTIPRINĀJUMS

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

Artūrs Ķempelis (paraksts)
Datums:

Promocijas darbs ir uzrakstīts latviešu valodā, tajā ir ievads, četras nodaļas, secinājumi, literatūras saraksts, 48 attēli, 21 tabula, pieci pielikumi, kopā 131 lappuse, neieskaitot pielikumus un literatūras sarakstu (kopā ar informācijas avotu sarakstu un pielikumiem – 169 lapaspuses). Literatūras sarakstā ir 163 nosaukumi.

SATURS

IEVADS	5
1. DATU VIRZĪTĀ AUDZĒŠANA PRECĪZAJĀ LAUKSAIMNIECĪBĀ	12
2. MAŠĪNMĀCĪŠANĀS METOŽU IZPĒTE ATTĒLU ANALĪZEI	14
3. MAŠĪNMĀCĪŠANĀS MODEĻU IZSTRĀDE UN APMĀCĪBA	17
3.1. DATU IEVĀKŠANAS PROCESS	17
3.2. DATU ANALĪZE	21
3.3. MĒRĪJUMU NOVĒRTĒŠANAS MODEĻU IZSTRĀDE	24
3.3.1. <i>CNN modeļa izstrāde un apmācība</i>	24
3.3.2. <i>ViT modeļa izstrāde un apmācība</i>	26
3.3.3. <i>CvT modeļa izstrāde un apmācība</i>	28
4. MĒRĪJUMU NOVĒRTĒŠANAS PIEEJAS IZSTRĀDE UN VALIDĀCIJA	30
4.1. PIEEJAS IZSTRĀDE	30
4.2. PROTOTIPA IZSTRĀDE	32
4.3. EKSPERIMENTU PLĀNS UN APRAKSTS	32
4.4. MODEĻU PRECIZITĀTES KOPĒJAIS NOVĒRTĒJUMS	35
4.5. PIEEJAS IEVIEŠANAS METODIKA	42
REZULTĀTI UN SECINĀJUMI	43
IZMANTOTIE INFORMĀCIJAS AVOTI	47

IEVADS

Kopš 21. gadsimta sākuma katru gadu ar vien biežāk tiek izmantotas viedās tehnoloģijas, kas paredzētas lauksaimniecības darbu atvieglošanai, kā arī to efektivitātes un precizitātes uzlabošanai. Viena no plašāk lietotajām tehnoloģijām ir *IoT* tīkli, kuros darbojas sensori, kas spēj veikt augu un citu objektu, piemēram, mājlopu, apkārtējās vides mērījumus, lai uzlabotu ražas efektivitāti un paaugstinātu pārtikas kvalitāti (*Morella et al., 2023*). *IoT* tīklu izmantošana lauksaimniecībā sniedz būtisku produktivitātes un efektīvas ražošanas pieaugumu dažādu augu, tostarp pārtikas augu, ražošanā. *IoT* ietilpst arī optisko sensoru mērījumi, kas uzņem, piemēram, augu lapu attēlus, ko pēc apstrādes lieto neironu tīkla apmācībā, lai būtu iespējams ar salīdzinoši augstu precizitāti jeb ticamību atpazīt dažādas slimības, piemēram, augu puves infekcijas (*Akilan & Baalamurugan, 2024*).

Tēmas aktualitātes pamatojums

Lauksaimniecības uzdevums ir nodrošināt pārtiku un resursus cilvēcei. Precīzās lauksaimniecības pamatuzdevums ir lietot tehnoloģijas, lai optimizētu ne tikai iegūtos ražas apjomus, bet arī katra resursa (kas palīdz maksimizēt ražu) izmantošanas aspektu. Šobrīd vairākas Eiropas Savienības valstis, tostarp arī Latvija, cenšas ieviest modernās tehnoloģijas, lai palielinātu ražību un samazinātu negatīvo ietekmi uz vidi. Liels akcents tiek likts uz digitālo risinājumu ieviešanu, piemēram, droniem ar integrētiem sensoriem, satelītu datiem un lietu interneta jeb *IoT* ierīcēm (*Heyu et al., 2021*). Pašlaik aptuveni 30–40 % no modernajiem lauksaimniekiem jau izmanto vismaz viena veida sensoru risinājumu. Turklāt pieaug publisko un privāto investīciju apjoms šādām tehnoloģijām, tostarp arī pētniecībā, kas saistīta ar mašīnmācīšanās lietojumu lauksaimniecības efektivitātes uzlabošanai. Arvien plašāks sensoru lietojuma spektrs atklāj jaunas iespējas veicināt ilgtspējīgu lauksaimniecību, vienlaikus mazinot izmaksas un veicinot konkurētspēju starptautiskajos tirgos. Rezultātā sensori jau kļuvuši par neatņemamu sastāvdaļu, virzot lauksaimniecību uz efektīvāku un ilgtspējīgāku nākotni (*Henrichs et al., 2022*).

Papildus dažādiem tehniskajiem izaicinājumiem arī sensoru datu pārvaldība var kļūt pārāk sarežģīta, ja šie sensori ir lielā skaitā. Piemēram, ievērojami palielinās datu vākšanas, uzglabāšanas un analīzes apjoms. Ņemot vērā pēdējā laika globālo situāciju lauksaimniecībā, ne visiem lauksaimniekiem ir pieejami pietiekami resursi vai personāls, lai apstrādātu lielu datu apjomu, lietu mašīnmācīšanās risinājumus un nodrošinātu datu analīzi pietiekamā apmērā, lai ļautu lauksaimniekiem pieņemt informētākus lēmumus. Datu pieaugums ne vienmēr palielina informācijas lietderību. Līdzsvaru bieži var panākt ar mazāku, bet mērķtiecīgi izvietotu sensoru

skaitu, kas palīdz risināt noteiktas problēmas un optimizē resursu izmantošanu. Lai arī sensori palīdz uzlabot lauksaimniecībā esošos procesus, to neierobežota izmantošana ne vienmēr ir vislabākais risinājums. Salīdzinoši labāka pieeja būtu izvēlēties atbilstošus sensorus noteiktām vajadzībām, kas nodrošina to, ka tehnoloģijas pienesums būs efektīvāks un ilgtspējīgāks (*Priva, 2024*), (*AJ agriplanting*).

Lauksaimniecībā tehnoloģiju ieviešana rezultējas ar to, ka audzēšanas procesos iespējams pieņemt precīzākus un informētākus lēmumus. Pēdējā laikā tas ir radījis *IoT* sensoru ierīču ražošanas pieaugumu, sekojot arī lauksaimnieku pieprasījumam. Tiek ievākti dati par dažādiem augu fizioloģiskiem un citiem faktoriem, kas ir būtiski, lai izprastu, vai audzēšanas metodes darbojas un vai tiks sasniegti maksimāli iespējamie ražas apjomi. Lai gan, analizējot šos datus no sensoriem, jau daļēji ir iespējams secināt par dažādu datu savstarpējo saistību, vēl joprojām trūkst pētījumu par šo saistību (*Alireza et al., 2023*) izpēti plašākā mērogā un šīs informācijas apvienošanu, kā arī mašīnmācīšanās modeļu iespējas dažādu sensoru mērījumu noteikšanai un to prognozēšanai. Viens no piemēriem un pētījuma jautājumiem šajā kontekstā ir par to, kādu informācijas apjomu būtu iespējams iegūt no dažāda veida sensoriem, piemēram, augiem nekaitīgiem optisko sensoru mērījumiem, piemēram, attēliem, kas iegūti augu uzraudzības procesā lauksaimniecībā, kā šo informācijas ieguves modeli efektīvi izvietot *IoT* ierīcēs un to validēt.

Darba pētījuma joma ir saistīta ar vides mērījumu datu analīzi lauksaimniecībā pārtikas augu audzēšanas procesā. Lai uzlabotu jau esošo sensoru tīklu darbību, darbā tiek piedāvāta mērījumu novērtēšanas (angļu val. *estimation*) pieeja.

Promocijas darba mērķis un uzdevumi

Darba mērķis ir izstrādāt jaunu, dziļās mašīnmācīšanās lietošanā balstītu pieeju, kas nodrošina lauksaimniecības precīzu mērījumu novērtēšanu, izmantojot mazāku sensoru skaitu, salīdzinot ar esošajiem *IoT* risinājumiem.

Mērķa sasniegšanai tika definēti vairāki uzdevumi.

1. Izpētīt dziļās mašīnmācīšanās algoritmu lietošanas iespējas *IoT* tīklu sistēmās augu uzraudzībā.
2. Analizēt esošos *IoT* risinājumus augu uzraudzībā, izvērtējot sensoru tīklus, datu apstrādes un uzglabāšanas risinājumus, kā arī mašīnmācīšanās modeļu integrāciju *IoT*.
3. Izstrādāt vides sensoru mērījumu novērtēšanas modeli augu uzraudzības *IoT* tīkla sistēmas darbības uzlabošanai.

4. Izstrādāt prototipu un eksperimentāli novērtēt sensoru mērījumu novērtēšanas modeļa precizitāti un stabilitāti.
5. Izstrādāt un aprobēt precīzās lauksaimniecības mērījumu novērtēšanas ieviešanas metodiku.

Aizstāvēšanai izvirzītās tēzes

Augu mikroklimata mērījumu novērtēšanas pieejas izstrādei un validācijai ir definētas vairākas tēzes.

1. Izmantojot izstrādāto mikroklimata mērījumu novērtēšanas pieeju, kas ietver konvolūciju redzes transformera modeli, ir iespējams iegūt mērījumu novērtējumu, kas ir salīdzinoši precīzāks relatīvā gaisa mitruma, apgaismojuma (angl. val. *illuminance*) un gaisa temperatūras sensoru mērījumiem nekā konvolūciju vai redzes transformera pamata modeļiem.
2. Izmantojot apmācīto konvolūciju redzes transformera mikroklimata mērījumu novērtēšanas modeli, ir iespējams sasniegt 80 % vai augstāku precizitāti relatīvā gaisa mitruma, apgaismojuma un gaisa temperatūras sensoru mērījumiem.

Pirmā tēze raksturo to, ka, lietojot sensoru datu apstrādes, analīzes un dziļās mācīšanās metodes, eksperimentāli apmācot konvolūciju redzes transformera un tā atsevišķos pamatmodeļus (konvolūciju tīklu un redzes transformera), tiks pārbaudīta un salīdzināta mikroklimata sensoru datu novērtēšanas precizitāte. Otrā tēze apstiprināsies, ja sensoru mērījumu novērtējumi sasniegs līdzvērtīgu precizitāti faktiskajiem sensoru mērījumiem.

Pētījuma objekts un priekšmets

Promocijas darba objekts ir *IoT* tīkls un sensoru dati, kas paredzēti mikroklimata uzraudzībai pārtikas ražošanas procesos lauksaimniecībā. Pētījuma priekšmets ir *IoT* tīkla sensoru datu apstrādes un analīzes metodes, kas ir piemērotas augu mikroklimatisko sensoru mērījumu novērtējumam.

Pētījuma metodes

Darbā tiek izmantotas literatūras analīzes, salīdzināšanas, modelēšanas, eksperimenta un aprakstošās metodes. Tiek veikta teorētiskā algoritmu analīze, lai izpētītu un salīdzinātu dažādu modeļu piemērotību dotajam mērījumu novērtēšanas uzdevumam. Prototipa projektēšanai ir izmantotas programmatūras izstrādes un tehnoloģiju integrācijas metodes.

Darba zinātniskais jauniegums un vērtība

- Darbā tiek piedāvāta mašīnmācīšanās balstīta pieeja, kas nodrošina mērījumu novērtēšanu, samazinot šo mērījumu veikšanai nepieciešamo sensoru skaitu.

- Samazinot mērījumu veikšanai nepieciešamo sensoru skaitu, ar apmācīta mašīnmācīšanās modeļa palīdzību tiek saglabāta faktiskajiem sensoru mērījumiem līdzvērtīga precizitāte.

Promocijas darbā izstrādāta dziļā apmācībā balstīta mērījumu novērtēšanas pieeja, kas ļauj nodrošināt augstu precizitāti mikroklimata sensoru mērījumu novērtējumam lauksaimniecības augu uzraudzības procesos.

Lai demonstrētu pieejas darbību un precizitāti, darbā tiek veikta mašīnmācīšanās modeļa izstrāde un apmācība, ievācot sensoru mērījumus augu audzēšanas procesā. Promocijas darbā lietota metode, kas ļauj veikt vairāku mikroklimata sensoru mērījumu automatizētu ievākšanu, kā arī termiskā starojuma kameras automatizētu datu izgūšanu un apstrādi. Ar prototipu veiktie eksperimenti liecina par praktisko lietojamību reālā siltumnīcas vidē augu audzēšanas procesos.

Izstrādātais prototips tiek eksperimentāli validēts, izmantojot ievāktos datus no prototipa modulim uzstādītajiem mikroklimata mērījumu sensoriem, kas salīdzināti ar dziļā apmācībā balstītā modeļa spēju termiskā starojuma attēlu datus pārveidot precīzos sensoru mērījumu novērtējumos. Iegūtie rezultāti, tostarp novērtēto mērījumu precizitāte un kļūdas, liecina par sensoru mērījumu salīdzinoši augstu novērtējuma precizitāti, salīdzinot tos ar citām metodēm, kas tiek lietotas līdzīgos uzdevumos.

Pēc validācijas, apkopojot darba gaitā gūtās atziņas un secinājumus, izstrādāta pieejas ieviešanas metodika, kas paredzēta automatizētu sensoru mērījumu novērtēšanas modeļu ieviešanai lauksaimniecībā augu uzraudzībai siltumnīcās.

Darba praktiskais nozīmīgums

Reālās vides testos iegūtie rezultāti par risinājuma efektivitāti var kalpot kā pamatojums resursu ieguldīšanai. Piemēram, ja prototips spēj ievērojami samazināt izmaksas vai laiku, kas nepieciešams kādam būtiskam procesam (piemēram, enerģijas patēriņa optimizēšanai vai ierīču uzturēšanai), tas palīdz uzņēmumiem skaidri pamatot investīcijas. Līdz ar to šāds praktiskais piensums sekmē ilgtermiņa konkurētspējas palielināšanu, jo tiek samazināti nevajadzīgi tēriņi. Pozitīvi prototipa ieviešanas rezultāti var veicināt arī plašāku risinājuma adaptāciju citās industrijās, tā radot pievienoto vērtību un jaunas tirgus iespējas.

Darba aprobācija

Promocijas darbā veiktie pētījumi un to rezultāti ir ziņoti un guvuši pozitīvu vērtējumu sešās starptautiskās zinātniskajās konferencēs.

1. 2021 IEEE 19th International Conference on Smart Technologies (EUROCON), Lviv, Ukraina, 6.–8. jūlijs, 2021.

2. 9th IEEE Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE'2021), 25.–26. novembris, 2021, Rīga, Latvija.
3. The 63rd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS'2022), 6.–7. oktobris, 2022, Rīga, Latvija.
4. 2023 The 10th Jubilee IEEE Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), 27.–29. aprīlis, 2023, Viļņa, Lietuva.
5. The 11th IEEE Workshop on Advances in Information, Electronic and Electrical Engineering AIEEE'2024, 31. maijs–1. jūnijs, 2024, Valmiera, Latvija.
6. 29th International Conference on Circuits, Systems, Communications and Computers (CSCC), 20.–24. jūnijs, 2025, Amalfi Coast, Salerno, Itālija.

Promocijas darba galvenie rezultāti atspoguļoti astoņās publikācijās starptautiskajos recenzējamajos Latvijas Zinātnes padomes atzītajos zinātniskajos izdevumos.

1. Arturs Kempelis, Andrejs Romanovs and Antons Patlins, “Design and Implementation of IoT Network Prototype to Facilitate the Food Production Process in Agriculture”, IEEE EUROCON 2021 – 19th International Conference on Smart Technologies, Lviv, Ukraina, 2021, pp. 71–76, doi: 10.1109/EUROCON52738.2021.9535556.
2. Arturs Kempelis, Andrejs Romanovs and Antons Patlins, “Implementation of Machine Learning based Approach in IoT Network Prototype”, 2021 IEEE 9th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Rīga, Latvija, 2021, pp. 1–6, doi: 10.1109/AIEEE54188.2021.9670255.
3. Arturs Kempelis, Andrejs Romanovs and Antons Patlins, “Using Computer Vision and Machine Learning Based Methods for Plant Monitoring in Agriculture: A Systematic Literature Review”, 2022 63rd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS), Rīga, Latvija, 2022, pp. 1–6, doi: 10.1109/ITMS56974.2022.9937119.
4. Arturs Kempelis, Marta Narigina, Eduards Osadcijs, Antons Patlins and Andrejs Romanovs, “Machine Learning-based Sensor Data Forecasting for Precision Evaluation of Environmental Sensing”, 2023 IEEE 10th Jubilee Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Viļņa, Lietuva, 2023, pp. 1–6, doi: 10.1109/AIEEE58915.2023.10135031.
5. Marta Narigina, Arturs Kempelis, Andrejs Romanovs, “Machine Learning-based

- Forecasting of Sensor Data for Enhanced Environmental Sensing”, WSEAS Transactions on Systems, vol. 22, pp. 543–555, 2023, doi: 10.37394/23202.2023.22.55.
6. Arturs Kempelis, Inese Polaka, Andrejs Romanovs, Antons Patlins. (2024). Computer Vision and Machine Learning-Based Predictive Analysis for Urban Agricultural Systems. *Future Internet*, 16 (2), 44. <https://doi.org/10.3390/fi16020044>.
 7. Arturs Kempelis, Andrejs Romanovs and Antons Patlins, “Review on Application of Vision Transformers in IoT Edge Devices for Plant Sensor Measurement Forecasting”, 2024 IEEE 11th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Valmiera, Latvija, 2024, pp. 1–7, doi: 10.1109/AIEEE62837.2024.10586690.
 8. Arturs Kempelis, Andrejs Romanovs, Antons Patlins, Rasa Brūzgienė. Machine Learning-Based Measurement Forecasting Approach for Smart Agriculture. *WSEAS Transactions on Environment and Development*. 2025; 21:937-949. doi: 10.37394/232015.2025.21.78.

Darba autors papildus iesaistījies dažādās akadēmiskās un pētniecības aktivitātēs.

1. RTU 2023. g. zinātnes un inovācijas pētniecības platformas projektā “Nākamās paaudzes *IoT* tīkla kompleksā modeļa izstrāde ar paaugstinātu fiziskā slāņa drošību” (projekta izpildītājs).
2. RTU 2024. g. zinātnes un inovācijas pētniecības platformas projektā “Kiberdrošās *IoT* datu virzītas lauksaimniecības pārvaldības izpēte” (projekta izpildītājs).
3. Dalība *COST CA22104* projekta “*Behavioral Next Generation in Wireless Networks for Cyber Security*” programmā “*Blended Intensive Programme on Internet of Things applied to Environmental Monitoring*” (15.09.2023.–10.11.2023.).
4. Stažēšanās *Universidad Politécnica de Cartagena* (Spānija) universitātē “*IoT applied to Environmental Monitoring*” (06.11.2023.–10.11.2023.).
5. Dalība “*Bosch* mākslīgā intelekta pavasara skolas” (*Bosch* Izpētes un attīstības centrs Roitlingenā, Vācija) apmācībās par rūpnieciskā mākslīgā intelekta iespējām un lietojumu mikroshēmu ražošanā (06.03.2024.–07.03.2024.).
6. Dalība starptautiskajā seminārā “*IEEE Europe & Africa Blockchain Local Groups*” (08.09.2021.) un uzstāšanās ar referātu “*Blockchain-driven Mobility as a Service*”.
7. Ikgadējās starptautiskās konferences “*IEEE International Scientific Conference on Information Technology and Management Science of Riga Technical University*”

vietējās organizēšanas komandas dalībnieks (kopš 2022. g.).

8. RTU ITMS žurnālā publicētā raksta līdzautors: Līva Deksnē, Arturs Kempelis, Toms Sniedzins, Armands Kozlovskis (2021). Automated System for Restaurant Services. Information Technology and Management Science, 24, 15–25. doi: 10.7250/itms-2021-0003.
9. Vairāku RTU bakalaura darbu vadīšana un dalība aizstāvēšanas procesā (2021.–2025.)
10. Praktisko un laboratorijas darbu vadīšana studijuursos “Informācijas tehnoloģijas loģistikā DE0782” un “Informācijas tehnoloģijas pārvaldība DE0650” (kopš 2021. g.).

Promocijas darba struktūra


Promocijas darbā ir ievads, četras nodaļas, secinājumi un literatūras saraksts. Ievadā definēts darba mērķis un uzdevumi, pamatota darba tēmas aktualitāte, raksturots pētījuma objekts un priekšmets, kā arī uzskaitītas darbā lietotās pētījuma metodes un darba zinātniskais un praktiskais jaunieguvums. Ievads noslēdzas ar darba aprobāciju autora pētījumu publicēšanu un dalību konferencēs. Pirmajā nodaļā aprakstītas precīzajā lauksaimniecībā izmantotās tehnoloģijas un sensori, to mērījumi, kā arī šo mērījumu nozīme datu ievākšanas procesā. Otrajā nodaļā analizēts mašīnmācīšanās un datorredzes potenciāls augu novērošanā, uzsverot agrīnas augu slimību un augu stresa prognozes nozīmi ilgtspējīgai lauksaimniecībai. Salīdzinošā analizē apkopots, kā mašīnmācīšanās metodes, salīdzinot tās ar fiziskajiem sensoriem un statistikas vai citām metodēm, nodrošina augstāku precizitāti, labāku datu sapludināšanu un zemākas uzturēšanas izmaksas. Trešajā nodaļā aprakstīts izstrādātais datu ievākšanas prototips un datu ievākšanas process, ievāktu datu sagatavošana, priekšapstrāde un sākotnējā analīze. Aprakstītas izvēlētās modeļu arhitektūras un veiktā sākotnējā modeļu apmācība piemērotākā apmācības reižu skaita noteikšanai. Ceturtajā nodaļā aprakstīta izstrādātā mērījumu novērtēšanas pieeja. Pieveja eksperimentāli pārbaudīta ar datu ievākšanas laikā iegūtajiem sensoru mērījumiem. Veikta modeļu apmācība un analizēti kopumā seši izstrādāto mērījumu novērtēšanas modeļu rezultāti. Ar izstrādātajiem modeļiem veikti vairāku eksperimentu sērija ar ierobežotām apmācības datu kopām un troksni ieejas datos. Balstoties iegūtajos rezultātos, tika izstrādāta un aprakstīta arī pieejas ieviešanas metodika, kas var kalpot kā vadlīnijas mērījumu novērtēšanas pieejas ieviešanai precīzajā lauksaimniecībā *IoT* tīklos. Nobeigumā formulēti darbā sasniegtie rezultāti un secinājumi, kas iegūti, veicot eksperimentālo modeļu validāciju. Nodaļā aprakstīta darba praktiskā nozīme, pētījuma ierobežojumi un iezīmēti arī iespējamie nākotnes pētījumu virzieni.

1. DATU VIRZĪTĀ AUDZĒŠANA PRECĪZAJĀ LAUKSAIMNIECĪBĀ

Precīzās lauksaimniecības metodes, kas paredzētas audzēšanas efektivitātes uzlabošanai, ir sasniegušas plašu atpazīstamību lauksaimnieku vidū saimniecībās pasaules mērogā (*Abhishek & Sanmeet, 2023; Alireza et al., 2023*). Viena no precīzās lauksaimniecības datu virzītās audzēšanas pieejām ir risināt problēmu, kā izaudzēt vairāk, nemainot audzēšanā izmantojamo platību vai samazinot līdz šim lauksaimniecībā lietoto resursu, piemēram, ūdens, barības vielu, siltuma, darba spēka un citu resursu, patēriņu. Viens no veidiem, kā panākt iepriekš minēto resursu efektīvu izlietošanu, ir ievākt precīzus mērījumus no dažādām mērierīcēm vai sensoriem (Kempelis u. c., 2021a). Precīzi mērījumi nodrošina pamatu datu analīzei un lēmumu pieņemšanai dažādos lauksaimniecības procesos, kā arī šādiem mērījumiem ir raksturīga mērījumu veikšana vietās, kur tas lauksaimniekiem dotu visvairāk noderīgas informācijas, piemēram, pie augu saknēm vai pie augu lapām, atkarībā no mērīšanas mērķa.

Vēsturiski tradicionālā lauksaimniecība balstījusi vienotā pārvaldības praksē, neņemot vērā mainīgos apstākļus uz lauka, bieži vien radot resursu izšķērdēšanu, piemēram, nelietderīgi izlietojot augiem paredzēto ķīmiju jeb augu barības vielas, tajā skaitā dažādus augsnes bagātinātājus (*Padhiary et al., 2025*). Ieviešot precīzo jeb viedo lauksaimniecību, šī neefektivitāte tiek ievērojami samazināta, pateicoties reāllaika datu ieguvei, izmantojot dažāda veida sensorus un lietu interneta ierīces (*Waleed, 2021*).

Pēdējos astoņos gados sensoru ieviešana lauksaimniecībā ir uzrādījusi pastāvīgu izaugsmi. Konkrēti, lauksaimniecības sensoru tirgus daļa pieaugusi no 1,05 mljrd. ASV dolāru visā pasaulē 2017. gadā līdz 2 miljardiem ASV dolāru 2023. gadā un līdz prognozei, kas pārsniedz aptuveni 2 miljardus. ASV dolāru līdz 2027. gadam (1.1. att.), turpinot palielināties (*Kbvresearch, 2022*).



1.1. att. Lauksaimniecības sensoru tehnoloģiju tirgus daļas, pēc lietojuma 2017.–2027. gadā (aizgūts no (Kbvresearch, 2022)).

Atsevišķas tirgus prognozes sniedz informāciju arī par 2030. gadu, kur paredzamā lauksaimniecībā izmantoto sensoru tirgus daļa varētu sasniegt 4,6 miljardus ASV dolāru (*Grandviewresearch, 2023*). Tomēr šīs tendences rada ievērojamu slodzi sensoru uzturēšanas jomā. Palielinoties ierīču skaitam, ekspluatācijas un uzturēšanas izmaksas arī strauji pieaug, un saimniecībām var neatmaksāties to izmantošana ilgtermiņā. Lielam ierīču skaitam seko proporcionāli augsts ierīču atteices risks, kas prasa manuālu darbinieka iejaukšanos. Pašas ierīces ir pakļautas dažādiem apkārtējās vides iedarbes faktoriem, piemēram, ultravioletajam starojumam, agroķīmijai, plūdiem, arī mājlopu izraisītiem bojājumiem vai cita veida bojājumiem. Sensori, kas mēra mitrumu, barības vielu saturu un tamlīdzīgus mērījumus, pakāpeniski zaudē savu precizitāti, un tiem var būt nepieciešama periodiska kalibrēšana, kas var ietvert arī ierīces demontāžu, kalibrēšanu, iespējams, arī apkopi un uzstādīšanu no jauna.

Rezultātā novērojamas arī salīdzinoši jaunas tendences, kas saistītas ar ievākto sensoru mērījumu datu izpēti, sensoru kalibrāciju, to sapludināšanu, paškalibrācijas metodēm. Dažādas datu analīzes, datizraces un mašīnāpmācībā balstītas metodes (*Padhiary et al., 2024*) ļauj atklāt sakarības mērījumu datus un potenciāli dod iespēju veikt mērījumus, samazinot fizisko ierīču skaitu, tādējādi radot mērierīču resursu ietaupījumu, nemainot kopējo sensoru tīkla nozīmi vai tā efektivitāti. Augu audzēšanas procesā ievāktos sensoru datus var izmantot analīzei un lēmumu pieņemšanai jeb informācijas izgūšanai (*Kempelis u. c., 2021b*), kas palīdz lauksaimniekiem vai automatizētām vadības iekārtām pieņemt lēmumus augu nodrošināšanai, piemēram, ar dažādām barības vielām.

2. MAŠĪNMĀCĪŠANĀS METOŽU IZPĒTE ATTĒLU ANALĪZEI

Mašīnmācīšanās tehnoloģijas ir radījušas ievērojamu potenciālu lauksaimniecībā, īpaši augu augšanas uzraudzības jomā (*Habib et al.*, 2022). Lietderīga mašīnmācīšanās tehnoloģiju izmantošana nodrošina plaši lietojamus rīkus augu uzraudzībā, piemēram, agrīnai dažādu augu veselības problēmu atklāšanai un prognozēšanai, kas ir svarīgi ilgtspējīgai un efektīvai lauksaimniecībai. Dažādi algoritmi spēj analizēt apjomīgas datu kopas, kas iegūtas no mikroklimata sensoru mērījumiem un dažādu optisko ierīču uzņemtajiem attēliem, kas tiek iegūti lauksaimniecībās. Datorredzē balstīti regresijas modeļi vai lēmumu koki spēj atklāt slēptas likumsakarības un saistības mērījumu datos. Augu novērošanas kontekstā tas nozīmē, ka ar algoritmu palīdzību iespējams prognozēt augu veselības stāvokli, analizējot vēsturiskos datus un aktuālos novērojumus. Šāda pieeja agrīnai veselības stāvokļa prognozēšanai nozīmē savlaicīgu risku noteikšanu, kas ļauj veikt arī preventīvus pasākumus, lai novērstu iespējamās veselības problēmas vai dažādu slimību izplatību (*Badidi*, 2023).

Pētījumā (*Almutawa & Eid*, 2023) aprakstīta infrasarkanā starojuma jeb termogrāfijas iekļaušana augsnes mitruma noteikšanas procesos, piedāvājot neinvazīvu un bezkontakta metodi, kas var būtiski uzlabot esošās augu novērošanas sistēmas. Izmantojot halogēna lampu un infrasarkanu kameru, lai fiksētu augsnes virsmas temperatūru, pētījums pierādīja ciešu korelāciju starp termiskajiem rādījumiem un augsnes mitruma līmeni. Sekmīga mitruma satura noteikšana šādā veidā parāda termiskā starojuma uztveršanas potenciālu, kas kalpo par vērtīgu rīku precīzajā lauksaimniecībā, dodot iespēju rūpīgi uzraudzīt augsnes apstākļus bez tiešas fiziskas ietekmes uz augsni vai pašu augu. Pētījumos konstatēta arī izteikta apgriezta sakarība starp augsnes virsmas temperatūru un mitruma saturu – mitrumam samazinoties, temperatūra pieauga, un otrādi. Šis atklājums ir nozīmīgs augu novērošanā, jo pierāda, ka termiskie dati var atklāt būtiskus vides faktorus, piemēram, augsnes mitrumu, kas tieši ietekmē augu veselību. Spēja iegūt šādus mērījumus no termiskajiem attēliem paver iespējas izstrādāt sarežģītus mašīnmācīšanās modeļus, lai prognozētu dažādus ar augu uzraudzību saistītus mērījumus. Apvienojumā ar transpirācijas procesa analīzi būtu iespējams izstrādāt precīzākus augu mikroklimata novērojumu modeļus.

Ņemot vērā to, ka datorredzes lietošana rada jaunu informācijas dimensiju, ļaujot analizēt augu vizuālās norādes, lai prognozētu augu labklājību, fizioloģiskās īpašības, veselību, augšanas procesus, tas teorētiski varētu dot iespēju izstrādāt pieeju arī dažādu sensoru mērījumu novērtēšanai, balstoties mikroklimata vai augu vizuālajās pazīmēs. Datorredzei, piemēram,

izmantojot konvolūciju neironu tīklus, ir būtiska loma precīzās lauksaimniecības procesos (*Liu et al.*, 2023). Konvolūciju tīkli ir plaši atpazīstama datorredzes konteksta uzdevumos un ir bieži lietota dziļās mācīšanās metode, kas uzrāda augstu efektivitāti apjomīgu vizuālās informācijas datu apstrādē un interpretēšanā, kas iegūta no augiem to audzēšanas procesā. Konvolūciju tīkli lietojami uzdevumos, piemēram, slimību pazīmju, uzturvielu trūkumu vai kaitēkļu invāzijas noteikšanā, analizējot augu lapu un augļu attēlus (Kempelis u. c., 2022). Pēdējā laikā arvien plašāk datorredzes uzdevumos tiek lietoti redzes transformeri (angļu val. *Vision Transformers, ViT*), kas, tāpat kā konvolūciju tīkli, ietilpst dziļās mācīšanās pieejā un radušies no transformēšanas arhitektūras, kas izmantota lielajos valodu modeļos (angļu val. *Large Language Models*) dabīgās valodas apstrādei (angļu val. *Natural Language Processing*) (*Dosovitskiy et al.*, 2020). Redzes transformeri literatūrā bieži atpazīstami ar to, ka eksperimentālos pētījumos tiek apgalvots, ka tie uzrāda salīdzinoši augstāku precizitāti nekā, piemēram, konvolūciju neironu tīklu modeļi. Lai gan katram no minētajiem modeļiem ir savas priekšrocības un trūkumi, jaunākajā literatūrā šie modeļi bieži tiek salīdzināti un atsevišķos pētījumos tiek piedāvāta arī šo modeļu arhitektūru kombinēšana (hibrīdo modeļu pieeja, kurā tiek apvienotas gan *CNN*, gan *ViT* modeļu priekšrocības), lai uzlabotu precizitāti dažādos lietojumos, piemēram, objektu atpazīšanā (*De Silva & Brown*, 2023). Šobrīd gan redzes transformeri vēl netiek plaši izmantoti augu vides faktoru (piemēram, gaisa temperatūras vai citu būtisku mērījumu) novērtēšanā vai prognozē – minētā pieeja nav pietiekami pētīta vai nav publicēta zinātniskajās datubāzēs. Pamatojoties literatūras analīzē atklātajā, var secināt, ka augu audzēšanā sastopamais mikroklimats ir nelineārs un mainīgs – sensoru mērījumi ir atkarīgi no mikroklimata ietekmes, augsnes tipa un augu fenoloģijas, datu plūsma ir nepārtraukta un bieži var būt arī nepilnīga (ar iztrūkstošu informāciju vai datiem). Mašīnmācīšanās algoritmi ir paredzēti šādu lielapjoma, daudzdimensionālu datu strukturēšanai, atklājot slēptas sakarības, ko statistiskās metodes bieži vien nespēj uztvert. Mašīnmācīšanās metodes ir paredzētas dažāda tipa ieejas datiem, piemēram, kombinēt augu lapu termoattēlu kadrus ar augsnes mitruma sensoru vai citiem mērījumiem vai prognozēm, tādējādi nodrošinot jēgpilnus (veicot mērījumus tur, kur tas visvairāk nepieciešams) un precīzus (ar minimālu kļūdu) aprēķinus.

Literatūrā konvolūciju tīklu arhitektūrā balstīti regresijas modeļi ticami spēj izteikt nepārtrauktas vērtības, izmantojot vizuālos datus, no augsnes mitruma līmeņa noteikšanas pēc informācijas no dažāda tipa attēliem līdz ražas prognozēšanai no satelītattēliem. Tas apliecina, ka mašīnmācīšanās metožu lietošana potenciāli ļautu aizvietot salīdzinoši dārgas mērīšanas ierīces, dažāda veida vizuālo informāciju pārvēršot kvantitatīvos mērījumos.

Fiziskie sensori, lai gan saglabā precizitāti, sniedz ierobežotu informāciju par vietu, kur tie uzstādīti, savukārt statistiskās metodes, piemēram, interpolācijas kartes, kļūst neprecīzas, ja mainās apgaismojums, augsnes fons vai citas īpašības. Dziļo neironu tīklu modeļi spēj apgūt nelineāras sakarības starp attēliem un reālajiem mikroklimata mērījumiem bez manuāli veidotām heuristikām. Fizisko sensoru tīklu ieviešana vai paplašināšana strauji var kļūt nesamērīgi dārga, jo katrs papildu sensors prasa aparatūru, uzstādīšanu un kalibrēšanu vai uzturēšanu. Mašīnmācīšanās metodēs balstīti virtuālie sensori vai mērījumu prognozes, novērtējumi var sapludināt fiziskos mērījumus ar dažāda veida attēliem, iegūstot mikroklimata mērījumu kartes, izmantojot tikai daļu no nepieciešamās aparatūras. Atsevišķo mērījumu veikšanā tradicionālās metodes reti izmanto dažādus datu tipus vai informācijas avotus.

Sensoriem nepieciešama periodiska kalibrēšana, un tie ir uzņēmīgi pret apkārtējās vides apstākļiem, arī to ietekmi, it īpaši lauksaimniecības lietojumos. Kad mašīnmācīšanās modeļi ir apmācīti, pēc izmēra optimizēti to varianti var darboties uz ierīcēm ar ierobežotiem resursiem. *MobileNet*, *MobileViT* un tamlīdzīgi varianti nodrošina pietiekami ātru inferenci, saglabājot augstu precizitāti. Statistisko metožu ieviešana ir salīdzinoši vienkāršāka, bet tām trūkst prognozēšanas precizitāte, kas nepieciešama dažādos mainīgos scenārijos, kas raksturīgi lauksaimniecības vidē.

Klasiskās aprēķina metodes vai heuristika var būt jutīgas pret gaismas leņķi, augsnes fonu un laikapstākļu vai mikroklimata straujām izmaiņām. Mašīnmācīšanās modeļi, izmantojot mērījumu novērtēšanu, mazina iztrūkstošo datu ierakstu skaitu gadījumos, kad atsevišķi sensori pārstāj darboties vai no tiem ienākošās datu plūsmas kļūst neregulāras. Mašīnmācīšanās modeļi spēj izvadīt praktiski izmantojamus rādītājus (ražas apjoms, slimību risks, nepieciešamais laistīšanas vai citu resursu apjoms), kas tieši izmantojams lauksaimniekiem lēmumu pieņemšanas procesā.

Visos iepriekš apskatītajos kritērijos, tajā skaitā precizitātē, mērogojamībā, izmaksās, datu sapludināšanā, modeļu pielāgojamībā un izvietošanā, mašīnmācīšanās metodes sasniedz līdzvērtīgu un bieži arī izteiktu pārkumu, salīdzinot gan ar tiešo mērījumu iespējām, gan ar statistikas, interpolācijas vai heuristikas metodēm. Tāpēc mūsdienīgas precīzas lauksaimniecības kontekstā, kur apstākļi ir bieži mainīgi, budžets ierobežots un lēmumi jāpieņem savlaicīgi, mašīnmācīšanās ir salīdzinoši piemērotākā un arī izmaksu ziņā efektīvākā metode mērījumu novērtēšanai.

3. MAŠĪNMĀCĪŠANĀS MODEĻU IZSTRĀDE UN APMĀCĪBA

Lai izpētītu atklātās nepilnības no literatūras analīzes laikā apkopotajiem pētījumiem sensoru mērījumu prognozēšanā un novērtēšanā lauksaimniecības vidē, šajā darbā izstrādāta mērījumu novērtēšanas pieeja. Darbā tiek piedāvāta jauna pieeja, kas spēj darboties precīzās lauksaimniecības vidē, kur norisinās dažādu augu audzēšana un uzraudzība. Piedāvātā sensoru mērījumu novērtēšanas pieeja ietver attēlu uzņemšanu un apstrādi no termokameras, pēc tam izmantojot šos termiskos attēlus kā ieeju mašīnmācīšanās modelī sensoru mērījumu prognozei, piemēram, apgaismojuma, augsnes ūdens saturs un relatīvā mitruma novērtēšanai vai prognozēšanai. Lai izstrādātu šo pieeju, ir nepieciešams iegūt sensoru mērījumus, ko izmantot datu analīzē un mērījumu prognozē vai novērtēšanā. Ņemot vērā to, ka literatūras analīzes laikā atklātajās datu kopās un pētījumos neietilpst atvērtu datu kopu ar termiskā starojuma attēliem un laikā, vietā sakritīgiem sensoru mērījumiem, tika pieņemts lēmums šo datu kopu izveidot darba izstrādes gaitā. Balstoties iegūtajos mērījumu datos, tika izvēlētas piemērotākās metodes datu analīzei un eksperimentāli validēta pieeja veikt mērījumu novērtēšanu no termoattēlu ieejas datiem.

3.1. Datu ievākšanas process

Darbā paredzēts veikt mērījumu novērtēšanu tajā pašā vidē un laikā, kur uzņemti termoattēli, tāpēc bija nepieciešams sagatavot prototipa sensoru mērījumu ievākšanas moduli reālā lauksaimniecības vidē. Tas darīts, lai varētu noteikt piemērotāko metodi un modeļus mērījumu novērtēšanai. Datu ievākšanas prototipa moduļa izveidē tika izmantoti dažāda veida sensori un ierīces, lai iegūtu informāciju, kas kritiski svarīga augu veselībai.


Prototipa moduļa izstrādē izmantotas šādas ierīces, kuru galvenais uzdevums ir nodrošināt mērījumu ievākšanas automatizāciju:

- *FLIR Lepton 3.5* termokamera ar 57° lēcu (*GroupGets*, 2024), izvēlēta, jo tā nodrošina radiometriskus mērījumus, kur katram attēla pikselim tiek iegūta kalibrēta temperatūras vērtība, nevis tikai relatīvs siltuma attēls;
- *FLIR Lepton* kameras saskarnes un papildu savienojumu modulis *PureThermal2* (*GroupGets PureThermal 2*, 2024), izvēlēts, lai nodrošinātu datu apmaiņu starp termokameru un vienplates datoru;
- *VEML7700* – apgaismojuma līmeņa noteikšanai (*Elektrokit VEML7700*, 2024), izvēlēts, jo nodrošina I^2C saskarni, augstu mērījumu precizitāti, zemu sensora

enerģijas patēriņu un salīdzinoši plašu mērījumu diapazonu;


- *HDC1080* – relatīvā gaisa mitruma un gaisa temperatūras mērījumiem (*Rosen et al.*, 2020), izvēlēts, jo nodrošina I²C saskarni, tam ir plašs mērījumu diapazons, salīdzinoši augsta mērījumu precizitāte un zems enerģijas patēriņš;
- vienplātes dators *Khadas*, modelis *VIM 1S* (*Khadas*, 2022), izvēlēts, jo tam ir zems enerģijas patēriņš un tas ir piemērots automatizētām mērījumu sistēmām; ierīce balstīta četrkodolu *ARM Cortex-A35* procesorā (līdz 2.0 GHz), tai ir iebūvēta 16 GB *eMMC* atmiņa, tā nodrošina pietiekamu skaitļošanas jaudu datu apstrādei reāllaikā.

Mērījumu veikšanai paredzētie sensori pievienoti vienplātes datoram *Khadas* (3.1. att.), izmantojot atsevišķus spraudņu savienojumus (*GPIO*, kas redzams 3.1. attēla labajā daļā). Lai nodrošinātu slēgumu ar minimālu savienojumu skaitu, sensori saslēgti divās I²C kopnēs.



3.1. att. Kopējā elektriskās ķēdes slēguma shēma.

Rezultātā saliktais prototips ievietots korpusā minimālai integrēto shēmu un kameras aizsardzībai pret gaisa mitruma ietekmi siltumnīcā (3.2. att.).



3.2. att. Korpusā salikts mērījumu ievākšanas prototips.

Datu mērījumi veikti siltumnīcā (3.3. att.), kurā tiek manuālā vai automatizētā veidā nodrošināti augšanai nepieciešamie apstākļi, ir ierobežota un paredzama temperatūras izmaiņu amplitūda, kā arī minimāli iespējama gaisa plūsma un citi faktori, kas īslaicīgi varētu ietekmēt veiktos mērījumus, piemēram, radīt trokšņainus datus.



3.3. att. Mērījumu ievākšana LBTU Dārzkopības institūta siltumnīcā avenu stādiem.

Konkrēti Latvijas Biozinātņu un tehnoloģiju universitātes (LBTU) Dārzkopības institūta siltumnīcā veiktie novērojumi divu mēnešu laikā (2024. gada jūnijs–jūlijs) veikti siltumnīcā, kur tiek sagatavoti dažādi stādi stādīšanai ārā apstākļos. Datu automatizētai ievākšanai tiek izmantoti vairāki skripti, kas apkopoti *github* repozitorijā (<https://github.com/ArtuursK/thermal-measurement-estimation>). Datu ievākšanas skripts tiek palaists reizi 15 minūtēs, izmantojot *crontab* komandas. Skripts nolasa vērtības no *Khadas PC*

kopnēm, lietojot *smbus2* bibliotēku. Termokameras kadru iegūšanai lietota bibliotēka *libuvc*, kas ļauj mijiedarboties ar *USB* video klases (*UVC*) ierīcēm. Kadru izgūšanai no *PureThermal* moduļa caur *USB* izmantota *OpenCV* bibliotēka.

Termiskā starojuma kamera ik pēc 15 minūtēm uzņem augu termālos attēlus. Katrs attēls tiek saglabāts kā 120×160 pikseļu 2D masīvs *CSV* formātā. *CSV* formāts izvēlēts, jo *Python*, *R*, *Excel* un vairāki citi rīki ļauj apstrādāt šī formāta failus bez papildu ārēju bibliotēku lietošanas. Lai gan izmantotā termokamera ir radiometriska (kameras izejas kanālā dotas kalibrētas vērtības), katram pikseļa mērījumam ir $\pm 0,05$ °C ražotāja noteiktā precizitāte, un kamera spēj reģistrēt temperatūru diapazonā no -40 °C līdz $+400$ °C.

Apgaismojuma **sensors *VEML7700*** mēra apgaismojumu ar aptuveni ± 10 % precizitāti $0-167\,000$ luksu (lx) diapazonā.

Temperatūras un mitruma sensors *HDC1080* nodrošināja apkārtējās vides temperatūras (ar $\pm 0,4$ °C precizitāti, mērījumu diapazonā no -40 °C līdz 125 °C) un relatīvā mitruma mērījumus (ar ± 2 % *RH* precizitāti diapazonā no 0 % līdz 100 % *RH*).

Informācija par mērījumu datu kopu. Divu mēnešu laikā (2024. gada jūnijs–jūlijs) katram sensoram (relatīvais gaisa mitrums, gaisa temperatūra, apgaismojums) tika iegūti kopumā 1053 izmantojami (laikā sakrītīgi ar automātiski iegūtajiem termokameru attēliem) stundas mērījumi.


- Gaisa temperatūra:
 - maksimālā vērtība – $38,01$ °C;
 - minimālā vērtība – $10,46$ °C;
 - vidējā vērtība – $22,86$ °C;
 - standartnovirze – $4,91$ °C.
- Relatīvais gaisa mitrums:
 - maksimālā vērtība – $99,99$ % *RH*;
 - minimālā vērtība – $37,9$ % *RH*;
 - vidējā vērtība – $88,60$ % *RH*;
 - standartnovirze – $15,80$ % *RH*.
- Apgaismojums:
 - maksimālā vērtība – $7952,5$ lx;
 - minimālā vērtība – $0,0$ lx;
 - vidējā vērtība – $1828,94$ lx;
 - standartnovirze – $1684,49$ lx.

3.2. Datu analīze

Datu ievākšanas laikā autors vairākkārt saskārās ar gadījumu, kad sensoriem un termālajiem attēliem dažādu iemeslu dēļ iztrūkst datu, piemēram, sensoru darbības traucējumu vai datu pārraides problēmu dēļ, kas šajā darbā sīkāk aplūkoti netiek. Šie trūkumi ir bieži sastopami reālā vidē un var radīt neprecizitātes prognožu rezultātos, ja tie ir neatbilstoši apstrādāti pirms modeļa apmācības. Tāpēc gan sensoru datiem, gan termālajiem attēliem tika izvēlēta pieceja grupēt mērījumus pa stundu vidējām vērtībām. Šāda pieceja nodrošināja no mērījuma biežuma viedokļa pilnīgāku datu kopu, lai kompensētu nepilnīgi iegūtus mērījumus un uzlabotu modeļa prognozēšanas spējas (Kempelis u. c., 2021b).

Dati no katra sensora tika sākotnēji apstrādāti, lai novērstu trūkstošās vērtības un neatbilstības. Termālie attēli un sensoru mērījumi tika normalizēti, izmantojot *min-max* normalizācijas pieceju (Nuraisha & Shidik, 2018), lai nodrošinātu vienādu mērogu starp visām attēlu un sensora vērtībām pirms to izmantošanas prognozēšanai.

Tā kā ievāktajiem termālajiem datiem bija laika rindu raksturs (katrs termālais attēls tika iegūts ik pēc 15 minūtēm), līdzīgi kā citiem sensora mērījumiem, tika nolemts izpētīt potenciālās sakarības starp modeļa ievadi (termālajiem attēliem) un izejas rādījumiem (gaisa temperatūra, relatīvais gaisa mitrums, augsnes mitruma līmenis, apgaismojums). Lai uzzinātu par dažādu mērījumu savstarpējo saistību, pirms modeļa apmācības tika veikta mērījumu korelācijas analīze (Senthilnathan, 2019). Korelācija tika veikta gan starp ievāktajiem sensoru mērījumiem (3.4. att.), gan starp termokameras pikseļu temperatūras vērtībām un sensoru mērījumiem (3.5. att.). Pēc mērījumu veikšanas izveidota korelācijas matrica (3.4. att.), kas uzrādīja salīdzinoši augstāku korelāciju starp gaisa temperatūras un apgaismojuma mērījumiem.




3.4. att. Korelācijas analīze pēc mērījumu veikšanas 2024. gadā.

Ievākto datu sākotnējā analīze raksturo ievākto datu saistību ar termogrāfisko attēlu, piemēram, korelācijas analīzē. Šajā analīzē tika vērtēts, kā katrs pikselis termālajos attēlos korelē ar citiem sensoriem (gaismas, temperatūras un mitruma, kā arī augsnes sensoriem) datu vākšanas laikā.

Korelācijas analīzes rezultāti apstiprināja, ka termālie attēli cieši korelē ar tuvējo gaisa temperatūras sensoru datiem. Savukārt 3.5. attēlā redzamās korelācijas kartes parāda pikseļu vērtību un dažādu sensoru mērījumu savstarpēju saistību. Katras korelācijas kartes asis atspoguļo 120×160 pikseļu koordinātes, kas atbilst termoattēla kadra izmēriem.

Piemēram, 3.5. attēla (a) daļā pikselis, kas atrodas 0. vertikālajā un 0. horizontālajā koordinātē ($X = 0$; $Y = 0$), parādās tumšākā zonā, kas liecina par salīdzinoši augstu korelāciju ar gaisa temperatūras mērījumiem, salīdzinot ar citiem pikseliem attēlā. To apliecina korelācijas koeficients, kas pārsniedz 0,5, kā redzams blakus esošajā korelācijas skalā. Ir būtiski uzsvērt, ka šajās siltumkartēs ir atspoguļota divu mēnešu ilga korelācijas analīze, kur pikseļu vērtības tiek salīdzinātas ar attiecīgajiem laika rindu datiem par gaisa temperatūru, relatīvo gaisa mitrumu un apgaismojumu, kas tika mērīti vienlaikus. Pēc mērījumu ievākšanas LBTU Dārzkopības institūta siltumnīcā no 2024. gada jūnija sākuma līdz jūlija beigām analizēta termokameras pikseļu korelācija ar sensoru mērījumiem (3.5. att.).



3.5. att. Korelācijas ar termokameras attēla pikseliem datu vākšanas periodā 2024. gadā. Korelācijas karte veidota starp termokameras temperatūras pikseļu vērtībām un: (a) gaisa temperatūras sensora mērījumiem; (b) relatīvā gaisa mitruma sensora mērījumiem; (c) aprēķinātiem augu mitruma pietiekamības mērījumiem; (d) apgaismojuma sensora mērījumiem.

Mitruma līmeņa pietiekamība aprēķināta, izmantojot gaisa temperatūras, relatīvā gaisa mitruma un lapu virsmas temperatūras mērījumus. Šī metode atrodama vairākos pētījumos un tiek izmantota augu mitruma radītā stresa noteikšanai (*Guebsi et al., 2024*), (*Katz et al., 2023*) un ir salīdzinoši precīzāka metode mitruma līmeņa pietiekamības noteikšanai augos nekā kapacitīvā tipa sensori, jo ietver papildu informāciju par apkārtnējo vidi. Kapacitīvā tipa sensori izmantoti šī darba datu ievākšanas laikā 2023. gadā un mēra mitruma līmeni tikai augsnē, kā arī tie ir pakļauti bieži nepieciešamai mērījumu kalibrēšanai (*Abdelmoneim et al., 2025*).

3.3. Mērījumu novērtēšanas modeļu izstrāde


Promocijas darbā tika izstrādāts dziļās mācīšanās un datorredzē balstīts prototipa modulis zemeņu (*Fragaria x ananassa 'Flair'*) un aveņu (2024. gada selekcijas jaunākie atlasītie hibrīdi) augu stādu mikroklimata sensoru mērījumu prognozēšanai, precīzāk – novērtēšanai, izmantojot mērījumus, kas kopumā četrus mēnešus (2023. gada jūlijs un augusts, kā arī 2024. gada jūnijs un jūlijs) laikā tika ievākti no dažāda veida sensoriem.

Šajā pētījumā tiek pētīts apgaismojums, relatīvais gaisa mitrums, temperatūra un augsnes ūdens saturs, jo šie faktori būtiski ietekmē lapotnes temperatūru, kas ir redzama termiskā starojuma attēlos. Apgaismojums veicina fotosintēzes norisi un augu atvēršanos (*stomata*) atvēršanos, kas palielina transpirāciju un nodrošina lapu dzesēšanu. Augsts relatīvā mitruma līmenis palielina augu slimību risku. Augsnes mitruma līmenis nodrošina vai ierobežo dzesēšanas efektu, kur pietiekams augsnes ūdens saturs palīdz uzturēt lapas vēsas, savukārt mitruma deficīts izraisa lapu sasilšanu.


3.3.1. CNN modeļa izstrāde un apmācība

Ņemot vērā (*Maskey et al., 2020*) un (*Ham et al., 2019*) pētījumos apskatītās sensoru mērījumu prognozēšanas metodes, kas uzrādījušas salīdzinoši augstu precizitāti, izmantojot tieši “*VGGnet*” (*Chandrapu et al., 2022*) tipa konvolūciju tīklu arhitektūru, izvietošanai uz prototipa tika izstrādāta šī modeļa arhitektūras konfigurācija. Izmantotā arhitektūra paredzēta attēlu analīzei ar vienas vērtības (mērījuma) ieguvī modeļa izejā. Izstrādātā modeļa ieejā paredzēts izmantot termiskās kameras ģenerētās radiometriskās 120×160 pikseļu temperatūras matricas, kas iegūtas no termokameras uzņemtajiem kadriem.

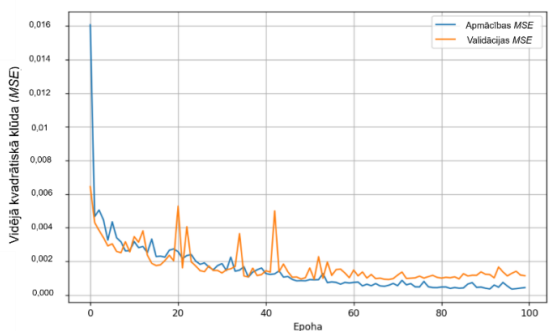
Sākotnējā apmācības procesā izmantota grafiskā karte *NVIDIA GeForce GTX1060* ar 6 GB atmiņu. Apmācībā izmantota vidējā kvadrātiskās kļūdas (*MSE*) zuduma funkcija ar *AdamW* optimizētāju. Apmācības cikls atzīmē gan apmācības, gan validācijas vidējo kvadrātisko kļūdu pēc katras epochas. Kļūdas rādītāji tika vizualizēti katram mērījumam sākotnēji pie 100 epochām (3.6. att.), lai noteiktu pārāpmācību vai nepietiekamu apmācību.



**Apgaismojuma
novērtējumi**



**Relatīvā
gaisa
mitruma
novērtējumi**



**Gaisa
temperatūras
novērtējumi**

3.6. att. Gaisa temperatūras, relatīvā mitruma un apgaismojuma apmācības kļūda dažāda epochu skaita gadījumā *CNN* apmācības laikā.

Apmācības un validācijas kļūdu salīdzinājums ir nepieciešamas, lai novērtētu modeļa veiktspēju. Apmācības kļūda tiek izskaitļota no tās datu kopas daļas, kas tiek izmantota, lai mainītu modeļa parametrus. Apmācības kļūda nosaka to, cik labi modeļa prognozes sakrīt ar tiem datiem, ko modelis jau ir izmantojis apmācības procesā. Ir sagaidāms, ka, pieaugot epochu skaitam, kļūda samazinās ar nelielām svārstībām, kas raksturo modeļa optimizācijas procesu. Validācijas kļūda šajā gadījumā tiek noteikta pēc atsevišķas datu kopas, ko modelis nav "redzējis" jeb izmantojis, un ir indikatīvs rādītājs par modeļa vispārināšanās spēju (pretēji pārāpmācībai). Ja tiktu izmantota tikai apmācības kļūda, lai noteiktu, cik ilgi apmācīt modeli,

tad tas varētu radīt pārāpmācību, kur modelis kļūtu pārāk pielāgots konkrētiem apmācības datiem. Savukārt, ja tiktu izmantota tikai validācijas kļūda bez apmācības kļūdas, tad arī nebūtu iespējams precīzi noteikt modeļa apmācības dinamiku, jo validācijas kļūda var pieaugt neatbilstošas apmācības ātruma konfigurācijas vai citu parametru, ko ir salīdzinoši sarežģīti noteikt, dēļ, ja blakus nav apmācības kļūda, ar ko salīdzināt.

- Nepietiekama apmācība (angļu val. *Underfitting*) raksturīga pirmajām epohām, kur apmācības un validācijas kļūdas ir salīdzinoši lielas.
- Optimāla modeļa vispārināšanās (angļu val. *Generalisation*) raksturīga vidusdaļai, kur apmācības kļūda turpina kristies, bet validācijas kļūda sasniedz globālu minimumu jeb līkne izlīdzinās.
- Pārāpmācība (angļu val. *Overfitting*) raksturīga gadījumos, kad apmācības kļūda krītas, bet validācijas kļūda pēc izlīdzinājuma sāk palielināties, kas skaidrojams ar to, ka apmācības kļūdas samazinājums vairs neietekmē validācijas kļūdas samazinājumu jeb prognozes modelis “nesakrīt” ar apmācībā neizmantotajiem datiem.

Tāpēc epohu skaita izvēle, kas atbilst minimālajai validācijas kļūdai, tiek pieņemta kā modeļa vispārināšanas optimums. Apskatot iegūtos rezultātus (3.6. att.), var secināt, ka piemērotākais epohu skaits katra mērījuma novērtēšanās konvolūciju tīkla modelī ir šāds:

- gaisa temperatūrai – 40 epohas;
- relatīvajam gaisa mitrumam – 60 epohas;
- apgaismojumam – 50 epohas.

Pēc tam apmācības kļūda izlīdzinās un ievērojama modeļu veikspējas uzlabošanās vairs nenotiek.


3.3.2. ViT modeļa izstrāde un apmācība

Redzes transformera modeļa realizācijai tika izmantots *PyTorch* atvērta pirmkoda dziļās mācīšanās satvars un *VitTiny* modelis (“*vit_tiny_patch16_224*”), kas ir oriģinālā redzes transformera konfigurācija ar mazāku parametru skaitu no *timm* dziļās mācīšanās modeļu bibliotēkas (*Wightman, 2022*), kas ir piemērots šajā darbā lietoto termoattēlu telpiskajam izmēram – 120×160 pikseļi. “*patch16*” norāda, ka attēls tiek sadalīts nepārklājošos 16×16 pikseļu blokos pirms to pārveidošanas par transformeru marķieriem, savukārt “*224*” nosaukumā apzīmē attēla malu garumu pikseļos, ar kādu oriģināli tika apmācīts šis transformeru arhitektūras konfigurācijas variants. “*vit_tiny_patch16_224*” modeļa svāri sākotnēji tika apmācīti ar izšķirtspēju 224×224 pikseļu ieejas attēliem. Ja ievades izmērs mainās (ir atšķirīgs no oriģinālā modeļa), tad atšķirības ir jāinterpolē, kas var nelielā mērā


ietekmēt modeļa veikspēju. Šajā gadījumā no 120×160 pikseļiem īsākā mala – 120 pikseļi – nedalās ar 16 (no attēla atdalīta bloka izmērs), tādēļ nepieciešams interpolēt papildu astoņus pikseļus, rezultātā iegūstot ieejas izmēru 128×160 (Touvron *et al.*, 2021).

Pēc modeļa apmācības, apskatot iegūtos rezultātus (3.7. att.), var secināt, ka piemērotākais epohu skaits katram mērījumam redzes transformeru modelī ir šāds:


- gaisa temperatūrai – 10 epohas;
- relatīvajam gaisa mitrumam – 45 epohas;
- apgaismojumam – 75 epohas.



**Apgaismojuma
novērtējumi**



**Relatīvā
gaisa
mitruma
novērtējumi**




**Gaisa
temperatūras
novērtējumi**


3.7. att. Gaisa temperatūras, relatīvā mitruma un apgaismojuma apmācības kļūda dažāda epohu skaita gadījumā *ViT-Tiny* apmācības laikā.

3.3.3. CvT modeļa izstrāde un apmācība


Konvolūciju redzes transformera modeļa sagatavošana ietvēra attēla apgriešanu līdz 112×112 pikseļiem. Tas darīts, jo lietotajā *timm* bibliotēkas *ConViT_Tiny* arhitektūrā attēls tiek pārvērsts par marķieru (angļu val. *token*) secīgu virkni, lietojot vienu divdimensiju konvolūciju. Tas nozīmē, ka arhitektūras ieejā paredzētā attēla platuma un garuma izmēriem ir obligāti jāsakrīt. Ņemot vērā to, ka termoattēla kreisajā pusē atrodas augi, 112×112 pikseļi ņemti no kreisā augšējā stūra, lai pēc iespējas vairāk saglabātu informāciju, kas nepieciešama mērījumu prognozei. Kļūdas rādītāji tika vizualizēti, lai noteiktu pārāpmācību vai nepietiekamu modeļa apmācību (3.8. att.).



**Apgaismojuma
novērtējumi**



**Relatīvā
gaisa
mitruma
novērtējumi**



**Gaisa
temperatūras
novērtējumi**

3.8. att. Gaisa temperatūras, relatīvā mitruma un apgaismojuma apmācības kļūda dažāda epochu skaita gadījumā *ConViT-Tiny* redzes transformera apmācības laikā.

Apskatot iegūtos rezultātus (3.8. att.), var secināt, ka apmācībai piemērotākais epohu skaits katram mērījumam konvolūciju redzes transformeru modelī ir šāds:

- gaisa temperatūrai – 10 epohas;
- relatīvajam gaisa mitrumam – 45 epohas;
- apgaismojumam – 160 epohas.

Pēc tam apmācībā ievērojama modeļu veiktspējas uzlabošanās nenotiek.

4. MĒRĪJUMU NOVĒRTĒŠANAS PIEEJAS IZSTRĀDE UN VALIDĀCIJA

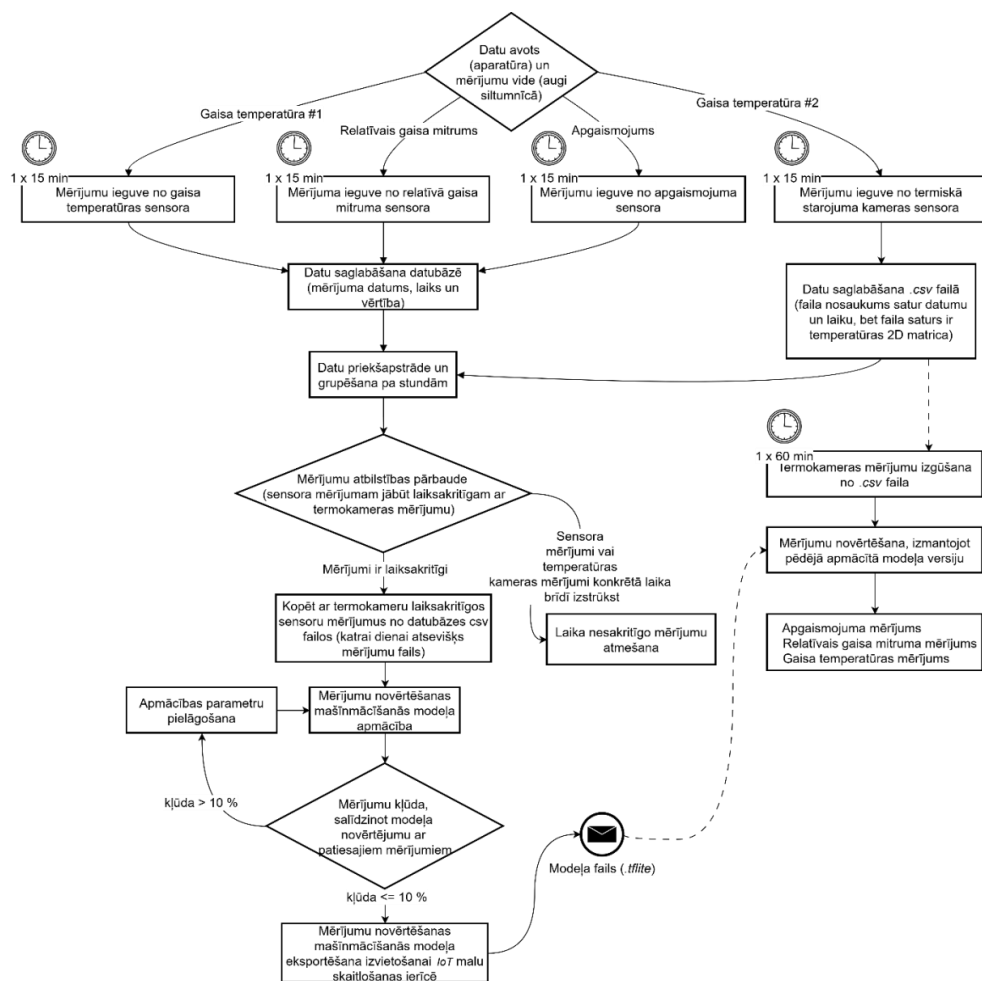
Darbā tiek izstrādāta pieeja, kas balstīta iepriekš uzbūvēto datu ievākšanas modulī, tā ievāktajos mērījumos un piemērotākā modeļa lietošanā mērījumu novērtēšanai. Lai validētu izstrādāto pieeju, tiek noskaidrotas piemērotākās modeļu veikspējas novērtēšanas metrikas un salīdzināti iegūtie mērījumu novērtēšanas modeļu rezultāti ar reālo mērierīču jeb sensoru mērījumiem, lai pārlicinātos par modeļu rezultātu ticamību un novērtētu kļūdas.

4.1. Pieejas izstrāde

Darbā izstrādātā pieeja paredz automatizētu augu vides mērījumu ievākšanu, apstrādi un novērtējumu siltumnīcās vai citās vietās, kur ir būtiska mikroklimatisko apstākļu uzraudzība precīzās lauksaimniecības kontekstā. Mērījumu novērtēšanas automatizācijai tiek izmantotas vairāku mērījumu avotu – vides jeb mikroklimata sensoru un termiskā starojuma sensora – ģenerētās datu plūsmas. Pieejas pamatā ir datu ieguve mašīnmācīšanās modeļa apmācībai, kur ar 15 minūšu intervālu tiek veikti un saglabāti gaisa temperatūras, relatīvā gaisa mitruma un apgaismojuma mērījumi. Minētais 15 minūšu intervāls nodrošina kompromisu starp datu detalizāciju un apstrādes efektivitāti, tāpēc tas tiek uzskatīts par pietiekamu, lai uztvertu būtiskas temperatūras tendences bez nozīmīga informācijas zuduma. Mērījumu vērtības tiek saglabātas datubāzē kopā ar datumu un laiku, kurā veikts katrs mērījums. Ar tādu pašu intervālu tiek ievākti arī termokameras mērījumi jeb kadri, kas tiek saglabāti kā atsevišķi faili (.csv formātā) ar datumu un laiku faila nosaukumā un divdimensiju temperatūras pikseļu matricu faila saturā.

Gan individuālo sensoru mērījumiem, gan termokameras kadriem ir nepieciešama priekšapstrāde, kas ietver laiksakrītīgo vērtību noteikšanu. Laiksakrītīgās vērtības ir mērījumi, kas sakrīt gan individuālajiem sensoru mērījumiem (gaisa temperatūra, relatīvais mitrums, apgaismojums), gan termokameras iegūtajiem kadriem. Lai maksimizētu sakrītīgos mērījumus un iegūtu pēc iespējas vairāk apmācības datu, eksperimenta ietvaros dati sagrupēti pa stundām ar vidējo vērtību katrā stundā. Ieraksti, kuriem nav sakrītīgie termālie mērījumi, vai termālie mērījumi, kuriem nav sakrītīgie sensoru mērījumu, tiek atmesti vai netiek ņemti vērā mašīnmācīšanās modeļa apmācībā, jo darba ietvaros netiek apskatīta laika rindu regresijas mērījumu prognozes jeb novērtēšana.

Lai nodrošinātu nepārtrauktu un autonomu modeļa mācīšanos, automātiski reizi diennaktī (kad mikroklimata novērošanas procesos ir vismazākā noslodze) tiek palaists mērījumu novērtēšanas modeļa apmācības process, lai iegūtu mērījumu novērtējumus un kļūdu. Modeļa veiktspēju klasificē kā pietiekamu vai nepietiekamu, izmantojot salīdzinājumu ar patiesajiem sensoru mērījumiem sakrītīgajā laika periodā. Tas ir nepieciešams, lai mazinātu kļūdu un modelis spētu pietiekami vispārināties mērījumu novērtējumam. Pieejas kopējā blokhēma dota 4.1. attēlā.



4.1. att. Mērījumu novērtēšanas pieejas blokhēma.

Pieejā minēto modeļu apmācību iespējams veikt gan malu skaitļošanas ierīcē paralēli mērījumu ievākšanas procesam, gan izmantojot augstas veiktspējas skaitļošanai paredzētu aparatūru.

4.2. Prototipa izstrāde

Prototips, kas ir saistīts ar iepriekš izstrādāto mērījumu novērtēšanas pieeju, ietver automatizētu mikroklimata mērījumu ievākšanas moduli, datu apstrādes un analīzes moduli, izmantojot termokameras un mikroklimata sensoru mērījumus. Prototips ir paredzēts kā praktisks risinājums, kas apvieno datu ievākšanas, analīzes un mašīnmācīšanās moduļu funkcionalitāti vienotā platformā, nodrošinot mērījumu novērtēšanu reālā laikā. Lai noteiktu piemērotāko arhitektūru, ko izvietot prototipa ierīcēs, tika veikts eksperimentu komplekss, izmantojot dažādas modeļu arhitektūras – konvolūciju tīklu, redzes transformeru un konvolūciju redzes transformeru hibrīdarhitektūru. Eksperimentu rezultāti ietekmē prototipa izstrādes stratēģiju, izvēloties galveno modeļarhitektūru malu skaitļošanas lietojumos precīzajā lauksaimniecībā. Tehniski prototips ietver *IoT* malu skaitļošanas ierīci ar integrētu termokameras moduli, lokālu datu apstrādes un glabāšanas programmatūru, kā arī tīmekļa lietotni reāllaika uzraudzībai un lietotāja mijiedarbības nodrošināšanai. Prototipa ierīcēm ir paredzēts darboties autonomi, periodiski ievācot datus un veicot to apstrādi lokāli, tādējādi samazinot atkarību no mākoņpakalpojumiem un nodrošinot sistēmas darbību arī ierobežotas savienojamības apstākļos.

Plānotā prototipa ieviešana paredz tā integrāciju esošajā lauksaimniecības *IoT* infrastruktūrā, nodrošinot atvērtās aparatūras un atvērtās programmatūras saderību ar citiem sensoriem un vadības ierīcēm. Tas ļauj sistēmu mērogot un pielāgot dažādu siltumnīcu vai lauku platību prasībām, vienlaikus saglabājot datu drošības un privātuma aspektus.

4.3. Eksperimentu plāns un apraksts

Pirms mērījumu novērtēšanas pieejā balstīta prototipa izstrādes nepieciešams veikt eksperimentus mērījumu novērtēšanai. Eksperimenti tiek realizēti kā eksperimentu komplekss, ko veido trīs pēc arhitektūras atšķirīgu mašīnmācīšanās modeļu apmācība.

Pētāmās problēmas nostādne. Mērījumu novērtēšanas modeļu salīdzinājums un to veikspējas analīze.

Pētāmās sistēmas modelis

Ieeja – termokameras attēli jeb temperatūras matrica.

Faktori – modeļa arhitektūra, hiperparametri (apmācības ātrums, apmācības iterāciju skaits, partijas izmērs), ieejas attēla izmērs (koordinātas).

Izeja – mērījuma novērtējums un tā atbilstība reālajam sensora mērījumam.

Eksperimentu plāns

1. Izmantojot izstrādāto datu ievākšanas prototipu un automatizētu skriptu, ievākt mērījumus.
2. Sagatavot un apstrādāt ieejas datus (temperatūras mērījumu kadrus) mašīnmācīšanās modeļu apmācībai atbilstoši modeļu arhitektūras specifikai.
3. Veikt datorredzes regresijas modeļu apmācību un salīdzināt to precizitātes.
4. Atkārtot katra modeļa apmācības procesu vairākas reizes, lai pārlicinātos par iegūto rezultātu stabilitāti un atkārtojamību.
5. Apkopot un analizēt iegūtos rezultātus.

Lai izpildītu eksperimentu plānu, tiek paredzēts veikt eksperimentu sēriju, kas ietver četrus galvenos eksperimentus. Katra eksperimenta apraksts un mērķis dots 4.1. tabulā.

4.1. tabula

Plānotie mērījumu novērtēšanas eksperimenti

Nr.	Eksperimenta apraksts	Eksperimenta mērķis
1.	Izmantojot konvolūciju tīklu arhitektūru un 2023. gadā iegūto datu kopu, apmācīti trīs konvolūciju modeļi. Apmācība atkārtota vairākas reizes, kā arī izmantojot režģa meklēšanas hiperparametru optimizācijas metodi, lai atrastu iespējami augstākās precizitātes modeļa konfigurāciju.	Noteikt konvolūciju tīklu optimālo modeļa konfigurāciju un modeļu precizitāti mērījumu (augšnes mitruma, relatīvā gaisa mitruma un apgaismojuma) novērtēšanā.
2.	Izmantojot konvolūciju tīklu arhitektūru un 2024. gadā iegūto datu kopu, apmācīti trīs konvolūciju modeļi.	Noteikt konvolūciju tīklu modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un apgaismojuma) novērtēšanā.
3.	Izmantojot redzes transformēru arhitektūru un 2024. gadā iegūto datu kopu, apmācīti trīs redzes transformēru modeļi.	Noteikt redzes transformēru modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un apgaismojuma) novērtēšanā.

Nr.	Eksperimenta apraksts	Eksperimenta mērķis
4.	Izmantojot konvolūciju redzes transformeru arhitektūru un 2024. gadā iegūto datu kopu, apmācīti trīs konvolūciju redzes transformeru modeļi.	Noteikt konvolūciju redzes transformeru modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un apgaismojuma) novērtēšanā.

Eksperimentu mērķis

Noteikt, kurš no trīs izvēlētajiem un apmācītajiem mašīnmācīšanās modeļiem ļauj veikt mērījumu novērtējumu ar salīdzinoši augstāko precizitāti un var tikt izmantots novērtēšanas pieejas ieviešanai prototipā.

Izmantojot ievākto datu kopu, tika apmācīti trīs dažādi mašīnmācīšanās modeļi. Modeļi izstrādāti ar nolūku novērtēt mērījumus – apgaismojumu, relatīvo gaisa mitrumu un gaisa temperatūru (4.2. tab.). Epohu skaits iegūts, ņemot vērā darbā iepriekš aplūkoto modeļu validācijas izpēti.

4.2. tabula

Mērījumu novērtēšanā apmācītie modeļi

	1. Modeļu kopa (<i>CNN, ViT, CvT</i>)	2. Modeļu kopa (<i>CNN, ViT, CvT</i>)	3. Modeļu kopa (<i>CNN, ViT, CvT</i>)
Modeļa ieeja	Termokameras attēla matrica 120 × 160 pikseļu (°C)	Termokameras attēla matrica 120 × 160 pikseļu (°C)	Termokameras attēla matrica 120 × 160 pikseļu (°C)
Modeļa izeja	Apgaismojums (lx)	Relatīvais gaisa mitrums (%)	Gaisa temperatūra (°C)
Hiperparametri	Apmācības ātrums – 0,001 Partijas izmērs – 16 Epohas – (<i>CNN</i> : 50, <i>ViT</i> :75, <i>CvT</i> :160)	Apmācības ātrums – 0,001 Partijas izmērs – 16 Epohas – (<i>CNN</i> : 60, <i>ViT</i> :45, <i>CvT</i> :45)	Apmācības ātrums – 0,001 Partijas izmērs – 16 Epohas – (<i>CNN</i> : 40, <i>ViT</i> :10, <i>CvT</i> :10)

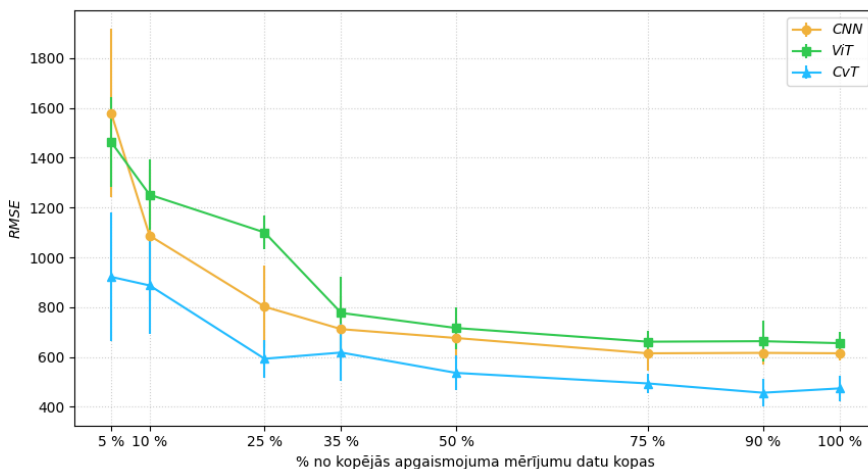
4.4. Modeļu precizitātes kopējais novērtējums

Lai novērtētu termoattēlos balstītas mērījumu novērtēšanas iespējamību, modeļi tika apmācīti vairākās iterācijās, izmantojot regresijai piemērotu zudumu funkciju – vidējo kvadrātisko kļūdu (*MSE*), kas bieži lietota, lai parādītu atšķirību starp prognozētajām jeb novērtētajām vērtībām un faktiskajām mērījumu vērtībām (*Naznin & Islam, 2023*).

VGG balstītais *CNN* modelis uzrādīja salīdzinoši augstāko precizitāti starp visiem trīs izmantotajiem modeļiem ($RMSE = 2,29\text{ }^{\circ}\text{C}$, $0,075\text{ \% RH}$, $0,059\text{ luks}$; $R^2 \geq 0,897$), izpildot 40–60 epohas. Kas liecina, ka dotajai datu kopai šādā scenārijā piedāvā stabilāko un precīzāko iespējamo alternatīvu. Savukārt *ViT-Tiny* un *CvT-Tiny*, lai gan konkurēja temperatūras mērījumu novērtēšanā, uzrādīja lielākas kļūdas mitruma un apgaismojuma mērījumu novērtēšanā.

Ņemot vērā salīdzinoši zemākas precizitātes rezultātus transformeru modeļiem un datu kopas apjomu (1053 mērījumi), nolemts atkārtot eksperimentus ar atšķirīgiem apmācības datiem, nemainot epohu skaitu. Eksperimentu atkārtēšanā izmantota šķērsvalidācijas metode, katrā eksperimentā mainot apmācības un validācijas kopu izlases. Turklāt eksperimentu ietvaros modeļu apmācība tiek atkārtota, izmantojot *K* locījuma šķērsvalidācijas pieeju, lai nodrošinātu objektīvu modeļu veikspējas novērtējumu. Papildus bija nepieciešams izmantot stratificētu *K* locījuma šķērsvalidāciju, jo apgaismojuma novērtēšanas modeļa apmācībā būtu svarīgi, lai katrā apmācības kopā eksistētu gan augsti, gan zemi apgaismojuma mērījumi (datus atspoguļojot diennakts režīmu).


Lai būtu iespējams objektīvāk salīdzināt modeļu veikspēju, veikta analīze par modeļu apmācības veikspēju, ja apmācības datu apjoms ir mainīgs. Piemēram, starp visiem apgaismojuma novērtējuma modeļiem (4.2. att.) redzams, ka visi modeļi demonstrē pastāvīgu *RMSE* samazinājumu, palielinoties apmācības datu daļai, kas liecina par novērtēšanas precizitātes uzlabošanos, palielinot apmācības datu kopas apjomu.



4.2. att. Apgaismojuma novērtējuma modeļu apmācības salīdzinājums.

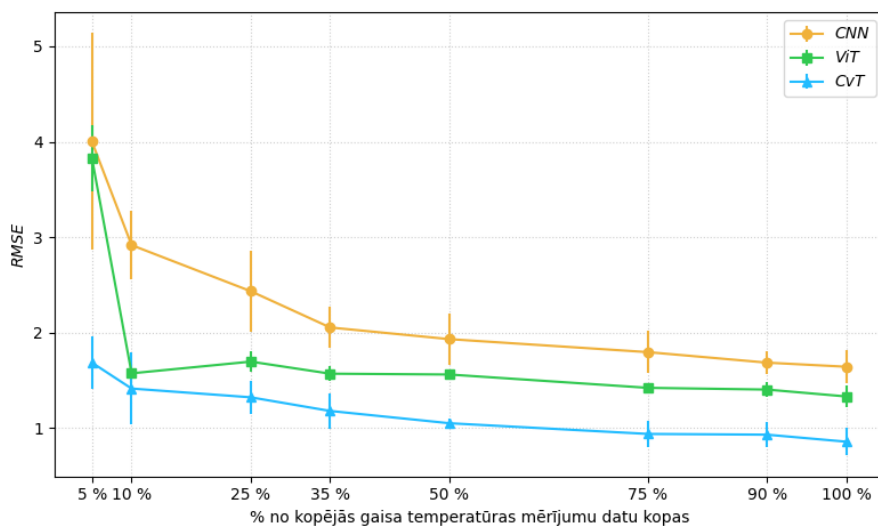
Ērtākai rezultātu interpretācijai apgaismojuma mērījumu maksimālā vērtība ir 7952,5 lx, minimālā vērtība – 0,0 lx, vidējā vērtība – 1828,94 lx, standartnovirze – 1684,49 lx. Līdz ar to izteiktākā modeļu kļūdu samazināšanās tiek novērota intervālā no 5 % līdz 35 % no kopējās datu kopas, pēc tam modeļu kļūdu samazinājums stabilizējas, kas nozīmē, ka datu kopas papildinājums varētu nedot būtisku precizitātes uzlabošanu visiem trim modeļiem. Starp modeļiem *CvT* sasniedz zemāko *RMSE* visos gadījumos.

Līdzīgi novērojumi ir, veicot relatīvā gaisa mitruma novērtējumu modeļu salīdzinājumu (4.3. att.), kur *CvT* sasniedz zemāko *RMSE* visos gadījumos pie katras datu kopas daļas. *ViT* modelis sasniedz salīdzinoši vājāku rezultātu un stabilizējas vēlāk nekā pārējie modeļi.



4.3. att. Relatīvā gaisa mitruma novērtējuma modeļu apmācības salīdzinājums.

Mazliet atšķirīgi rezultāti iegūti gaisa temperatūras novērtējumu modeļu salīdzinājumā, kur CvT modelis uzrāda zemāko $RMSE$ (4.4. att.), kas liecina par augstu vispārināšanas spēju un apmācības datu izmantošanas efektivitāti. ViT modelis uzrāda viduvēju veikspēju ar stabilu kļūdas samazinājumu, palielinoties datu apjomam, savukārt CNN modelis saglabā lielāko $RMSE$ kļūdu skaitu un stabilizējas salīdzinoši lēnāk par pārējiem modeļiem. Kopumā CvT modelis demonstrē visaugstāko spēju efektīvi mācīties, izmantojot ierobežotu datu apjomu, vienlaikus saglabājot stabilu veikspēju, izmantojot pilnu datu kopu.




4.4. att. Gaisa temperatūras novērtējuma modeļu apmācības salīdzinājums.

Rezultātā visos salīdzinājumos iespējams noteikt arī punktus, kuros datu kopas apjoma palielināšana vairs nesniedz būtisku precizitātes pieaugumu, liecinot par datu pietiekamību stabilai modeļu vispārināšanās spējai.

Pēc eksperimentu atkārtotības un šķēršvalidācijas metodes lietošanas abu transformēto modeļu salīdzinājums liecina, ka CvT uzrāda augstāku precizitāti nekā ViT visos trīs mērījumu veidos (apgaisojuma, gaisa temperatūra, relatīvais gaisa mitrums). Lielākās uzlabojuma atšķirības vērojamas apgaisojuma un relatīvā mitruma prognozēs, kur kļūdu samazinājums un R^2 pieaugums ir būtisks. Temperatūras gadījumā abi modeļi uzrāda līdzvērtīgi augstu precizitāti, bet CvT saglabā priekšrocību ar mazāku kļūdu un augstāku determinācijas koeficientu. Rezultāti liecina, ka konvolūcijas elementu integrācija transformera arhitektūrā uzlabo modeļa spēju novērtēt dotos mērījumus.


Iegūtie rezultāti apkopoti un salīdzināti arī citām kļūdu metrikām (4.5. att.). CvT

demonstrē augstāko precizitāti, ko nosaka zemākās *MAE* un *RMSE* metrikas un augstākais determinācijas koeficients, liecinot par salīdzinoši ciešāko sakarību starp termālajiem attēliem un temperatūras mērījumiem. *ViT* modelim ir lielākas kļūdas, bet joprojām augsts R^2 , savukārt *CNN* atpaliek gan pēc kļūdu lielumiem, gan pēc R^2 . Starp modeļiem novērojamas standartnovirzes ir nelielas.




4.5. att. Kļūdu un precizitātes metrikas gaisa temperatūras novērtēšanas modeļiem.

Arī relatīvā mitruma novērtējumā (4.6. att.) *CvT* viennozīmīgi pārspēj pārējos modeļus, tam ir būtiski zemāks *MAE/RMSE* un augstāks R^2 , turklāt ar mazāku variāciju starp locījumiem, kas liecina par salīdzinoši labāku vispārināmību. *CNN* pēc precizitātes ieņem otro vietu un sasniedz salīdzinoši augstāku precizitāti nekā *ViT*, kura kļūdas ir augstākas un R^2 zemāks.




4.6. att. Kļūdu un precizitātes metrikas relatīvā gaisa mitruma novērtēšanas modeļiem.

Apgaismojuma novērtējumos (4.7. un 4.8. att.) *CvT* ir salīdzinoši labākais modelis (ar zemāko *MAE/**RMSE* un augstāko R^2 koeficientu). *CNN* nedaudz apsteidz *ViT*, sasniedzot augstāku R^2 un mazākas kļūdas. Standartnovirzes modeļiem ir salīdzinoši mērenas, kas liecina par pietiekamu stabilitāti starp šķersvalidācijas locījumiem.




4.7. att. *MAE*, *RMSE* salīdzinājums apgaismojuma novērtēšanas modeļiem.



4.8. att. R^2 salīdzinājums apgaismojuma novērtēšanas modeļiem.

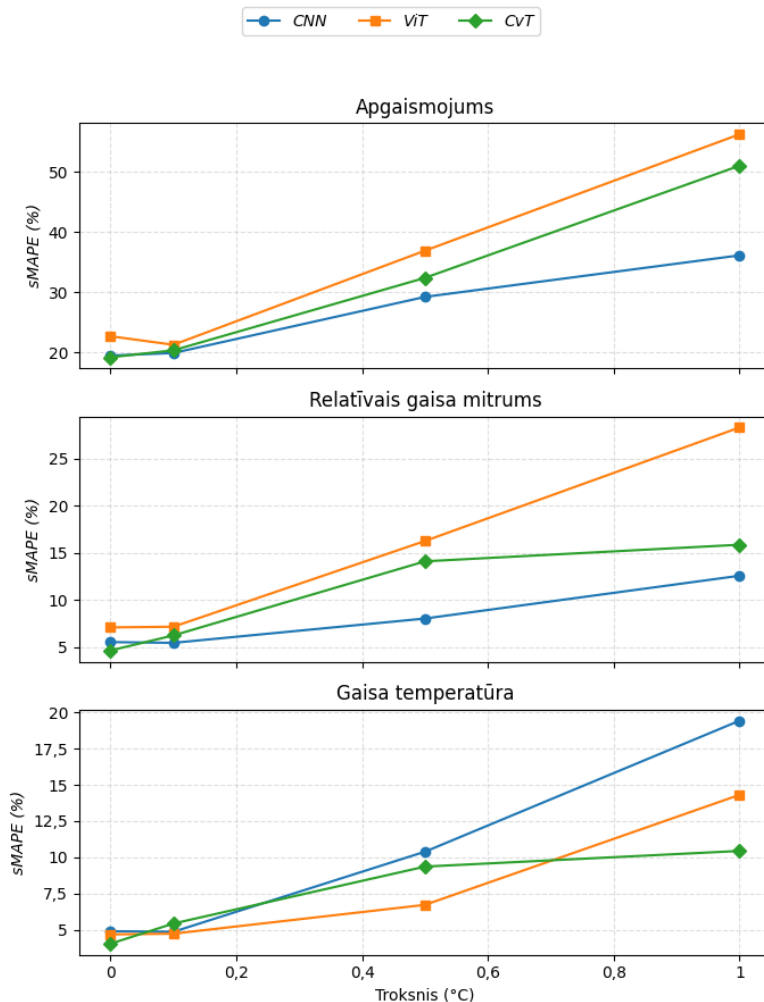
Kopumā *CvT* veikspēja dominē visu trīs mērījumu novērtēšanā. Šie rezultāti kopumā apstiprina, ka transformeru arhitektūras, papildinātas ar *CNN* īpašībām, termālo attēlu regresijā

spēj sasniegt augstāko precizitāti arī apmācības procesā, izmantojot salīdzinoši nelielu datu kopu. Tomēr, lai vairāk pārliecinātos par hibrīdo konvolūciju transformeru veikspējas stabilitāti pēc modeļu apmācības, tika izvēlēti un no visiem modeļiem atlasīti salīdzinoši augstākās precizitātes locījuma modeļi, uz kuriem pārbaudīta un salīdzināta noturība pret troksni attēlos. Tas darīts, lai imitētu trokšņainus datus modeļu ieejā, kas varētu rasties dažādu ārēju apstākļu ietekmē vai termiskā starojuma sensora nolietojuma rezultātā, kas var radīt neprecizitātes ievāktajos datos (Juan *et al.*, 2024). Viens no variantiem, kā imitēt sensora nolietojumu, ir izmantot Gausa troksni (Chowdhury *et al.*, 2017). Gausa troksnis raksturo kļūdu mērījumos, kuru vērtības izriet no normālā jeb Gausa varbūtības sadalījuma ar vidējo vērtību 0 un noteiktu standartnovirzi. Eksperimentu veikšanai mākslīgi izveidotas dažāda trokšņainības līmeņu termoattēlu datu kopas, izmantojot Gausa filtru. Katra pikseļa vērtība tiek neatkarīgi izmainīta, izmantojot šo troksni, kas raksturo nelielas svārstības ap patieso mērījumu, piemēram, tās, kas rodas sensora termiskā trokšņa ietekmē (Wantao *et al.*, 2025). Termālajos attēlos Gausa troksnis ar standartnovirzi σ rada aptuveni $\pm\sigma$ °C nesekārtību katram pikselim, kas izmantots trokšņaino datu kopu izveidē (4.9. att.).



4.9. att. Dažāda līmeņa trokšņaino datu piemērs.

Analizējot rezultātus, iespējams secināt, ka salīdzinoši lielākā noturība pret trokšņainiem ieejas datiem ir *CNN* modelim, novērtējot divus no trīs jeb apgaismojuma un relatīvā gaisa mitruma mērījumus (4.10. att.).



4.10. att. Modeļu salīdzinājums dažādu trokšņa līmeņu gadījumā katram mērījuma veidam.

CNN modelis saglabāja zemāko relatīvo kļūdu gan apgaismojuma, gan relatīvajam gaisa mitrumam ar lēnāku *SMAPE* pieaugumu, palielinoties trokšņa līmenim, kas liecina par konvolūcijas arhitektūras noturību pret trokšņa pieaugumu. Konvolūciju redzes transformers saglabāja salīdzinoši augstāku noturību pret trokšņa pieaugumu attēlos.

4.5. Pieejas ieviešanas metodika

Lai būtu iespējams izmantot darbā iegūtos rezultātus un izstrādāto pieeju būtu iespējams praktiski ieviest lauksaimniecībā augu uzraudzības procesos, darbā tiek piedāvāta pieejas ieviešanas metodika. Ņemot vērā literatūras analīzē atklātās lietu interneta tīklu arhitektūras, kas veiksmīgi tiek lietotas lauksaimniecībā, metodika galvenokārt balstīta pieejas integrēšanā esošos lauksaimniecību *IoT* tīklos. Šajā darbā izstrādātās pieejas komponentes ir mērījumu novērtēšanas ierīce (kas var būt arī vairākas ierīces), kas izvietota siltumnīcas vidē, ierīcē izvietots mašīnmācīšanās modelis mērījumu novērtēšanai, skripti modeļa palaišanai un datu ievākšanai no ierīces termokameras moduļa, arī tīmekļa lietotne lokālai un starptautiskai komunikācijai.

Minētās mērījumu novērtēšanas pieejas ieviešanas metodika ietver vairākus posmus.

- Mērījumu novērtēšanas vadlīniju definēšana.
- Konceptuālo modeļa izstrādi (definējot resursus, struktūru, parametrus un citus atribūtus vai komponentes).
- *IoT* komponentu definēšana.
- Funkcionālo vadlīniju definēšana.
- Ierīču un komponentu integrācija (komunikāciju tīkli, izvietošanas metodes, datu uzglabāšanas metodes un izmantotās ierīces).
- Lietotāja saskarnes izstrāde.

Informācijas un datu drošības aspekti pieejas ieviešanas metodikas izveidē paredz izmantot nozarē plaši zināmās un pieņemtās vadlīnijas, tāpēc šajā promocijas darbā tie atsevišķi aprakstīti netiek.

REZULTĀTI UN SECINĀJUMI

Promocijas darba rezultāti

Promocijas darbā veikta plaša zinātniskās literatūras analīze par *IoT* sensoru un datorredzes tehnoloģiju izmantošanu precīzajā lauksaimniecībā.

Izstrādāts atvērtā pirmkoda un atvērtās aparatūras risinājumos balstīts prototipa datu ievākšanas modulis. Četru mēnešu periodā (2023. gada jūlijs–augusts un 2024. gada jūnijs–jūlijs) ievākti mērījumi un kopā iegūti 6592 radiometriski termoattēli (120×160 pikseļi) un 4860 mikroklimata mērījumi (gaisa temperatūra, relatīvais gaisa mitrums, augsnes mitrums un apgaismojums).

Veikta korelācijas analīze starp termoattēlu pikseļiem un mikroklimata mērījumiem. Korelācijas analīzes rezultāti liecināja par vairāku atsevišķu mērījumu savstarpējo saistību. Rezultāti uzrādīja augstu pozitīvu saistību ar gaisa temperatūru ($r = 0,9$), vidēju negatīvu saistību ar relatīvo mitrumu ($r = -0,5$) un pozitīvu saistību ar apgaismojumu ($r = 0,77$).

Izstrādāti un vairāku eksperimentu gaitā salīdzināti trīs dziļās mācīšanās modeļi – konvolūciju neironu tīkls, redzes transformeru un konvolūciju transformeru hibrīds jeb konvolūciju redzes transformeru modelis mikroklimata mērījumu novērtēšanai no termoattēliem.

Modeļu salīdzinošā analīze atklāja, ka redzes transformeru modelis uzrāda salīdzinoši augstāko precizitāti visu mērījumu novērtēšanā, pie oriģinālās datu kopas sasniedzot šādus rezultātus:

- gaisa temperatūras novērtējumos ($RMSE = 0,86$ °C, $R^2 = 0,969$);
- relatīvā gaisa mitruma novērtējumos ($RMSE = 3,75$ % RH, $R^2 = 0,943$);
- apgaismojuma novērtējumos ($RMSE = 474$ lx, $R^2 = 0,920$).

Redzes transformeru modelis saglabāja arī salīdzinoši augstāko precizitāti, veicot tā apmācību, ja ir ierobežotas datu kopas apjoma daļas.

Sistemātiski tika testēta arī visu trīs augstākās precizitātes apmācīto modeļu noturība un stabilitāte pret trokšņainiem ieejas datiem. Rezultātā augstāko noturību pret trokšņa pieaugumu termoattēlos apgaismojuma un relatīvā gaisa mitruma novērtēšanā uzrādīja CNN modelis, uzrādot zemāku simetrisko vidējo absolūto procentuālo kļūdu nekā konvolūciju transformera modelis.

Rezultāti pierādīja augstu saistību starp termoattēlu radiometrisko attēlu vērtībām un vairākiem būtiskiem mikroklimata mērījumiem (gaisa temperatūru, relatīvo gaisa mitrumu, augsnes mitruma līmeņa, apgaismojumu). Modeļu veikspēja validēta ar šķērsvalidācijas

metodi, kas apstiprināja stabilu rezultātu iegūšanu neatkarīgi no apmācības kopas izlases.

Izstrādāta mērījumu novērtēšanas pieeja, tajā balstīts prototips, kā arī aprakstīta pieejas ieviešanas metodika, mērījumu novērtēšanas integrēšanai precīzās lauksaimniecības *IoT* tīklos.

Pēc iegūto rezultātu apkopošanas un analīzes var secināt, ka abas darba ievadā definētas tēzes ir apstiprinātas.

1. Izmantojot izstrādāto mikroklimata mērījumu novērtēšanas pieeju, kas ietver konvolūciju redzes transformera modeli, ir iespējams iegūt mērījumu novērtējumu, kas ir salīdzinoši precīzāks relatīvā gaisa mitruma, apgaismojuma un gaisa temperatūras sensoru mērījumiem nekā konvolūciju vai redzes transformera pamata modeļiem.
2. Izmantojot apmācīto konvolūciju redzes transformera mikroklimata mērījumu novērtēšanas modeli, ir iespējams sasniegt 80 % vai augstāku precizitāti relatīvā gaisa mitruma, apgaismojuma un gaisa temperatūras sensoru mērījumiem.

Promocijas darba secinājumi

Mērījumu prognozēšana un novērtēšana no attēlu datiem līdz šim nav tikusi pietiekami plaši aprakstīta starptautiskajās zinātniskajās publikācijās, kas motivēja arī šī pētījuma veikšanu. Šī darba nozīmīgākais zinātniskais ieguldījums ir jaunas dziļās mācīšanās pieejas formulēšana mikroklimata mērījumu novērtēšanai no termoattēliem, demonstrējot transformera un konvolūciju arhitektūru priekšrocības un ierobežojumus trokšņainos, ierobežota apjoma datu apstākļos precīzās lauksaimniecības kontekstā.

Datorredzes un dziļās mācīšanās metodes ļauj efektīvi novērtēt mikroklimata mērījumus no termoattēliem, sasniedzot augstu precizitāti. Mašīnmācīšanās modeļu lietojums ļauj saglabāt zemas augu uzraudzības izmaksas un dod potenciālu integrācijai resursu ierobežotās *IoT* ierīcēs.

Uz izstrādātā prototipa pamata ir iespējams papildināt jau esošu lauksaimniecības *IoT* tīklu ar termiskā starojuma un cita veida vizuālās uztveršanas ierīcēm, lai veiktu ievāktu datu analīzi un turpinātu uzlabot prototipa reāllaika mērījumu novērtēšanu.

Rezultāti sniedz teorētisku un praktisku pamatu nākotnes risinājumiem, kas ļaus aizvietot vai papildināt tradicionālos sensoru tīklus ar termoattēlu analīzi, būtiski samazinot datu iegūšanas izmaksas un enerģijas patēriņu *IoT* sistēmās.

Darbā izstrādātā jauna dziļās mācīšanās pieeja mikroklimata mērījumu novērtēšanai papildina zināšanas par netiešo mērījumu izmantošanu lauksaimniecības augu uzraudzības sistēmās.

Sistemātisks modeļu salīdzinājums atklāja, ka hibrīdā *CvT-Tiny* arhitektūra nodrošina augstāko precizitāti visos trijos mērījumu novērtēšanas uzdevumos, kā arī spēj saglabāt šo precizitāti ar ierobežotu apmācībā izmantotās datu kopas apjomu, par ko līdz šim vēl nav veikti pētījumi. *CNN* modeļi saglabā arī augstu precizitāti relatīvā mitruma un apgaismojuma novērtēšanā, īpaši tad, ja ieejas attēlu datos rodas troksnis. Troksnis datos precīzās lauksaimniecības kontekstā var būt bieži sastopams dažādu ārējo apstākļu vai ierīces nolietojuma rezultātā. Tas ir viens no šī darba svarīgākajiem zinātniskajiem jaunieguvumiem, jo parāda, ka *CNN* modeļi vai *CvT* kopā ar *CNN* arhitektūras modeļiem būtu salīdzinoši piemērotāki precīzās lauksaimniecības kontekstā sensoru mērījumu novērtējumos. Darba ietvaros tiek kvantitatīvi novērtēts, kā prognozēšanas nenoteiktība palielinās trokšņa ietekmē dažādās arhitektūrās, tādējādi atklājot atšķirības datorredzes nozarē jaunāko arhitektūru veikspējā. Tas sniedz jaunu teorētisku ieskatu par transformera un konvolūciju arhitektūru priekšrocībām un ierobežojumiem atkarībā no datu apjoma, trokšņainiem datiem un uzdevuma.

Atšķirībā no līdzšinējiem darbiem, kas koncentrējās uz tiešo sensoru datu analīzi vai vienas arhitektūras izmantošanu, šajā pētījumā veikts sistemātisku trīs dažādu dziļās mācīšanās modeļu salīdzinājums ar īpašu uzsvāru uz trokšņa noturību un datu ierobežojumiem, kas līdz šim literatūrā nav detalizēti analizēti.

Šie novērojumi paplašina teorētisko izpratni par transformera modeļu stabilitāti un to apmācības dinamikas īpatnībām precīzās lauksaimniecības uzdevumos.

Kopumā pētījums apliecina, ka mikroklimate parametru netieša novērtēšana no termoattēliem ir ne tikai tehniski iespējama, bet arī praktiski realizējama ar augstu precizitāti. Tas iezīmē jaunu virzienu precīzās lauksaimniecības attīstībā, kur viedās vizuālās sistēmas kļūst par pilnvērtīgu alternatīvu tradicionālajiem sensoriem un paver iespējas ekonomiski efektīvākai un ilgtspējīgākai datu ievākšanai.

Pētījuma ierobežojumi

Pētījuma ierobežojumi ir saistīti ar relatīvi nelielu un sezonāli ierobežotu datu kopu, kas iegūta konkrētā nemainīgā lokācijā, kā arī ar faktu, ka testētās arhitektūras tika adaptētas konkrētajam uzdevumam, nevis veidotas pilnībā no jauna. Starp šī pētījuma ierobežojumiem jāmin arī termālās kameras mērījumu raksturiezīmes, t. i., spēja tiešā veidā uztvert tikai virsmas temperatūru. Kā zināms, gaisa temperatūras, apgaismojuma un relatīvā mitruma mērījumus var ietekmēt ārējie faktori, piemēram, gaisa spiediens, tvaika spiediena deficīts un citi, kuru ietekme uz mērījumiem ir ārpus šī darba tvēruma. Minētos ierobežojumus varētu novērst turpmākos pētījumos ar modeļu apmācību, ietverot ilgākā laika periodā ievāktus mērījumus, trokšņainus

mērījumus un papildu zināmus parametrus vietā, kur mērījumu novērtēšanas pieeja tiek izmantota, piemēram, par ēnojumu, saules gaismas leņķi, atspīdumu, kā arī izmantojot meteoroloģisko staciju datus par vidējo gaisa temperatūru, nokrišņiem, vēja ātrumu un gaisa mitrumu reģionā u. c.. Lai nodrošinātu modeļu vispārināmību, nepieciešama plašāka datu kopa, ietverot arī dažādus gadalaikus, augus un audzēšanas vides, tajā skaitā, veicot mērījumu novērtējumus ārpus siltumnīcas.

Turpmākie pētījuma virzieni

Lai izteiktāk pamatotu termoattēlu izmantošanu mikroklimata mērījumu novērtēšanā, nepieciešams paplašināt datu kopu dažādos gadalaikos, reģionos, aplūkojot arī citus kultūraugus un audzēšanas apstākļus (gan siltumnīcās, gan ārpus tām). Tas ļautu uzlabot modeļu vispārināšanās spējas novērtējumu dažādos precīzās lauksaimniecības scenārijos.

Pētījumā atklātā transformera arhitektūru jutība pret troksni attēlos liecina par nepieciešamību teorētiski un praktiski analizēt trokšņainu datu ietekmi uz modeļa stabilitāti un apmācību. Tāpēc varētu veikt datu paplašināšanas stratēģiju izpēti transformera arhitektūrās, piemēram, lietot trokšņainus datus modeļu apmācībā vai vairāku termoattēlu vēsturisko datu kopu modeļa apmācībā viena konkrēta mērījuma novērtēšanai, lai mašīnmācīšanās modelim dotu plašāku kontekstu precizitātes uzlabojumiem. Balstoties iespējā prognozēt mikroklimata mērījumus no termoattēliem, nākotnes pētījumos jāizstrādā metodikas, kas kombinē termālos, spektrālos un cita veida attēlus ar tiešo mērījumu sensoriem. Tas ļautu validēt mērījumu novērtēšanas pieejas pārākumu pār citām pieejām un paplašināt zināšanas par dažādu mērījumu savstarpējām sakarībām.

Lai uzlabotu iegūto rezultātu teorētisko vērtību, nepieciešams pētīt, kā izstrādātie modeļi darbojas ar citiem augiem un dažādos klimatiskajos reģionos, kā arī formulēt nosacījumus, kuros modeļu pārnese nodrošina pietiekamu precizitāti. Nākotnes pētījumos būtu lietderīgi izstrādāt modeļus, kas termoattēlu un citu vizuālo datu analīzē ļauj novērtēt arī tādus būtiskus mērījumus kā gaismas spektru, tvaika spiedienu un citus. Šāda pieeja papildinātu teorētisko ietvaru par mikroklimata mērījumu novērtēšanu bez tiešo sensoru izmantošanas.

IZMANTOTIE INFORMĀCIJAS AVOTI

Ar pilnu promocijas darbā izmantoto informācijas avotu sarakstu var iepazīties pilnajā promocijas darba versijā.

- Abdelmoneim, A. A., Al Kalaany, C. M., Khadra, R., Derardja, B., & Dragonetti, G. (2025). Calibration of low-cost capacitive soil moisture sensors for irrigation management applications. *Sensors*, 25(2), 343. <https://doi.org/10.3390/s25020343>
- Agriplanting. (n.d.). Advantages and disadvantages of precision farming. Retrieved December 11, 2024, from <https://agriplanting.com/advantages-and-disadvantages-of-precision-farming>
- Akilan, T., & Baalamurugan, K. M. (2024). Automated weather forecasting and field monitoring using GRU-CNN model along with IoT to support precision agriculture. *Expert Systems with Applications*, 249, 123468. <https://doi.org/10.1016/j.eswa.2024.123468>
- Almutawa, N., & Eid, W. (2023). Soil moisture content estimation using active infrared thermography technique: An exploratory laboratory study. *Kuwait Journal of Science*, 50, 399–404.
- Badidi, E. (2023). Edge AI for early detection of chronic diseases and the spread of infectious diseases: Opportunities, challenges, and future directions. *Future Internet*, 15, 370.
- Baglat, P., Hayat, A., Mendonça, F., Gupta, A., Mostafa, S. S., & Morgado-Dias, F. (2023). Non-destructive banana ripeness detection using shallow and deep learning: A systematic review. *Sensors*, 23(2), 738. <https://doi.org/10.3390/s23020738>
- Chandrapu, R. R., Pal, C., Nimbekar, A. T., & Acharyya, A. (2022). SqueezeVGGNet: A methodology for designing low complexity VGG architecture for resource constraint edge applications. In *Proceedings of the 2022 20th IEEE Interregional NEWCAS Conference (NEWCAS)* (pp. 109–113). IEEE. <https://doi.org/10.1109/NEWCAS52662.2022.9841955>
- Chowdhury, D., Gupta, S., Roy, D., Sarkar, D., Chattopadhyay, C., & Das, S. (2017). A quantum study on digital image noises and their in-depth clusterization. In *Proceedings of OPTRONIX 2017* (pp. 1–7). IEEE. <https://doi.org/10.1109/OPTRONIX.2017.8349973>
- De Silva, M., & Brown, D. (2023). Multispectral plant disease detection with vision transformer–convolutional neural network hybrid approaches. *Sensors*, 23, 8531. <https://doi.org/10.3390/s23208531>

- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Hounsby, N. (2020). An image is worth 16×16 words: Transformers for image recognition at scale. arXiv. <https://arxiv.org/abs/2010.11929>
- Elektrokit. (n.d.). Adafruit VEML7700 Ijussensor I2C. Retrieved May 10, 2025, from <https://www.elektrokit.com/en/adafruit-veml7700-ijussensor-i2c>
- Grand View Research. (2023). Agriculture sensor market size, share & trends analysis report by type, by application (dairy management, soil management, climate management, water management, others), by region, and segment forecasts, 2025–2030. Retrieved June 29, 2025, from <https://www.grandviewresearch.com/industry-analysis/agriculture-sensor-market-report>
- Grobotronics. (n.d.). BH1750 light sensor. Retrieved May 10, 2025, from <https://grobotronics.com/light-sensor-bh1750.html?sl=en>
- GroupGets. (n.d.). FLIR Lepton 3.5. Retrieved May 10, 2025, from <https://groupgets.com/products/flir-lepton-3-5>
- GroupGets. (n.d.). PureThermal 2 datasheet (Version 1.7). Retrieved May 10, 2025, from <https://groupgets-files.s3.amazonaws.com/PT2/PureThermal%20%20-%20Datasheet%20-%201.7.pdf>
- Guebsi, R., Mami, S., & Chokmani, K. (2024). Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges. *Drones*, 8, 686. <https://doi.org/10.3390/drones8110686>
- Habib, T., Raza, D. M., Islam, M., Victor, D. B., & Arif, A. I. (2022). Applications of computer vision and machine learning in agriculture: A state-of-the-art glimpse. In *Proceedings of the 2022 International Conference on Innovative Trends in Information Technology (ICITIIT)* (pp. 1–5).
- Ham, Y.-G., Kim, J.-H., & Luo, J.-J. (2019). Deep learning for multi-year ENSO forecasts. *Nature*, 573, 568–572.
- Handson Technology. (n.d.). BH1750 light intensity sensor specification document. Retrieved June 21, 2025, from <https://www.handsontec.com/dataspecs/sensor/BH1750%20Light%20Sensor.pdf>
- Henrichs, E., Noack, T., Pinzon Piedrahita, A. M., Salem, M. A., Stolz, J., & Krupitzer, C. (2022). Can a byte improve our bite? An analysis of digital twins in the food industry. *Sensors*, 22(1), 115. <https://doi.org/10.3390/s22010115>

- Hsieh, C.-T. (2021). Development of a low-cost and Raspberry-based thermal imaging system for monitoring human body temperature. In Proceedings of the 2021 16th International Microsystems, Packaging, Assembly and Circuits Technology Conference (IMPACT) (pp. 248–251).
- Jia, W., Guo, Q., Lyu, M., & Zan, W. (2026). Dynamic reliability analysis of systems under combined Gaussian and Poisson white noise by time-varying extreme value process. *Reliability Engineering & System Safety*, 265(B), 111514. <https://doi.org/10.1016/j.ress.2025.111514>
- Katz, L., Ben-Gal, A., Litaor, M. I., Naor, A., Peeters, A., Goldshtein, E., Lidor, G., Keisar, O., Marzuk, S., & Alchanatis, V. (2023). How sensitive is thermal image-based orchard water status estimation to canopy extraction quality? *Remote Sensing*, 15(5), 1448. <https://doi.org/10.3390/rs15051448>
- KBV Research. (2022). Global agriculture sensor market size, share & industry trends analysis report by type (location sensors, livestock sensors, optical sensors, water sensors, others), by application, by regional outlook and forecast, 2021–2027. Retrieved June 29, 2025, from <https://www.kbvresearch.com/agriculture-sensor-market/amp/>
- Kempelis, A., Romanovs, A., & Patlins, A. (2021a). Implementation of machine learning based approach in IoT network prototype. In Proceedings of the 2021 IEEE 9th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE) (pp. 1–6). IEEE. <https://doi.org/10.1109/AIEEE54188.2021.9670255>
- Kempelis, A., Romanovs, A., & Patlins, A. (2021b). Design and implementation of IoT network prototype to facilitate the food production process in agriculture. In Proceedings of the IEEE EUROCON 2021 – 19th International Conference on Smart Technologies (pp. 71–76). IEEE. <https://doi.org/10.1109/EUROCON52738.2021.9535556>
- Kempelis, A., Romanovs, A., & Patlins, A. (2022). Using computer vision and machine learning-based methods for plant monitoring in agriculture: A systematic literature review. In Proceedings of the 2022 63rd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS) (pp. 1–6).
- Khadas. (2022). VIM1S product page. Retrieved February 3, 2025, from <https://www.khadas.com/product-page/vim1s>
- Khanna, A., & Kaur, S. (2023). An empirical analysis on adoption of precision agricultural techniques among farmers of Punjab for efficient land administration. *Land Use Policy*,

- 126, 106533. <https://doi.org/10.1016/j.landusepol.2022.106533>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (Vol. 25). <https://doi.org/10.1145/3065386>
- Liu, G., Zhong, K., Li, H., Chen, T., & Wang, Y. (2024). A state-of-the-art review on time series forecasting with machine learning for environmental parameters in agricultural greenhouses. *Information Processing in Agriculture*, 11(2), 143–162. <https://doi.org/10.1016/j.inpa.2022.10.005>
- Liu, J., Jiang, W., Han, H., He, M., & Gu, W. (2023). Satellite internet of things for smart agriculture applications: A case study of computer vision. In *Proceedings of the 2023 20th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)* (pp. 66–71).
- Mamabolo, E., Mashala, M. J., Mugari, E., Mogale, T. E., Mathebula, N., Mabitsela, K., & Ayisi, K. K. (2025). Application of precision agriculture technologies for crop protection and soil health. *Smart Agricultural Technology*, 12, 101270. <https://doi.org/10.1016/j.atech.2025.101270>
- Martín, J., Sáez, J. A., & Corchado, E. (2024). Tackling the problem of noisy IoT sensor data in smart agriculture: Regression noise filters for enhanced evapotranspiration prediction. *Expert Systems with Applications*, 237, 121608. <https://doi.org/10.1016/j.eswa.2023.121608>
- Maskey, M., Ramachandran, R., Ramasubramanian, M., Gurung, I., Freitag, B., Kaulfus, A., Bollinger, D., & Cecil, D. J. (2020). Deepti: Deep-learning-based tropical cyclone intensity estimation system. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 4271–4281.
- Miletičev, R., Damyanov, I., Iontchev, E., & Yordanov, R. (2020). Smart in-vehicle environment monitoring system. In *Proceedings of the International Conference on Electronics and Telecommunications (ET)* (pp. 1–4). <https://doi.org/10.1109/ET50336.2020.9238166>
- Morella, P., Lambán, M. P., Royo, J., & Sánchez, J. C. (2023). Vertical farming monitoring: How does it work and how much does it cost? *Sensors*, 23(7), 3502. <https://doi.org/10.3390/s23073502>
- Naznin, I., & Islam, M. (2023). Age estimation from face image leveraging concatenated features of vision transformer along with ResNet-50. In *Proceedings of the 2023 International Conference on Computer and Information Technology (ICCIIT)* (pp. 1–6).

<https://doi.org/10.1109/ICCIT60459.2023.10441470>

- Nouaze, J. C., Kim, J. H., Jeon, G. R., & Kim, J. H. (2022). Monitoring of indoor farming of lettuce leaves for 16 hours using electrical impedance spectroscopy (EIS) and double-shell model (DSM). *Sensors*, 22(24), 9671. <https://doi.org/10.3390/s22249671>
- Nuraisha, S., & Shidik, G. F. (2018). Evaluation of normalization in fake fingerprint detection with heterogeneous sensor. In *Proceedings of the 2018 International Seminar on Application for Technology of Information and Communication* (pp. 83–86).
- Padhiary, M., Hoque, A., Prasad, G., Kumar, K., & Sahu, B. (2025). Precision agriculture and AI-driven resource optimization for sustainable land and resource management. In *Advances in smart agriculture and sustainability* (Chapter 9). <https://doi.org/10.4018/979-8-3693-8074-1.ch009>
- Padhiary, M., Saha, D., Kumar, R., Sethi, L. N., & Kumar, A. (2024). Enhancing precision agriculture: A comprehensive review of machine learning and AI vision applications in all-terrain vehicles for farm automation. *Smart Agricultural Technology*, 8, 100483. <https://doi.org/10.1016/j.atech.2024.100483>
- Polo Rodríguez, A., Montoro-Lendinez, A., Espinilla, M., & Medina, J. (2022). Classifying sport-related human activity from thermal vision sensors using CNN and LSTM. In *Proceedings / Lecture Notes in Computer Science series* (pp. unknown). https://doi.org/10.1007/978-3-031-13321-3_4
- Priva. (2024). Wireless sensors for enhanced monitoring and control. Retrieved December 11, 2025, from <https://www.priva.com/horticulture/solutions/greenhouse-sensors/wireless-sensors>
- Sanaeifar, A., Guindo, M. L., Bakhshipour, A., Fazayeli, H., Li, X., & Yang, C. (2023). Advancing precision agriculture: The potential of deep learning for cereal plant head detection. *Computers and Electronics in Agriculture*, 209, 107875. <https://doi.org/10.1016/j.compag.2023.107875>
- Senthilnathan, S. (2019). Usefulness of correlation analysis. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3416918>
- Silva, G. F. C., Goncalves, A. C. A., da Silva Junior, C. A., Nanni, M. R., Facco, C. U., Cezar, E., & da Silva, A. A. (2016). NDVI response to water stress in different phenological stages in culture bean. *Journal of Agronomy*, 15, 1–10. <https://doi.org/10.3923/ja.2016.1.10>
- SparkFun Electronics. (n.d.). VEML7700 sensor datasheet. Retrieved June 21, 2025, from

- https://cdn.sparkfun.com/assets/a/2/b/a/4/VEML7700_Datasheet.pdf
- Texas Instruments. (n.d.). HDC1080 humidity and temperature sensor datasheet. Retrieved June 21, 2025, from <https://www.ti.com/lit/ds/symlink/hdc1080.pdf>
- Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., & Jégou, H. (2021). Training data-efficient image transformers & distillation through attention. In Proceedings of the 38th International Conference on Machine Learning (pp. 10347–10357).
- Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., & Jégou, H. (2021). Training data-efficient image transformers and distillation through attention. arXiv. <https://doi.org/10.48550/arXiv.2012.12877>
- Wightman, R. (n.d.). timm library documentation. Retrieved May 19, 2025, from <https://timm.fast.ai/>
- Yin, H., Cao, Y., Marelli, B., Zeng, X., Mason, A., & Cao, C. (2021). Smart agriculture systems: Soil sensors and plant wearables for smart and precision agriculture. *Advanced Materials*, 33, 2170156. <https://doi.org/10.1002/adma.202170156>
- Zhao, W., Dong, X., Wu, Z., Wei, C., Li, L., Yu, D., Fan, X., & Ma, Y. (2022). Using infrared thermal imaging technology to estimate the transpiration rate of citrus trees and evaluate plant water status. *Journal of Hydrology*, 615(A), 128671.



Artūrs Ķempelis dzimis Liepājā, Latvijā. Rīgas Tehniskajā universitātē (RTU) ieguvis bakalaura grādu datorvadībā un datorzinātnē (2019) un maģistra grādu informācijas tehnoloģijā (2021). Strādājis par programmatūras izstrādātāju, kopš 2022. gada ir RTU Datorzinātnes, informācijas tehnoloģijas un enerģētikas fakultātes Informācijas tehnoloģijas institūta zinātniskais asistents un datorzinātņu jomas mācībspēks, kā arī ir programmēšanas un datorzinātņu mācību priekšmetu skolotājs RTU Inženierzinātņu vidusskolā un RTU Starptautiskajā zinātņu un tehnoloģiju skolā. Zinātniskās intereses saistītas ar zemas veiktspējas ierīču skaitļošanas metodēm un autonomām bezsaistes sistēmām.