


**Artūrs Ķempelis**

**MAŠĪNMĀCĪŠANĀS BALSTĪTA  
MĒRĪJUMU NOVĒRTĒŠANAS PIEEJA  
PRECĪZAJAI LAUKSAIMNIECĪBAI**

Promocijas darbs



**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 darbs**

Zinātniskie vadītāji:

asoc. profesors

*Dr. sc. ing.* ANDREJS ROMĀNOVS

*Dr. sc. ing.* ANTONS PATĻINS

Rīga 2026

## ANOTĀCIJA

Atslēgvārdi: *termiskā starojuma sensori, dziļā mācīšanās, konvolūciju redzes transformeri, konvolūciju tīklu regresija, redzes transformeru regresija, precīzā lauksaimniecība*

Precīzajā lauksaimniecībā arvien plašāk tiek ieviesti sensoru tīkli, taču to lielais fizisko ierīču apjoms un uzturēšanas izmaksas rada izaicinājumus ilgtspējai un mērogojamībai. Šajā promocijas darbā pirmo reizi piedāvāta dziļās mācīšanās pieeja, kas ļauj novērtēt vairākus mikroklimata mērījumus, izmantojot tikai termiskā starojuma attēlus, tādējādi samazinot nepieciešamību pēc tiešajiem sensoriem un to uzraudzības. Darbā izstrādāts atvērta pirmkoda prototipa datu ievākšanas modulis, kas nodrošināja automatizētu radiometrisko termoattēlu un tiem laikā sakritīgu gaisa temperatūras, relatīvā gaisa mitruma, augsnes mitruma un gaismas intensitātes mērījumu ievākšanu. Apmācīti un salīdzināti trīs dziļās mācīšanās modeļi – konvolūciju neironu tīkls, redzes transformers un hibrīdais konvolūciju redzes transformers, lai novērtētu to spēju prognozēt mikroklimata parametrus no termoattēlu datiem. Eksperimentu rezultāti parādīja, ka konvolūciju redzes transformera modelis sasniedz visaugstāko precizitāti un stabilitāti, īpaši pie ierobežota datu kopas apjoma, uzrādot zemāku kļūdu nekā pārējie modeļi. Izstrādātā pieeja iezīmē jaunu virzienu precīzās lauksaimniecības attīstībā, kur vizuālie dati kalpo kā alternatīvs risinājums mikroklimata uzraudzībai IoT sistēmās.

Darbs satur 131 lappusi, 48 attēlus, 21 tabulas, 163 literatūras avotus un 4 pielikumus.

## ABSTRACT

Keywords: *Thermal radiation sensors, Deep learning, Convolutional Vision Transformers, Convolutional Network regression, Vision Transformer regression, Precision Agriculture*

In precision agriculture, sensor networks are increasingly being implemented, but the large volume of physical devices and maintenance costs pose challenges to sustainability and scalability. This doctoral dissertation presents a pioneering deep learning approach that allows the assessment of multiple microclimate measurements using only thermal radiation images, thereby reducing the need for direct sensors and their monitoring. An open-source prototype data collection module was developed in the work, which provided automated collection of radiometric thermal images and concurrent measurements of air temperature, relative humidity, soil moisture, and light intensity. Three deep learning models were trained and compared—convolutional neural network, vision transformer, and hybrid convolutional vision transformer to assess their ability to predict microclimate parameters from thermal image data. The experimental results showed that the convolutional vision transformer model achieves the highest accuracy and stability, especially with a limited dataset, demonstrating lower error than the other models. The developed approach marks a new direction in the development of precision agriculture, where visual data serve as an alternative solution for microclimate monitoring in IoT systems.

The work contains 131 pages, 48 figures, 21 tables, 163 references and 4 appendices.

# SATURA RĀDĪTĀJS

<b>IEVADS .....</b>	<b>7</b>
<b>1 DATU VIRZĪTĀ AUDZĒŠANA PRECĪZAJĀ LAUKSAIMNIECĪBĀ .....</b>	<b>17</b>
1.1 PRECĪZĀS LAUKSAIMNIECĪBAS TENDENCES .....	17
1.2 MĒRĪJUMU VEIDI UN TO IEVĀKŠANAS PROCESS LAUKSAIMNIECĪBĀ .....	20
1.2.1 Optiskie mērījumi.....	21
1.2.2 Termiskā starojuma mērījumi .....	22
1.2.3 Hiperspektrālie un multispektrālie mērījumi .....	23
1.2.4 Augsnes mērījumi .....	24
1.2.5 Virtuālo sensoru mērījumi .....	27
1.3 INFORMĀCIJAS IZGŪŠANA UN MĒRĪJUMU ANALĪZE AUGU AUDZĒŠANAS PROCESĀ.....	29
1.3.1 Normalizētais veģetācijas indekss.....	30
1.3.2 Termiskā starojuma attēlu analīze.....	31
1.3.3 Sarkanā, zaļā, zilā kanālu attēlu analīze .....	32
1.3.4 Hiperspektrālo un multispektrālo attēlu analīze .....	32
1.3.5 Iegūto datu apstrāde un sākotnējā analīze .....	33
1.4 NODAĻAS KOPSAVILKUMS UN SECINĀJUMI.....	35
<b>2 MAŠĪNMĀCĪŠANĀS METOŽU IZPĒTE ATTĒLU ANALĪZEI .....</b>	<b>36</b>
2.1 DZIĻĀ MĀCĪŠANĀS .....	36
2.2 SEGMENTĀCIJA .....	41
2.3 KONVOLŪCIJU NEIRONU TĪKLI .....	43
2.4 REDZES TRANSFORMERI .....	46
2.4.1 Redzes transformeru arhitektūra .....	47
2.4.2 Konvolūciju redzes transformeri.....	51
2.5 APMĀCĪTO MODEĻU IZVIETOŠANA .....	51
2.6 MAŠĪNMĀCĪŠANĀS PIEMĒROTĪBA MĒRĪJUMU NOVĒRTĒŠANAI.....	57
2.7 NODAĻAS KOPSAVILKUMS UN SECINĀJUMI.....	64
<b>3 MAŠĪNMĀCĪŠANĀS MODEĻU IZSTRĀDE UN APMĀCĪBA.....</b>	<b>65</b>
3.1 DATU IEVĀKŠANAS PROCESS .....	65
3.1.1 Datu ievākšanā izmantotā aparatūra.....	65

3.1.2	Datu ievākšanas vide .....	70
3.1.3	Datu ievākšanas process .....	71
3.2	DATU ANALĪZE .....	74
3.3	MĒRĪJUMU NOVĒRTĒŠANAS MODEĻU IZSTRĀDE.....	79
3.3.1	CNN modeļa izstrāde un apmācība .....	81
3.3.2	ViT modeļa izstrāde un apmācība .....	84
3.3.3	CvT modeļa izstrāde un apmācība .....	88
3.4	NODAĻAS KOPSAVILKUMS UN SECINĀJUMI.....	91
<b>4</b>	<b>MĒRĪJUMU NOVĒRTĒŠANAS PIEEJAS IZSTRĀDE UN VALIDĀCIJA .....</b>	<b>93</b>
4.1	PIEEJAS IZSTRĀDE .....	93
4.2	PROTOTIPA IZSTRĀDE.....	95
4.3	EKSPERIMENTU PLĀNS UN APRAKSTS .....	97
4.4	EKSPERIMENTU GAITA.....	100
4.5	MODEĻU PRECIZITĀTES NOVĒRTĒŠANAS VEIDI.....	102
4.6	MODEĻU PRECIZITĀTES KOPĒJAIS NOVĒRTĒJUMS .....	105
4.7	PIEEJAS IEVIEŠANAS METODIKA.....	119
4.7.1	Mērījumu novērtēšanas vadlīniju definēšana .....	120
4.7.2	Konceptuālais modelis .....	120
4.7.3	IoT komponentu definēšana .....	121
4.7.4	Funkcionālās vadlīnijas .....	123
4.7.5	Ierīču un komponentu integrācija .....	126
4.7.6	Lietotāja saskarne.....	126
4.8	NODAĻAS KOPSAVILKUMS UN SECINĀJUMI.....	126
	<b>REZULTĀTI UN SECINĀJUMI .....</b>	<b>129</b>
	<b>IZMANTOTIE INFORMĀCIJAS AVOTI.....</b>	<b>133</b>
	<b>PIELIKUMI .....</b>	<b>151</b>

## SAĪSINĀJUMU UN APZĪMĒJUMU SARAKSTS

Saīsinājums	Nosaukums angļu valodā	Nosaukums latviešu valodā
CNN	<i>Convolutional Neural Networks</i>	<i>Konvolūciju neironu tīkli</i>
CRUD	<i>Create Read Update Delete</i>	<i>Izveidot Nolasīt Atjaunot Izdzēst</i>
CVT	<i>Convolutional Vision Transformers</i>	<i>Konvolūciju redzes transformeri</i>
DNN	<i>Deep Neural Networks</i>	<i>Dziļie neironu tīkli</i>
FLOPS	<i>Floating Point Operations Per Second</i>	<i>Peldošā punkta operācijas sekundē</i>
IoT	<i>Internet of Things</i>	<i>Lietu internets</i>
MAE	<i>Mean Absolute Error</i>	<i>Vidējā absolūtā kļūda</i>
MAPE	<i>Mean Absolute Percentage Error</i>	<i>Vidējā absolūtā procentuālā kļūda</i>
MSE	<i>Mean Square Error</i>	<i>Vidējā kvadrātiskā kļūda</i>
NDVI	<i>Normalized Difference Vegetation Index</i>	<i>Normalizētais veģetācijas indekss</i>
NIR	<i>Near-Infrared Reflectance</i>	<i>Tuvu infrasarkanā spektra atstarojamība</i>
RBF	<i>Radial basis function</i>	<i>Radiālā bāzes funkcija</i>
RH	<i>Relative Humidity</i>	<i>Relatīvais Mitrums</i>
RMSE	<i>Root Mean Square Error</i>	<i>Saknes vidējā kvadrātiskā kļūda</i>
RNN	<i>Recurrent neural networks</i>	<i>Rekurentie neironu tīkli</i>
TVOC	<i>Total Volatile Organic Compounds</i>	<i>Kopējie gaistošie organiskie savienojumi</i>
ViT	<i>Vision Transformers</i>	<i>Redzes Transformeri</i>

## IEVADS

Kopš XXI gadsimta sākuma katru gadu ar vien biežāk tiek izmantotas viedās tehnoloģijas, kuras paredzētas lauksaimniecības darbu atvieglošanai, kā arī to efektivitātes un precizitātes uzlabošanai. Viena no plašāk pielietotajām 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, Lambán, et al., 2023). IoT tīklu izmantošana lauksaimniecībā sniedz būtisku produktivitātes un efektīvas ražošanas pieensumu dažādu augu, tostarp pārtikas augu ražošanā. Tie spēj nodrošināt reāllaika datu apkopšanu, dodot lauksaimniekiem noderīgu informāciju un iespēju laicīgi reaģēt uz vides un augu stāvokļa izmaiņām. Lauksaimniecībā ieviestie IoT tīkli sniedz lietderīgu informāciju par apkārtējo vidi, kas ļauj lauksaimniekiem noteikt, piemēram, augsnes mitruma līmeni, temperatūru, barības vielu pietiekamību, dažādu slimību pazīmes un augu gatavības pakāpi (Baglat, Hayat et al., 2023). Piemēram, augsnes mitruma un elektrovadītspējas mērījumi palīdz precīzi noteikt augam nepieciešamo ūdens un barības vielu daudzumu, tādējādi samazinot resursu patēriņu un piesārņojumu (Nouaze, Kim, et al., 2022). Cita veida sensori palīdz novērot klimatiskos apstākļus un laikapstākļu izmaiņas, kas savukārt ļauj izveidot efektīvākas stādīšanas un ražas novākšanas stratēģijas, kā arī veikt atbilstošas īstermiņa un ilgtermiņa prognozes.

Viedās lauksaimniecības IoT arī paver iespējas reāllaikā sūtīt ar mikroklimatu un augu stāvokli saistītos sensoru mērījumus dažādu mašīnmācīšanās modeļu ieejā (Gedi, Keyang et al., 2024). Tas darīts ar nolūku, piemēram, lai veiktu dažādu mērījumu prognozes, kuras iespējams izmantot audzēšanas efektivitātes uzlabošanai un ražas maksimizēšanai.

IoT ietilpst arī optisko sensoru mērījumi, kas uzņem, piemēram, augu lapu attēlus, kurus pēc apstrādes pielieto 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 pielietot tehnoloģijas, lai optimizētu ne tikai iegūtos ražas apjomus, bet arī katra resursa (kurš 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, Yunteng et al., 2021). Pašlaik, aptuveni 30 līdz 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 pielietojumu lauksaimniecību efektivitātes uzlabošanai. Arvien plašāks sensoru lietojuma spektrs atklāj jaunas iespējas veicināt ilgtspējīgu lauksaimniecību, vienlaikus mazinot izmaksas un veicinot konkurētspēju starptautiskajos tirgos. Rezultātā sensori ir jau kļuvuši par neatņemamu sastāvdaļu, virzot lauksaimniecību uz efektīvāku un ilgtspējīgāku nākotni (Henrichs, Noack, et al., 2022).

IoT izmantošana lauksaimniecībā piedāvā vairākas priekšrocības, taču to uzturēšana un apkope mēdz būt sarežģīta un resursietilpīga. Izvēloties uzstādīt sensorus lielā apjomā, jāreķinās, ka katram no tiem nepieciešamas regulāras pārbaudes, kalibrācija un, iespējams arī remonts. Sensoru veiktie mērījumi var būt jutīgi pret laikapstākļiem un citiem ārējiem faktoriem, piemēram vibrācijām, klimatisko apstākļu iedarbi un tamlīdzīgiem faktoriem, kas ietekmē to darbības precizitāti un kalpošanas ilgumu. Vēja iedarbība vai temperatūras svārstības var sabojāt atsevišķas mērierīču daļas, savukārt augsts mitruma līmenis veicina koroziju. Arī uzturēšanas procesu jeb darbu organizācija prasa laiku un izmaksas. Ir nepieciešamas specifiskas tehniskās zināšanas vai uzņēmumi, kas specializējas sensoru apkopē. Arī sensoru, ierīču un to akumulatoru ražošana lielos apjomos prasa daudz resursu, kā arī var nodarīt kaitējumu apkārtējai videi.

Papildus tehniskajiem izaicinājumiem, arī sensoru datu pārvaldība var kļūt pārāk sarežģīta, ja šie sensori darbojas 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, pielietotu mašīnmācīšanās risinājumus un nodrošinātu datu analīzi pietiekamā apjomā, lai ļautu lauksaimniekiem pieņemt informētākus lēmumus. Datu pieaugums ne obligāti 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 piensums būs efektīvāks un ilgtspējīgāks (Priva, 2024), (AJ agriplanting).

Kā viens no piedāvātajiem risinājumiem iepriekšminētajai problēmātikai ir mašīnmācīšanās pielietojums lauksaimniecības sensoru tīklos. Šobrīd mašīnmācīšanās risinājumi arvien plašāk tiek ieviesti lauksaimniecībā, lai automatizētā veidā analizētu lielu

datu apjomu, meklējot sakarības starp dažādiem mērījumiem, piemēram, augsnes mitrumu, temperatūru, slimību pazīmēm, barības vielu patēriņu vai citiem faktoriem. Rezultātā lauksaimniekiem nav manuāli jāapstrādā un jāpārbauda katra sensora dati. Mašīnprogrammā balstītas sistēmas autonomi spēj atpazīt anomālijas un brīdināt par kļūmēm vai neatbilstībām. Lauksaimnieki vai citas automatizētas sistēmas iegūto datu analīzi un tās rezultātu var izmantot turpmāku lēmumu pieņemšanai.

Šobrīd plaši pielietota tiek arī sensoru datu apvienošana jeb sensoru sapludināšana (sensor fusion), kas ļauj apvienot vairākus informācijas avotus vienā kopīgā modelī, tādējādi samazinot vajadzību pēc atsevišķiem sensoriem un to apkopi. Piemēram, ja viens sensors uz laiku pārstāj darboties vai rada maldinošus datus, algoritmi ar dažādām metodēm spēj tos papildināt vai aizvietot (Kempelis, Romanovs, et al., 2021). Šāda pieeja ļauj ne tikai mazināt neprecizitātes, bet arī pagarināt sensoru ekspluatācijas laiku.

Papildus tam tiek izmantotas arī datu novērtēšanas un interpolācijas metodes, kas ļauj kompensēt trūkstošos mērījumus, turklāt uzlabojot vispārējo analīzes kvalitāti. Šādi risinājumi arī palīdz noteikt optimālāko augu laistīšanas periodu, barības vielu piegādi un ražas novākšanu, vienlaikus samazinot kļūdu risku. Rezultātā šīs tehnoloģijas lielā mērā atvieglo sensoru uzturēšanu, ievērojami uzlabojot to lietderību lauksaimniecībā un sekmējot ilgtspējīgu resursu izmantošanu.

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, kuri 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 savstarpēju saistību, vēl joprojām trūkst pētījumu par šo saistību (Alireza, Mahamed, 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, kuri 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 (no angl. val. *estimation*) pieeja. Tiek pētīta iespēja iegūt lielāku informācijas apjomu, nepalielinot fizisko ierīču skaitu IoT tīklā.

### **Promocijas darba mērķis un uzdevumi**

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

Mērķa sasniegšanai tika izvirzīti šādi uzdevumi:

1. Izpētīt dziļās mašīnmācīšanās algoritmu pielietojšanas 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 izvirzītas sekojošas 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 mitrums, gaismas intensitātes 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 mitrums, gaismas intensitātes un gaisa temperatūras sensoru mērījumiem.

Pirmā tēze raksturo to, ka pielietojot 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 darba ietvaros 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 darba ietvaros pielietota metode, kas ļauj veikt vairāku mikroklimata sensoru mērījumu automatizētu ievākšanu, kā arī termiskā starojuma kameras automatizētu datu izgūšanu un apstrādi. Ar prototipu veiktie eksperimenti norāda uz praktisko pielietojamību 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, kuras tiek pielietotas 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 guva pozitīvu vērtējumu 6 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), Rīga, Latvija, 25. novembris, 2021. – 26. novembris, 2021
3. The 63rd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS'2022), Oktobris 6-7, 2022, Rīga, Latvija
4. 2023 The 10th Jubilee IEEE Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Viļņa, Lietuva, 27-29 Aprīlis 2023.
5. The 11th IEEE Workshop on Advances in Information, Electronic and Electrical Engineering AIEEE'2024, Valmiera, Latvija, 31 Maijs – 1. Jūnijs, 2024
6. 29th International Conference on Circuits, Systems, Communications and Computers (CSCC), Amalfi Coast, Salerno, Itālija. Jūnijs 20-24, 2025.

Promocijas darba galvenie rezultāti ir atspoguļoti 8 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 Osadcis, 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 Brūzgienē. 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

Papildus darba autors iesaistījies dažādās akadēmiskās un pētnieciskās 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” (Spānijā) 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, Vācijā) apmācībās par rūpnieciskā mākslīgā intelekta iespējām un pielietojumu 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. 10.7250/itms-2021-0003
9. Vairāku RTU bakalaura darbu vadīšana un dalība aizstāvēšanas procesā (2021.g – 2025.g.)
10. Praktisko un laboratorijas darbu vadīšana studijuursos “Informācijas tehnoloģijas loģistikā DE0782” un “Informācijas tehnoloģijas pārvaldība DE0650” (kopš 2021.g.)

## Promocijas darba struktūra

Promocijas darbs sastāv no ievada, 4 nodaļām, secinājumiem un literatūras saraksta.

**Ievadā** ir definēts darba mērķis un darba uzdevumi, pamatota darba tēmas aktualitāte, raksturots pētījuma objekts un priekšmets, kā arī uzskaitītas darbā lietotās pētījuma metodes un darba zinātniskais un praktiskais jaunieguvums. Ievadā, pamatojot darba aktualitāti, izcelti dažādi precīzās lauksaimniecības izicinājumi, kā arī to iespējamie risinājumi. Nodaļā aprakstīts par to, kā IoT sensori un viedās tehnoloģijas mūsdienu lauksaimniecībā sniedz reāllaika datus par augsni, mikroklimatu un augu veselību. Tiek izklāstīta pētījuma problēma, kas saistīta ar sensoru tīklu uzturēšanas, kalibrēšanas un datu pārvaldības izaicinājumiem, kas rezultātā var arī mazināt tehnoloģiju ieguvumus. Īsumā aprakstīta arī prototipa izstrāde un eksperimentu veikšana siltumnīcā, kur modelis tiek validēts, salīdzinot novērtētos mērījumus ar reālo sensoru mērījumiem. 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. Tiek dots ieskats datu analīzē, mērījumu procesa automatizācijā un iespējamais mašīnmācīšanās pielietojuma ieguvums precīzās lauksaimniecības kontekstā. Nodaļa sākas ar ievadu par datu virzītas precīzās lauksaimniecības mērķi, kas paredz ražot vairāk, vienlaikus samazinot ūdens, barības vielu un darba resursu patēriņu, balstoties uz precīziem sensoru mērījumiem. Turpinājumā tiek aprakstītas tehnoloģiju ieviešanas tendences, sensoru lietojuma straujā izaugsme, sensoru tipi un to uzturēšanas izaicinājumi, kā arī tiek aprakstīta atvērtais aparatūras nozīme. Tiek izklāstīti datu veidi un to ievākšanas process, detalizēti aplūkojot optiskos, termiskos, hiperspektrālos, multispektrālos, augsnes un virtuālos sensorus, to darbības principus, ieguvumus un potenciālos trūkumus. Tiek skaidrots, kā iegūtie dati tiek apvienoti, analizēti ar datorredzes un mašīnmācīšanās metodēm un pārvērsti reāllaika lēmumos, kas optimizē laistīšanu, barības vielu un slimību risku pārvaldību. Tiek salīdzinātas dažādās neinvazīvās mērīšanas metodes, uzsvērts datorredzes potenciāls precīzajā lauksaimniecībā un iezīmēti atlikušie izaicinājumi modeļu vispārināšanā un skaitļošanas resursu efektivitātes uzlabošanā.

**Otrajā nodaļā** tiek analizēts mašīnmācīšanās un datorredzes potenciāls augu novērošanā, uzsverot agrīnas augu slimību un augu stresa prognozes nozīmi ilgtspējīgai lauksaimniecībai. Šajā kontekstā tiek analizēta dziļā mācīšanās un tiek parādīts, kā to iespējams pielietot apstrādājot sensoru datus un augu attēlus, lai noteiktu, piemēram, barības vielu trūkumu vai transpirācijas izmaiņas. Tiek skaidrota segmentācijas loma kā priekšapstrādes solis un detalizēti

konvolūciju arhitektūras pielāgojumi sensoru mērījumu regresijai. Tiek analizētas redzes transformeru iespējas un to hibrīdās modeļu arhitektūras, salīdzinot datu prasības, precizitāti un piemērotību regresijas uzdevumiem. Tiek apskatītas modeļu izvietošanas stratēģijas malu skaitļošanas ierīcēs. Salīdzinošā analizē tiek 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** izstrādāts un aprakstīts datu ievākšanas prototips un aprakstīts datu ievākšanas process. Veikta ievākto datu sagatavošana, priekšapstrāde un sākotnējā analīze, kuras ietvaros tiek veikta arī korelācijas analīze, kas parāda ciešo saistību starp pikseļu temperatūru un relatīvā gaisa mitrumu, gaisa temperatūras, augsnes mitruma un gaismas intensitātes mērījumiem. Tiek aprakstītas un izvēlētas modeļu arhitektūras un veikta sākotnējā modeļu apmācība piemērotākā apmācības reižu skaita noteikšanai.

**Ceturtajā nodaļā** izstrādāta mērījumu novērtēšanas pieeja. Pieveja eksperimentāli pārbaudīta ar datu ievākšanas laikā iegūtajiem sensoru mērījumiem. Veikta modeļu apmācība un analizēti kopumā 6 izstrādāto mērījumu novērtēšanas modeļu rezultāti. Ar izstrādātajiem modeļiem veikti vairāku eksperimentu sērija ar ierobežotām apmācības datu kopām un troksni ieejas datos. Balstoties uz iegūtajiem rezultātiem 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 eksperimentālu modeļu validāciju. Nodaļā tiek aprakstīta darba praktiskā nozīme, pētījuma ierobežojumi un iezīmēti arī iespējamie nākotnes pētījumu virzieni.

# 1 DATU VIRZĪTĀ AUDZĒŠANA PRECĪZAJĀ LAUKSAIMNIECĪBĀ


Precīzās lauksaimniecības metodes, kuras paredzētas audzēšanas efektivitātes uzlabošanai ir sasniegušas plašu atpazīstamību lauksaimnieku vidū saimniecībās pasaules mērogā (Abhishek, Sanmeet, 2023; Alireza, Mahamed, et al., 2023). Viena no precīzās lauksaimniecības datu virzītās audzēšanas pieejām ir risināt problēmu, kā izaudzēt vairāk, nemainot audzēšanā izmantojamo platību vai arī, 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, Romanovs, et al., 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.

## 1.1 Precīzās lauksaimniecības tendences

Vēsturiski tradicionālā lauksaimniecība balstījies uz vienotu pārvaldības praksi, 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, Hoque, 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). Sensori palīdz lauksaimniekiem pieņemt lēmumus, kas balstīti uz precīziem datiem, lai uzlabotu resursu izmantošanas efektivitāti, maksimizētu ekonomisko ieguvumu un nodrošinātu stingrāku izmaksu kontroli. Sensoru mērījumu analīze ļauj uzlabot enerģijas patēriņu, minimizēt barības vielu izlietojumu, ātrāk atklāt augu slimības un veikt augu apūdeņošanu, kas pielāgojas konkrētām augu vajadzībām. Rezultātā var tikt iegūti augstāki ražas apjomi, samazinātas darbaspēka izmaksas, uzlabota augu veselība un mazināta negatīvā ietekme uz vidi kas lauksaimniecībā šobrīd ir aktuāli (Emogine, Makgabo, et al., 2025).

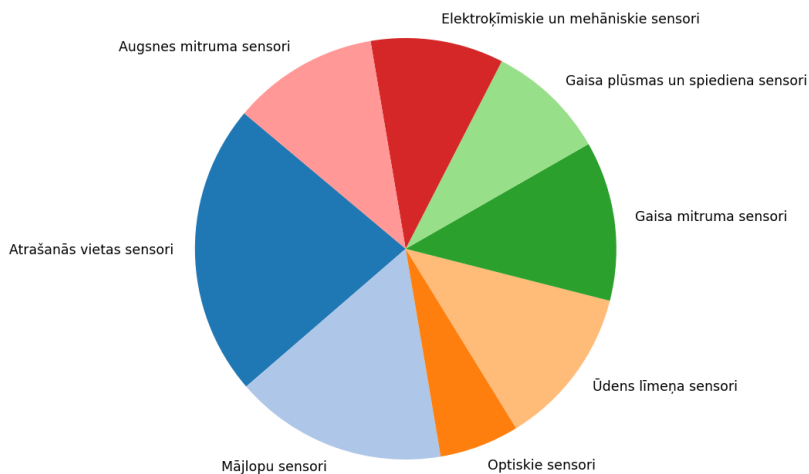
Pēdējos 8 gados sensoru ieviešana lauksaimniecībā ir uzrādījusi pastāvīgu izaugsmi. Konkrēti, lauksaimniecības sensoru tirgus daļa pieaugusi no 1.05 mljrd. ASV dolāru visā pasaulē 2017. gadā, līdz 2 miljardiem ASV dolāru 2023. gadā un līdz prognozei, kas pārsniedz

aptuveni 2 mljrd. ASV dolāru līdz 2027. gadam (1.1. att.), turpinot palielināties (Kbvresearch, 2022).



**1.1. att. Lauksaimniecības sensoru tehnoloģiju tirgus daļas, pēc pielietojuma, 2017-2027 gads (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). Pēc sensoru tipa, lielākā daļa pieder ar atrašanās vietu saistītiem sensoriem, kam seko mājlopu uzraudzībai paredzētie sensori, kā arī augsnes un gaisa mitruma līmeņa sensori (1.2. att.).



**1.2. att. Lauksaimniecības sensoru tirgus daļas, pēc sensoru tipa (aizgūts no (Kbvresearch, 2022))**

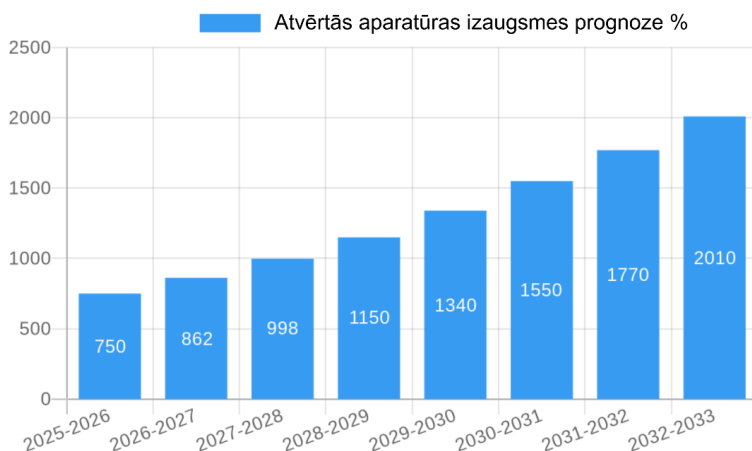
Līdzšinējā tehnoloģijas virzība norāda, ka izaugsme, visticamāk, paātrināsies un turpināsies arī pēc 2030. gada. Tas skaidrojams ar to, ka lauksaimniecībai paredzēto sensoru izmantošana palīdz mazināt atkarību no manuāla roku darba. Lauksaimniecības gūst labumu no sensoriem, kas mēra kritiskus faktorus, piemēram, ūdens saturu augsnē. Dažāda tipa sensori bieži vien ir integrēti ar automatizētām laistīšanas sistēmām, optimizējot resursu izmantošanu, samazinot vai atvieglojot manuālo darbu un saīsinot laiku līdz lēmumu pieņemšanai.

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, ultravioletam 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.

Ierīcēm, kas darbojas, izmantojot akumulatoru bateriju var nākties regulāri tās uzlādēt vai mainīt pašu bateriju. Ja izmanto vadu savienojumus, tad tas palielina uzstādīšanas sarežģītību un atsevišķos gadījumos arī palielina izmaksas. Katrai ierīcei, kas pievienota tīklā ir nepieciešami arī programmatūras atjauninājumi vai drošības ielāpu uzstādīšana.

Atkarībā no mērījumu veikšanas biežuma un veida, lauksaimniecībām būtu jāizvērtē arī datu uzglabāšanas un apstrādes izmaksas (Devi, Raghunath, 2021). Ja lauksaimniecībai trūkst atbilstoša tehniskā personāla, tad jāizmanto ārpalpojuma sniedzēji vai to piedāvātās abonēšanas platformas, kuru izmaksas var būt atkarīgas no pievienoto ierīču skaita vai kopējā datu apjoma. Atkarībā no lauksaimniecības darbinieku prasmēm un zināšanām var būt nepieciešamība ierīču uzturēšanā, kalibrēšanā un citos darbos izmantot ārpalpojuma sniedzējus, kas specializējas konkrēta ražotāja ierīču apkalpošanā. Lauksaimniecības atkarība no ārpalpojuma sniedzējiem var radīt arī zaudējumus bojājumu un dīkstāves gadījumos, kad tehniķiem jāveic ilgi pārbraucieni starp dažādām saimniecībām, lai novērstu bojājumus.

Pozitīvā tendence ir ar atvērtā tipa aparatūru saistītām pieaugumam (1.3. att.). Atvērtā tipa aparatūra ļauj lauksaimniekiem pašiem iesaistīties dažādu ierīču izstrādes procesos un veidot arī savai saimniecībai specifiskus ierīču pielāgojumus, kas mazina atkarību no ārpalpojuma sniedzēju specifikas.



**1.3. att. Atvērtās aparatūras jomas procentuālā izaugsmes prognoze (aizgūts no (DiMarket, 2025))**

Rezultātā novērojama arī salīdzinoši jauna tendence, kas saistīta ar ievākto sensoru mērījumu datu izpēti, sensoru kalibrāciju, to sapludināšanu, paškalibrācijas metodēm. Dažādas datu analīzes, datizraces un mašīnāpmācībā balstītas metodes (Padhiary, Saha 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.

## 1.2 Mērījumu veidi un to ievākšanas process lauksaimniecībā

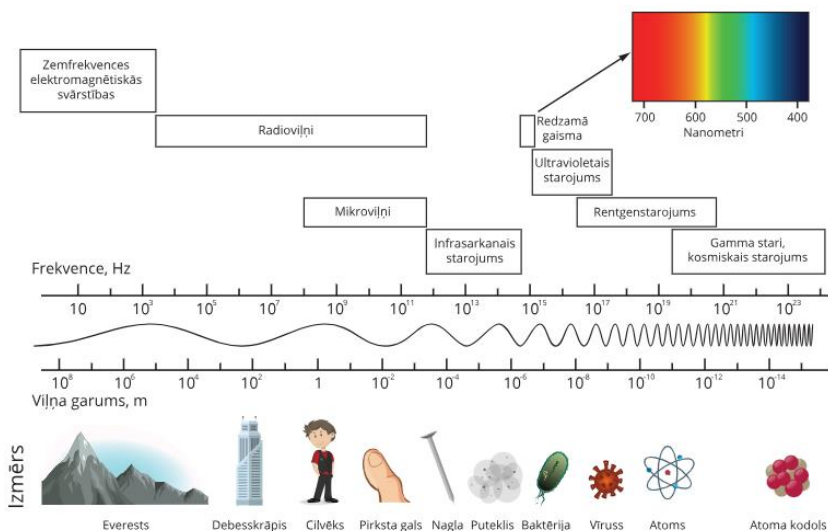
Lai ievāktu informāciju par augiem un vidi, kurā tie aug, ir iespējams izmantot dažāda veida tehnoloģijas, tostarp dažādas ierīces jeb sensorus, kas atšķiras pēc tipa un iespējām fizikālās un ķīmiskās parādības pārvērst elektronisko signālu veidā (Chai, Xu, et al., 2023), (Kempelis, Romanovs, et al., 2021b).

Dati no dažādām ierīcēm tiek nolasīti manuāli vai automatizētā veidā ik pēc noteikta laika intervāla vidē, kur norisinās augu augšanas process (M. Saini, R. Saini, 2020). Nepieciešamie augšanas vides un procesa mērījumi parasti var tikt ievākti divos veidos, tiešā un netiešā jeb bezkontakta veidā no dažādām ierīcēm, piemēram satelītattēliem vai sensoriem, kuri atrodas tuvāk augiem, kuriem veikti mērījumi. Balstoties uz reāllaika vai vēsturiski iegūtajiem mērījumiem, tiek veikti secinājumi par apstākļiem un aktuāli notiekošajām tendencēm, kā arī var tikt pieņemti informēti lēmumi par precīzām augiem nepieciešamajām un optimālajām resursu devām.

Tiešā veida mērījumi raksturīgi ar to, ka pašam augam vai auga tuvumā var tikt pievienota ierīce, piemēram augsnes mitruma/temperatūras, relatīvā gaisa mitruma, CO<sub>2</sub>, slāpekļa, gaisa temperatūras, gaismas intensitātes, pH līmeņa un citu rādītāju mērīšanai (Olalla, Flores, et al., 2023). Šie mērījumi ir būtiski augu labklājībai, jo tie nosaka auga spēju dot ražu, pretoties slimībām un uzņemt nepieciešamās barības vielas (Wang, Li et al., 2024). Bezkontakta mērījumu gadījumā var tikt izmantotas tehnoloģijas, kas nav tiešā saskarē ar augiem un neietekmē to augšanas procesus.

### 1.2.1 Optiskie mērījumi

Viens no zināmiem bezkontakta mērījumu veidiem ir optiskie sensori, kas ir sensori ar spēju pārvērst gaismu elektriskajos signālos tādā veidā nosakot elektromagnētisko starojumu dažādos viļņa garumos. Optiskie sensori mēra gaismas intensitāti un kvalitāti. Bieži vien šie mērījumi tiek veikti gaismas spektrā atsevišķos viļņa garuma intervālos (1.4. att.). Optiskie sensori izmanto fotodiodes vai līdzīgas pusvadītāju iekārtas, lai uztvertu gaismu dažādās elektromagnētiskā spektra daļās, piemēram, cilvēkam redzamajā vai tuvu infrasarkanā spektra daļā.



1.4. att. Elektromagnētisko viļņu skala (aizgūts no (Uzdevumi.lv))

Lauksaimniecības kontekstā aktuāli ir viļņa garumu diapazoni, kuri ir saistīti ar gaismas atstarošanas, piemēram, no dažādiem augiem. Parasti izmanto redzamo gaismu (400 – 700 nm) un īpaši tuvās, īsviļņu infrasarkanās joslas (700 – 1000 nm), kur mēra atstaroto starojumu, kā arī termālo (8 – 14 μm), kur mēra augu izstaroto siltumu. Šādas ierīces ļauj iegūt ar aci

neredzamu informāciju, piemēram, par augu ūdens līmeni, fotosintēzes aktivitāti un augu stresa pazīmēm. Viena no pēdējā laikā plaši apskatītām elektromagnētisko viļņu uztveres pielietojuma jomām ir informācijas izgūšana no augu lapām, kas arī plašāk apskatīta šī darba ietvaros.

Lauksaimniecībā optiskie sensori, izmantojot informāciju par gaismas absorbciju un atstarošanu, palīdz lauksaimniekiem un agronomiem novērtēt augu veselību, noteikt barības vielu pietiekamību un izvērtēt ūdens resursa radīto slodzi uz augiem. Atkarībā no auga veselības un iekšējās struktūras mainās tas kā augi spēj atstarot gaismu. Piemēram fizioloģiski vesela auga lapas atstaro vairāk tuvu infrasarkanā spektra daļas gaismu, absorbējot sarkano gaismu, bet bojātiem augiem atstarojot gaismu ir iespējams redzēt izmaiņas augu atstarotajā gaismā.

Optisko sensoru rezultējošā informācija tiek pārtulkota digitālā formātā, norādot, piemēram, hlorofila daudzumu vai kādu citu metriku, piemēram normalizēto veģētācijas indeksu (*NDVI*), kas izmanto tuvu infrasarkanās gaismas mērījumus. Izmantojot uztvertos attēlus vai atstarojuma analīzes datus, ir iespējams izveidot augu veģētācijas kartes, kas izceļ problemātiskās vietas, kam būtu jāpievērš vairāk uzmanības un jāpārplāno augiem atbilstošās barības vielu devas. Optiskie sensori spēj laicīgi noteikt barības vielu trūkumu, nosakot izmaiņas augu lapu nokrāsā un novērtējot auga gaismas atstarošanās iezīmes. Tas ir arī viens no veidiem kā tiek mazināts un optimizēts barības vielu izlietojums, mazināti zudumi, kā arī vides piesārņojums (Acosta, Quiñones et al., 2023).

Pētot un analizējot atstarošanās iezīmes, ir iespēja arī laicīgi atklāt augu slimības vai dažādu kaitēkļu klātbūtni augos. Tas palīdz novērst augu bojāšanos un citus zudumus. Kombinējot uztvertos datus no optiskajiem sensoriem ar mašīnāpmācībā balstītu modeļu pielietojumu, ir iespējams prognozēt arī ražas apjomus, laika gaitā nosakot augu biomasu.

Bieži vien no optiskajiem sensoriem atsevišķi tiek izdalīti arī termiskā starojuma, hiperspektrālās, kā arī multispektrālās kameras, kas uzņem attēlus dažādos viļņa garumos, lai noteiktu barības vielu pietiekamību, uzraudzītu dažādas augu slimības, vai noteiktu cita veida audzēšanā noderīgu informāciju.

### **1.2.2 Termiskā starojuma mērījumi**

Termiskā starojuma sensori paredzēti lai noteiktu un mērītu kādu konkrētu objektu temperatūru vai siltumenerģiju. Sensoru darbības princips saistīts ar infrasarkanā starojuma uztveršanu, ko izstaro dažādi objekti (1.5. att.). Jo augstāka ir mērāmā objekta temperatūra, jo vairāk tas izstaro infrasarkanā starojumu (Jiao, Cao, et al., 2022).



**1.5. att. Termoattēla piemērs (aizgūts no (Ali, Hashim et al., 2020))**

Atšķirībā no optiskajiem sensoriem, termo infrasarkanās jeb termiskā starojuma kameras spēj noteikt starojumu elektromagnētiskā spektra garo viļņu infrasarkanajā diapazonā (aptuveni 5000 līdz 14 000 nm jeb 5 līdz 14  $\mu\text{m}$ ) (Sadeh, Alchanatis et al., 2025). Šis diapazons ir saistīts ar objektu siltuma emisiju un tā uztveršanas pielietojums ir aktuāls un plaši pielietots mūsdienās arī viedās lauksaimniecības kontekstā (Das, Christopher et al., 2020).


### **1.2.3 Hiperspektrālie un multispektrālie mērījumi**

Hiperspektrālās kameras uztver gaismu plašā viļņu garuma diapazonā, bieži vien ietverot diapazonu no cilvēkam redzamās gaismas līdz tuvu infrasarkanās gaismas spektram (atsevišķos gadījumos arī plašāku diapazonu). Katram attēla pikselim hiperspektrālā kamera rada spektru, kas būtībā ir gaismas intensitātes un viļņa garuma grafiks (Asaari, Mertens, et al., 2018).

Savukārt, atšķirībā no hiperspektrālās attēlveidošanas, multispektrālie mērījumi lauksaimniecībā ietver attēlu iegūšanu konkrētos viļņu garumos elektromagnētiskajā spektrā, parasti izmantojot no trim līdz divpadsmit atsevišķām spektrālajām joslām jeb intervāliem. Šī pieeja atšķiras no hiperspektrālās tālīzpētes, kas iegūst nepārtrauktu spektrālo informāciju ļoti lielā skaitā šauru viļņu garumu joslu, bieži vien vairākiem simtiem (Sudars, Namatevs, et al., 2023). Lai gan hiperspektrālie attēli nodrošina ļoti detalizētu spektrālo informāciju, ļaujot atklāt smalkas spektrālās nianšes un īpašības, to izmantošana ir sarežģītāka, datorresursu ietilpīgāka un finansiāli prasīgāka.

Multispektrālā attēlveidošana, savukārt, tiek atzīta par praktiskāku risinājumu lauksaimniecības vajadzībām, kurās ir zināmas specifiskas spektrālās pazīmes, kas var norādīt uz augu stāvokli. Multispektrālās kameras, kas var būt pielāgotas lauksaimniecības pielietojumiem, arvien vairāk tiek integrētas bezpilota lidaparātos un bezpilota sauszemes transportlīdzekļos (Scutelnic, Muradore, et al., 2024). Šādas sistēmas ļauj detalizēti izvērtēt augu veselības stāvokli, augšanas rādītājus un dažādus stresa faktorus, piemēram mitruma līmeņa pietiekamību. Multispektrālā kamera darbojas optiskajā (redzamās gaismas un tuvā infrasarkanā starojuma) un termiskā starojuma diapazonā (garo viļņu infrasarkanais diapazons), papildināta ar vides sensoriem temperatūras, mitruma, CO<sub>2</sub> koncentrācijas un gaismas

intensitātes noteikšanai (Scutelnic, Muradore, et al., 2024). Šādā veidā iespējams nodrošināt iespēju aprēķināt dažādus veģetācijas indeksus, piemēram, normalizēto veģetācijas indeksu (NDVI) (Nugroho, Wahyudi, et al., 2021) un normalizēto sarkanās malas indeksu (NDRE) (Haran, Swetha, et al., 2025), kas būtiski atvieglo augu veselības novērošanu un stresa pazīmju laicīgu atklāšanu (1.6. att.).



**1.6. att. NDVI kartējums, iegūts no multispektrālās attēlveides (aizgūts no (Amarasingam, Powell et al., 2025))**


Multispektrālās kameras ar maināmiem filtriem, piemēram, izmantojot rotējošo filtru mehānismu, ļauj veikt multispektrālo attēlveidi noteiktos, uz konkrētu uzdevumu orientētos viļņu garumos, piemēram, agrīnai slimību noteikšanai un uzturvielu deficīta identificēšanai (Scutelnic, Muradore, et al., 2024). Multispektrālās neinvazīvā, augam nekaitīgā veidā sniedz informāciju par auga stāvokli, veicinot precīzās lauksaimniecības metožu pielietojumu, mērķtiecīgu resursu izmantošanu un uzlabojot ražas kvantitatīvos un kvalitatīvos rādītājus. Multispektrālajām kamerām salīdzinājumā ar hiperspektrālajām ir zemāka spektrālā izšķirtspēja, tomēr lauksaimniecības kontekstā tās sasniedz optimālu efektivitātes, funkcionalitātes un izmaksu attiecību.

#### **1.2.4 Augsnes mērījumi**

Augsnes sensori ir specializētas ierīces, kas parasti ir tiešā saskarē ar augsni, kurā tiek audzēti augi. Tie ļauj noteikt un kvantificēt dažādas augsnes īpašības – gan fiziskās (mitrums, struktūra, temperatūra), gan ķīmiskās (barības vielu koncentrācija, pH, elektrovadītspēja), gan bioloģiskās, piemēram, mikroorganismu aktivitāti.

Piemēram, augsnes mitruma mērītāji sniedz reāllaika datus par ūdens saturu augsnē, galvenokārt izmantojot elektriskās īpašības, piemēram, dielektrisko konstanti (1.7. att.). Tādējādi iespējams noteikt, kad laistīšana ir nepieciešama, novēršot pārmērīgu ūdens patēriņu

un potenciālu sakņu puvi (Puengsungwan, 2020).



### 1.7. att. Kondensatora tipa kapacitīvā augsnes mitruma sensora darbības princips (aizgūts no (Hrisko, 2020))

Ūdens resurss ir viens no galvenajiem augu augšanas faktoriem, tāpēc precīza mitruma uzraudzība palīdz sasniegt augstāku ražu un taupīt resursus. Mūsdienu mitruma sensori bieži tiek integrēti automatizētās laistīšanas sistēmās, ļaujot attālināti kontrolēt augsnes stāvokli un laikus reaģēt uz izmaiņām. Apvienojot augsnes mērījumu datus ar informāciju par klimata apstākļiem, iespējams paredzēt mitruma līmeņa tendences augsnē un veikt darbības sausuma vai pārmērīga mitruma gadījumā (Puengsungwan, 2020).


Barības vielu sensori reāllaikā uzrauga galveno mikroelementu – slāpekļa (N), fosfora (P) un kālija (K) saturu augsnē. Precīzas koncentrācijas vērtības ļauj lauksaimniekiem optimizēt mēslojuma lietošanu, novēršot gan barības vielu deficītu, gan pārmērības, kas var izraisīt eitrofikāciju tuvākajos ūdensobjektos (Balasuriya, Ghose, et al., 2022).

Modernie barības vielu sensori mēdz izmantot elektroķīmiskās, optiskās vai spektroskopiskās mērīšanas metodes, kas nodrošina augstu precizitātes līmeni. Šo ierīču datus iespējams savietot ar citu sensoru informāciju (mitrums, pH) un GPS koordinātēm, lai veidotu augsnes kartes un veiktu lokāli pielāgotu mēslošanu (Rajeswari, Kavitha, 2022). Tiek uzskatīts, ka šāda, precīzajā lauksaimniecībā balstīta pieeja, ilgtermiņā pazemina izmaksas un samazina ietekmi uz vidi, vienlaikus stimulējot spēcīgu augu attīstību un stabilu ražu.

pH sensori nosaka augsnes skābuma vai sārmainības pakāpi, kas tieši ietekmē barības vielu pieejamību augiem. Pārāk skābā vidē var palielināties alumīnija un citu metālu jonu toksicitāte, bet pārāk sārmainā augsnē dažas barības vielas kļūst mazāk uztveramas.

Tehniski pH mērījumus veic, salīdzinot potenciālu starp stikla elektrodu un references


elektrodu augsnes šķīduma paraugā (1.8. att.). Reāllaika dati par augsnes pH ļauj savlaicīgi piemērot kalķošanu vai citus skābumu korigējošus pasākumus, tādējādi optimizējot mēslojuma izlietojumu.



1.8. att. pH sensora darbības princips (aizgūts no (InstTools, 2018a))

Izmantojot pH sensoru datus, lauksaimnieki var precīzi pielāgot mēslojuma un augsnes uzlabotāju lietošanu, kas uzlabo augšanas apstākļus un samazina barības vielu zudumus, kā arī palielina ražu un nodrošina stabilu augsnes ekosistēmu.

Elektriskās vadītspējas sensori mēra augsnes spēju vadīt elektrību, ko galvenokārt nosaka vielā sāļu un izšķīdušo jonu koncentrācija (1.9. att.). Augsts sāļuma līmenis kavē augu ūdens un minerālvielu uzņemšanu, izraisot stresu un ražas samazināšanos.



1.9. att. Elektrovadītspējas sensora darbības princips (aizgūts no (InstTools, 2018b))

Elektriskās vadītspējas sensoru izmantošana palīdz operatīvi konstatēt sāls uzkrāšanos un pielāgot laistīšanas režīmu vai veikt augsnes attīrīšanu, lai novērstu negatīvu ietekmi uz augu augšanu. Turklāt EV rādītāji sniedz papildu informāciju par augsnes struktūru un organisko vielu saturu, tādējādi palīdzot izvērtēt augsnes veselību kopumā. Kad EV dati tiek integrēti ar citiem sensoru parametriem, iespējams veidot pilnīgāku priekšstatu par augsnes vispārējo stāvokli.

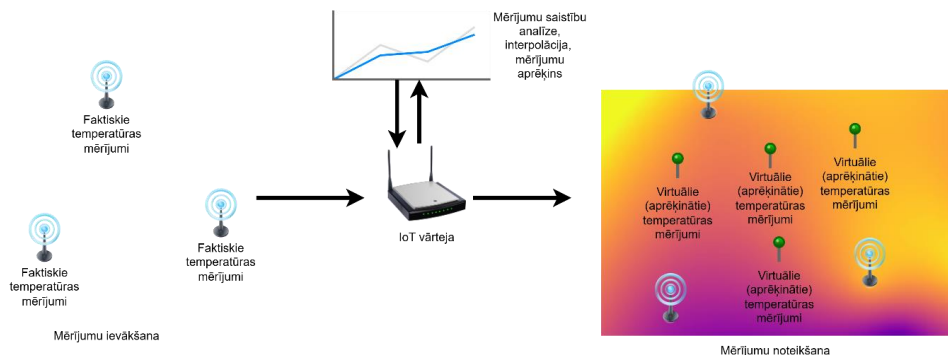
Lai gan augsnes sensori sniedz būtisku informāciju lauksaimniekiem, tiem ir arī vairāki ierobežojumi un potenciāli trūkumi. Pirmkārt, augstās sākotnējās iegādes un uzstādīšanas izmaksas var būt šķērslis mazākiem uzņēmumiem vai saimniecībām ar ierobežotiem finanšu resursiem. Otrkārt, precīza mērījumu veikšana bieži vien prasa rūpīgu kalibrāciju un regulāras tehniskās pārbaudes, kas prasa laiku un darbspēku. Tāpat sensori ir pakļauti nolietojumam un var zaudēt precizitāti, ja tie nav pienācīgi apkopti vai tiek pakļauti nelabvēlīgiem vides apstākļiem (piemēram, pārmērīgam mitrumam, vai salnām, sasalšanai).

Vēl viens izaicinājums ir datu interpretācija un to integrācija ar citām lauksaimniecības sistēmām vai informācijas avotiem. Ja sensora rādījumi netiek pareizi analizēti vai tiek ignorēti konteksti, piemēram, vietējie klimatiskie apstākļi, augsnes īpatnības un kultūraugu prasības, pastāv risks pieņemt nepareizus lēmumus. Tas var novest pie pārmērīgas mēslojuma lietošanas, augsnes degradācijas vai nepietiekamas ražības. Turklāt dažādiem viena tipa sensoriem var būt atšķirīgas mērīšanas metodes vai skalas, kas nozīmē, ka vienas saimniecības ietvaros var rasties nesakritības datu interpretācijā, ja netiek lietota vienota standartizēta pieeja.

### **1.2.5 Virtuālo sensoru mērījumi**

Lai novērstu vairākus trūkumus, kas raksturīgi fiziskiem sensoriem, ir zināma iespēja izmantot virtuālos sensorus, kas ir nozīmīgs sasniegums sensoru tehnoloģijās, radot augstu potenciālu precīzās lauksaimniecības attīstībai (Chourlias, Violos et al., 2025). Šī tehnoloģija lielākoties ietver programmatūru, kas netiešā veidā apkopo un analizē datus, iegūtus no fiziskiem vai citiem virtuāliem sensoriem, lai identificētu un interpretētu dažādas fiziskas parādības. Virtuālo sensoru galvenais ieguvums ir to spēja sintezēt datus no vairākiem avotiem un iegūt informāciju, kuru būtu sarežģīti, dārgi vai pat neiespējami iegūt, izmantojot tikai atsevišķo sensoru tiešos mērījumus (Martin, Kühn, et al., 2021). Pētījumos par virtuālo sensoru pielietojumu tiek norādīts uz virtuālo sensoru plašajām iespējām novērst fizisko sensoru ierobežojumus (Ratnak, Arravind, et al. 2024), kas bieži ietver augstas sākotnējās sensoru un to uzstādīšanas izmaksas, dārgus un sarežģītus uzturēšanas procesus, sensora kalibrāciju, troksni un grūtības sensoru uzstādīšanā vietās ar ierobežotu pieejamību (1.10. att.). Virtuālie

sensori, piedāvā papildu abstrakcijas slāni, nodrošina datu apvienošanu, tādējādi uzlabojot sensoru sistēmu precizitāti, uzticamību un arī lauksaimniecības resursu izlietojumu. Lauksaimniecības nozarē virtuālo sensoru tehnoloģijai ir plašas pielietošanas iespējas – precīza vides apstākļu, augu veselības, augsnes īpašību un dzīvnieku labturības uzraudzība, kas ir tikai daži no svarīgākajiem faktoriem precīzās lauksaimniecības pārvaldības uzlabošanai.



**1.10. att. Virtuālo sensoru mērījumu iegūšanas koncepcija**

Fizisko sensoru izvietošana plašās teritorijās var būt sarežģīta un dārga, tāpēc virtuālie sensori piedāvā alternatīvu risinājumu, apvienojot vairāku sensoru datus vienā integrētā sistēmā. Tas ievērojami samazina nepieciešamo fizisko sensoru skaitu, kā arī samazina izmaksas un atvieglo kopējo sistēmas pārvaldību. Viens no virtuālo sensoru pielietojumiem ir precīzās lauksaimniecības kontekstā, izmantojot dažādus risinājumus, lai nodrošinātu efektīvu resursu izmantošanu augu un to augsnes kopšanā. Fizisko sensoru izvietošana dažādās saimniecības zonās nodrošina detalizētus datus par augsnes mitrumu, uzturvielām, vides temperatūru un relatīvo gaisa mitrumu, kā arī citiem augu mikroklimatiskajiem faktoriem (Patrizi, Bartolini, et.al., 2022). Virtuālie sensori analizē šos datus, izmantojot specializētus algoritmus, lai sniegtu detalizētas rekomendācijas, piemēram, precīzus ūdens un barības vielu apjomus, kā arī agrīnu brīdinājumu par potenciāliem kaitēkļu vai slimību riskiem. Virtuālie sensori pielietojami arī dažādu lauksaimniecībā izmantojamo tehnikas iekārtu uzturēšanā, prognozējot nepieciešamos apkopes laikus (Bettucci, Sozzi, et al., 2024). Izmantojot sensoru datu analīzi, kļūst iespējams arī prognozēt iespējamus tehnikas bojājumus, tādējādi samazinot iekārtu dīkstāvi un optimizējot tehnikas uzturēšanas izmaksas (Wang, Lao, et al. 2025).

Sensoru virtualizācija piedāvā vienkāršu datu replicēšanu vai pamata apstrādi no fiziskā sensora, kas piemērota vienkāršiem uzraudzības uzdevumiem, piemēram, augsnes mitruma vai

temperatūras uzraudzībai. Iespējams izmantot arī vairāku neatkarīgu sensoru mērījumus vienam parametram, lai palielinātu datu precizitāti un uzticamību, piemēram, augsnes pH vai apkārtējās vides apstākļu uzraudzībai (Martin, Kühl, et al., 2021). Tāpat iespējams arī apvienot dažādu sensoru datus, lai iegūtu kompleksāku, citādi nepieejamu informāciju, piemēram, izvērtējot augu veselības stāvokli, kombinējot augsnes mitruma, uzturvielu un optiskos mērījumus. Virtuālie sensori pielāgojas mainīgajai sensoru datu pieejamībai un vides apstākļiem, kas ir īpaši būtiski lauksaimniecībā, kur sensori var pārtraukt darbību dažādu tehnisku vai vides apstākļu dēļ. Virtuālo sensoru tehnoloģija tiek lietota arī digitālo dvīņu izstrādē, kas ļauj nepārtraukti novērot, simulēt un optimizēt lauksaimniecības procesus (Awais, Wang, et al., 2025). Pagaidām gan virtuālo sensoru ieviešana saistīta ar dažādiem izaicinājumiem, piemēram, datu standartizāciju, mērījumu precizitāti, savietojamību un drošas datu apmaiņas nodrošināšanu.

### **1.3 Informācijas izgūšana un mērījumu analīze augu audzēšanas procesā**

Ņemot vērā pēdējā laika tehnoloģiskos sasniegumus, pastāv vairāki veidi kā no mērījumiem iegūt noderīgu informāciju, ko pēc tam izmantot lauksaimniecības efektivitātes uzlabošanai. Tiklīdz sensoru veiktie mērījumi tiek iegūti, tie tiek validēti un glabāti datubāzēs, kas var būt sagatavotas konkrētiem lēmumu atbalsta modeļiem. Ienākošā mērījumu datu plūsma var tikt savienota ar mašīnmācīšanās algoritmiem, kas reāllaikā prognozē ražas apjomus, mērījumus, to tendenci vai slimību risku, un rezultāti tiek nodoti lauksaimniekam kā ieteikumi. Lauksaimniekam šāda informācija ir vērtīga, jo bieži saistīta ar izmaksu un ieguvumu analīzi, piemēram, precīzāka laistīšana samazina ūdens vai barības vielu patēriņu, tajā pašā laikā nemainot vai uzlabojot ražas apjomus. Tādā veidā var tikt uzkrāta arī lauksaimniecības digitālā vēsture, kas var būt vērtīgs informācijas resurss ilgtermiņā.

Augu audzēšanas procesā ievāktie sensoru dati tiešā veidā var tikt izmantoti vizualizācijai, bet bieži vien tos izmanto arī tālākai apstrādei, analīzei un lēmumu pieņemšanai jeb informācijas izgūšanai (Ravishankar, Siddharth et al., 2023). Datu analīze palīdz lauksaimniekiem vai automatizētām vadības iekārtām pieņemt lēmumus augu nodrošināšanai, piemēram, ar dažādām barības vielām – slāpekli, oglekli, un citām, ar mērķi maksimizēt ražas apjomu. Iegūtie dati ļauj iegūt arī informāciju par kritiskajām augu fizioloģiskajām īpašībām, piemēram dažādu blakusaugošo augu augšanas ātrumu, slimību izplatību un tamlīdzīgu informāciju.

Informācijas iegūšanai salīdzinoši vienkāršā veidā var izmantot datorredzē balstītas

metodes (Abhishek, Sanmeet, 2023), Viens no galvenajiem augu labklājības rādītājiem ir auga mitruma līmenis (Narigina, Kempelis, et al., 2023). Augu mitruma līmeņa noteikšanai šobrīd plaši tiek pielietotas tiešās mērījuma metodes, kas bieži var kaitēt pašam augam, piemēram bojājot augu saknes (veicot augsnes mitruma mērījumus).

Ņemot vērā pēdējā laika tehnoloģiskos sasniegumus, pastāv vairāki veidi kā, ievācot informāciju no optiskā tipa sensoriem, ir iespējams bezkontakta veidā noteikt vairākus augu labklājību raksturojošus faktoros. Piemēram, lai noteiktu vai augs saņem pietiekami daudz mitruma, līdzšinējie pētījumi piedāvā dažādus bezkontakta mitruma mērīšanas veidus:

- NDVI (Normalizētais veģetācijas indekss), kas izmanto tuvu infrasarkanā staru gaismas spektru.
- Termālo attēlu analīzi (Abhishek, Sanmeet, 2023).
- Standarta RGB (*Red, Green, Blue*) tipa attēlu analīzi (Kempelis, Narigina, et al., 2023).
- Hiperspektrālos sensorus (Abhishek, Sanmeet, 2023).

### 1.3.1 Normalizētais veģetācijas indekss

Normalizētais veģetācijas indekss kalpo kā vispārējs vizuāls rādītājs veģetācijas novērtēšanai, nosakot atšķirību starp tuvu infrasarkanā starojumu un sarkanā gaismu, ko absorbē augi (1.11. att.). Kad augiem trūkst mitruma, to lapas atstaro mazāku NIR gaismas daudzumu, tomēr redzamās gaismas atstarojums paliek nemainīgs (tāpēc ar cilvēka acīm to nevarētu pamanīt pietiekami laicīgi, lai novērstu augu bojājumus).




1.11. att. Augu NDVI attēla piemērs (aizgūts no (Silva, Goncalves et al., 2016))

NDVI izmanto kontrastu starp sarkanā un tuvā infrasarkanā starojuma atstarojumu, lai iegūtu vienkāršu lapotnes zaļuma rādītāju. Tā kā zaļuma rādītājs korelē ar lapu platības indeksu, biomasu un fotosintēzi, NDVI laika rindas var atklāt brīdi, kad augi uzdīgst, sasniedz

fenoloģiskos posmus vai izjūt stresu (Biney, 2022). Lauksaimnieki šos telpiskos signālus izmanto mainīgas mēslošanas, laistīšanas un augu kartēs, kā arī ražas prognozēs. NDVI kalpo arī kā maska, kur vegetācijas pikseļi norāda uz augu lapotni, tādējādi izceļot un ļaujot veikt augsnes īpašību analīzi. Ņemot vērā, ka NDVI ir atkarīgs no sarkanā un tuvu infrasarkanā starojuma atstarošanas attiecības, tas var mainīties atkarībā no apgaismojuma, optiskā sensora kalibrācijas, augsnes fona un citiem faktoriem, kas nozīmē, ka objektīviem salīdzinājumiem ir nepieciešams stabils apgaismojums un dažreiz arī korekcijas. Nelielas saules gaismas, leņķa, vai lapu mitruma svārstības var mainīt spektrālo attiecību pietiekami, lai izplūstu robeža starp optiskā sensora uztvertajiem artefaktiem un reālām vegetācijas izmaiņām. Neskatoties uz šīs metodes dažādiem trūkumiem, izmantojot NDVI augu augšanas modeļos vai mašīnmācīšanās sistēmās, tā ir salīdzinoši vienkārša metode, kas ļauj uzlabot agrārās ražas prognozes, palīdz pārtikas uzglabāšanā, kā arī noder dažādu ekosistēmu atjaunošanas uzraudzībā (Biney, 2022).

### 1.3.2 Termiskā starojuma attēlu analīze

Zināms, ka augi izvada ūdeni caur nelielām atverēm uz lapām, ko sauc par stomatu. Šis process tiek saukts par transpirācijas procesu un to pielieto dažādās jomās, jo īpaši augu mitruma uzņemšanas procesa novērtēšanai (Song, Zhu et al., 2024). Ja mitruma līmenis augā ir pietiekams, transpirācijas ātrums parasti ir augsts, kā rezultātā lapu virsma atdziest un ir relatīvi vēsāka nekā apkārtējā gaisa temperatūra. Turpretim, kad augi ir pakļauti ūdens trūksam, transpirācijas ātrums samazinās, kas bieži izraisa lapu temperatūras paaugstināšanos. Uzņemot augu termiskos attēlus (1.12. att.), ir iespējams atklāt šīs temperatūras atšķirības, lai noteiktu tā saucamo augu ūdens resursa radīto stresu.



1.12. att. Infrasarkanā spektra attēlu piemēri (zemeņu stādi attēlā pa kreisi, avenes stādi, pa labi).

Termiskā starojuma attēlu analīze sniedz tiešu informāciju par augu ūdens stresa stāvokli jeb pietiekamību un tā ir iespējams noteikt mitruma līmeni augā, pirms tas ir redzams ar neapbruņotu aci vai pat pirms var būt redzamas izmaiņas NIR atstarojumā.

### 1.3.3 Sarkanā, zaļā, zilā kanālu attēlu analīze

Sarkano, zaļo, zilo kanālu kameras fiksē attēlus, kas ir līdzvērtīgi cilvēka acs uztvertajam. Tie reģistrē gaismas intensitāti sarkanajā, zaļajā un zilajā gaismas spektrā. Atsevišķos gadījumos, piemēram, NDVI novērtēšanas gadījumā, var tikt izmantota RGB kanālu kamera, bet bez infrasarkanās gaismas filtra, jo NDVI tiek aprēķināts no tuvā infrasarkanā un redzamās sarkanās gaismas atstarošanas un kamerai un ir jāļauj NIR gaismai sasniegt optisko sensoru (1.13. att.).



#### 1.13. att. Kameras (bez infrasarkanā filtra) uzņemts aveņu stādu attēls

Augi, kuriem trūkst mitruma var būt nelielas krāsas izmaiņas. Tie kļūst dzelteni vai brūni un biežāk tas sākotnēji ir novērojams tieši augu lapās (Xing, Zhang et al., 2024). Tāpat arī augu lapas var sākt vīst vai saritināties. RGB kameras var uztvert šīs morfoloģiskās izmaiņas, kuras var apstrādāt un analizēt, izmantojot attēlu apstrādes metodes. Labi mitrināti augi ar stingrām lapām var radīt cita veida nokrāsu vai formu, salīdzinot ar vīstošiem augiem. RGB attēlus var izmantot, lai analizētu šīs atšķirības.

### 1.3.4 Hiperspektrālo un multispektrālo attēlu analīze

Spektrālo attēlu jeb rādītāju analīze un aprēķini ļauj konstatēt smalkas ūdens resursu, lignīna vai citu augu organiskā satura izmaiņas (Vuletić, Car et al., 2023). Laika rindu modelēšana dod iespēju analizēt un sekot līdzi fenoloģiskajiem posmiem, vides izraisītam augu barības vielu stresam un dažādu lauksaimniecības jeb audzēšanas metožu ietekmei. Sarežģītākās analīzes pieejās hiperspektrālie un multispektrālie rādītāji tiek integrēti ar

meteoroloģiskajiem, augsnes un audzēšanas pārvaldības datiem un izmantoti kā ieejas dati mašīnmācīšanās modeļos, lai prognozētu ražu, diagnosticētu barības vielu trūkumus, sekotu līdz nezāļu izplatībai vai agrīni brīdinātu par slimību parādīšanos.


Spektrālā informācija ļauj noteikt arī smalkas atšķirības gaismas atstarošanas un absorbcijas modeļos, ļaujot detalizēti raksturot materiālus, tostarp veģetācijas veidus, augsnes īpašības, slimības un ūdens piesārņojumu. Piemēram, hiperspektrālie attēli spēj noteikt konkrētus veģetācijas tipus, īpaši atšķirot noteiktas augu sugas un tipus, bet salīdzinājumā ar multispektrālo attēlu analīzi to pielietojuma priekšrocības ir nelielas (Pang, Räsänen et al., 2024). Multispektrālie attēli, ir efektīvi salīdzinoši neliela mēroga veģetācijas monitoringam kūdrāju ekosistēmās, potenciāli sniedzot rentablāku alternatīvu hiperspektrāliem attēliem, kuru iegūšana un apstrāde ir sarežģītāka (Pang, Räsänen et al., 2024).

Uzņemot hiperspektrālos vai multispektrālos attēlus gan ir salīdzinoši dārgāks process nekā izmantot infrasarkanā starojuma vai optiskos sensorus, tāpēc pastāv iespēja arī veidot hiperspektrālus attēlus no RGB attēliem, veicot salīdzinošu dziļās mācīšanās metožu analīzi (Ahmed, Villordon et al., 2024). Šāds dziļās mācīšanās pieejā balstīts hiperspektrālo attēlu rekonstrukcijas potenciāls izmaksu ziņā var būt efektīva un praktiska alternatīva tradicionālajai hiperspektrālajai attēlveidošanai, lai gan ir zināmi izaicinājumi, kā piemēram augstas skaitļošanas resursu prasības un uzlabot modeļa vispārināšanu dažādos augu uzraudzības scenārijos.

### **1.3.5 Iegūto datu apstrāde un sākotnējā analīze**

Lauksaimniecībā augu audzēšanas procesā neviena atsevišķa sensora datu kopa nenodrošina pietiekamu informāciju par auga apkārtējo vidi, tās ietekmi vai augšanas procesiem. Pēc datu ievākšanas no dažādiem sensoriem, informācija bieži ir jāapvieno un jāapstrādā vienotā formā.

Viens no variantiem ir veikt datu apvienošanu divu vai vairākdimensiju kartēs. Transformējot dažādu sensoru, piemēram, ultraskaņas vai temperatūras datus attēlam līdzīgā formā, iespējams iegūt konkrētas audzēšanas zonas matricu jeb karti. Šādas kartes ļauj iegūt audzēšanas procesa esošā stāvokļa kopskatu. Iegūt kartes iespējams veicot datu interpolāciju, piemēram, pēc RBF metodes (Ferreira, Ruano, 2002). Tādējādi iegūstot temperatūru starp diviem vai vairākiem fiziskajiem sensoriem, kā arī identificēt dažādas anomālijas (Ryu, Song et al., 2024) (1.14. att).



#### 1.14. att. Temperatūras mērījumu siltumkartes piemērs (RBF interpolācija ar nejausiem datiem)

Analizējot šāda veida vizuālo temperatūras karti, ir iespējams prognozēt augu saslimšanas riskus, ko var radīt krāsas temperatūras atšķirības atsevišķās audzējamās platības daļās. Iegūtās vairākdimensiju kartes var kombinēt arī ar cita veida, piemēram, gaisa mitruma sensoru datiem, lai analizētu un prognozētu ietekmi uz augiem.

Rezultātā iegūtā karte jeb matrica var tikt apstrādāta kā jebkurš cits attēls, kuriem pielietojami dažādi datorredzē balstīti algoritmi informācijas, pazīmju izgūšanai, objektu atdalīšanai jeb segmentēšanai, klasificēšanai, un citām operācijām.

Lai apkopotu un analizētu dažāda veida sensoru ievāktu informāciju datorredzē var būt noderīga optisko, kā arī neoptisko sensoru datu apstrādei. Datorredzes pieeja lauksaimniecībā sevī ietver dažādas metodes informācijas izgūšanai no attēliem, kuri uzņemti audzēšanas procesa laikā. Datorredzes pielietošana, atšķirībā no vairuma mērījumu veikšanas metožu, pieder pie neinvazīvām metodēm, kas neiejaucas auga fizioloģijā vai augšanas procesos (netraucē augam, nebojā augu, tā saknes vai netraucē tam uzņemt dabīgo saules gaismu), tāpēc šai pieejai ir salīdzinoši liela perspektīva nākotnes pētījumos.

## 1.4 Nodaļas kopsavilkums un secinājumi

Lai gan katra neinvazīvā mērīšanas metode sniedz unikālu ieskatu par augu veselību un mitruma saturu, to efektivitāte lielā mērā ir atkarīga no konkrētā pielietojuma mērķiem un apstākļiem. Piemēram, NDVI ir noderīgs ātrai un plaša mēroga informācijas iegūšanai par augu veselību, taču tas ir mazāk precīzs, ja nepieciešams diferencēt līdzīgas stresa pazīmes vai noteikt specifiskus fizioloģiskos parametrus. Šādos gadījumos efektīvāka ir hiperspektrālā attēlveidošana, kas ļauj iegūt detalizētākus spektrālos datus. Tomēr hiperspektrālā pieeja ir salīdzinoši dārga un laikietilpīga metode, tādēļ ikdienas augu uzraudzības vajadzībām bieži tiek izvēlētas vienkāršākas alternatīvas.

Termālo attēlu analīze ir efektīva, ja jākonstatē ūdens radītā stresa pazīmes vai jānovērtē mitruma saturs augos un augsnē, tomēr to var ietekmēt ārējie faktori, piemēram, straujas gaisa temperatūras vai gaisa plūsmas svārstības, kas var radīt maldīgus rezultātus. Savukārt RGB attēlu analīze ir vienkārša, pieejama un vizuāli intuitīva, taču tā nav piemērota detalizētai fizioloģiskā stresa diagnostikai, jo tā spēj identificēt tikai vispārīgus augu veselības pazīmes.

Vairākos pētījumos uzsvērts, ka datorredzes pielietojums sniedz lielu potenciālu precīzai un objektīvai augu stāvokļa novērtēšanai. Datorredzes metodes ir efektīvas, ja nepieciešams apstrādāt lielus datu apjomus un agrīni atklāt slimības vai kaitējumu, taču datorredzes modeļi joprojām saistīti ar to vispārīnāšanas problēmām un augstām skaitļošanas prasībām. Turklāt sensori, kas tiek izvietoti pie, uz vai zem auga, nodrošina precīzus rezultātus, taču tie bieži ir laikietilpīgi uzstādīšanā un dārgi uzturēšanā, tādēļ praksē var tikt aizstāti ar mērījumu novērtēšanas vai prognozējošiem risinājumiem.

Kopumā var secināt, ka neinvazīvās metodes augu uzraudzībai vai novērtēšanai ir dažādos apstākļos savstarpēji aizvietojamās, taču līdzšinējos pētījumos tas vēl nav pietiekami izpētīts un metožu izvēle jābalsta uz konkrēto vajadzību atkarībā no tā vai ir nepieciešams plašs, ātrs pārskats, detalizēta fizioloģiska analīze, vai arī izmaksu ziņā efektīva ikdienas uzraudzība.

## 2 MAŠĪNMĀCĪŠANĀS METOŽU IZPĒTE ATTĒLU ANALĪZEI

Mašīnmācīšanās tehnoloģijas ir radījušas ievērojamu potenciālu lauksaimniecībā, īpaši augu augšanas uzraudzības jomā (Habib, Raza, et al., 2022). Lietderīgs mašīnmācīšanās tehnoloģiju pielietojums nodrošina plaši pielietojamus 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, kuri tiek iegūti lauksaimniecībās. Datorredzē balstīti regresijas modeļi vai lēmumu koki spēj atklāt slēptas likumsakarības un saistības mērījumu datus. Augu novērošanas kontekstā tas nozīmē, ka ar algoritmu palīdzību iespējams prognozēt augu veselības stāvokli, analizējot vēsturiskos datus un tekošos 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).

### 2.1 Dziļā mācīšanās

Dziļā mācīšanās jeb dziļie neironu tīkli un ar to saistītie pētījumi bieži apskata arī gadījumus, kas saistīti ar iespēju apstrādāt secīgus datus un ļauj novērtēt augu stāvokļa izmaiņas laika gaitā, apstrādājot iegūtās laika rindas (Badidi, 2023). Apvienojot šīs tehnoloģijas, lauksaimnieki un nozares speciālisti var pieņemt informētus un pamatotus lēmumus, kā rezultātā tiek uzlabota raža un pēc iespējas efektīvāk izmantoti ražas maksimizēšanai paredzētie resursi. IoT balstītā augu uzraudzībā lauksaimniecībā dziļā mācīšanās var būt salīdzinoši noderīga metode, jo īpaši augu datu analizē, kas sastāv no vairākiem posmiem. Pirmais posms ir datu pirmapstrāde, kas ir būtiska, lai atklātu iespējamās anomālijas, konstatētu datu dublēšanos, kā arī sagatavotu datus mašīnmācīšanās algoritmu apmācībai, validācijai un testēšanai. Praksē sensoru mērījumi var tikt apvienoti ar manuāli (lauksaimniecības darbinieka) ievāktiem datiem, lai izveidotu paplašinātu datu kopu. Iespējams iegūt datu kopu, kas ietver dažādus mērījumus, tostarp temperatūru, mitrumu, apgaismojuma intensitāti un CO2 līmeni, kas visi kā minēts literatūrā, ir kritiski svarīgi, novērtējot augu veselību un vides apstākļus (Kempelis, Romanovs, et al., 2022). Lai nodrošinātu datu kopas kvalitāti, bieži tiek izmantota sensora mērījumu neievākšanas pieeja vai izslēgšana noteiktos laika periodos, piemēram, naktīs. Kā piemēru var minēt datu atmešanu, kas ievākti iekštelpu noslodzes jeb apmeklētības

mērījumos, lai izvairītos no nosliecēm jeb “izlēcošajām” vērtībām rezultātos (Adeogun, Rodriguez, et al., 2019).

Nākamais posms ir izpētīt dažādu mērījumu savstarpējās sakarības datu kopā. Piemēram, iekštelņu noslodzes noteikšanā korelāciju analīze parādīja, ka atsevišķi rādītāji, piemēram, CO<sub>2</sub> un TVOC, ir cieši saistīti, kas nozīmē, ka vienu no šiem mainīgajiem ar nosacītu precizitāti varētu izslēgt, nepazeminot algoritma veikspēju (Adeogun, Rodriguez, et al., 2019). Šāda veida datu analīze ir nozīmīga arī augu uzraudzībā, kur tādi faktori kā temperatūra, relatīvais mitrums un apgaismojuma līmenis jeb intensitāte var būt savstarpēji saistīti. Šo sakarību izpratne ir būtiska, lai vienkāršotu modeli un koncentrētos uz tiem mērījumiem, kuriem ir vislielākā ietekme uz augu veselības analīzi.

Noslēdzošajā posmā ir būtiski izvēlēties atbilstošu dziļās mācīšanās algoritmu datu apstrādei un jaunu zināšanu ieguvei. Iekštelņu aizņemšanas noteikšanas scenārijā (Adeogun, Rodriguez, et al., 2019) tiek izmantots “*feedforward*” neironu tīkls. Šādu tīklu izvēle tiek pamatota ar tā spēju iemācīties un modelēt dažāda veida sakarības, tostarp arī nelineāras, kas ir salīdzinoši sarežģītākas sakarības. Lauksaimniecības augu novērošanā pareizā algoritma izvēle ir būtiska, lai interpretētu sensoru tīklu ievāktos datus, kuros var parādīties dažādas likumsakarības atkarībā no vides faktoriem, piemēram, augsnes mitruma, relatīvā mitruma un temperatūras. Šī informācija ir nepieciešama, lai palīdzētu lauksaimniekiem pieņemt datus balstītus lēmumus savās lauksaimniecībās un uzlabotu ražu.

Pētījumā (Han, Watchareeruetai, 2020) demonstrēts, kā dziļās mācīšanās un datorredzes metodes iespējams izmantot, lai prognozētu augu veselības stāvokli. Pētījumā galvenā uzmanība veltīta attēlu apstrādei un dziļās mācīšanās pieejai, lai noteiktu barības vielu trūkumus melno mungo pupiņu (*no aglu val. black gram*) augos. Pētījumā (Han, Watchareeruetai, 2020) aplūkoto metodi iespējams pielāgot arī citiem kultūraugiem, vērtējot to veselību un prognozējot slimības tālāku attīstību. Pētījumā (Han, Watchareeruetai, 2020) katru dienu 28 dienas fotografēti mungo pupiņu augi, kas auguši kontrolētos apstākļos un saņēmuši noteiktas barības vielas. Attēlos tika uzņemtas gan jaunas, gan novecojušas augu lapas. Lai risinātu problēmu, kā vienā attēlā parādīt kopējo informāciju par augu, pētnieki apvienoja gan vecāku, gan jaunāku lapu attēlus, kas ne tikai paplašināja datu kopu, bet arī parādīja, cik svarīgi ir aplūkot dažādas augs daļas, novērtējot kopējo veselības stāvokli. Tika izmantotas arī citas datu paplašināšanas metodes, piemēram, attēlu horizontāla pagriešana un mērogošana, lai palielinātu datu apjomu un uzlabotu modeļa apmācību.

Šajā pašā pētījumā (Han, Watchareeruetai, 2020) attēlu pazīmju izgūšanai tika izmantoti

jau iepriekš apmācīti dziļās mācīšanās modeļi, īpaši izcelts konvolūciju tīkls. Piemēram, “ResNet50” izmantošana nodrošināja efektīvu attēlu apstrādi un modeļa apmācību, neprasot ievērojamus skaitļošanas resursus. Tas parāda, kā ir iespējams pielāgot esošos modeļus specifiskām lauksaimniecības vajadzībām. Izgūtās pazīmes nodrošināja svarīgu informāciju par augu veselību, ļaujot noteikt barības vielu trūkumus, kas varētu nelabvēlīgi ietekmēt auga attīstību. Klasifikācijas uzdevuma veikšanai pētījumā tika izmantotas vairākas metodes, tostarp daudzklāšu loģistikā regresija, atbalsta vektoru mašīnas (angl. val. *Support Vector Machines*) un daudzslāņu perceptroni (angl. val. *Multilayer Perceptrons*) (Han, Watchareeruetai, 2020). Salīdzinot to veiktspēju dažādu barības vielu trūkumu noteikšanā, pētījuma autori secināja, ka dziļās mācīšanās modeļi ir spējīgi nošķirt dažādus augu veselības stāvokļus, balstoties tieši uz vizuāliem rādītājiem. Šī klasifikācijas spēja ir būtiska augu veselības prognozēšanā, jo tā ļauj savlaicīgi atklāt iespējamās problēmas un veikt atbilstošus pasākumus to novēršanai. Piemēram, laikus pamanot slāpekļa trūkumu, var nekavējoties veikt augam atbilstošu barības vielu dozēšanu, tādējādi pasargājot ražu no potenciālajiem zudumiem un uzlabojot augu veselību.

Pētījumā (Zhao, Dong, et al., 2022) piedāvāta augu novērošanas stratēģija, kas piemērota urbānās jeb pilsētvides lauksaimniecībai, kas unikāla ar to kā audzēt augus dažādās ierobežotas pieejamības un platības vietās, piemēram, uz ēku jumtiem, fasādēm, palodzēm, dzīvokļos, daudzstāvu namu pagrabos un tamlīdzīgās vietās. Pētījumā apskatīta infrasarkanās termiskās attēlveides tehnoloģija un inovatīvs trīsdimensiju temperatūras (3D-3T) modelis, lai noteiktu augu lapotnes transpirācijas ātrumu citrusaugiem. Šī metode var būtiski veicināt augu uzraudzības un ūdens resursa pārvaldības uzlabošanu pilsētvidē. Izmantojot infrasarkanā termisko attēlveidi, pētījumā precīzi mēra vidējo augu lapotnes temperatūru, kas precīzajā lauksaimniecībā ir svarīga, jo bieži mainīgais pilsētas mikroklimats padara vides uzraudzību sarežģītu un salīdzinoši grūti prognozējamu. Tradicionālās augu transpirācijas ātruma noteikšanas metodes bieži ir sarežģītas, jo ir aprūtinātas iegūt vai aprēķināt tādus raksturlielumus kā aerodinamiskā pretestība un lapotnes pretestība (Zhao, Dong, et al., 2022). 3D-3T modeļa priekšrocība ir saistīta ar tā neatkarību no šiem raksturlielumiem, kas procesu padara vienkāršāku un potenciāli precīzāku augu uzraudzībā. Precīzi lapotnes temperatūras mērījumi sniedz būtisku informāciju par augu ūdens vajadzībām un mitruma stresa līmeni, kas ir izšķiroši laistīšanas optimizēšanā un augu veselības uzturēšanā pilsētā. Rezultāti (Zhao, Dong, et al., 2022) ņem vērā arī papildu enerģiju, ko no dažādiem leņķiem nodrošina saules starojums – faktors, kas ir īpaši nozīmīgs pilsētvidē, kur ēnojums un apgaismojums var

ievērojami atšķirties ēku un citu struktūru dēļ. Pētījumā apstiprinājās modeļa spēja precīzi noteikt transpirācijas ātrumu, padarot apmācīto modeli par efektīvu rīku ūdens patēriņa pārvaldībai un uzraudzībai precīzajā lauksaimniecībā.

Balstoties informācijā, kas atrodama iepriekš minētajos pētījumos, var secināt, ka dotās metodes ir tieši pielāgotas precīzās lauksaimniecības vajadzībām, kā arī vietās, kur pieejamā platība ir neliela un augi bieži tiek audzēti netradicionālās vietās, piemēram, uz jumtiem, balkoniem vai iekštelpās. Termiskās attēlveides bezkontakta mērījumu veikšana arī atbilst prasībām neinvazīvajā mērīšanā, kas nozīmē pēc iespējas mazāk iejaukties audzēšanas procesos. Papildus tam dotie modeļi galvenokārt izmanto salīdzinoši vienkāršā veidā iegūstamus ieejas datus – lapu temperatūru un saules starojumu, kas padara to pieejamu arī lauksaimniekiem ar ierobežotiem tehniskajiem resursiem.

Augšanas uzraudzībā ir sasniegts būtisks progress dažādu specializētu metožu izstrādē, kas veltītas konkrētiem augu veselības novērtēšanas aspektiem. Tomēr joprojām pastāv nozīmīgs trūkums datu savstarpējā integrācijā, īpaši datorredzes metožu un sensoru datu uzraudzības apvienojumā, lai nodrošinātu visaptverošu augu veselības un fizioloģisko aspektu prognozēšanu un novērtēšanu.

Kaut arī atsevišķi apskatītie pētījumi par augu uzraudzību prezentē vērtīgus rezultātus, tie tomēr ir savstarpēji nesaistīti un tiek realizēti salīdzinoši nošķirti viens no otra. Piemēram, pētījumā, kurā izmanto infrasarkanā termisko attēlveidi un 3D-3T modeli (Zhao, Dong, et al., 2022), galvenais uzsvars likts uz augu lapotnes transpirācijas ātruma noteikšanu. Lai gan šī termiskā starojuma attēlanalīzes pieeja ir inovatīva, tajā netiek iekļauta informācija par citiem svarīgiem sensoru mērījumiem, kurus varētu secināt ar tiem pašiem ieejas datiem. Tas varētu sniegt pilnīgāku ieskatu augu veselības un fizioloģiskajā stāvoklī.

Saistītā pētījumā (Han, Watchareeruetai, 2020), kurā tiek izmantoti CNN, ir pierādīta datorredzes efektivitāte, identificējot konkrētus barības vielu trūkumus mungo pupiņu augiem, izmantojot attēlu analīzi. Tomēr šajā pētījumā nav iekļauti sensora dati, piemēram, par augsnes mitruma līmeni, barības vielu koncentrāciju vai vides apstākļiem, kas būtu būtiski visaptverošākai augu veselības izvērtēšanai.

Citā pētījumā (Catalbas, Kobav, 2022) norādīts, ka CNN balstīti regresijas modeļi veiksmīgi novērtē korelēto krāsu temperatūru (angl. val. Correlated Color Temperature) no RGB attēliem, ļaujot noteikt krāsu temperatūru attēlā Kelvina skalā. Šie tīkli, kas ir viens no daudzslāņu perceptronu paveidiem, atdarina cilvēka redzes darbību, tādējādi tie ir īpaši piemēroti attēlapstrādes uzdevumos. Minētais pētījums (Catalbas, Kobav, 2022) apliecina

konvolūciju tīklu spēju apstrādāt lielapjoma attēlu kopas, pierādot to efektivitāti ne tikai stacionāru 2D attēlu, bet arī dinamisku 3D video datu analizēšanā. Izmantojot CNN termiskā starojuma attēlu analīzei augu novērošanā, šī pielāgošanās spēja rada jaunas iespējas precīzākai augu veselības rādītāju prognozēšanai, skaidrojot termiskos raksturlielumus, kas atspoguļo augu fizioloģisko stāvokli.

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.

Tika konstatēta arī izteikta apgriezta sakarība starp augsnes virsmas temperatūru un mitruma saturu – mitrumam samazinoties, temperatūra pieaug, un otrādi. Šis atklājums ir nozīmīgs augu novērošanā, jo pierāda, ka termiskie dati var atklāt būtiskus vides faktoros, 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.

Līdzīgi pētījumā (Vieira, Ferrarezi, 2021) piedāvātas uzlabotas metodes precīzajai lauksaimniecībai, izmantojot termiskā starojuma attēlanalīzes tehnoloģiju, lai novērtētu citrusaugu ūdens stresu, kas ir pieeja, ko varētu pielāgot augu novērošanai pilsētās, ierobežotas telpas augšanas vietās. Veicot tiešu viena gada vecu citrusaugu lapotnes temperatūras mērīšanu kontrolētā siltumnīcas vidē, pētniekiem izdevās noteikt augu ūdens uzņemšanas spēju, analizējot temperatūras svārstības (Vieira, Ferrarezi, 2021). Šī neinvazīvā metode parādīja skaidru saistību starp laistīšanas līmeni un lapotnes temperatūru, termiskajā starojuma uztveršanas kamerām efektīvi atklājot augus, kuriem trūkst ūdens, pateicoties paaugstinātai lapotnes temperatūrai salīdzinājumā ar apkārtējo gaisa temperatūru. Rezultāti uzsver termisko datu uzticamību kā augu novērošanas rīku un norāda, ka, integrējot šādas metodes automatizētās sistēmās, būtu iespējams būtiski uzlabot laistīšanas procesu plānošanu precīzajā lauksaimniecībā (Vieira, Ferrarezi, 2021). Šāda pieeja var veicināt efektīvāku ūdens resursu izmantošanu un nodrošināt augu veselību pilsētās, kur svarīga ir racionāla resursu pārvaldība

un izlietojums.

Pētījumi (Maskey, Ramachandran, et al., 2020) un (Ham, Kim, et al., 2019) apskata konvolūciju tīklu arhitektūru izmantošanu, lai izgūtu sarežģītas attēlu pazīmes prognozēšanas uzdevumiem. Pētījumā (Maskey, Ramachandran, et al., 2020) parādīts, kā CNN spēj noteikt tropisko ciklonu intensitāti no satelītattēliem, interpretējot vizuālos datus laikapstākļu analīzei, savukārt (Ham, Kim, et al., 2019) piedāvā līdzīgu pieeju vētras “El Niño” prognozēšanai, analizējot klimata datu telpiskos raksturojumus. Abi pētījumi apliecina, ka CNN ir piemēroti arī regresijas uzdevumiem, kuros no attēlu datiem tiek iegūtas atsevišķas izejas vērtības, piemēram, sensora mērījumi, atklājot vizuālās likumsakarības ar noteiktiem mainīgajiem lielumiem.

Viena no būtiskākajām problēmām esošajos pētījumos precīzās lauksaimniecības jomā ir vienotas pieejas trūkums, kas apvienotu gan datorredzi, gan sensoru datu uzraudzību un analīzi. Patlaban esošās pieejas ir vērstas uz atsevišķiem augu veselības aspektiem, piemēram, barības vielu trūkumiem vai transpirācijas ātrumu, vai slimību atpazīšanu, neņemot vērā datu saistības, ko varētu nodrošināt kopīga vizuālo datu un sensoru mērījumu analīze. Rezultātā izpratne par augu veselību vai stāvokli ir dalīta, jo katra metode sniedz informāciju par noteiktu faktoru, bet neveido pilnīgu kopainu par augšanas procesu.

Ņemot vērā, ka datorredzes pielietošana 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.

## 2.2 Segmentācija

Datorredzes uzdevumos salīdzinoši svarīga nozīme ir segmentācijai (Mei, Sun et al., 2021), kas vairumā gadījumu ir datu priekšapstrādes posms, kas sakārto vizuālos datus skaidri definētos komponentos, kas kalpo kā ievade specializētākiem modeļiem, piemēram, augu slimību noteikšana (Anandhi, Sathiamoorthy, 2023). Pirms slimību atpazīšanas modeļi var efektīvi diagnosticēt un klasificēt slimības, segmentācijas algoritmi izolē attiecīgās augu struktūras, piemēram lapas vai augļus, no nebūtiskas fona informācijas vai trokšņa. Segmentācija var uzlabot mērķa modeļa precizitāti un samazināt skaitļošanas resursus, ierobežojot kopējo analīzi tikai ar tiem attēla reģioniem, kurus paredzēts izmantot modeļa apmācībā. Piemēram, lapu, kas segmentēta jeb atdalīta no fona, var izmantot kā ieeju neironu tīklā, kas tiek plaši pielietots tieši augu slimību identificēšanai (Dananjayan, Tang et al., 2022).

Segmentāciju var veikt izmantojot dažādas segmentācijas metodes, piemēram, sliekšņa metodes, K-vidējo klasterēšanas pieeju (2.1. att. vidū), ar diviem klastera centriem, kur viens no klasteriem var būt pati auga lapa un otrs klasteris – attēla fons (Deisy, Francis, 2018), vai izmantot vēl citas metodes, piemēram krāsu masku (2.1. att. labā pusē).



**2.1 att. Auga lapu segmentēšana, izmantojot k-vidējo un krāsu masku metodes**

Tāpat segmentācija var būt noderīga dažādām nezāļu noteikšanas sistēmām. Sākotnējie attēli tiek apstrādāti, izmantojot segmentācijas modeļus, lai skaidri nošķirtu nezāles no kultūraugiem un augsnes. Šie rezultāti pēc tam tiek nodoti klasifikatoriem kā precizēti ieejas dati. Šie klasifikatori pēc tam var ar salīdzinoši augstāku precizitāti noteikt, kurās vietās lietot papildus barības vielas vai kur būtu jāveic nezāļu kontrole. Segmentācija tādējādi palielina modeļu efektivitāti, ievērojami samazinot arī dažādu barības vielu izlietojumu un ar to saistīto ietekmi uz vidi, tomēr papildus priekšapstrādes modeļa lietojums rada papildus skaitļošanas resursu patēriņu.

Segmentēšana var uzlabot arī ražas novākšanas procesus, kur robotizētas sistēmas paļaujas uz precīzu informāciju no uzņemtajiem attēliem lai saskaitītu vai efektīvi identificētu un savāktu gatavus augļus (Dhiman, Kukreja et al., 2021). Segmentācijas procesā sākotnēji tiek atdalīti augļi no lapām, zariem un citiem apkārtējiem objektiem vai fona. Rezultātus pēc tam izmanto specializētos klasifikācijas un objektu noteikšanas modeļos, lai noteiktu augļu gatavību, kvalitāti un precīzus savākšanas punktus jeb koordinātas.

Atbilstoši segmentēti dati samazina kļūdu iespējamību, ko var izraisīt fona troksnis, atspīdumi un elementi, kas pārklājas, tādējādi nodrošinot uzticamāku modeļa izvadī. Segmentēšana atkarībā no izvēlēta algoritma pārsvarā gadījumu spēj samazināt skaitļošanas sarežģītību, jo turpmākai apstrādei atdala tikai atsevišķus attēla reģionus. Dziļajā apmācībā balstīti segmentēšanas algoritmi patērēs vairāk resursus, bet pārējās metodes, kas nav saistītas ar

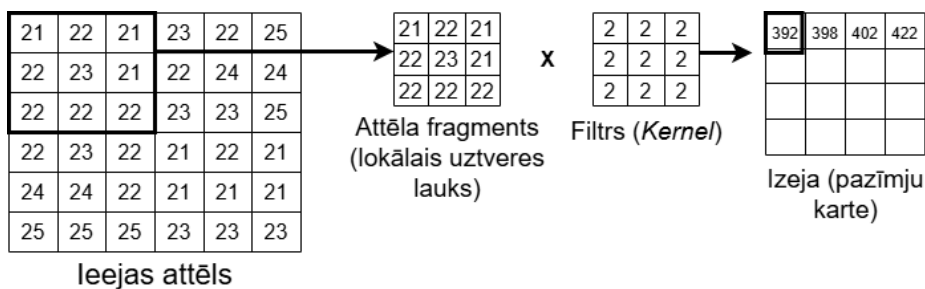
mašīnāpmācību, mazāk.

## 2.3 Konvolūciju neironu tīkli

Datorredzei, piemēram, izmantojot konvolūciju neironu tīklus ir būtiska loma precīzās lauksaimniecības procesos (Liu, Jiang, et al., 2023). Konvolūciju tīkli ir plaši atpazīstama datorredzes konteksta uzdevumos un ir bieži pielietota dziļās mācīšanās metode, kas uzrāda augstu efektivitāti apjomīgu vizuālās informācijas datu apstrādē un interpretēšanā, kas iegūta no augiem to audzēšanas procesā. Konvolūciju tīkli pielietojami uzdevumos, piemēram, slimību pazīmju, uzturvielu trūkumu vai kaitēkļu invāzijas noteikšanā, analizējot augu lapu un augļu attēlus (Kempelis, Romanovs, et al., 2022).

Konvolūciju neironu tīkli ir dziļās mašīnmācīšanās algoritmi, kas sākotnēji izveidoti objektu atpazīšanai attēlos, kā arī klasifikācijas uzdevumiem, bet tos iespējams pielāgot arī laikrindu datu analīzei, piemēram, sensoru datu prognozēšanai (Wang, Yan, et al., 2017). CNN sastāv no konvolūciju slāņiem, kuriem seko apvienošanas (no angļu val. *pooling*) slāņi un pēc tam pilnībā savienotie (no angļu val. *fully connected*) slāņi. Konvolūciju slāņi spēj identificēt lokālas datu sakarības un iezīmes, savukārt apvienošanas slāņi samazina datu telpisko dimensiju un līdz ar to arī nepieciešamo skaitļošanas apjomu sekojošos slāņos. Pilnībā savienotie slāņi izmanto iegūtās pazīmes, lai izveidotu galīgās prognozes.

Laikrindu datu analīzei, atšķirībā no divdimensiju konvolūcijām, kas tiek lietotas attēlu apstrādē, tiek izmantotas viendimensiju konvolūcijas. Šīs konvolūcijas, izmantojot slīdošo logu (literatūrā tiek minēts kā filtrs (*kernel*)), pārvietojas pa ieejas datiem, mācoties atpazīt sensoru datu lokālās sakarības vai iezīmes (2.2. att.).



### 2.2. att. Konvolūciju slīdošā loga piemērs


Lai uztvertu šīs datu pazīmes vai sakarības, tiek izmantoti vairāki filtri, kuru izvades tiek apvienotas, veidojot parametru kartes (no angļu val. *feature maps*). Pēc katra konvolūciju un

pilnībā savienotā slāņa tiek lietota aktivācijas funkcija ReLU (no angļu val. *Rectified Linear Unit*), kas nodrošina modeļa nelinearitāti, ļaujot tam apgūt dažādas kompleksas sakarības (Kido, Hirano, et al., 2018).

Laika gaitā dažādos pētījumos un uzdevumos ir izpētīti vairāki konvolūciju tīklu arhitektūras varianti, lai uzlabotu modeļu veiktspēju, efektivitāti un pielietojamību dažādās nozarēs. Sākotnējie sasniegumi ietvēra LeNet, ko izstrādāja Jans Lekuns, un kas parādīja konvolūcijas slāņu potenciālu rokraksta atpazīšanā (Lecun, Bottou, et al., 1998). Vēlāk AlexNet demonstrēja dziļāku tīklu un GPU paātrinājuma iespējas modeļu apmācībā, demonstrējot pielietojamību arī citos risinājumos (Krizhevsky, Sutskever, et al., 2012). Turpmākajos gados radītās arhitektūras, kuras jau tiek pielietotas arī lauksaimniecības kontekstā dažādos uzdevumos, piemēram, VGG, SegNet, U-Net, Zabnet (González, Martínez-Rosas, et al., 2025), (Mughair, Syam, et al., 2024) u.c. koncentrējās uz vienota lieluma filtriem un dziļām slāņu kombinācijām, vēršot uzmanību uz, tīkla dziļuma būtību. Atsevišķās arhitektūrās tika ieviests paralēlu apmācības ceļu princips vienā modelī, ļaujot vienlaicīgi apstrādāt attēla pazīmes vairākos mērogos. ResNet arhitektūra atrisināja problēmu ar zūdošo gradientu, ieviešot savienojumus, kas veicina dziļu tīklu stabilu apmācību (Kaiming, Xiangyu, et al., 2015). DenseNet turpināja šo ideju, atbalstot pazīmju atkārtotu izmantošanu, izmantojot blīvu savienojumu starp slāņiem (Huang, Liu, et al., 2017).

Arhitektūras vēl joprojām attīstās, lai atbilstu turpmākajiem izaicinājumiem, tostarp izvietojšanai mobilajās ierīcēs, kur MobileNet samazina modeļa izmēru un nepieciešamos skaitļošanas apjomus (Howard, Zhu, et al., 2017). Jaunākās pieejas, piemēram, EfficientNet, sistemātiski mērogo modeļa dimensijas, lai sasniegtu labāku precizitāti un efektivitāti (Mingxing, Quoc, 2019).

Ja aplūko lauksaimniecības kontekstu, tad viens no plaši pielietotajiem modeļa arhitektūras piemēriem, īpaši augu slimību klasifikācijas uzdevumos, ir VGGNet (2.3. att.) (Zarboubi, Bellout, et al., 2025). VGGNet tipa konvolūcijas neironu tīklus iespējams pielietot arī regresijas uzdevumos, piemēram, lai prognozētu sensoru mērījumus balstoties uz modeļa ieejā padoto attēlu.



2.3. att. VGGNet arhitektūras piemērs (aizgūts no (Bangar, 2022))

Modeļa arhitektūra satur ievades slāni, kas paredzēts modeļa ieejas datiem – attēlam jeb vairākdimensiju masīvam. Pēc tam ievade tiek apstrādāta ar vairākiem konvolūcijas slāņiem, kuros atrodas vairāki filtri, lai atpazītu un noteiktu ieejas datus (attēlos) esošās pazīmes. Filtrus eksistē vairākas parametru kartes, kas var palielināt vai samazināt tīkla dziļumu.

Sākotnējais konvolūciju slānis samazina ievades attēla izmēru, un pēc katra nākamā konvolūcijas slāņa seko *max-pooling* slānis, kas samazina datu telpisko apgabalu un kopējo parametru skaitu, kā arī mazina pārāpmācības (no angļu val. *overfitting*) risku (Nirthika, Manivannan, et al., 2021). Tas sadala katru pazīmju karti jeb iepriekšējā slāņa rezultātu vairākos mazos apgabalos jeb logos (piemēram, izmērā  $2 \times 2$ ) un no katra loga izgūst tikai matimātiski lielāko apgabala vērtību. Pielietojot *max-pooling* metodi, neatkarīgi katram attēla krāsu kanālam, tiek radīta samazinātas izšķirtspējas pazīmju karte, kas izceļ objektus un to robežas attēlā, vienlaikus atmetot citas detaļas, samazinot aprēķinu slodzi nākamajiem slāņiem un palīdzot modelim koncentrēties uz attēlā dominējošām pazīmēm. (DhanushKumar, 2023).

Kā *max-pool* alternatīva, tiek lietota vidējā apvienošanas metode (angl. *average-pooling*), kas sadala katru iezīmju karti vairākos mazos logos, līdzīgi kā *max-pooling* gadījumā, tikai ar vidējo vērtību konkrētajā attēla apgabalā. Salīdzinot ar *max-pooling*, vidējā apvienošana vairāk saglabā attēla vispārējo kontekstu un ir mazāk atkarīga no atsevišķiem lokāliem maksimumiem, tādējādi nodrošinot vienmērīgākus, zemākas dispersijas attēla pazīmju kopsavilkumus (DhanushKumar, 2023).

Globālā apvienošana, kas var būt gan globālā maksimālā, gan globālā vidējā, samazina

katru pazīmju karti līdz vienai vērtībai uz kanālu. Šī metode bieži tiek piemērota tuvu modeļa izejas regresijas vai klasifikatora slānim, lai optimizētu pazīmju kartes bez papildu parametru pievienošanas (DhanushKumar, 2023).

Konvolūcijas slāņu hierarhiskā struktūra palīdz uztvert augstāka līmeņa pazīmes no ievades attēla – sākot ar vienkāršām attēla malām, līdz sarežģītākiem rakstiem un objektiem un augsta līmeņa attēla raksturojumam. Pēc pēdējā konvolūciju un *max-pooling* slāņa dati tiek pārveidoti vienā dimensijā, lai tos varētu pārvietot uz nākamo slāņu ieejām. Tālāk arhitektūra ietver pilnībā apvienoto (no angļu val. *fully connected*) slāni, kas apkopo konvolūciju slāņu izvilktais pazīmes. Tam seko pilnībā apvienotais slānis ar, piemēram, 128 neironiem, kas apstrādā datus līdz galīgajam izvades slānim. Pēdējais slānis ir viens neirons, kas paredzēts viena sensora mērījuma izvadei, piemēram, gaismas intensitātei, relatīvajam gaisa mitrumam vai augsnes ūdens satura līmenim.

Šāda veida konvolūciju regresijas modelis var būt noderīgs precīzajā lauksaimniecībā, lai iegūtu nepārtrauktus sensoru mērījumus, izmantojot attēlos esošo informāciju.

## 2.4 Redzes transformeri

Pēdējā laikā arvien plašāk datorredzes uzdevumos tiek pielietoti redzes transformeri (angl. *Vision Transformers, ViT*), kas, tāpat kā konvolūciju tīkli, ietilpst dziļās mācīšanās pieejā un radušies no transformēru arhitektūras, kura izmantota lielajos valodu modeļos (no angļu val. *Large Language Models*) dabīgās valodas apstrādei (no angļu val. *Natural Language Processing*) (Dosovitskiy, Beyer, 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 pielietojumos, piemēram objektu atpazīšanā (De Silva, Brown, 2023).

Līdzīgi kā konvolūciju neironu tīkli, redzes transformēru modeļi ir pielietojami arī regresijas uzdevumos (Parmar, Parker, et al., 2023), piemēram, sensora mērījumu prognozēšanā no attēlu datiem. Neliels skaits esošie pētījumi rāda, ka redzes transformeri ir lietojami sensora mērījumu prognozēšanai jeb regresijas uzdevumos, taču tam ir nepieciešamas salīdzinoši apjomīgākas datu kopas nekā konvolūciju tīklu modeļiem (Gai, Chen, et al., 2022). Ja datu apjoms ir nepietiekams, transformēru modeļi var nerasniegt augstāku precizitāti nekā

konvolūciju tīkli. Konvolūciju tīkli spēj sasniegt augstu precizitāti ar salīdzinoši nelielu datu kopu un arī īsākā modeļa apmācības laikā.

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 publiskota zinātniskajās datubāzēs. Pamatprincips ir līdzīgs kā iepriekš minētajos klasifikācijas uzdevumos un galvenā atšķirība starp transformeru modeļu lietošanu klasifikācijā un lietošanu regresijā ir modeļa izejas slāni un zuduma funkcijā (*no angļu val. Loss Function*). Regresijas uzdevumos izejas slānis ir pielāgots nepārtrauktu vērtību ģenerēšanai, atšķirībā no diskrēta rezultāta klasifikācijas uzdevumos.

Viens no transformeru modeļu parametriem ir tā slāņu skaits. Palielinot transformera slāņu skaitu var paaugstināt modeļa precizitāti, jo tas uzlabo tā spēju apgūt kompleksas datu raksturezīmes. Pārāk liels slāņu skaits var novest pie pārāpmācības (Fukushima, Ishikawa, 2022). Turklāt transformeru modeļu apmācībā bieži ir nepieciešama apjomīgāka apmācības kopa un nepieciešams ilgāks apmācības laiks, lai sasniegtu augstāko iespējamo veiktspēju. Salīdzinot ar CNN, ViT var būt grūtāk precīzi noteikt objektu pozīcijas vai analizēt ļoti sīkas attēla detaļas, jo ievades dati visbiežāk tiek samazināti, un tas var izraisīt daļu informācijas zudumu (Sunitha, Sudeepthi, et al., 2023).

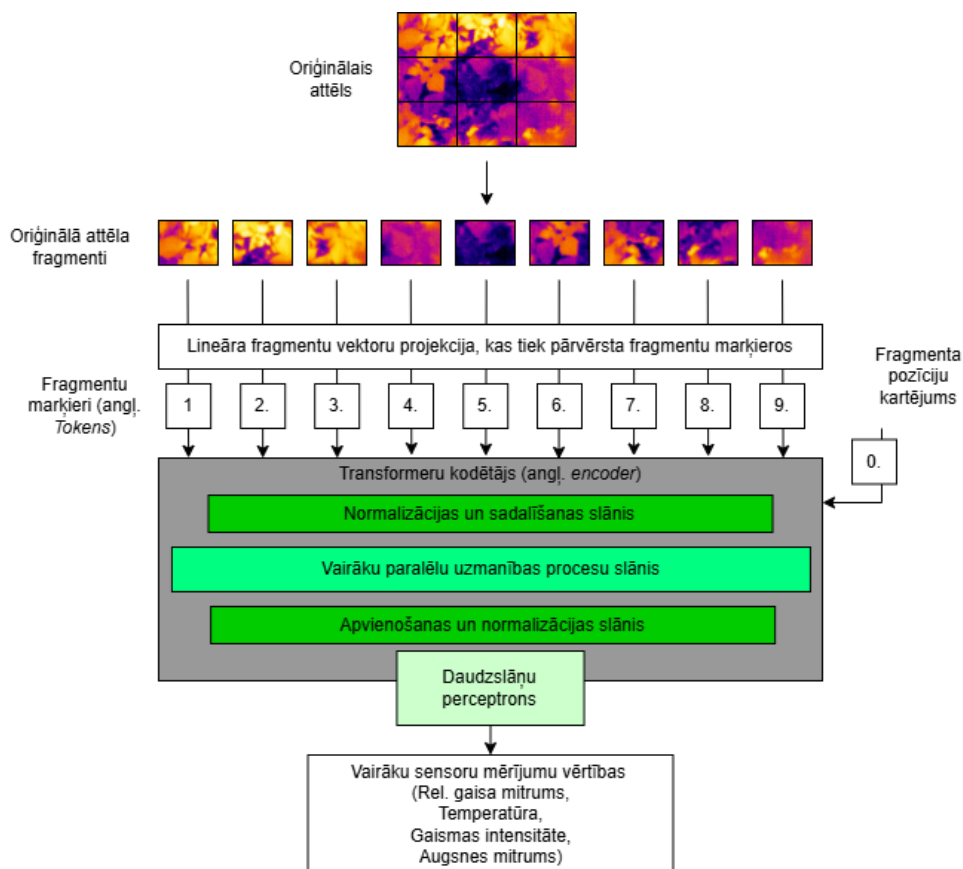
Augu uzraudzībā, kur ir svarīga precīza un nepārtraukta augšanas vai veselības rādītāju mērīšana, redzes transformeru modeļi var būt piemēroti, jo tie ir pierādījuši spēju veikt regresijas uzdevumus sarežģītās un dinamiskās vidēs. Piemēram, kad izmantojot attēlus, tiek prognozēts augsnes mitruma līmenis, jāņem vērā gan lokālā, gan globālā vizuālā informācija, piemēram, augsnes tekstūra, lapu krāsa un citi augu stresa indikatori, kas var atrasties dažādās attēla vietās. Zināms, ka konvolūciju tīklu modeļiem ir priekšrocības lokālo pazīmju noteikšanā (attēla malas, tekstūras un citas iezīmes), taču šajos modeļos apvienošanas slāņi parasti samazina telpiskos izmērus un tādējādi var zaudēt informāciju par daļu detaļu, kas var apgrūtināt novērojumu kopsakarību atklāšanu. Piemēram augsnes tekstūra, kopā ar augu lapu krāsas vai formas maiņu var liecināt par noteiktu mitruma līmeni, kas pieejams augam. Konvolūciju tīkli apskatot individuālās iezīmes – augsnes tekstūru vai augu lapu formu var neuzvert iepriekš minēto globālo kopsakarību par mitruma līmeni.

#### **2.4.1 Redzes transformeru arhitektūra**

Redzes transformeru arhitektūra datorredzes uzdevumu risināšanā būtiski atšķiras no, piemēram, konvolūciju neironu tīklu arhitektūrām. Atšķirībā no konvolūciju tīklu arhitektūras modeļiem, kas galvenokārt izmanto telpiskās filtrēšanas pieeju un lokālās uztveres laukus,

redzes transformeri uztver jeb apstrādā attēlu, kā vairāku nelielu attēla daļu jeb fragmentu (*no angļu val. patches*) virkni un ievēro globālo sakarību nozīmi starp šiem fragmentiem (Berroukham, Housni, et al., 2023). Transformeru arhitektūras spēja mācīties tālkatkarības (*no angļu val. long-range dependencies*) no dabiskās valodas apstrādes konteksta tiek pārnesta arī uz attēlu apstrādes uzdevumiem, līdz ar to redzes transformeri spējīgi efektīvi atklāt dažādu kompleksu attēlu saturu.

Lietojot redzes transformerus, process parasti sākas ar to, ka attēls tiek sadalīts mazākos fragmentos, piemēram, katrs izmērā  $16 \times 16$  pikseļi. Katrs šāds fragments tiek pārveidots par vienu ievades elementu transformera arhitektūrā (2.4. att.). Pēc sadalīšanas katram fragmentam tiek pievienoti iezīmju vektori (*no angļu val. embeddings*), kas palīdz modelim saglabāt informāciju par krāsu, malu struktūrām un citiem attēla raksturlielumiem. Papildus tam izmanto arī pozicionālos iezīmju vektorus (*no angļu val. positional embeddings*), lai modelis spētu atpazīt fragmenta atrašanās vietu attēlā un neaizmirstu tā telpisko informāciju (Dosovitskiy, Beyer, et al., 2020). Šāda pieeja atšķiras no konvolūciju tīkliem, kur informācija par fragmenta novietojumu tiek iekodēta, izmantojot konvolūciju saskaitīšanas, jeb slīdošā loga pieeju.



**2.4. att. Redzes transformēru arhitektūra mērījumu prognozēšanai no termoattēla (aizgūts no (Al-hammuri, Gebali et al., 2023))**

Kad attēls sadalīts fragmentos un šie fragmenti nodoti tālāk transformera blokam, seko vairāki transformera slāņi, kur galvenā loma ir uzmanības slāņiem. Transformeru modeļos uzmanības mehānisms nodrošina modeļa spēju novērtēt citu informācijas komponentu nozīmīgumu (arī izmaiņu ietekmi uz citiem komponentiem), kad tiek apstrādāts konkrēts marķieris (Vaswani, Shazeer, et al., 2017). Katra pozīcija secībā ģenerē pieprasījumu (angl. *query*) (kas tiek meklēts), atslēgas (angl. *keys*) (kā tas var tikt atrasts) un vērtības (angl. *values*) (informācija, kas jāiegūst). Modelis aprēķina līdzību starp pieprasījumu un visām atslēgām, pārveido šos rezultātus varbūtībās, un veido vērtību svērtu summu. Tas nodrošina kontekstuālu attēlojumu, kas dinamiski koncentrējas uz informatīvākajām ievades komponentēm. Transformeru modeļi izmanto daudzgalvu (angl. *multi-head*) uzmanības mehānismu, kas ietver vairākas paralēlas uzmanības "galvas" ar dažādām projekcijām, lai vienlaikus uztvertu dažādus attiecību veidus. Tā kā transformēru modeļos neeksistē, piemēram, konvolūcijas, tiek ieviests

pozīciju kartējums, lai uzmanības mehānisms varētu ņemt vērā informācijas komponentu secību vai to atrašanās vietu.

Pašuzmanība (angl. *self-attention*) ir īpašs uzmanības mehānisma gadījums, kurā tas darbojas vienas secīga procesa ietvaros. Katrs marķieris pievērš uzmanību katram citam marķierim (un arī pats sev) tajā pašā ievadē (Dosovitskiy, Beyer, et al., 2020). Tas ļauj modelim efektīvi uztvert ilgtermiņa un ne lokālas atkarības, jo jebkuras divas pozīcijas var tieši mijiedarboties vienā solī. Kodētāja blokos pašuzmanība ir divvirzienu (marķieri var pievērst uzmanību blakus pozīcijām), kas ļauj iegūt plašāku kontekstu. Pašuzmanības mehānismā katrs attēla fragments var aplūkot jebkuru citu attēla fragmentu, mācoties, kā savstarpēji saistās atsevišķas attēla daļas. Piemēram, fragments, kurā ir redzama objekta mala, var būt cieši saistīts ar fragmentu, kas satur to pašu objektu citā vietā vai varbūt pat ar pilnīgi citu objektu, kas ir vizuāli vai semantiski nozīmīgs. Šī mācīšanās notiek, pateicoties vairāku galvu (*multi-head*) pašuzmanības pieejai, kur katrs galvenā elementa mehānisms fokusējas uz atšķirīgiem aspektiem attēlā. Pēc tam transformera slāņi apvieno savāktu informāciju, izmantojot summēšanu un normalizēšanu, un nodod to “uz priekšu padeves” (*no angļu val. feed-forward*) tīklam, kas mācās sarežģītākus attēla reprezentācijas raksturlielumus (Dosovitskiy, Beyer, et al., 2020).

Vēl viena svarīga redzes transformeru iezīme ir klasifikācijas marķiera (*no angļu val. class token*) ieviešana. Tas ir īpašs marķieris, kas tiek piesaistīts fragmentu sarakstam, kalpojot kā konteineris galīgajai apkopotajai informācijai par attēla saturu (Dosovitskiy, Beyer, et al., 2020). Pēc tam, kad transformera slāņi ir apstrādājuši gan fragmentus, gan klasifikācijas marķieri, tīkla izejā var izmantot tieši šo marķieri, lai veiktu klasifikāciju vai citu uzdevumu, piemēram, objektu atpazīšanu.

Viens no redzes transformeru izaicinājumiem ir tas, ka, salīdzinot ar konvolūciju tīkliem, transformeru arhitektūrā balstītiem modeļiem ir nepieciešams salīdzinoši lielāks apmācības datu kopas apjoms, lai tie spētu apmācīties ar plašu telpisko un semantisko informāciju. Tas nozīmē, ka, ja nav pieejamas apjomīgas attēlu datu kopas, modeļi var tikt iepriekš apmācīti uz plašākiem un vispārīgākiem datiem un pēc tam pielāgoti konkrētiem uzdevumiem, izmantojot pārnese mācīšanos (*no angļu val. transfer learning*). Neskatoties uz datu kopas apjoma prasībām, redzes transformeru modeļi spēj sasniegt salīdzinoši augstāku precizitāti, jo pašuzmanības mehānisms nav ierobežots ar lokālajiem uztveres laukiem kā konvolūciju modeļu gadījumā (Tabbakh, Barpanda, 2023). Šobrīd tiek pētītas arī dažādas optimizācijas metodes, lai uzlabotu redzes transformeru modeļu ātrdarbību un veiktspēju, piemēram,

samazinot individuālo attēla fragmentu izmērus vai pielāgojot pašuzmanības mehānisma efektivitāti (Ibrahimovic, 2023).

## 2.4.2 Konvolūciju redzes transformeri

Konvolūciju redzes transformeri (*no angļu val. Convolutional Vision Transformers*) apvieno konvolūcijas slāņus ar transformeru arhitektūru, lai izmantotu abu CNN un ViT stiprās puses (Wu, Xiao, et al., 2021). Konvolūciju slāņi konvolūciju tranformeru modeļos salīdzinoši efektīvāk uztver un apstrādā lokālās telpiskās iezīmes un kontekstu, līdzīgi kā konvolūciju tīklu modeļi. Transformera slāņi, izmantojot pašuzmanības mehānismu, apstrādā plašas attēla reģionu atkarības un globālo kontekstu. Šāds apvienojums – hibrīdā pieeja, rezultātā modeļa apmācībā pieļauj mazāk apjomīgas datu kopas un mazāk nepieciešamos skaitļošanas resursus, jo sākotnējā posmā tiek efektīvi apstrādātas salīdzinoši svarīgākās lokālās pazīmes, bet pašuzmanības mehānisms pievēršas tikai būtiskajām globālajām attēla reģionu mijiedarbībām, līdzsvarojot efektivitāti un veiktspēju.

## 2.5 Apmācīto modeļu izvietošana

Redzes transformeri ir mazliet pētīti arī IoT tīklu kontekstā, un tie var būt piemēroti arī augstas precizitātes modeļu izvietošanai malu skaitļošanas (*angl. Edge*) vidē (Xu, Hao, et al., 2024). Tomēr, lai risinātu dažādus, ar transformeru modeļu ierobežojumiem saistītus trūkumus, ir nepieciešami papildu pētījumi, jo šādu modeļu izvietošana esošajos IoT tīklos nav pietiekami izpētīta un var radīt salīdzinoši lielu resursu patēriņu vai noslodzi. Pašreizējie pētījumu rezultāti liecina, ka pastāv vairāki optimizācijas un sasniešanas paņēmieni, kas ļautu plašāk ieviest transformeru modeļus malu skaitļošanas kontekstā dažādiem datorredzes uzdevumiem lauksaimniecībā (Kempelis, Romanovs, et al., 2024).

Lielākoties mašīnmācīšanās modeļi tiek apmācīti vidē ar augstu skaitļošanas jaudu, lai nodrošinātu salīdzinoši ātrāku apmācības procesu. Kad apmācītais modelis sasniedz pieņemamu veiktspēju un ir gatavs izvietošanai, tas parasti tiek saglabāts failā vai pakotnē, kas pielāgota konkrētajai gala ierīcei. Atsevišķi pētījumi piedāvā izmantot *Docker* kā rīku modeļa „attēla” (*angl. Docker image*) izveidei, padarot modeli viegli pieejamu un salīdzinoši vienkāršāk izplatāmu un uzstādāmu vairākām ierīcēm (Krishnamurthi, Maheshwari, et al., 2019), (Park, Cho, et al., 2023). Modeļa fails jeb „attēls” satur visas arhitektūras detaļas, parametrus un konfigurācijas, kuras var izmantot un izvietot cita programmatūra, piemēram, IoT malu ierīcēs.

Tomēr malu ierīces, uz kurām paredzēts izvietot modeli, bieži vien ir ar ierobežotiem

skaitļošanas resursiem (to pielietojuma īpatnību dēļ), tādēļ var būt nepieciešamas optimizācijas metodes, piemēram, kvantēšana (*angl. Quantization*), lai samazinātu modeļa izmēru un nepieciešamo skaitļošanas jaudu, būtiski nezaudējot precizitāti (Park, Cho, et al., 2023). Literatūrā līdzās kvantizācijai tiek minētas arī citas optimizācijas metodes, piemēram (Gopalakrishnan, 2023):

- Modeļa saspiešana, kas samazina modeļa izmēru, izņemot vai pārveidojot tos svarus, kas minimāli ietekmē veikspēju, tādējādi samazinot atmiņas patēriņu un paātrinot aprēķinu laiku. Bieži izmantotās metodes ietver svaru apcirpšanu (*angl. weight pruning*) un zemā ranga sadalīšanu (*angl. low-rank decomposition*).
- Atzarošana ir process, kurā veic mazāk nozīmīgu neironu vai filtru izņemšanu no neironu tīkla, lai samazinātu modeļa sarežģītību un izmēru. Pēc atzarošanas modeli var atkārtoti apmācīt, ļaujot atlikušajiem svāriem pielāgoties un kompensēt izņemtos elementus, tādējādi saglabājot vai uzlabojot veikspēju.
- Kvantēšana pārveido modeļa svarus un aktivācijas zemākas precizitātes formātos, piemēram, 16 vai 8 bitu veselos skaitļos. Kvantēšana ievērojami samazina modeļa izmēru un nepieciešamo skaitļošanas jaudu, lai gan lietojot šo metodi ir nepieciešama kalibrācija, lai izvairītos no modeļa precizitātes samazināšanās.
- Zināšanu destilācija (*angl. Knowledge Distillation*) ir salīdzinoši mazāka modeļa apmācība, lai imitētu lielāka, iepriekš apmācīta modeļa darbību. Destilācija mazina atšķirību starp abu modeļu prognozēm, saglabājot augstu veikspēju, vienlaikus būtiski samazinot modeļa izmēru un sarežģītību.

Papildu optimizācijas metodes, kuras būtu jāapsver, ietver modeļu sadalīšanu (*angl. model partitioning*), kas paredz modeļa aprēķinu slodzes sadali starp mākoņservisiem un malu ierīcēm, samazinot lokālo skaitļošanas slodzi. Vēl viena pieeja ir aparatūrai specifiska optimizācija, kur optimizēti modeļi tiek izvietoti aparatūras līmeņa paātrinātājos, piemēram, Malu skaitļošanai paredzētās mikroshēmās, kas speciāli veidotas ar mērķi uzlabot veikspēju un efektivitāti. Pēc optimizācijas metožu piemērošanas būtu jāizvērtē arī resursu patēriņš un energoefektivitāte, nodrošinot tā piemērotību reāliem izvietojuma apstākļiem. Svarīgi arī ieviest automatizētus uzraudzības un metrikas iegūšanas mehānismus, kas ļauj reāllaikā sekot modeļa darbības laikam, caurlaidspējai un enerģijas patēriņam. Balstoties uz šādiem datiem, var veikt sistemātisku modeļu un infrastruktūras pielāgošanu, lai saglabātu līdzsvaru starp veikspēju un izmaksām dažādos scenārijos.

Iepriekš minētās stratēģijas nodrošina modeļa efektīvu darbību, ņemot vērā aparatūras ierobežojumus. Lai modeli izvietotu uz ierīces, nepieciešama izpildlaika vide (*angl. Runtime environment*), kas spēj interpretēt modeļa formātu un veikt darbības, izmantojot ierīces aparatūru. Šāda vide bieži vien ir daļa no plašākas programmatūras arhitektūras, kuras mērķis ir nodrošināt mijiedarbību starp modeli un citām programmatūras vai aparatūras komponentēm reālos lietojumos. Šajā procesā var būt iesaistītas arī citas tīklā saslēgtās ierīces, kas piedalās modeļa apmācībā un izpildē, tādējādi sadalot datu apstrādes slodzi.

Malu skaitļošana lietu interneta tīklu kontekstā apzīmē skaitļošanu un datu apstrādi, kas tiek veikta datu avota atrašanās vietas tuvumā, nevis centralizētā datu apstrādes vidē, piemēram, mākoņpakalpojumā (*angl. Cloud service*) (Makondo, Kobo, et al., 2023). Tas tiek darīts ar nolūku ārpus lokālā tīkla (piemēram, mākoņpakalpojumam) sūtīt tikai tos datus, kas ir nepieciešami turpmākai apstrādei.

Transformeru tipa modeļi, kuri ir zināmi ar savu sarežģītību un salīdzinoši lielu parametru skaitu, parasti tiek uzskatīti par nepiemērotiem izvietošanai uz ierīcēm ar ierobežotiem resursiem, piemēram, IoT vārtējām. Šādām ierīcēm parasti piemīt ierobežota skaitļošanas jauda un neliela atmiņas ietilpība, tāpēc resursietilpīgu modeļu darbināšana uz tām ir ievērojams izaicinājums, īpaši veiktspējas ziņā. Daži pētījumi ir mēģinājuši paplašināt zināšanas šajā jomā, risinot šo modeļu izvietošanas problēmu uz minētajām mazjaudas sensoru tīklu ierīcēm (Xu, Hao, et al., 2024). Pētījumā piedāvātais ietvars paredz lielāka redzes transformera modeļa sadalīšanu vairākās mazākās daļās, kuras ir salīdzinoši vienkāršāk uzturēt un kuras vienlaicīgi var darboties uz dažādām malu skaitļošanas ierīcēm, tādējādi nodrošinot pietiekami ātru apstrādi arī uz mazjaudas ierīcēm. Šādi sadalīti modeļi tiek integrēti, izmantojot dekompozīciju, kuras pamatā ir zināšanu destilācija, ļaujot saglabāt modeļu precizitāti, neskatoties uz to samazināto izmēru. Šī metode samazina komunikāciju (pārsūtīto datu apjomus) starp ierīcēm un nodrošina, ka salīdzinoši mazāki modeļi spēj efektīvi atkārtot sākotnējā lielāka transformera modeļa darbību (Xu, Hao, et al., 2024). Ietvara efektivitāte tika pārbaudīta, veicot eksperimentus ar dažādiem transformeru modeļiem uz dažādām standarta datu kopām. Pētījumā (Xu, Hao, et al., 2024) minētajos eksperimentos tika izmantotas NVIDIA Jetson Nano ierīces (Nvidia, 2022). Iegūtie rezultāti liecina, ka ir iespējams panākt datu pārraides un enerģijas patēriņa samazinājumu bez būtiska precizitātes zuduma. Piedāvātā metode ievērojami pārspēj esošos vieglos (*angl. lightweight*) transformera modeļus gan ātrdarbības, gan energoefektivitātes ziņā, padarot to par daudzsoļu risinājumu dziļās mašīnmācīšanās modeļu izvietošanai malu skaitļošanas ierīcēs, tajā skaitā, viedtālruņos, dronos un citās lietu interneta

tīklu ierīcēs.

Apskatot pieejamos literatūras avotus, kas saistīti ar transformeru un citu veikspējas ziņā līdzvērtīgu modeļu izvietošānu uz malu skaitļošanas ierīcēm, tika apkopota informācija, kas redzama 2.1. tabulā. Modeļu izvietošānā izmantoto rīku kontekstā, transformera balstītās arhitektūras modeļus izvietoj ietverot apmācītā modeļa formatēšanu vai pārveidošanu, piemēram, uz TensorFlow Lite formātu vai izmantojot PyTorch Mobile vai citus konvertēšanas rīkus.

**2.1. tabula**

**Modeļu izvietošāna IoT ierīcēs (aizgūts no (Kempelis, Romanovs, et al., 2024))**

<b>Ierīce</b>	<b>Bibliotēkas, rīki un lietotie satvari</b>	<b>Modeļu arhitektūras</b>	<b>Uzdevumi, kurus izstrādātajam modelim jāveic</b>
NVIDIA Jetson Nano	PyTorch	<b>ViT</b> (Dosovitskiy, Beyer, et al., 2020) <b>DeiT</b> (Touvron, Cord, et al., 2021) <b>CCT</b> (Hassani, Walton, 2021)	Klasifikācija (Objektu atpazīšana)
Raspberry Pi 4 ARM Cortex-A72, 4 GB memory, Broadcom Videocore VI GPU Ubuntu Linux OS	Tensorflow un Keras	<b>MobileNet</b> <b>MobilNetV2</b> <b>EfficientNet-B0</b> (Howard, Zhu, et al., 2017), (Attanayka, Malkanthi, 2022)	Klasifikācija (Sejas masku atpazīšana)
14 kodolu Intel(R) Xeon(R) Gold 6330 CPU @ 2.00 GHz, ar 45 GB of RAM un NVIDIA GeForce RTX 3090 grafiskā karte (Attanayka, Malkanthi, 2022)	PyTorch	<b>SqueezeNet</b> <b>MobileNetV3</b> <b>ShuffleNetV2</b> <b>EfficientNet-B0</b> <b>CVT</b> <b>PMVT</b> <b>MobileViT</b> (Li, Wang,	Iegūt vienkāršu ( <i>angl. lightweight</i> ) slimību noteikšanas modeli

		et al., 2023)	
NVIDIA TESLA P100 ar 16 GB grafisko atmiņu	Pytorch un cu117 dziļās mācīšanās satvars	<b>GLDCNet</b> (Shan, Guowei, et al., 2024)	Iegūt vienkāršu ( <i>angl. lightweight</i> ) modeli vīnogu lapu blīvuma noteikšanai un klasifikācijai

Lai noteiktu modeļu piemērotību izvietošanai IoT tīklu (ierobežotas veiktspējas) ierīcēs, atsevišķos pētījumos tiek piedāvāta iespēja izmantot vieglus vai pēc sarežģītības vienkāršākus modeļus, kas apmācīti uz ierīcēm ar augstiem skaitļošanas resursiem, izvērtējot arī to veiktspēju pēc peldošā punkta operāciju (*angl. Floating Point Operations per Second, FLOPS*) metrikas (Li, Wang, et al., 2023), (Shan, Guowei, et al., 2024). Zemāks FLOPs līmenis un augstāka precizitāte sākotnēji varētu šķist piemērotākā izvēle malu skaitļošanas lietojumiem, tomēr zemāks FLOPs bieži nozīmē arī vienkāršākas arhitektūras modeļus. Izvietojot modeļus malu skaitļošanas ierīcēs, modeļi ar zemāku FLOPs prasa mazāk skaitļošanas resursu, kas ļauj tos efektīvāk darbināt uz ierīcēm ar ierobežotu apstrādes jaudu. Vienlaikus zemais FLOPs jeb vienkāršākas arhitektūras modeļi nozīmē to, ka šie modeļi var nepietiekami labi uztvert sarežģītākas datu struktūras, iespējams samazinot modeļa kopējo precizitāti. Svarīgi atrast līdzsvaru starp skaitļošanas efektivitāti un modeļa veiktspēju. Pārmērīga modeļa vienkāršošana var negatīvi ietekmēt tā precizitāti. Metodes kā atzarošana (mazāk svarīgu neironu izņemšana) un kvantēšana ļauj samazināt FLOPs, būtiski nezaudējot precizitāti.

Atsevišķos pētījumos arī apskatīts kompresijas metožu potenciāls redzes formateru modeļu izvietošanai ierobežotas jaudas ierīcēs, tomēr šobrīd trūkst eksperimentālu datu no reālām situācijām, piemēram, lai noskaidrotu, kā modeļa veiktspēju ietekmē dažādi kompresijas paņēmieni vai citas optimizācijas metodes (Chen, Gao, et al., 2022). Minētās metodes samazina skaitļošanas slodzi un atmiņas patēriņu, taču var izraisīt precizitātes samazināšanos, salīdzinot ar modeļa izpildi uz jaudīgākām ierīcēm. Malu ierīces specifikācija, konkrētais uzdevums un pieejamie dati nosaka izvietotā modeļa darbības efektivitāti, kas šobrīd tiek uzskatīta par salīdzinoši jaunu pētījumu jomu, kura pieprasa izvērstu eksperimentālu pieeju, lai šādu pieeju varētu pilnībā novērtēt.

Nepieciešamais datu apjoms ir atkarīgs no konkrētā uzdevuma, un tas ir jānosaka eksperimentālā veidā. To iespējams veikt, salīdzinot konvolūciju un formateru modeļu rezultātus uz identiskiem datiem, mainot apmācībai izmantoto datu apjomu tā, lai noteiktu punktu, kurā konvolūciju un tranformeru modeļu veiktspēja ir vienāda vai arī formateru

modelis pārspēj konvolūciju tīkla modeļa sniegumu. Pēc tam ir jānovērtē, vai šāds modelis spēs darboties IoT ierīcē. Lai iegūtu patiesu salīdzinājumu, hiperparametri (piemēram, mācīšanās ātrums (*angl. Learning rate*) un partijas (*angl. batch*) izmērs) visos eksperimentos jā saglabā nemainīgi. Jāpielāgo tikai tie parametri, kuri ir nepieciešami, ņemot vērā atšķirības modeļu arhitektūrās.

Konvolūciju modeļu veikspēja var būt salīdzinoši augstāka uzdevumos, kuros jāizceļ mērķa jeb meklētā objekta pazīmes uz dažādiem foniem. Ja konvolūciju modeļos izmantota segmentācija, tas palīdz samazināt fona radīto troksni un ļauj modeļiem koncentrēt uzmanību uz attēla būtiskākajām daļām, tādējādi paaugstinot apmācības efektivitāti un modeļa veikspēju. Veicot attēlu segmentāciju, konvolūciju tīkla ievades dati pēc uzbūves kļūst mazāk sarežģīti, kas var palīdzēt samazināt pārāpmācības risku, īpaši situācijās ar ierobežotu apmācības datu apjomu atšķirībā no tā kā tas notiek transformeru modeļu apmācības gadījumā.

Redzes transformeru modeļi paļaujas uz pašuzmanības mehānismiem, kas ļauj modeļiem konkrētas darbības laikā koncentrēties uz vairākām ieejas attēla daļām, dinamiski pielāgojot uzmanību atbilstošai attēla daļai atbilstoši konkrētajam uzdevumam. Tāpēc segmentācija atšķirībā no konvolūciju tīkla modeļiem, redzes transformeriem var nedot tādas priekšrocības kā konvolūciju tīkla modeļiem. Redzes transformeru modeļi izmanto konteksta informāciju no visa attēla kopā, un segmentācija vai pārāk vienkāršota objektu struktūra varētu samazināt šo informāciju, kas palīdz izprast attēlu kopumā. Ņemot vērā transformeru arhitektūru, šie modeļi var būt noturīgāki pret fona radīto troksni (piemēram ēnām vai konkrētā brīža apgaismojumam) un tiem var nebūt nepieciešama segmentācija, lai koncentrētos uz būtiskām pazīmēm. Tas gan ir atkarīgs no datu kopas un, piemēram, ja attēlu foni ir ļoti mainīgi un būtiski atšķiras no analizējamajiem objektiem, segmentācija varētu palīdzēt transformeru modeļiem apmācības sākuma fāzēs, samazinot šo mainīgumu. Īpaši tas var būt noderīgi, ja apmācības dati ir ierobežoti vai modeļa izmērs ir mazāks, kas bieži sastopams IoT risinājumos.

Šajā kontekstā pastāv vairāki iespējamie pētījumu virzieni, kas vēl nav pietiekami izpētīti saistībā ar redzes transformeru modeļu izvietojumu malu ierīcēs, īpaši attiecībā uz optimizācijas un saspišanas metodēm, lai modeļi darbotos efektīvi arī ierobežotās jaudas ierīcēs. Analizējot literatūru var secināt, ka iespējams izmantot arī hibrīdmodeļu arhitektūras, lai izpētītu šādu modeļu priekšrocības un potenciāli uzlabotu to veikspēju IoT vidē. Apskatītajos pētījumos redzes transformeru modeļi tika izmantoti tikai klasifikācijas uzdevumiem, taču pašlaik nav zināmu ierobežojumu jebkura transformera modeļa izmantošanai regresijas uzdevumos, piemēram, augu vides uzraudzībā vai sensoru mērījumu prognozēšanā vai novērtēšanā

balstoties uz attēliem kā ieejas datiem.

Transformeru modeļiem ir potenciāls pārspēt alternatīvus modeļus arī ierobežotu resursu ierīcēs, taču, lai izvairītos no pārāpmācības un uzlabotu to veiktspēju, ir ieteicama datu mākslīga papildināšana, piemēram, attēlu rotācija un apgriešana vai citas metodes. Kā liecina literatūras analīze, ne visos gadījumos redzes transformeru arhitektūras modeļi pārspēj konvolūciju vai citus modeļus (Al-hammuri, Gebali et al., 2023). Konvolūciju modeļu arhitektūra ir efektīva lokālo pazīmju noteikšanā, bet ierobežo spēju uztvert globālas atkarības un saistības attēlā. Piemēram, konvolūciju tīkliem var būt grūtāk efektīvi saistīt augu slimības pazīmes attēla vienā pusē ar šīs slimības ietekmi uz auga lapām citā attēla daļā. Šis ierobežojums samazina konvolūciju modeļu efektivitāti mikroklimata sensoru uzdevumos, piemēram, prognozējot vai novērtējot augsnes mitrumu vai apgaismojuma intensitāti, kur būtiska ir plašāka konteksta izpratne. Redzes transformeru modeļiem ir iespēja pārvarēt šos ierobežojumus, izmantojot attēlu fragmentus, lai uztvertu globālas sakarības, kas nepieciešamas plašākā konteksta izpratnei augu uzraudzībā. Redzes transformeru pašuzmanības mehānismi ļauj katru attēla fragmentu salīdzināt ar jebkuru citu fragmentu neatkarīgi no to atrašanās vietas attēlā. Ņemot vērā visu attēla kontekstu, transformeru arhitektūras spēj salīdzinoši labāk atpazīt mijiedarbību starp dažādām attēla daļām. Tomēr, lai šo pieņēmumu pilnībā novērtētu, nepieciešami eksperimentāli pētījumi konkrētos pielietojuma gadījumos augu vides uzraudzībā, kur bieži ir dinamisks jeb mainīgs fons, apgaismojuma izmaiņas un dažādi vizuāli attēlu defekti.

## **2.6 Mašīnmācīšanās piemērotība mērījumu novērtēšanai**

Pamatojoties uz literatūras analīzē atklāto, 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, kuras 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 no vizuāliem datiem, sākot ar augsnes mitruma līmeņa noteikšanu pēc informācijas no dažāda tipa attēliem, līdz ražas prognozēšanai no satelītattēliem. Tas apliecina,

ka mašīnmācīšanās metožu pielietošana potenciāli ļautu aizvietot salīdzinoši dārgas mērīšanas ierīces, dažāda veida vizuālo informāciju pārvēršot kvantitatīvos mērījumos.

Redzes transformeru modeļi, kuri pēdējos gados precizitātes ziņā pārspējuši konvolūciju tīklus klasifikācijas uzdevumos, var tikt veiksmīgi pielāgoti arī sensoru mērījumu prognozēšanai vai novērtēšanai, pie nosacījuma, ja pieejama pietiekami apjomīga un dažādīga apmācības datu kopa. Atsevišķos pētījumos izmantota arī hibrīdā pieeja, apvienojot konvolūciju lokālo uztveri ar transformeru globālo kontekstu, ļaujot samazināt modeļu apmācībā nepieciešamo datu kopas apjomu un var potenciāli uzlabot mērījumu novērtējuma precizitāti.

Lauksaimniekiem ir svarīga automatizēto sistēmu autonomija. Salīdzinoši mazāk resursietilpīgie modeļi, piemēram, *MobileNet*, *MobileViT* un citi uzrāda augstu veikspēju malu skaitļošanai piemērotos vienplates datoros, piemēram, *Raspberry Pi* vai *Jetson Nano*, neskatoties uz to, ka ierīcei ir tikai daži simti MB atmiņas. Mašīnmācīšanās modeļu versijas ar zemu *FLOPs* ļauj lokāli rēķināt mērījumus bez atsevišķa mākoņpakalpojuma iesaistes, saglabājot pietiekamu precizitāti, ja netiek pārlietu vienkāršota modeļa arhitektūra. Dati, kas iegūti no ierobežota skaita fizisku sensoru, var tikt sintezēti, pielietojot mašīnmācīšanās algoritmus, piemēram, lai aizpildītu laikā trūkstošos mērījumus. Minētā pieeja var būt īpaši nodrīga lauksaimniecībā ar lielu platību, kur katrs papildu sensors būtiski palielina kopējās sistēmas izmaksas. Kad modeļi ir izvietoti, tie var reāllaikā prognozēt ražas apjomus, slimību risku vai nepieciešamo laistīšanas vai citu barības vielu apjomu un dot ieteikumus lietotājiem, kas lauksaimniekam realizējas tiešā ūdens resursu, barības vielu vai darba spēka ekonomijā.

Balstoties uz literatūras analīzē iegūtajiem rezultātiem, tika apkopots mērījumu novērtēšanai piemērotāko metožu salīdzinājums (2.2. tab.), kur tiešā fizisko sensoru mērīšana raksturo mērījumu veikšanu tiešā veidā, izmantojot kalibrētu sensoru ierīci, statistiskā vai heuristiskā novērtēšana raksturo mērījumu datu iegūšanu ar dažādu matemātisku algoritmu pielietojumu un mašīnmācīšanās balstītā novērtēšana raksturo mašīnmācīšanās modeļu pielietojumu mērījumu iegūšanā.

Salīdzinošā analīze mašīnmācīšanās piemērotībai mērījumu novērtēšanā

Novērtējuma kritērijs	Kritērija skaidrojums	Tiešie fiziskie sensoru mērījumi	Statistiskā vai heuristiskā novērtēšana	Mašīnmācīšanās balstīta mērījumu novērtēšana
Precizitāte nelineāros, trokšņainos datos vai scenārijos	Vai metode saglabā augstu precizitāti, kad dati ir nepilnīgi, trokšņaini (mainīgs apgaismojums, augsnes dažādība). Jo augstāka precizitāte, jo mazāk nepieciešami atkārtoti mērījumi vai manuāla kalibrēšana.	Ierobežota: nepieciešama bieža kalibrācija.	Viduvēja: iespējama trokšņu izlīdzināšana ar filtriem, bet ne augsta sarežģītība.	Augsta: modeļi spēj pielāgoties nelinearitātēm un trokšņiem.
Telpiskā vai laika mērogojamība	Cik viegli risinājumu var paplašināt uz lielāku teritoriju vai biežākiem mērījumiem, nepalielinot izmaksas proporcionāli platībai vai laikam. Augsta mērogojamība nozīmē, ka papildu hektārs vai papildu mērījuma intervāls nerada ievērojamas papildu izmaksas.	Zema: katrs papildu sensors palielina izmaksas lineāri.	Viduvēja: daļēji iespējams ar datu agregāciju.	Augsta: modeļi spēj izmantot lielus datu apjomus ar nelielu izmaksu pieaugumu.

Novērtējuma kritērijs	Kritērija skaidrojums	Tiešie fiziskie sensoru mērījumi	Statistiskā vai heuristiskā novērtēšana	Mašīnmācīšanās balstīta mērījumu novērtēšana
Dažāda tipa datu sapludināšana	Spēja apvienot dažādus datus (piemēram, sensoru mērījumi, prognozes, attēlu kadri). Tas ļauj precīzāk uztvert procesus, ko viens sensors atsevišķi neparāda.	Ierobežota: sensors sniedz datus tikai par vienu konkrētu parādību, ko tas mēra.	Iespējama / sarežģīta: nepieciešami īpaši algoritmi katram datu tipam.	Augsta: multimodālie mašīnmācīšanās modeļi (CNN, RNN) ļauj apvienot dažādu uztverto parādību datus vienoti.
Izmaksas un uzturēšana ierīces dzīves cikla laikā	Kopējās izmaksas, ietverot iegādi, uzstādīšanu, darbināšanu, kalibrēšanu un uzturēšanu visa risinājuma darbības laikā. Zemākas izmaksas atstāj vairāk resursu citām saimniecības vajadzībām.	Augstas: Jo lielāks sensoru skaits, jo lielākas izmaksas un iespējami biežāka apkope.	Vidējas: lielākā daļa darba notiek programmatūrā.	Vidējas: lielākā daļa darba notiek programmatūrā.

Novērtējuma kritērijs	Kritērija skaidrojums	Tiešie fiziskie sensoru mērījumi	Statistiskā vai heuristiskā novērtēšana	Mašīnmācīšanās balstīta mērījumu novērtēšana
Reāllaika darbināšana un izvietošana uz Malu skaitļošanas ierīcēm	Vai algoritmus var palaist uz tām pašām ierīcēm, kas veic mērījumus, saņemot rezultātu bez tīkla aizkaves un bez atsevišķa interneta pieslēguma. Nodrošina salīdzinoši ātrāku lēmumu pieņemšanas iespēju un mazina atkarību no mākoņpakalpojumiem.	Nav iespējams: sensors tikai veic mērījumus.	Ierobežoti iespējams ar vienkāršiem algoritmiem.	Plaši pielietojams: vairāki ML modeļi optimizēti malu skaitļošanai.
Noturība pret trūkstošiem vai kļūdainiem datiem	Kā samazinās precizitāte, ja daži sensori iziet no ierindas, signāls ir trokšņains vai dati saglabājas ar aizkavi. Sistēmas spēja turpināt strādāt ar minimālu precizitātes zudumu.	Ierobežota: bojāts sensors nozīmē zaudētus datus.	Viduvēja: iespējama interpolācija vai filtrēšana.	Augsta: dažādi modeļi spēj kompensēt vai aizstāt trūkstošos datus.

Novērtējuma kritērijs	Kritērija skaidrojums	Tiešie fiziskie sensoru mērījumi	Statistiskā vai heuristiskā novērtēšana	Mašīnmācīšanās balstīta mērījumu novērtēšana
Sasaiste ar lēmumu atbalstu	Spēja modeļa izvades (piemēram, mitruma līmeņa karte, slimības risks) interpretēt un automātiski nodot lauksaimniekam lietotāja saskarnē vai vadības sistēmā, lai atbalstītu lēmumu pieņemšanā. Jo tiešāka sasaiste, jo ātrāk datus iespējams pārvērst praktiskā vērtībā.	Ierobežota: jēldati (angl. <i>raw data</i> ) prasa papildu interpretāciju.	Daļēji iespējama: nepieciešami noteikumi rezultātu pārveidei.	Augsta: modeļi var ģenerēt tieši interpretējamas izvades (piem. prognozes, rekomendācijas, tendences).

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. Mašīnmācīšanās metožu pielietojumā jau sākotnēji ir paredzēta iespēja dažādu datu tipu apvienošanā modeļa ieejā, piemēram, apvienojot termālos, multispektrālos attēlus un individuālos sensorus vienā modelī, kas literatūras analizē noteikts kā trūkstošais posms pašreizējā augu audzēšanas procesu uzraudzībā.

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 salīdzinājumā 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 tehnoloģija mērījumu novērtēšanai.

## 2.7 Nodaļas kopsavilkums un secinājumi

Analizējot literatūru, kas saistīta ar dziļās mācīšanās balstītām mērījumu prognozēm vai mērījumu novērtēšanu no netiešā veidā iegūtās informācijas, var secināt, ka konvolūciju tīkli ir piemēroti, lai veidotu efektīvus modeļus, kas spēj darboties arī ierobežotas veikspējas ierīcēs (Jouini, Sethom, et al., 2023). Analizējot pētījumus par redzes transformēšanu modeļu ieviešanu ierīcēs ar ierobežotiem resursiem, kļūst skaidrs, ka šie modeļi (ņemot vērā to līdzību ar lielajiem valodas modeļiem) var prasīt vairāk skaitļošanas resursu, nekā malu ierīces šobrīd spēj nodrošināt. Redzes transformēšanu modeļi precizitātes ziņā pārspēj alternatīvus modeļus gadījumos, kad tos apmāca ar salīdzinoši lielu apjomu apmācības datu. Modeļu veikspēju ir iespējams uzlabot, izmantojot arī datu mākslīgas datu papildināšanas (*angl. Data augmentation*) metodes (Lv, Wu, et al., 2022).

Lauksaimniecības vidē mainīgi apgaismojuma apstākļi var ietekmēt datorredzes modeļu veikspēju, jo attēli ir galvenā modeļu ievade. Redzes transformēšanu šo problēmu risina, izmantojot pašuzmanības mehānismus, kas ļauj modeļiem koncentrēties uz būtiskām attēla daļām neatkarīgi no apgaismojuma izmaiņām. Tas ir īpaši nozīmīgi augu veselības novērtēšanā, kur krāsu un tekstūras izmaiņas var norādīt uz slimībām vai barības vielu deficītu (Zheng, Zheng, et al., 2024). Apvienojot datorredzes analīzi ar sensoru datiem, tostarp termālajiem attēliem, iespējams prognozēt savstarpēji saistītus mērījumus, tādējādi uzlabojot diagnostikas precizitāti un veicinot efektīvāku kultūraugu pārvaldību un pētniecību.

Salīdzinājumā ar klasiskām interpolācijas vai heuristiskām metodēm, mašīnmācīšanās, kā piemēram CNN un ViT arhitektūru modeļi, kā arī ar to mazāk resursietilpīgie atvasinājumi, piedāvā salīdzinoši augstāku precizitāti nelineāros, trokšņainos datos, spēju strādāt ar dažāda tipa ieejas datu avotiem. Atkarībā no aparatūras, piedāvā pielāgojamu skaitļošanas slodzi, un sniedz rezultātus, kurus var tieši ieviest lēmumu atbalsta sistēmās. Tāpēc mašīnmācīšanās šobrīd ir loģiska izvēle mērījumu novērtējumu iegūšanai precīzajā lauksaimniecībā.

Ir zināmi salīdzinoši maz publiski pieejami pētījumi par dažādu mērījumu novērtējumu, izmantojot attēlu apstrādē un mašīnmācīšanās pieejā balstītas metodes. Šādu pētījumu trūkuma dēļ pastāv pētniecības potenciāls, kas var veicināt gan pašas mašīnmācīšanās jomas attīstību, gan precīzās lauksaimniecības nozares izaugsmi.

### **3 MAŠĪNMĀCĪŠANĀS MODEĻU IZSTRĀDE UN APMĀCĪBA**

Lai izpētītu atklātās nepilnības no literatūras analīzes laikā apkopotajiem pētījumiem sensoru mērījumu prognozēšanā un novērtēšanā lauksaimniecības vidē, šī darba ietvaros veikta mērījumu novērtēšanas pieejas izstrāde. 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, gaismas intensitātes, 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, ka literatūras analīzes laikā atklātajās datu kopās un pētījumos neietilpst atvērtu datu kopu ar termiskā starojuma attēliem un laikā, vietā sakritīgiem sensoru mērījumiem, tad tika pieņemts lēmums šo datu kopu izveidot darba ietvaros. Balstoties uz iegūtajiem mērījumiem tika izvēlētas piemērotākās metodes datu analīzei un eksperimentāli validēta pieeja veikt mērījumu novērtēšanu no termoattēlu ieejas datiem.

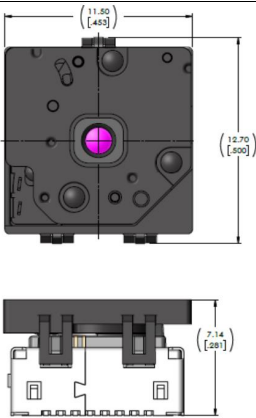
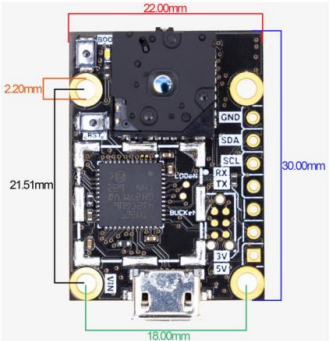
#### **3.1 Datu ievākšanas process**


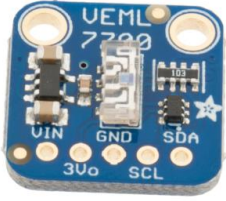
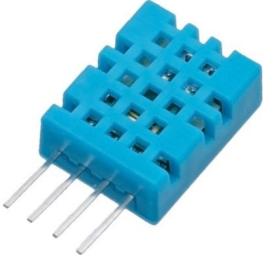
Darbā paredzēts veikt mērījumu novērtēšanu tajā pašā vidē un laikā, kur uzņemti termoattēli, tāpēc nepieciešams sagatavot prototipa sensoru mērījumu ievākšanas moduli reālā lauksaimniecības vidē. Tas darīts, lai varētu noteikt piemērotāko metodi un modeļus mērījumu novērtēšanai. Datu ievākšanas prototipa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

##### **3.1.1 Datu ievākšanā izmantotā aparatūra**

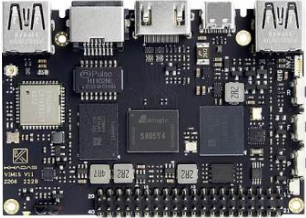
Prototipa moduļa izstrādē izmantotas dažādas ierīces, kuru galvenais uzdevums ir nodrošināt mērījumu ievākšanas automatizāciju (3.1. tabula).

Datu ievākšanas moduļi iekļautās ierīcēs


Ierīce	Specifikācija un apraksts
 <p>(attēls aizgūts no (GroupGets, 2024))</p> <p>FLIR Lepton 3.5 radiometriskā termokamera ar 57° lēcu</p>	<p>Pieejama kā salīdzinoši lētāka alternatīva rokās turamajām termokamerām, ar pielietojumu mobilajās ierīcēs dažādos automatizācijas projektos (Hsieh, 2021).</p> <p>Dotās versijas kameras ir radiometriskās kameras, kas nozīmē, ka to uztverto siltuma starojumu aparātprogrammatūra (angl. firmware) pārveido ražotāja kalibrētā temperatūrā Celsija vai Fārenheita skalā katram kameras pikselim. Termokameras izšķirtspēja ir 120 x 160 pikseļi – viens kameras uzņemtais kadrs satur 19200 pikseļus jeb temperatūras mērījumus.</p> <p>Kamera tiek lietota kopā ar kameras saskarnes moduli (<i>PureThermal</i>).</p>
 <p>(attēls aizgūts no (GroupGets PureThermal 2, 2024))</p> <p>FLIR Lepton kameras saskarnes un papildus savienojumu modulis PureThermal2</p>	<ul style="list-style-type: none"> <li>• Nodrošina programmvadāmu piekļuvi kamerai, izmantojot gan I2C, gan USB un citus savienojumus (Rodríguez, Lendinez et al., 2022).</li> <li>• Datu sūtīšana un barošanas avots: Micro USB</li> <li>• Maksimālais ieejas spriegums: 5.5v</li> <li>• Atbalsta kameras versijas Lepton 2.x un 3.x</li> <li>• Paplašinājumi I2C, UART, GPIO, JTAG</li> <li>• Procesors STM32F412 (1M Flash, 512K RAM)</li> <li>• Video izeja: caur Micro USB</li> </ul>

Ierīce	Specifikācija un apraksts
 <p>(attēls aizgūts no (Grobotronics BH1750, 2024)) BH1750</p>	<ul style="list-style-type: none"> <li>• Gaismas intensitātes līmeņa sensors ar pielietojumu gaismas intensitātes automatizētai noteikšanai (Dewi, Suseno, et al., 2022).</li> <li>• Ieejas spriegums: 5Vdc.</li> <li>• Datu diapazons: 0-65535 luksi</li> <li>• Tieša digitālā izeja, bez sarežģītiem aprēķiniem un izlaižot kalibrēšanu. Vizuālajai jutībai tuvs spektrālo raksturlielumu jutīgums. Plašam spilgtuma diapazonam mērījumiem ar 1 luksa precizitāti.</li> <li>• izmērs: 13.9 mm X 18.5 mm.</li> </ul>
 <p>(attēls aizgūts no (Elektrokit VEML7700, 2024)) VEML7700</p>	<ul style="list-style-type: none"> <li>• Pielietots gaismas intensitātes līmeņa noteikšanai</li> <li>• Ieejas spriegums 2.5 līdz 3.6V</li> <li>• Datu diapazons: 0-167000 luksi</li> <li>• Precizitāte 0.005 luksi</li> </ul>
 <p>(attēls aizgūts no Manju, 2024) DHT11</p>	<ul style="list-style-type: none"> <li>• Relatīvā gaisa mitruma un gaisa temperatūras mērījumiem, plaši atpazīstams un pielietots mērījumu automatizācijas projektos un pētījumos (Priya, Balambica, 2023).</li> <li>• Ieejas spriegums 3 – 5.5 V</li> <li>• Mērījumu diapazons: 20-90 %RH un 0-50 °C</li> <li>• Relatīvā gaisa mitruma precizitāte ±5%RH</li> <li>• Gaisa temperatūras precizitāte ±2°C</li> </ul>

Ierīce	Specifikācija un apraksts
 <p data-bbox="211 493 479 607"><b>(attēls aizgūts no Rosen, Iliyan et al., 2020)</b> HDC1080</p>	<ul data-bbox="571 311 1108 505" style="list-style-type: none"> <li>• Relatīvā gaisa mitruma un gaisa temperatūras mērījumiem</li> <li>• Ieejas spriegums 2.7 V līdz 5.5 V</li> <li>• Relatīvā gaisa mitruma precizitāte <math>\pm 2</math> RH%</li> <li>• Gaisa temperatūras precizitāte <math>\pm 0.2^{\circ}\text{C}</math></li> </ul>
 <p data-bbox="194 1152 497 1312"><b>(attēls aizgūts no Gümüser, Pichlhöfer et al., 2025)</b> DFRobot augsnes mitruma līmeņa kapacitīvais sensors</p>	<ul data-bbox="571 633 1096 1485" style="list-style-type: none"> <li>• Augsnes mitruma līmeņa noteikšanai izmantots “DFRobot” elektronikas piegādātāja augsnes mitruma līmeņa sensors, salīdzinoši precīzākais no pieejamajām alternatīvām (Radi, Murtiningrum, et al., 2018)</li> <li>• Ieejas spriegums: 3.3 - 5.5 V</li> <li>• Izejas spriegums (mērījuma diapazons): 0 ~ 2.9V iespējamais analogo vērtību diapazons: 0 - 4096</li> <li>• Sausas augsnes mērījumu diapazons: (570, 380]</li> <li>• Vidējo mitras augsnes mērījumu diapazons: (380, 190]</li> <li>• Mitras augsnes mērījumu diapazons: (190, 0]</li> <li>• Tā kā šis sensors nosaka augsnes mitrumu pēc kapacitatīvās uztveršanas principa, tas uzrādīs atšķirīgu mitruma līmeni, ja to ievietos pēc tipa dažādās augsnēs, pēc augsnes blīvuma dažādās pakāpēs un dažādos dziļumos. Mitrums ir apgriezti proporcionāls nolasītajai vērtībai. Atšķirīgā gaisa mitruma dēļ dažādos reģionos un dažādos laika apstākļos, un starp atsevišķiem sensoriem var būt atšķirības.</li> </ul>

Ierīce	Specifikācija un apraksts
 <p>(attēls aizgūts no (Khadax, 2022))</p> <p>Vienplātes dators Khadas, modelis VIM 1S</p>	<ul style="list-style-type: none"> <li>• Khadas VIM 1S izvēlēts aparatūras, cenas, plašo saskarņu iespēju un jaudas dēļ, lai nodrošinātu regulāru automātisku sensoru mērījumu veikšanu, galbāšanu, nepārtrauktu attālinātu piekļuvi un datu apstrādi</li> <li>• Khadas vienplātes datoram ir 2.0GHz <i>Quad core ARM Cortex-A35</i> processors, 2GB <i>LPDDR4</i> operatīvā atmiņa, kā arī 40 spraudņu konektors. Khadas platei ir <i>HDMI</i>, <i>USB-C</i>, <i>Ethernet</i> ligzda un divas <i>USB</i> saskarnes, no kurām viena šī darba ietvaros izmantota mobilā interneta savienojuma nodrošināšanai un otra kā <i>FLIR</i> termokameras saskarne.</li> </ul>

Mērījumu veikšanai paredzētie sensori pievienoti vienplātes datoram *Khadax* (3.1. att.), izmantojot atsevišķus spraudņu savienojumus (*GPIO*, kas redzams 3.1. att. labajā daļā). Lai nodrošinātu slēgumu ar minimālu savienojumu skaitu, sensori saslēgti divās I<sup>2</sup>C kopnēs.



3.1. att. Kopējā elektriskās ķēdes slēguma shēma

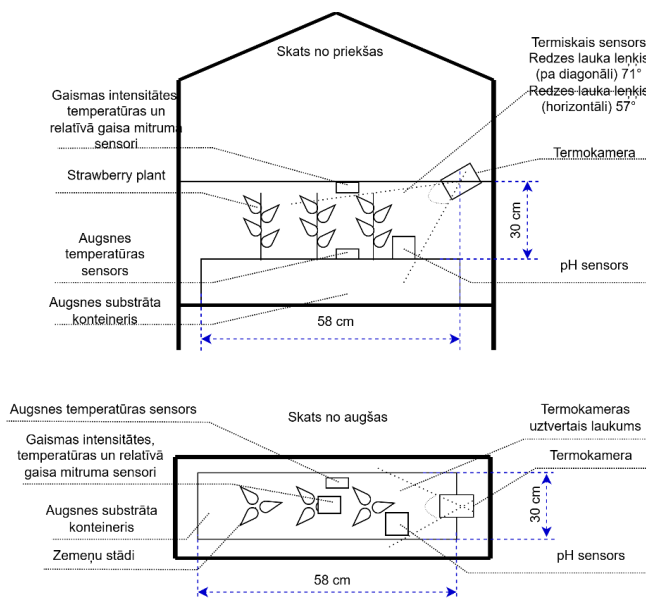
Rezultātā saliktais prototips ievietots korpusā minimālai integrēto shēmu un kameras aizsardzībai pret gaisa mitruma ietekmi siltumnīcā (3.2. att.).



**3.2. att. Korpusā salikts mērījumu ievākšanas prototips.**

### 3.1.2 Datu ievākšanas vide

Datu ievākšanas procesā bija jānodrošina datu ieguvi kontrolētos apstākļos, tāpēc mērījumi veikti siltumnīcās (3.3. att. un 3.4. att.), kurās 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 neliela izmēra siltumnīcā zemeņu stādiem**



#### 3.4. att. Mērījumu ievākšana LBTU Dārzkopības institūta siltumnīcā aveņu stādiem

Konkrēti LBTU dārzkopības institūta siltumnīcā veiktie novērojumi divu mēnešu laikā (2024. gada jūnijs līdz 2024. gada jūlijs) veikti salīdzinoši lielāka izmēra siltumnīcā, kur tiek sagatavoti dažādi stādi stādīšanai āra apstākļos.

#### 3.1.3 Datu ievākšanas process

Datu automatizētai ievākšanai tiek izmantoti vairāki skripti, kuri 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 I<sup>2</sup>C* kopnēm, pielietojot *smbus2* bibliotēku.

Temperatūras nolasišanai izveidota funkcija *read\_temperature*, kurai ir arguments “*bus*” (mainīgais *bus1* vai *bus4* atkarībā no kopnes, kuru izmanto) un kurai sākotnēji nepieciešams ieraksts temperatūras reģistrā, lai inicializētu mērījumu, no kā pēc tam iegūst 2 baitus ar temperatūras mērījumu. Funkcijas beigās tiek pārveidota neapstrādāta analoga vērtība uz cilvēkam viegli interpretējamu temperatūras mērījumu Celsija grādos. Līdzīgi rīkojas arī relatīvā gaisa mitruma nolasišanai kopnē pieslēgtam relatīvā gaisa mitruma un gaisa temperatūras *HDC1080* sensoram.

Gaismas intensitātes mērījumiem tiek izmantota funkcija *read\_light\_intensity* kura arī, lai inicializētu sensoru kopnē, veic ierakstu konfigurācijas *VEML7700\_LIGHT\_SENSOR\_CONF* reģistrā, pēc tam iespējams iegūt 16 bitu jeb 2 baitu gaismas intensitātes vērtību, ko arī atgriež funkcijas beigās. Iegūtos mērījumus skripta noslēgumā sagatavo *JSON* formātā un nosūta to lokāli darbinātai *Java* programmsaskarnei, saglabāšanai *Postgres* datubāzē.

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.

Pirmajā datu ievākšanas periodā 2023. gadā kopumā jūlija un augusta mēnešos tika ievākti 1072 termālie attēli un 2220 dažādu sensoru mērījumi, kuri tika izmantoti tālākai datu priekšapstrādei un modeļa apmācībai. Savukārt citi tiešo mērījumu sensori (pH un augšnes temperatūra) minētajā laika posmā nedeva derīgus mērījumus, dēļ vairākkārt izlādētas akumulatoru baterijas un neprecizitātēm, tādēļ tie netika iekļauti modeļa apmācībā. Apmācībā tika izmantoti tikai to laika momentu dati, kuri sakrīta abās datu kopās (termokameras un sensoru).

**Termiskā starojuma kamera** ik pēc 15 minūtēm uzņem augu termālos attēlus. Katrs attēls tiek saglabāts kā 120x160 pikseļu 2D masīvs CSV formātā. CSV formāts izvēlēts, jo Python, R, Excel un vairāki citi rīki ļauj apstrādāt šī formāta failus bez papildus ārēju bibliotēku pielietošanas. Lai gan izmantotā termokamera ir radiometriskā (kamerā izejas kanālā dotas kalibrētas vērtības), katram pikseļa mērījumam ir +/-0,05 °C ražotāja noteiktā precizitāte, un kamera spēj reģistrēt temperatūru diapazonā no -40 °C līdz +400 °C.

**Gaismas intensitātes sensors BH1750** mēra gaismas intensitāti augu vidē ar aptuveni ±20% precizitāti, diapazonā no 0,11 līdz 65 535 luksiem (lx). Šie dati ir nepieciešami, lai novērtētu fotosintēzes aktivitāti.

**Temperatūras un mitruma sensors DHT11** nodrošina apkārtējās vides temperatūras (ar ±2 °C precizitāti un mērījumu diapazonu no 0 līdz 50 °C) un relatīvā gaisa mitruma mērījumus (ar ±5% RH precizitāti un diapazonu no 0 līdz 100% RH).

**Kapacitatīvais augšnes ūdens saturs sensors** sniedz analogus mērījumu datus (ar aptuveni ±2% precizitāti un diapazonu no 0 līdz 100% RH) par augšnes mitruma līmeni, kas ir viens no galvenajiem faktoriem augu barības vielu uzņemšanas procesā. Otrajā datu ievākšanas periodā 2024. gadā jūnija un jūlija mēnešos tika ievākti 5520 termālie attēli un 2640 sensoru mērījumi (Datu piemērs dots 1. pielikumā). Šajā periodā arī izmantota termiskā starojuma attēlu ievākšana, pielietojot 15 minūšu intervālu. Datu precizitātes uzlabošanai šajā periodā izmantoti papildus gaismas intensitātes, relatīvā gaisa mitruma līmeņa un gaisa temperatūras sensori.

**Gaismas intensitātes sensors VEML7700** mēra gaismas intensitāti ar aptuveni ±10% precizitāti, diapazonā no 0 līdz 167 000 luksiem (lx).

**Temperatūras un mitruma sensors HDC1080** nodrošināja apkārtējās vides temperatūras (ar ±0.4 °C precizitāti un mērījumu diapazonu no -40 līdz 125 °C) un relatīvā

mitruma mērījumus (ar  $\pm 2\%$  RH precizitāti un diapazonu no 0 līdz 100% RH). Izmantojot vairākus mērījumu ievākšanas periodus tika nodrošināta plaša datu kopa par dažādām augu mikroklimata izmaiņām kopumā 4 mēnešu periodā.

#### **Informācija par 2023. gada mērījumu datu kopu:**

Divu mēnešu laikā (2023. gada jūlijs līdz 2023. gada augusts) katram sensoram (mitrums, temperatūra, gaisma) tika iegūti kopumā 1055 izmantojami (laikā sakritīgi ar automātiski iegūtajiem termokameru attēliem) stundas mērījumi.

- Gaisa temperatūra:
  - Maksimālā vērtība: 30.73 °C,
  - Minimālā vērtība: 16.39 °C,
  - Vidējā vērtība: 22.59 °C,
  - Standartnovirze: 2.59 °C
- Relatīvais gaisa mitrums:
  - Maksimālā vērtība: 93.0 RH%,
  - Minimālā vērtība: 12.7 RH%,
  - Vidējā vērtība: 35.08 RH%,
  - Standartnovirze: 9.56 RH%
- Gaismas intensitāte:
  - Maksimālā vērtība: 18388.47 lux,
  - Minimālā vērtība: 0.0 lux,
  - Vidējā vērtība: 764.66 lux,
  - Standartnovirze: 1700.99 lux

#### **Informācija par 2024. gada mērījumu datu kopu:**

Divu mēnešu laikā (2024. gada jūnijs līdz 2024. gada jūlijs) katram sensoram (relatīvais gaisa mitrums, gaisa temperatūra, gaismas intensitāte) tika iegūti kopumā 1053 izmantojami (laikā sakritīgi 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%
- Gaismas intensitāte:
  - Maksimālā vērtība: 7952.5 lux,
  - Minimālā vērtība: 0.0 lux,
  - Vidējā vērtība: 1828.94 lux,
  - Standartnovirze: 1684.49 lux

### 3.2 Datu analīze

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

Sensoru dati tika ielādēti, un lauks, kas saistīts ar mērījuma nolasīšanas laiku pārveidots par datuma un laika jeb laika zīmoga (*no angļu val. timestamp*) formātu, kas ļāva to izmantot, lai veiktu stundu izlases vidējo vērtību aprēķinu. Pēc tam apstrādātie dati tika saglabāti tādā formātā, lai nodrošinātu modeļa apmācību.


Līdzīga metode tika piemērota termālo attēlu datu priekšapstrādē, kur failu nosaukumos esošie laika zīmogi tika nolasīti un attēlu dati tika sakārtoti ar vidējo vērtību katrā stundā. Katrs CSV formāta attēla fails tika nolasīts, un, izmantojot identificēto stundu laika zīmogu, tika aprēķināts stundu vidējās vērtības, sakārtojot vienādā laikā uzņemtos attēlus un aprēķinot to vidējās vērtības katram pikselim. Šie apstrādātie dati, kur katram laika zīmogam atbilst vidējo vērtību matricas, tika saglabāti un izmantoti modeļa apmācībā.

Dati no katra sensora tika sākotnēji apstrādāti, lai novērstu trūkstošās vērtības un neatbilstības. Termālie attēli un sensoru mērījumi tika normalizēti, izmantojot min-max normalizācijas pieeju (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, gaismas intensitāte). Lai uzzinātu par dažādu mērījumu savstarpējo saistību, pirms modeļu apmācības tika veikta mērījumu korelācijas analīze (Senthilnathan, 2019).

Korelācija tika veikta gan starp ievāktajiem sensoru mērījumiem (3.5. att. un 3.6. att.), gan starp termokameras pikseļu temperatūras vērtībām un sensoru mērījumiem (3.7. att. un 3.8. att.).



### 3.5. att. Korelācijas analīze pēc sākotnējo mērījumu iegūšanas 2023. gadā

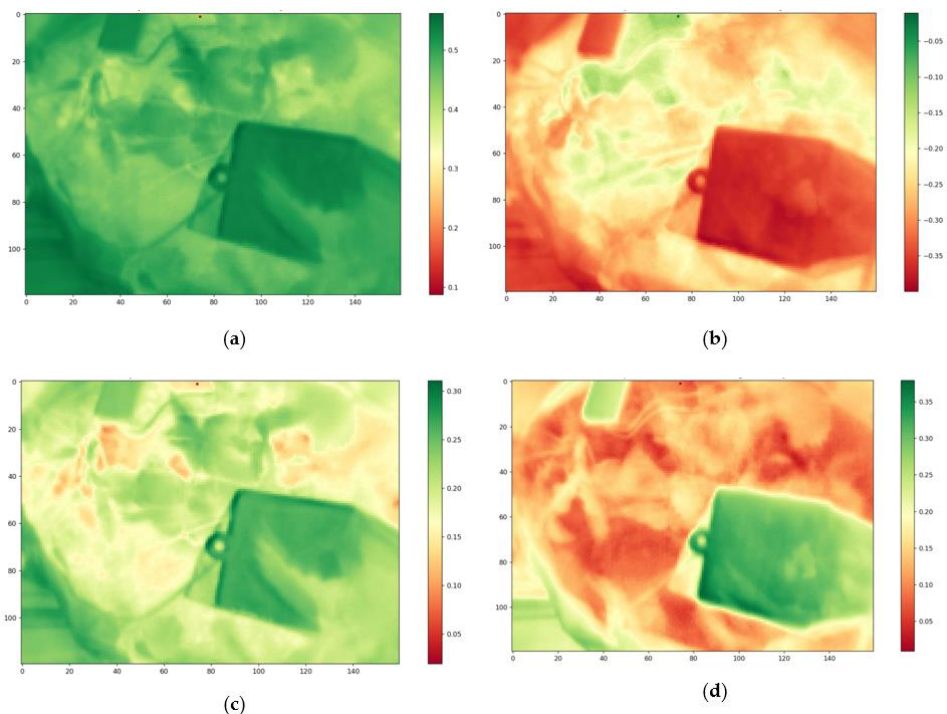
Pēc atkārtotu mērījumu veikšanas nākamajā (2024.) gadā izveidota korelācijas matrica (3.6. att.), kas uzrādīja salīdzinoši augstāku korelāciju starp gaisa temperatūras un gaismas intensitātes mērījumiem.



**3.6. att. Korelācijas analīze pēc atkārtotu 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. Šis solis palīdzēja noskaidrot, kā augu virsmas temperatūras, kas redzamas termālajos attēlos, ir saistītas ar citiem apkārtējiem vides sensoru mērījumiem. Tādējādi bija iespējams noteikt likumsakarības un savstarpējās atkarības, ko izmantot, izvēloties mašīnmācīšanās modeļa parametrus.


Korelācijas analīzes rezultāti apstiprināja, ka termālie attēli cieši korelē ar tuvējo gaisa temperatūras sensoru datiem. Savukārt 3.7. attēlā redzamās korelācijas kartes parāda pikseļu vērtību un dažādu sensoru mērījumu savstarpēju saistību divu mēnešu griezumā no jūlija sākuma līdz augusta beigām 2023. gadā. Katras korelācijas kartes asis atspoguļo 120x160 pikseļu koordinātes, kas atbilst termoattēla kadra izmēriem.



**3.7. att. Dažādas sensoru korelācijas ar termokameras attēla pikseļiem datu vākšanas periodā 2023. gadā. Korelācijas karte veidota starp termokameras temperatūras pikseļu vērtībām un: (a) gaisa temperatūras sensora mērījumiem; (b) relatīvā gaisa mitruma sensora mērījumiem; (c) augsnes mitruma līmeņa sensora mērījumiem; (d) Gaismas intensitātes sensora mērījumiem. (aizgūts no (Kempelis, Polaka, et al., 2024))**

Piemēram, 3.7. attēla (a) daļā, pikselis, kas atrodas 0. vertikālajā un 0. horizontālajā koordinātē ( $X = 0$ ;  $Y = 0$ ), parādās tumšākā zonā, kas norāda uz salīdzinoši augstu korelāciju ar gaisa temperatūras mērījumiem, salīdzinot ar citiem pikseļiem 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, augsnes ūdens saturu un gaismas intensitāti, kas tika vienlaikus mērīti. Tika konstatēts, ka gaismas intensitāte korelē vismazāk ar termālajiem attēliem, lai gan atsevišķas tuvumā esošas virsmas (piemēram, pH un augsnes temperatūras sensoru korpusi) uzrādīja nelielu korelāciju. Interesanti atzīmēt arī, ka aplūkojot šīs korelācijas kartes, var secināt, ka augsnes virsmas temperatūru salīdzinoši vismazāk ietekmē apkārtējās temperatūras izmaiņas.

Līdzīgi, kā 2023. gadā, arī 2024. gadā, pēc mērījumu ievākšanas LBTU (Latvijas Biozinātņu un tehnoloģiju universitātes) dārzkopības institūta siltumnīcā no jūnija sākuma līdz jūlija beigām analizēta termokameras pikseļu korelācija ar sensoru mērījumiem (3.8. att.).



**3.8. att. Korelācijas ar termokameras attēla pikseļiem 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) gaismas intensitātes 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, Mami et al., 2024), (Katz, Bengal et al., 2023) un ir salīdzinoši precīzāka metode mitruma līmeņa pietiekamības noteikšanai

augos nekā kapacitīvā tipa sensori, jo ietver papildus informāciju par apkārtējo 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, Al Kalaany et al., 2025). Analīzes rezultātā iespējams secināt, ka gaismas intensitātes, gaisa temperatūras un relatīvā gaisa mitruma mērījumi ir salīdzinoši vairāk saistīti ar termokameras uztverto termisko starojumu nekā augu mitruma līmeņa pietiekamības mērījumi.

Pēc tam, kad tika novērtēta katra sensora (gaisa temperatūras, relatīvā gaisa mitruma, augsnes ūdens satura un gaismas intensitātes) mērījumu korelācija ar termālajos attēlos iegūtajiem pikseļu datiem, katram no minētajiem sensoriem tika izstrādāts atsevišķs modelis. Šajā darbā sensora mērījumu prognozes modeļu izstrādei tika izvēlēti konvolūciju neironu tīkls un redzes transformeri, jo veicot literatūras analīzi apstiprinājās, ka divas minētās tehnoloģijas ar salīdzinoši augstāko precizitāti darbojas gan attēlu datu klasifikācijā, gan regresijas uzdevumos, lai gan redzes transformeri pagaidām vēl nav pietiekami pētīti regresijas uzdevumos.

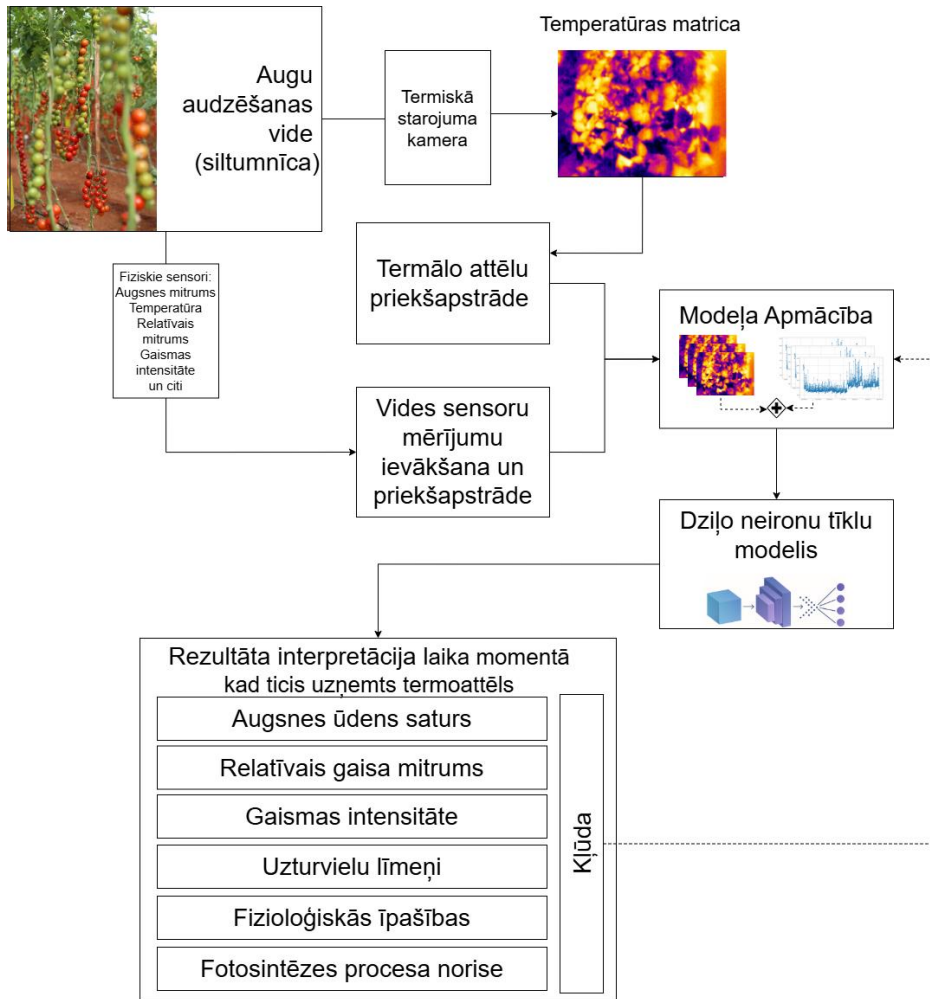
### 3.3 Mērījumu novērtēšanas modeļu izstrāde

Šī darba ietvaros 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.

Mērījumu novērtēšanas modeļu izstrādes un apmācības process sastāv no vairākiem savstarpēji saistītiem posmiem:

1. datu ievākšanas,
2. priekšapstrādes,
3. modeļa apmācības,
4. testēšanas,
5. novērtēšanas jeb salīdzināšanas ar reāliem mērījumiem

Prototipa sensoru mērījumu novērtēšanas moduļa darbības konceptuālais modelis redzams 3.9. attēlā.




**3.9. att. Modeļa apmācības un testēšanas procesa konceptuālais modelis.**

Šī pētījuma ietvaros tiek pētīta gaismas intensitāte, relatīvais gaisa mitrums, temperatūra un augsnes ūdens saturs, jo šie faktori būtiski ietekmē lapotnes temperatūru, kas ir redzama termiskā starojuma attēlos. Gaismas intensitāte veicina fotosintēzes norisi un augu atvārsnīšu (*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, Ramachandran, et al., 2020) un (Ham, Kim, et al., 2019) pētījumos apskatītās sensoru mērījumu prognozēšanas metodes, kuras uzrādījušas salīdzinoši augstu precizitāti, izmantojot tieši “VGGnet” (Chandrapu, Pal, et al., 2022) tipa konvolūciju tīklu arhitektūru, priekš izvietojanas uz prototipa tika izstrādāta šī modeļa arhitektūras konfigurācija (3.10. att.). Izmantotā arhitektūra paredzēta attēlu analīzei, ar vienas vērtības (mērījuma) ieguvu modeļa izejā.



**3.10. att. CNN VGG tīkla modeļa arhitektūra sensoru mērījumu novērtēšanai (aizgūts no (Kempelis, Polaka, et al., 2024))**

Izstrādātā modeļa ieejā paredzēts izmantot termiskās kameras ģenerētās radiometriskās 120x160 pikseļu temperatūras matricas, kas iegūtas no termokameras uzņemtajiem kadriem. Temperatūras mērījumu attēls (ieejas dati modelī 3.10. att), izmantots tikai temperatūras atšķirību vizualizācijai, bet modeli apmācot ieejā tika nodota divdimensiju matrica ar katra pikseļa temperatūras mērījumiem (3.11. att.).


17.75	17.72	17.65	17.56
17.72	17.65	17.65	17.65
17.77	17.96	17.42	17.65
17.65	17.58	17.61	17.3
17.75	17.44	17.39	17.37
17.65	17.61	17.46	17.58
17.7	17.46	17.32	17.39
17.54	17.56	17.46	17.28

**3.11. att. Temperatūras mērījumu pikseļu matricas daļējs piemērs 17 Celsija grādu temperatūras reģionā (pilns tabulas piemērs 2. pielikumā)**


Modeļa izejā tiek iegūts iepriekš noteikta sensora (gaismas intensitātes, gaisa mitruma, augsnes mitruma) mērījums ar noteiktu precizitāti tajā pašā laika momentā, kad ticis uzņemts termiskais attēls. Modelis izstrādāts, izmantojot *Tensorflow* bibliotēku, kas ir atvērtā pirmkoda mašīnmācīšanās platforma (Rauf, Zaid, et al., 2023). Iepriekš aplūkotais modelis (3.10. att.) ietver konvolūcijas slāņus augsta līmeņa pazīmju iegūšanai no termālajiem attēliem, *pooling* jeb apvienojošos slāņus datu dimensiju samazināšanai (sekojošajiem slāņiem), kā arī pilnībā savienotos slāņus šo iegūto pazīmju analīzei. Lai gan konvolūciju tīkli bieži tiek izmantoti attēlu klasifikācijas uzdevumos, šajā pētījumā arhitektūra tika pielāgota, lai prognozētu tikai vienu sensora mērījumu, kas atbilst tam pašam laika momentam kad iegūta modeļa izejā nodotā temperatūras matrica. Šī iemesla dēļ bija nepieciešams iekļaut “blīvo” (angl. *dense*) slāni ar vienu neironu modeļa izvadi, kas atbilst prognozētajam sensora mērījumam.

Datu kopa tika sadalīta divās daļās, modeļa apmācībai un pārbaudei. Apmācībai tika izmantoti 80% datu, kuri sadalīti attiecīgi 60% un 20%. 60% apmācības kopa izmantota tikai modeļa modeļa svaru jeb parametru iemācīšanai, bet 20% validācijas kopa izmantota hiperparametru izvēlei. Šajā posmā testēšanas dati netiek izmantoti. Pēc galīgā modeļa un hiperparametru izvēles modeļa veiktspēja novērtēta uz atlikušajiem 20% jeb testēšanas kopas. Testēšanas dati netiek izmantoti apmācībai vai validācijai, tāpēc tie sniedz modeļa vispārināšanās spējas novērtējumu.


Sākotnējā apmācības procesā izmantota grafiskā karte NVIDIA GeForce GTX1060 ar 6GB 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 (3.12. att.), lai noteiktu pārāpmācību vai nepietiekamu apmācību.



**Gaismas intensitātes prognozes**



**Relatīvā gaisa mitruma prognozes**



**Gaisa temperatūras prognozes**

**3.12. att. Gaisa temperatūras, Relatīvā mitruma un gaismas intensitātes apmācības kļūda pie dažāda epohu skaita 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 cik labi modeļa prognozes sakrīt ar tiem datiem, kurus modelis jau ir izmantojis apmācības procesā. Ir sagaidāms, ka pieaugot epohu skaitam, kļūda samazinās ar nelielām svārstībām, kas raksturo modeļa optimizācijas procesu. Validācijas kļūda šajā gadījumā tiek noteikta pēc atsevišķas datu kopas, kuru 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 novest pie pārāpmācības, 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 dēļ neatbilstošas apmācības ātruma konfigurācijas vai citiem parametriem, kurus ir salīdzinoši sarežģīti noteikt, ja blakus nav apmācības kļūda ar ko salīdzināt.

- Nepietiekama apmācība (angļ. Underfitting) raksturīga pirmajām epohām, kur apmācības un validācijas kļūdas ir salīdzinoši lielas.
- Optimāla modeļa vispārināšanās (angļ. Generalisation) raksturīga vidusdaļai, kur apmācības kļūda turpina kristies, bet validācijas kļūda sasniedz globālu minimumu jeb līkne izlīdzinās.
- Pārāpmācība (angļ. 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 (3.12. att.) var secināt, ka piemērotākais epohu skaits katra mērījuma novērtēšanās konvolūciju tīkla modelī ir:

1. Gaisa temperatūrai: 40 epohas
2. Relatīvajam gaisa mitrumam: 60 epohas
3. Gaismas intensitātei: 50 epohas

pēc kurām apmācības kļūda izlīdzinās un vairs nenotiek ievērojama modeļu veiktspējas uzlabošanās.

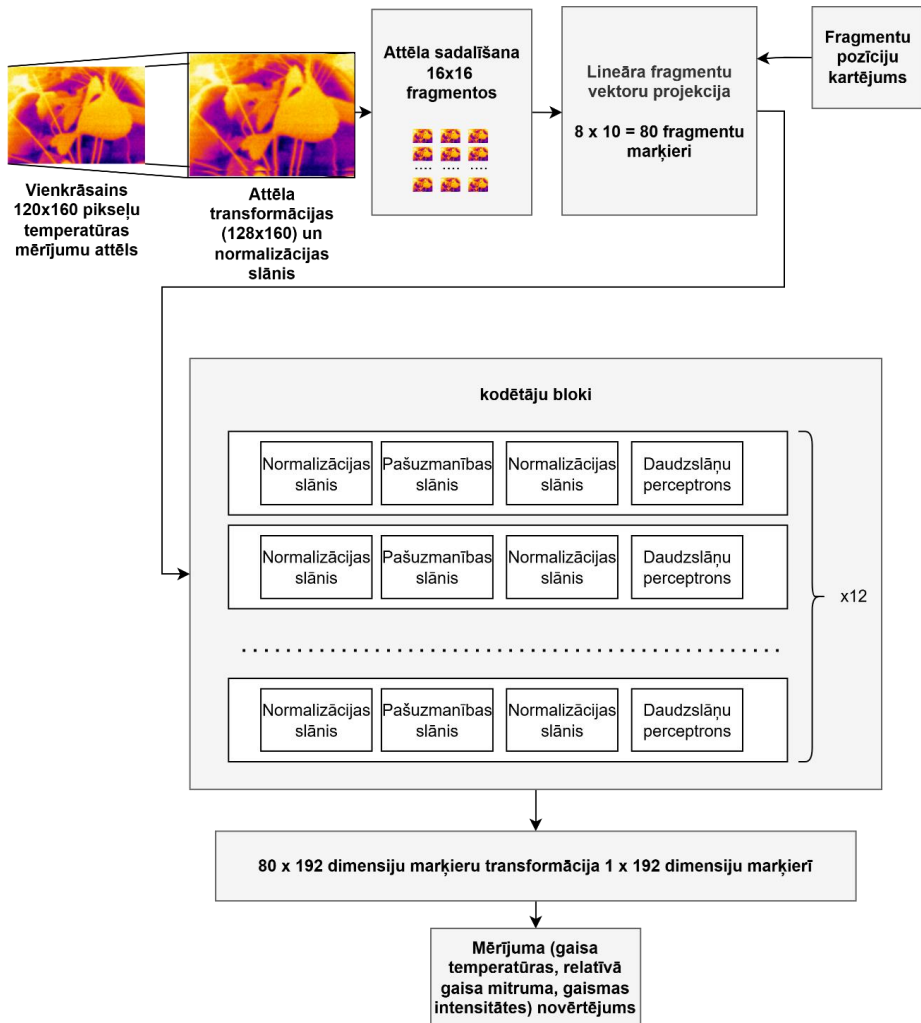
### 3.3.2 ViT modeļa izstrāde un apmācība

Redzes transformeru modeļa izstrādī šī darba ietvaros veidoja trīs savstarpēji saistīti posmi, kas ir termokameras radiometrisko mērījumu laika grupēšana pa stundām, līdzīgi kā

iepriekš CNN modeļa izstrādē, arhitektūras izvēle, kas paredzētu telpisko atkarību atklāšanai vienkanāla (temperatūras mērījumu) termālajos kadros, un atkarīgais apmācības process.

Katram stundas vidējam kadam tika piesaistīts atbilstošs tās pašas stundas mērījums no ievāktajiem reālo sensoru mērījumiem. Modeļa ieeja ir neatkarīga no izejas dimensijas un rezultātā no katra stundas vidējā termokameras kadra tiek prognozēts viens stundas vidējais mērījums, gaisa temperatūra, relatīvais gaisa mitrums vai gaismas intensitāte. Datu kopai izmantota normalizācija, nodrošinot identisku datu mērogošanu modeļa apmācībā un inferences laikā.

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 – 120x160 pikseļi. *VitTiny* ir viens no salīdzinoši mazākajiem modeļiem *timm* bibliotēkas ViT modeļu saimē, jo tam ir salīdzinoši mazākais slēpto slāņu aptuvenais skaits, kas ir 192 un parametru kopējais aptuvenais skaits ir 5 milj., līdz ar to tas ir salīdzinoši piemērotākais no ViT modeļiem tieši malu skaitļošanas IoT ierīcēs. “*patch16*” norāda, ka attēls tiek sadalīts nepārklājošos 16 x 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 x 224 pikseļu ieejas attēliem. Ja ievades izmērs mainās (ir atšķirīgs no oriģinālā modeļa), tad atšķirības ir jāinterpolē, kas var nelielā mērā ietekmēt modeļa veiktspēju. Šajā gadījumā no 120x160 pikseļiem īsākā mala – 120 pikseļi nedalās ar 16 (no attēla atdalīta bloka izmērs), tādēļ nepieciešams interpolēt papildus 8 pikseļus, rezultātā iegūstot ieejas izmēru 128x160 (3.13. att.) (Touvron, Cord, et al., 2021).




3.13. att. Transformera *ViT-tiny* arhitektūra

Atšķirībā no konvolūciju tīkliem, kas lieto un pārvieto attēlā lokālu uztveres režģi (literatūrā tiek saukts arī par filtru), redzes transformēru gadījumā tiek izmantots pašuzmanības mehānisms globālu termālo iezīmju uztveršanai, kas ir būtiski, lai noteiktu temperatūras atkarības lielākā mērogā, izmantojot iespējamās korelācijas ar mērījumiem, piemēram, relatīvo mitrumu vai gaismas intensitātes mērījumiem.


Pēc modeļa apmācības, apskatot iegūtos rezultātus (3.14. att.) var secināt, ka piemērotākais epohu skaits katram mērījumam redzes transformēru modeļi ir:

1. Gaisa temperatūrai: 10 epohas
2. Relatīvajam gaisa mitrumam: 45 epohas
3. Gaismas intensitātei: 75 epohas


pēc kurām apmācības rezultāts izlīdzinās un vairs nenotiek ievērojama modeļu veikspējas uzlabošanās.



**Gaismas  
intensitātes  
prognozes**



**Relatīvā  
gaisa  
mitruma  
prognozes**



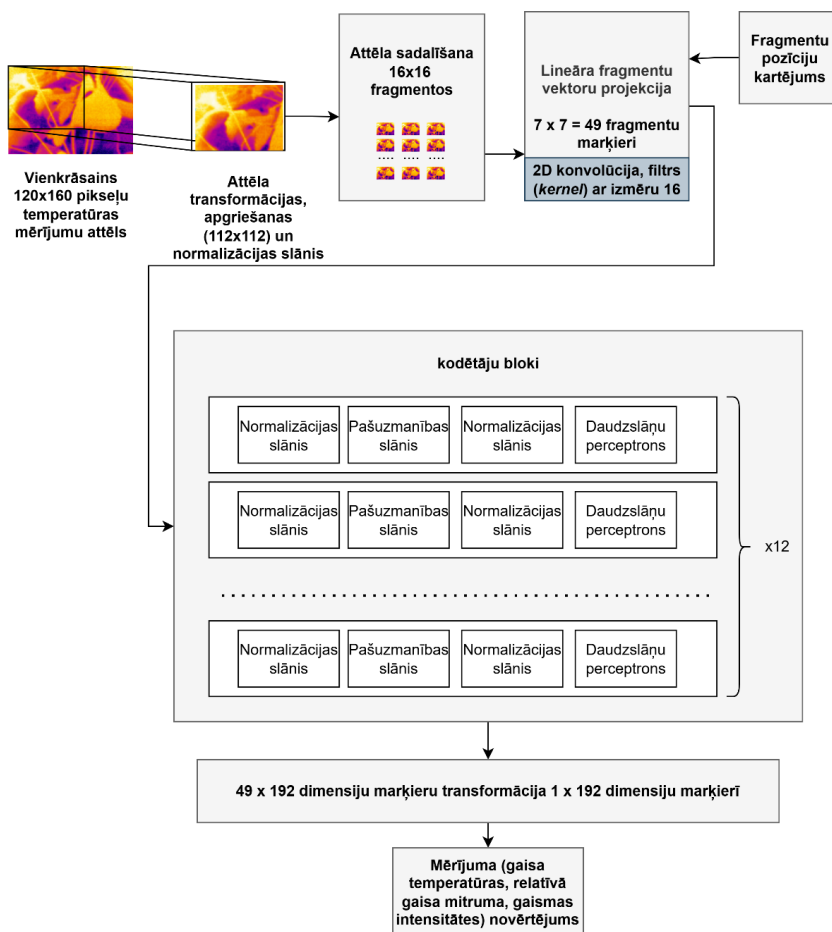
**Gaisa  
temperatūras  
prognozes**

**3.14. att. Gaisa temperatūras, Relatīvā mitruma un gaismas intensitātes apmācības kļūda pie dažāda epohu skaita ViT-Tiny apmācības laikā**

Atšķirībā no konvolūciju tīklu apmācības redzes transformeri skaitļošanas ziņā prasa vairāk resursus un apmācība uz datora procesora ir iespējama, bet ir vairākas reizes lēnāka. Salīdzinājumam var minēt, ka eksperimentu laikā viena redzes transformeru modeļu epoha, kas izpildīta uz datora procesora aizņēma aptuveni 10 minūtes, savukārt uz grafiskās kartes šis apmācības solis aizņēma aptuveni dažas sekundes.

### 3.3.3 CvT modeļa izstrāde un apmācība


Ņemot vērā abu (ViT un CNN) arhitektūru priekšrocības, darba praktiskās daļas ietvaros apskatīta arī literatūrā pieminētā hibrīdā ideja par konvolūciju redzes transformeriem (no angļu val. *CvT*) (Wu, Xiao, et al., 2021) (3.15. att.).



3.15. att. Konvolūciju transformera *ConvViT*-tiny arhitektūra


Līdzīgi kā iepriekš, arī CvT modeļa sagatavošanā attēli vispirms tiek apkopoti ar vidējo vērtību katrā stundā. Katrs vidējā mērījuma termo attēla kadrs tiek piekārtots laika vērtībai no sensora mērījumu datiem, iegūstot katram attēlam atbilstošu mērījumu, konkrētā laika momentā.

Nākamais priekšapstrādes solis ietvēra attēla apgriešanu līdz 112 x 112 pikseliem. Tas darīts, jo pielietotajā *timm* bibliotēkas *ConViT\_Tiny* arhitektūrā attēls tiek pārvērsts par marķieru (angl. *token*) secīgu virkni, pielietojot vienu divdimensiju konvolūciju. Tas nozīmē, ka arhitektūras ieejā paredzētā attēla platuma un garuma izmēriem ir obligāti jāsakrīt. Ņemot vērā, ka termoattēla kreisajā pusē atrodas augi, 112 x 112 pikseli ņemti no kreisā augšējā stūra (laukums iezīmēts ar sarkanu rāmi 3.16. att.), lai pēc iespējas vairāk saglabātu informāciju, kas nepieciešama mērījumu prognozei.




**3.16. att.** Termokameras attēlā redzamais augu audzēšanas reģions 112 x 112 pikseli


Modeļu apmācībā, līdzīgi kā ViT, izmantota MSE zuduma funkcija. Kļūdas rādītāji tika vizualizēti temperatūras un relatīvā gaisa mitruma mērījumiem pie 100 un gaismas intensitātei pie 200 epohām, lai noteiktu pārāpmācību vai nepietiekamu modeļa apmācību (3.17. att.).



**Gaismas intensitātes prognozes**



**Relatīvā gaisa mitruma prognozes**



**Gaisa temperatūras prognozes**

**3.17. att. Gaisa temperatūras, Relatīvā mitruma un gaismas intensitātes apmācības kļūda pie dažāda epohu skaita ConViT-Tiny redzes transformera apmācības laikā**

Apskatot iegūtos rezultātus (3.17. att.) var secināt, ka apmācībai piemērotākais epohu skaits katram mērījumam konvolūciju redzes transformera modeli ir:

1. Gaisa temperatūrai: 10 epohas
2. Relatīvajam gaisa mitrumam: 45 epohas
3. Gaismas intensitātei: 160 epohas

pēc kurām apmācībā nenotiek ievērojama modeļu veiktspējas uzlabošanās.

### 3.4 Nodaļas kopsavilkums un secinājumi

Šajā nodaļā aprakstīta datu ievākšanas prototipa moduļa izstrāde un mērījumu prognozēšanas modeļu izstrāde, kas pārveido termiskos attēlus vides mērījumu reāllaika prognozēs. Tā kā publiski pieejamu datu kopu, kur termokameras radiometriskie attēli būtu saistīti ar sensoru mērījumiem, trūkst, tika izveidots prototipa datu ievākšanas modulis. Datu ievākšanā izmantota FLIR Lepton 3.5 radiometriskā kamera (ar 120 x 160 pikseļu izšķirtspēju) kopā ar dažādiem sensoriem – gaismas intensitātes (BH1750, VEML7700), gaisa temperatūras, relatīvā mitruma (DHT11, HDC1080) un kapacitīvo augsnes mitruma sensoru. Khadas VIM 1S vienplates dators, kas ik pēc 15 minūtēm nolasītās sensoru mērījumu un kameras uzņemtās temperatūras matricas vērtības automātiski saglabā datubāzē. Tika veikti divi datu ievākšanas mēģinājumi: 2023. gada jūlijā–augustā (1 072 termoattēli un 2 220 sensoru mērījumi) un 2024. gada jūnijā–jūlijā (5 520 termoattēli un 2 640 sensoru mērījumi). Abos gadījumos fiksētais temperatūru (5–38 °C), relatīvā mitruma (13–100 % RH) un apgaismojuma (0–18 389 lx) diapazons nodrošina datu kopu četru mēnešu periodā. 3. pielikumā dots termoattēlu piemērs konkrētai dienai.

Pirmsapstrādē sensoru mērījumi un pikseļu matricas tiek grupētas pa stundu vidējām vērtībām. Trūkstošie punkti tiek atvesti, atribūti normalizēti ar min–max metodi. Korelācijas analīze rāda, ka vairums termisko attēlu pikseļu korelē ar gaisa temperatūru, relatīvo mitrumu un gaismas intensitāti, tādējādi nodrošinot pamatotu sensoru ieejas vērtību izvēli modeļu apmācībā. Stundu vidējie rādītāji, korelācijās balstīta iezīmju analīze bija svarīga modeļu vispārīnāšanas spējai, jo tie sākotnējo eksperimentu laikā deva uzlabojumus modeļa veikspējā.

Modeļu izstrādē pielietotas trīs dziļās mācīšanās arhitektūras:

1. *VGG* tipa konvolūciju neironu tīkls saņem 120 x 160 pikseļu temperatūras matricu un, caur konvolūcijas apvienojošajiem blokiem iegūst vienu sensora vērtību, kas atbilst ieejas attēla laika momentam.
2. *ViT-tiny* redzes transformers, kur 120 x 160 pikseļu attēli tiek interpolēti līdz 128 x 160 pikseļiem, lai padotu modeļa ieejā arhitektūrai atbilstoša izmēra attēlu.
3. *ConViT-tiny*, kur ievade tiek apgriezta līdz 112 x 112 pikseļiem, lai nodrošinātu kvadrātveida ieejas attēla formātu, kas ir nepieciešams dotajā arhitektūrā *timm* bibliotēkas pielietošanas kontekstā.

Visi modeļi izmanto vidējo kvadrātisko kļūdu, kā zuduma funkciju, *AdamW* optimizētāju un 60% apmācības, 20% validācijas un 20% testēšanas datu kopas dalījumu.

Sākotnējā modeļu apmācības līkņu analīze nosaka apmācības apstāšanās punktus, lai atrastu nepietiekamu vai pārmērīgu modeļa vispārināšanos. ViT gadījumā 10 epochas (gaisa temperatūrai), 45 epochas (relatīvais mitrums) un 75 epochas (gaismas intensitāte). ConViT modelim gaismas intensitātes mērījuma prognozei bija nepieciešams līdz 160 epochām. Redzes transformeru modelis atsevišķos gadījumos spēja apmācīties salīdzinoši ātrāk nekā konvolūciju redzes transformeru modelis, kas liecina par hibrīdās arhitektūras piemērotību dotajai datu kopai šāda veida mērījumu prognozē.

Modeļu izstrādes laikā gūtās atziņas apstiprināja, ka vienas ierīces radiometrisko attēlu analīze, pielietojot dziļās mācīšanās metodes, rada potenciālu noteikt gaisa temperatūras, relatīvā mitruma un gaismas intensitātes mērījumus kontrolētā lauksaimniecības vidē, neizmantojot atsevišķus sensorus, kas ļautu samazināt mērījumiem nepieciešamo ierīču skaitu.

## 4 MĒRĪJUMU NOVĒRTĒŠANAS PIEEJAS IZSTRĀDE UN VALIDĀCIJA

Darba ietvaros tiek izstrādāta pieeja, kas balstīta uz iepriekš uzbūvēto datu ievākšanas moduli, tā ievāktajiem mērījumiem un piemērotākā modeļa pielietošanu 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.

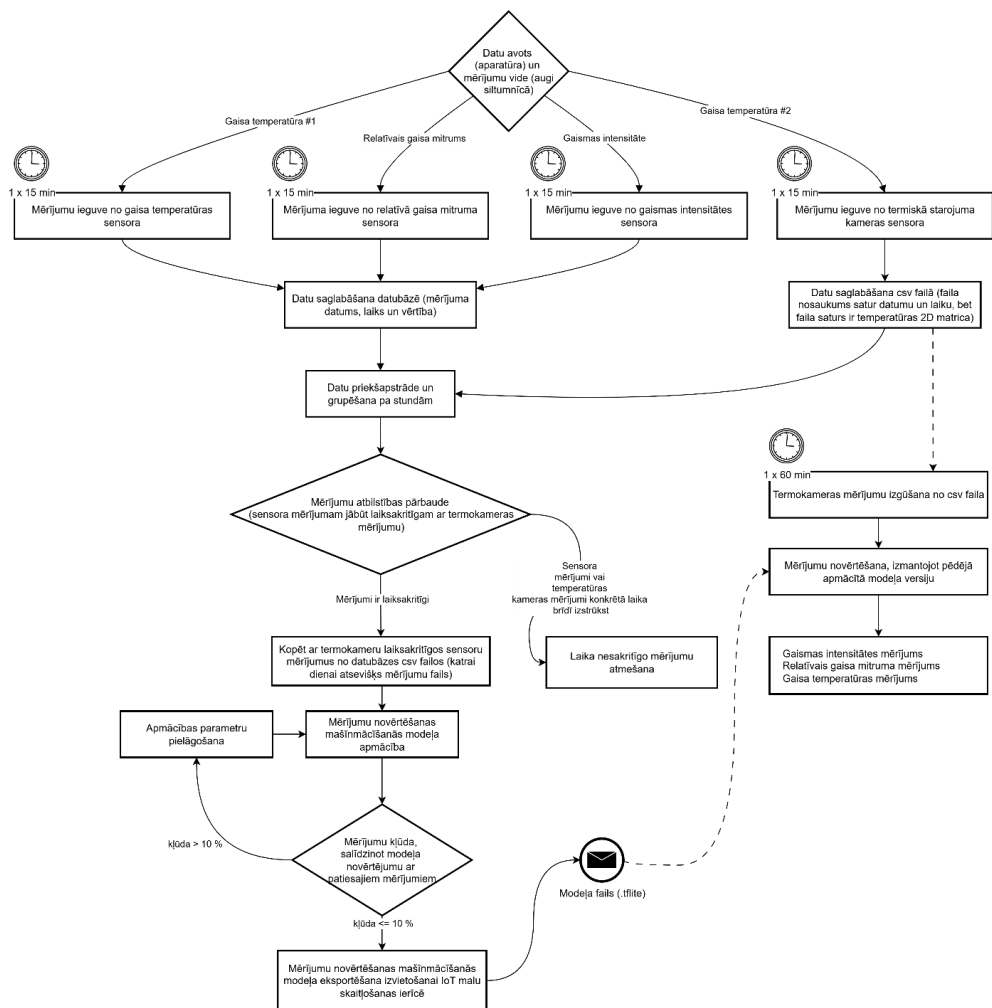
### 4.1 Pieejas izstrāde

Darba ietvaros 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 sensoriem 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 gaismas intensitātes 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 nozīmīgas 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, gaismas intensitāte), 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 ieraksti tiek atnesti vai netiek ņemti vērā mašīnmācīšanās modeļa apmācībā, jo darba ietvaros netiek apskatīta laika rindu regresijas mērījumu prognozes jeb novērtēšanas veids.

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. Ja iegūtā mērījumu kļūda pārsniedz 10%, tad apmācība tiek atkārtota, pielāgojot apmācības parametrus vai izmantojot papildus ievāktos mērījumus. Gadījumā, ja kļūda nesasniedz 10%, tad apmācība tiek uzskatīta par veiksmīgu un modelis tiek kompilēts un eksportēts modeļa failā (piemēram, *tflite* vai *pkl* formātā), kas izmantojams izvietošanai dažādās malu skaitļošanas ierīcēs. Malu ierīcē, kas ievāc termālos kadrus, tiek veikta mērījumu novērtēšana, pielietojot pēdējās versijas izvietoto novērtēšanas modeļa failu un skriptu, kas tiek palaists reizi stundā. Pēc automātiskas skripta palaišanas reizi stundā tiek iegūts rezultāts, kas ietver trīs mērījumu novērtējumus (gaisa temperatūru, relatīvo gaisa mitrumu un gaismas intensitātes mērījumiem). Pieejas kopējā blokshēma dota 4.1. attēlā.



**4.1. att. Mērījumu novērtēšanas pieejas blokshēma**

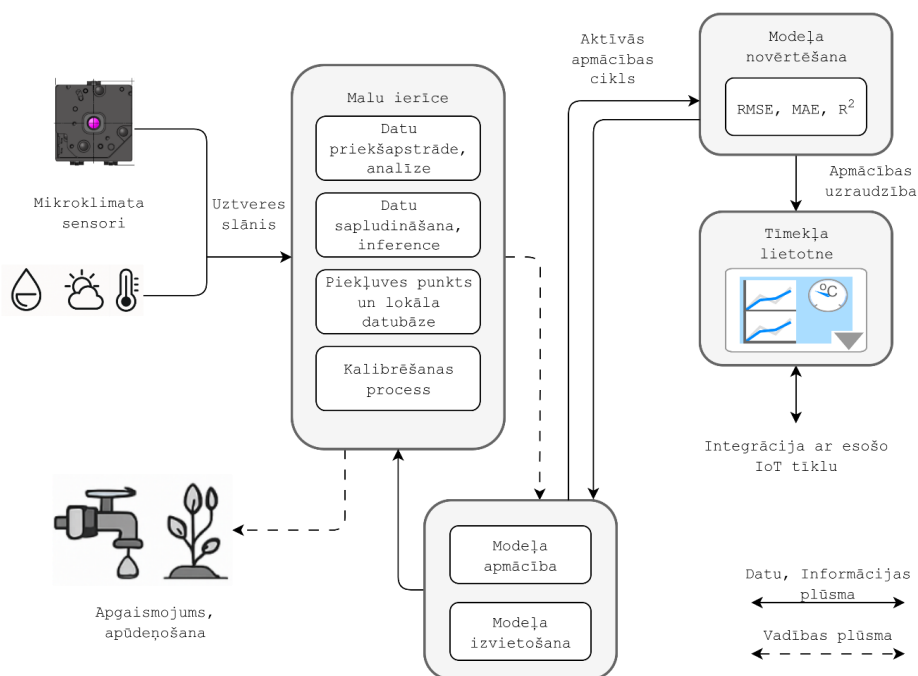
Pieejā minēto modeļu apmācību iespējams veikt gan malu skaitļošanas ierīcē paralēli mērījumu ievākšanas procesam, gan izmantojot augstas veiktspējas skaitļošanai paredzētu aparatūru.

## 4.2 Prototipa izstrāde

Prototips, kas ir saistīts ar iepriekš izstrādāto mērījumu novērtēšanas pieeju, sevī 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.

Prototipa mērķis ir kalpot par pamatu automatizētai un uz datiem balstītai lauksaimniecības procesu pārvaldībai, īpaši precīzās lauksaimniecības siltumnīcu mikroklimata uzraudzības kontekstā. Tas ļauj lauksaimniecības darbiniekiem attālināti sekot augu augšanas procesiem un savlaicīgi pieņemt lēmumus par nepieciešamajām darbībām, piemēram, apūdeņošanu vai apgaismojuma regulēšanu. Prototips ir nozīmīgs arī no resursu optimizācijas viedokļa, jo potenciāli var samazināt ūdens, enerģijas un barības vielu patēriņu.

Prototipa pamatā ir apmācīta mašīnmācīšanās modeļa izvietošana malu skaitļošanas ierīcēs, lai no tajās uzstādītajiem termokameras attēliem novērtētu trīs galvenos mikroklimata mērījumus – gaisa temperatūru, relatīvo gaisa mitrumu un gaismas intensitātes līmeni (4.2. att.). Izstrādātā pieeja paredz modeļu regulāru apmācību un to precizitātes novērtēšanu, salīdzinot prognozētās vērtības ar patiesajiem sensoru mērījumiem. Ja kļūdas līmenis pārsniedz noteiktu sliekšni (piemēram, 10%), apmācība tiek atkārtota ar pielāgotiem parametriem vai papildus ievāktajām datu kopām. Atkārtotā apmācība nodrošina prototipa spēju pielāgoties mainīgajiem vides apstākļiem un ilgtermiņā saglabāt salīdzinoši augstu mērījumu novērtējumu precizitāti.



**4.2. att. Mērījumu novērtēšanas prototips**

Lai noteiktu piemērotāko arhitektūru, ko izvietot prototipa ierīcēs, tika veikts eksperimentu komplekss, izmantojot dažādas modeļu arhitektūras – konvolūciju tīklu, redzes

transformeru un konvolūciju redzes transformeru hibrīdarhitektūra. 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, kuru veido trīs pēc arhitektūras atšķirīgu mašīnmācīšanās modeļu apmācība. Apmācība veikta, lai atrastu patieso mērījumu novērtējumiem piemērotāko modeli, kā arī noteiktu atbilstošā modeļa veikspēju.

**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. Mērījumu ievākšanas laiki un apraksts apkopots 4.1. tabulā.

Mērījumu ievākšanas grafiks

	2023. gads	2024. gads
<b>Sākuma datums</b>	01.07.2023.	01.06.2024.
<b>Beigu datums</b>	31.08.2023.	31.07.2024.
<b>Intervāls starp mērījumiem</b>	15 minūtes	15 minūtes
<b>Ievāktie mērījumi</b>	Gaisa temperatūra, Relatīvais gaisa mitrums, augsnes mitrums, gaismas intensitāte, termokameras kadri	Gaisa temperatūra, Relatīvais gaisa mitrums, gaismas intensitāte, termokameras kadri

Minimālais gaisa temperatūras, gaismas intensitātes un relatīvā gaisa mitruma mērījumu skaits nav noteikts, bet eksperimentu izpildei ievāktajiem mērījumiem jāatbilst datu kopai, kas pietiekami aptver vides apstākļu izmaiņas, bieži tie ir vismaz vairāki tūkstoši mērījumu katram sensoram, kas ietver vairākus diennakts ciklus. Ņemot vērā sākotnējo datu analīzi un to, ka visi trīs modeļi spēj konverģēt pie esošā mērījumu skaita, tad mērījumu skaita apjoms šajā darbā veiktajā pētījumā tiek uzskatīts par pietiekamu.

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.

#### **Eksperimentu apraksts:**

Lai izpildītu eksperimentu plānu, tiek paredzēts veikt eksperimentu sēriju, kas satur četrus galvenos eksperimentus. Katra eksperimenta apraksts un mērķis dots 4.2. tabulā.

## Plānotie mērījumu novērtēšanas eksperimenti

Nr	Eksperimenta apraksts	Eksperimenta mērķis
1.	Izmantojot konvolūciju tīklu arhitektūru un 2023. gadā iegūto datu kopu, apmācīti 3 konvolūciju modeļi. Apmācība atkārtota vairākas reizes un 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 gaismas intensitātes) novērtēšanā.
2.	Izmantojot konvolūciju tīklu arhitektūru un 2024. gadā iegūto datu kopu, apmācīti 3 konvolūciju modeļi.	Noteikt konvolūciju tīklu modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un gaismas intensitātes) novērtēšanā.
3.	Izmantojot redzes transformēšanu arhitektūru un 2024. gadā iegūto datu kopu, apmācīti 3 redzes transformēšanu modeļi.	Noteikt redzes transformēšanu modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un gaismas intensitātes) novērtēšanā.
4.	Izmantojot konvolūciju redzes transformēšanu arhitektūru un 2024. gadā iegūto datu kopu, apmācīti 3 konvolūciju redzes transformēšanu modeļi.	Noteikt konvolūciju redzes transformēšanu modeļu precizitāti mērījumu (gaisa temperatūras, relatīvā gaisa mitruma un gaismas intensitātes) 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. Eksperimentāli galvenokārt pārbaudīta modeļu veiktspēja mērījumu novērtēšanā. Tiek pārbaudīts cik lielā mērā iespējams iegūt reāla mērījuma prognozi jeb novērtējumu no katra termoattēla kadra atsevišķi.

## 4.4 Eksperimentu gaita

Izmantojot konvolūciju tīklu arhitektūru un sākotnējo datu kopu, kura iegūta 2023. gadā, tika apmācīti trīs dažādi mašīnmācīšanās modeļi. Modeļi izstrādāti ar nolūku veikt novērtējumus sensoru mērījumiem – gaismas intensitātei, relatīvajam gaisa mitrumam un augsnes mitruma saturam jeb līmenim (4.3. tabula).

4.3. tabula

Mērījumu novērtēšanā apmācītie CNN modeļi #1 (aizgūts no (Kempelis, Polaka, et al., 2024))

	1. Modelis	2. Modelis	3. Modelis
<b>Modeļa ieeja</b>	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )
<b>Modeļa izeja</b>	Gaismas intensitāte (Lux) (0–65,535)	Relatīvais gaisa mitrums (%)	Augsnes mitruma līmenis (0–4095, kur 0 atbilst augstam ūdens mitruma līmenim un 4095 mazākajam iespējamajam ūdens mitruma līmenim, ko spēj nomērīt sensors)
<b>Hiperparametri</b>	Apmācības ātrums: 0.001 Partijas izmērs: 15 Epočas: 35	Apmācības ātrums: 0.001 Partijas izmērs: 10 Epochas: 40	Apmācības ātrums: 0.001 Partijas izmērs: 15 Epochas: 30

Katrs konvolūciju modelis izmanto termālo attēlu matricu ar izmēru  $120 \times 160$  kā ievaddatus. Konkrēti, 1. modelis nosaka gaismas intensitātes vērtības, kas izteiktas luksiem; 2. modelis nosaka gaisa mitruma procentuālo vērtību; savukārt 3. modelis nosaka augsnes mitruma saturu, dodot sensoru mērījumu diapazonā no 0 līdz 4095 – kur 0 atbilst augstākajam ūdens saturam un 4095 – zemākajam.

Lai optimizētu konvolūciju modeļus sensoru mērījumu novērtēšanai, izmantojot augu termālos attēlus, jāveic hiperparametru pielāgošana, piemēram, konvolūciju slāņu filtru izmērs,

mācīšanās ātrums (*angl. Learning rate*) un neironu skaits pilnībā apvienotajos un blīvajos (*angl. dense*) slāņos (Alkaff, Prasetyo, 2022), (Wang, Li, et al., 2020). Šajā pētījumā optimizācijai tika izvēlēti tādi hiperparametri kā partijas izmērs (*angl. batch size*), mācību ciklu skaits jeb epohas (*angl. epochs*) un mācīšanās ātrums. Mācīšanās ātrums visos eksperimentos izvēlēts konstants ar vērtību 0.001, lai nodrošinātu modeļu stabilitāti un iespēju tos salīdzināt ar atkārtoto eksperimentu laikā apmācīto modeļu rezultātiem. Partijas izmērs un epohu skaits tika mainīts, lai līdzsvarotu modeļa konverģences ātrumu un vispārināšanas spējas. Mazāku partiju izmantošana, piemēram 10, parasti prasa vairāk epohas, piemēram 40, lai sasniegtu augstāku precizitāti, savukārt nedaudz lielākas partijas spēj konverģēt mazāk epohās. Šādi parametru iestatījumi atspoguļo hiperparametru pielāgošanu, lai kontrolētu pārmērīgu pielāgošanos jeb pārāpmācību un maksimizētu modeļa veiktspēju, saglabājot nemainīgu mācīšanās ātrumu. Papildus tika veikta modeļu hiperparametru optimizācija, kuras mērķis bija iegūt precīzākus sensoru mērījumu novērtējumu modeļus. Viena no plaši izmantotām hiperparametru optimizācijas metodēm ir režģa meklēšana (*angl. Grid Search*) (Nurhopipah, Larasati, 2021). Šī metode sistemātiski izveido un novērtē modeļus, izmantojot visas iespējamo parametru kombinācijas, kas noteiktas parametru režģī. Lai gan režģa meklēšana ir efektīva pie neliela hiperparametru skaita, tā var būt skaitļošanas ziņā resursietilpīga lielākiem un sarežģītākiem modeļiem. Šādas sistemātiskas parametru vērtību pārbaudes mērķis ir atrast labāko kombināciju, kas maksimāli uzlabo modeļa sniegumu (Nurhopipah, Larasati, 2021). Rezultātā pēc režģa pārmeklēšanas iegūti dotie parametri, kas tika izmantoti modeļu apmācības un novērtēšanas procesā. Lai nodrošinātu rezultātu uzticamību, katrs konvolūciju modelis tika apmācīts un validēts vairākas reizes, izmantojot apmācības parametrus, kas deva salīdzinoši augstāko precizitāti.

Turpinot eksperimentus un izmantojot iepriekšējā gadā iegūtos rezultātus, veikta konvolūciju tīklu un redzes transformeru modeļu apmācība ar datu kopu, kura iegūta 2024. gadā. Kopā tika apmācīti trīs dažādi mašīnmācīšanās modeļi. Modeļi izstrādāti ar nolūku novērtēt mērījumus – gaismas intensitāti, relatīvo gaisa mitrumu un gaisa temperatūru (4.4. tabula). Epohu skaits iegūts no darbā iepriekš aplūkotās modeļu validācijas izpētes.

Mērījumu novērtēšanā apmācītie modeļi #2

	<b>1. Modeļu kopa (CNN, ViT, CvT)</b>	<b>2. Modeļu kopa (CNN, ViT, CvT)</b>	<b>3. Modeļu kopa (CNN, ViT, CvT)</b>
<b>Modeļa ieeja</b>	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )	Termokameras attēla matrica $120 \times 160$ pikseļu ( $^{\circ}\text{C}$ )
<b>Modeļa izeja</b>	Gaismas intensitāte (Lux)	Relatīvais gaisa mitrums (%)	Gaisa temperatūra ( $^{\circ}\text{C}$ )
<b>Hiperparametri</b>	Apmācības ātrums: 0.001 Partijas izmērs: 16 Epočas: (CNN: 50, ViT:75, CvT:160)	Apmācības ātrums: 0.001 Partijas izmērs: 16 Epochas: (CNN: 60, ViT:45, CvT:45)	Apmācības ātrums: 0.001 Partijas izmērs: 16 Epochas: (CNN: 40, ViT:10, CvT:10)

Katrs modelis izmanto termālo attēlu matricu ar izmēru  $120 \times 160$  kā ievaddatus, izņemot CvT modeļa ieejā padota koriģēta  $112 \times 112$  izmēra matrica. Konkrēti, 1. modeļu kopa nosaka gaismas intensitātes vērtības, kas izteiktas luksiem; 2. modeļu kopa nosaka gaisa mitruma procentuālo vērtību; savukārt 3. modeļu kopa paredzēta, lai novērtētu gaisa temperatūras mērījumus.

#### 4.5 Modeļu precizitātes novērtēšanas veidi

Izstrādāto modeļu izejā ir nepārtrauktas skaitliskas vērtības, kas nozīmē, ka tie ir regresijas veida modeļi un regresijas veida modeļu veikspējas novērtēšana būtībā ir jautājums par to, cik precīzi tā prognozētās jeb novērtētās izejas vērtības atbilst patiesajām vērtībām (Hachimi, Belaqziz, et al., 2021). Jau modeļa apmācības laikā, pēc katras apmācības iterācijas (Epochas) tiek salīdzināta prognoze ar patiesajām vērtībām, lai veiktu nelielus modeļa uzlabojumus un atkārtotu apmācību. Prognozes un patiesās vērtības salīdzinājums modeļa apmācības procesā parasti tiek veikts, izmantojot zuduma funkciju (angl. *loss function*).

Neskaitot zuduma funkciju, arī pēc modeļa apmācības novērtējums tiek balstīts uz dažādiem aprēķināmiem regresijas modeļu novērtēšanai paredzētiem rādītājiem:

- **MSE – Vidējā kvadrātiskā kļūda**, kas var tikt izmantota arī kā zuduma funkcija modeļa apmācības laikā (4.1.).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.1.)$$

kur  $n$  – vērtības kopā,  $y_i$  – patiesā vērtība ar ko salīdzina  $\hat{y}_i$  – prognozēto vērtību. MSE ir salīdzinoši bieži izmantots regresijas rādītājs, kas atspoguļo vidējo vērtību kvadrātiskajai starpībai starp prognozēto un patieso vērtību, tāpēc tās vērtība vienmēr ir 0, ja kļūdu nav, vai  $> 0$ , ja eksistē kļūda starp salīdzināmām vērtībām. Šīs metrikas galvenais trūkums ir tās jutība pret novirzēm jeb netipiskām vērtībām. Ja atsevišķas datu izlases kļūda ir daudz lielāka nekā pārējām, šīs kļūdas kāpināšana kvadrātā kļūdu pastiprina vēl vairāk (Vagelis, German et al., 2022).

- **RMSE - Saknes vidējā kvadrātiskā kļūda** (4.2.)

$$RMSE = \sqrt{MSE} \quad (4.2.)$$

RMSE ir vēl viens plaši izmantots rādītājs, lai noteiktu, cik lielā mērā modeļa prognozētās vērtības atšķiras no faktiskajiem novērojumiem. Būtībā tā ir kvadrātsakne no vidējās kvadrātiskās kļūdas. Kvadrātsaknes dēļ RMSE izsaka kļūdu tajās pašās mērvienībās kā vērtība, kura tiek prognozēta, padarot rezultātu vieglāk interpretējamu. RMSE vienmēr ir 0 vai pozitīva vērtība, sasniedzot nulli tikai tad, ja prognozēs nav kļūdu (Vagelis, German et al., 2022). Tā pat kā MSE arī RMSE ir jutīgs pret netipiskām vērtībām.

- **MAE – Vidējā absolūtā kļūda** (4.3.)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.3.)$$

ir vidējā vērtība no absolūtās starpības starp prognozēm un patiesajām vērtībām. Līdzīgi kā MSE, arī MAE tiek salīdzinoši bieži izvēlēts kā zuduma funkcija modeļu apmācības procesā. Atšķirībā no MSE, MAE ievērojami nepalielina kļūdu tikai dēļ datu kopai netipiskām vērtībām un rezultējošā kļūda ir tādās pašās mērvienībās, kā prognozētā vērtība (Qi, Du et al., 2020).

- **MAPE – Vidējā absolūtā procentuālā kļūda** (4.4.)

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4.4.)$$

ir procentuāls rādītājs prognožu precizitātes mērīšanai, tā vērtība nav atkarīga no absolūtā lieluma vai prognozējamo vērtību mērvienībām, kā arī tas ir salīdzinoši vienkārši interpretējams. Tomēr šīs kļūdas galvenais trūkums ir tas, ka tā var kļūt “bezgalīga” (>100%) vai to vispār nav iespējams aprēķināt, kad reālā mērījuma vērtība ir nulle vai tuvu nullei (Sungil, Heeyoung, 2016). Ņemot vērā, ka šī darba ietvaros iegūtās datu kopas gaismas intensitātes mērījumi diennakts tumšajās stundās ir tuvu nullei vai nulle, šī metrika nav tiešā veidā pielietojama doto mērījumu prognozei, jo tā eksperimentu laikā ir vairāk par 100% un nesniedz pietiekamu informāciju par patieso kļūdu.

- **$R^2$**  (4.5.) – norāda to prognozējamā mērījuma dispersijas daļu, ko modelis izskaidro (starp 0 = neizskaidro un 1 = pilnībā izskaidro)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.5.)$$

kur  $\bar{y}$  – vidējā aritmētiskā mērījuma vērtība.  $R^2$  dod salīdzinoši vienkārši saprotamu procentuālu rādītāju modeļa atbilstības datiem novērtēšanai un modeļu salīdzināšanai. Tomēr šis rādītājs var būt maldinošs nelineāru sakarību gadījumos, tas automātiski pieaug, pievienojot vairāk apmācības parametru (palielinot pārāpmācīšanas risku), ir jutīgs pret novirzēm jeb netipiskiem mērījumu datiem, var ignorēt sistemātisku prognožu nobīdi, var būt negatīvs, kā arī var kļūt neuzticams, ja datu kopas izmērs ir salīdzinoši mazs (Terven, Cordova et al., 2023).

- **SMAPE** (4.6.) – **Simetriskā vidējā absolūtā procentuālā kļūda** novērš *MAPE* problēmas, kas saistītas ar, piemēram, nulles vērtībām patiesajās vērtībās, kā arī novērš pārmērīgi lielas kļūdas vērtības gadījumos, kad faktiskie novērojumi ir tuvu nullei.

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\frac{1}{2} (|y_i| + |\hat{y}_i|)} \cdot 100 \quad (4.6.)$$

kur  $\hat{y}_i$  – prognozētā vērtība. SMAPE novērtē prognozes precizitāti, aprēķinot absolūto atšķirību starp faktiskajām un prognozētajām vērtībām un dalot to ar šo vērtību vidējo. Tā rezultāts, izteikts procentos, ļauj objektīvi salīdzināt dažādus modeļus (Hasan, Rahman, et al., 2025).

Ņemot vērā atklātās pazīmes ievāktajā datu kopā sākotnējā datu analīzes procesa laikā, *MSE* izvēlēta kā modeļa apmācības procesa zuduma funkcija, kā arī papildus modeļu novērtēšanai apskatītas arī  $R^2$ , *MAE*, *RMSE*, *SMAPE* metrikas.

## 4.6 Modeļu precizitātes kopējais novērtējums

Lai novērtētu uz termoattēliem balstītas mērījumu novērtēšanas iespējamību, modeļi tika apmācīti vairākās iterācijās, izmantojot regresijai piemērotu zudumu funkciju – vidējo kvadrātisko kļūdu (MSE), kas bieži lietots, lai parādītu atšķirību starp prognozētajām jeb novērtētajām vērtībām un faktiskajām mērījumu vērtībām (Naznin, Islam, 2023). Pēc apmācības, izmantojot 2023. gada datu kopu, iegūts katra modeļa novērtējums (4.5. tabula) kur redzams, ka salīdzinoši augstākas precizitātes modelis bija modelis, kas prognozēja augsnes mitruma līmeņa sensora mērījumus.

4.5. tabula

Modeļu sākotnējais novērtējums (aizgūts no (Kempelis, Polaka, et al., 2024))

	1. Modelis (gaismas intensitātes novērtējums)	2. Modelis (relatīvā gaisa mitruma novērtējums)	3. Modelis (augšnes mitruma līmeņa novērtējums)
<b>MAE</b>	332.38	4.35	40.37
<b>MAPE</b>	100%	11.22%	10.35%
<b>RMSE</b>	781.05	7.09	68.71
<b>R<sup>2</sup></b>	0.719	0.497	0.633

1. Modelis, kas tika izstrādāts gaismas intensitātes mērījumu novērtēšanai, uzrādīja ievērojamas prognožu kļūdas ar vidējo absolūto kļūdu (MAE) 332,38, vidējo kvadrātisko kļūdu (RMSE) 781,05 un vidējo absolūto procentuālo kļūdu (MAPE), kas sasniedz 100%, norādot uz jau iepriekš konstatēto MAPE metrikas nepiemērotību šai datu kopai (dēļ gaismas intensitātes mērījumiem, kas ir 0 vai tuvu 0). Lai uzlabotu šī modeļa rezultātus, tika novērtēta arī hibrīdā pieeja, kas apvieno CNN modeli ar atmiņā balstītu laika rindu modeli LSTM (CNN-LSTM) (Xing, Wang, et al., 2023). Pētījuma laikā radās ideja, ka vairāku attēlu izmantošana kā ievade varētu uzlabot sensoru mērījumu prognozes precizitāti. Tomēr daži šākotnējie eksperimenti parādīja, ka šī hibrīdā pieeja būtiski neuzlaboja gaismas intensitātes prognožu precizitāti. Tas sākotnēji liecināja, ka, iespējams, nepieciešami termālajiem datiem vēl papildus mērījumi, lai uzlabotu prognožu precizitāti. Kā piemēru var minēt pētījumu, kurā apskatīti papildus ietekmējošie faktori, saistīti ar pētāmā objekta attālumu līdz gaismas avotam vai šo avotu skaitam telpā, kur aug augi (Kazanasmaz, Günaydin, et al., 2009). Citā pētījumā tika secināts,

ka, lai precīzi prognozētu apgaismojumu, nepieciešams detalizēti ņemt vērā virsmas fiziskās un optiskās īpašības, iekļaujot tās kā atsevišķus modeļa ievaddatus (Martell, Castilla, et al., 2019).

2. Modelis, kas tika izmantots relatīvā gaisa mitruma prognozēšanai, uzrādīja salīdzinoši labākus rezultātus ar MAPE 11,22%, MAE 4,35 un RMSE 7,09, norādot uz augstu prognožu precizitāti. Šie rezultāti saskan ar citu pētījumu secinājumiem un korelācijām šajā pētījumā, kur tika konstatēta apgriezta sakarība starp relatīvo gaisa mitrumu un temperatūru. Tas liecina, ka gaisa mitrumu ir iespējams precīzi prognozēt, izmantojot šo pieeju.

3. Modelis, kas prognozē augsnes mitruma līmeni, uzrādīja līdzīgu veiktspēju kā 2. modelis, ar nedaudz zemāku MAPE – 10,35%. Turklāt 3. modeļa  $R^2$  vērtība 0,633 norāda, ka šis modelis ir salīdzinoši vairāk atbilstošs apmācības datiem, tādējādi uzrādot salīdzinoši augstāko precizitāti starp visiem trim modeļiem. Lai gan MAPE vērtības 2. un 3. modeļiem ir līdzīgas, pastāv atšķirības MAE un RMSE vērtībās, kas ir augstākas 3. modelim. Šīs atšķirības galvenokārt skaidrojamas ar atšķirīgajām mērījumu skalām katram sensoram.

Lai gan sākotnējie rezultāti atsevišķos gadījumos uzrāda augstu precizitāti, gaismas intensitātes novērtēšanā rezultātu būtu nepieciešams uzlabot. Tāpēc atkārtoti tika izveidotas un sagatavotas eksperimentēšanai trīs dziļās mācīšanās arhitektūras. Tika izvēlēts konvolūciju tīkls, kas balstīts VGG arhitektūrā, salīdzinoši mazākais pēc sarežģītības pieejamais redzes transformers *ViT-Tiny* un hibrīds konvolūciju redzes transformers *CvT-Tiny*. Katrs modelis tika inicializēts ar nejaušiem svāriem, papildināts ar uzdevumam specifiskām regresijas izejas struktūrām apmācīts novērtēt gaisa temperatūru ( $^{\circ}\text{C}$ ), relatīvo gaisa mitrumu (RH %) un redzamās gaismas intensitāti (luksos) no vienas un tās pašas termoattēlu kopas.

Pēc 2024. gadā ievāktu mērījumu datu izmantošanas modeļu apmācībā, eksperimenti tika atkārtoti un tika iegūti novērtējuma rezultāti CNN arhitektūras modelim (4.6. tabula).

#### 4.6. tabula

##### CNN modeļa novērtējums

Modeļa arhitektūra	Novērtētais sensora mērījums (Izejas mērījums)	Modeļa precizitātes novērtēšanas metrikas
CNN (VGG arhitektūra)	Temperatūra ( $^{\circ}\text{C}$ )	MAE = 0.019 RMSE = 2.29 $R^2 = 0.978$ Epohas = 40

Modeļa arhitektūra	Novērtētais sensora mērījums (Izejas mērījums)	Modeļa precizitātes novērtēšanas metrikas
	Relatīvais gaisa mitrums (RH %)	MAE = 0.05 RMSE = 0.075 $R^2 = 0.897$ Epochas = 60
	Gaismas intensitāte (lux)	MAE = 0.036 RMSE = 0.059 $R^2 = 0.924$ Epochas = 50

Temperatūras novērtējums uzrāda salīdzinoši lielāko atbilstību starp novērtējumu un patiesajiem mērījumiem ( $R^2 = 0,978$ ) un salīdzinoši viszemāko novirzi (MAE = 0,019 °C), neskatoties uz mērenu dispersiju RMSE = 2,29 °C.

Relatīvais mitruma modelis konverģē pēc 60 epochām, tā atbilstības koeficients ( $R^2 = 0,897$ ) un absolūtā kļūda (MAE = 0,050 RH%) atpaliek no temperatūras un gaismas intensitātes mērījumiem.

Gaismas intensitātes kļūdu metrikas uzrāda zemu kļūdu (MAE = 0,036 luksis; RMSE = 0,059 luksis), un dispersija ir salīdzinoši augsta ( $R^2 = 0,924$ ). Apmācība stabilizējas pēc 50 epochām.

Pēc apmācības var secināt, ka VGG tipa CNN arhitektūra spēj pietiekami vispārināties uz dažādiem regresijas mērījumu mērķiem, sasniedzot augstus novērtējuma koeficientus (> 0,90 diviem no trim sensoriem) un zemas vidējās absolūtās kļūdas. Temperatūras prognozēšana ir īpaši precīza, kas bija sagaidāms, jo ciešā saistība starp mērījumiem tika novērota arī veicot korelācijas analīzi.

Relatīvā mitruma novērtēšanai būtu nepieciešama turpmāka optimizācija, piemēram, potenciāli datu kopas dažādības palielināšana, alternatīva zuduma funkcija vai dotās VGG arhitektūras pielāgošana, kas varētu ietekmēt arī pārējos divus mērījumus.

Atsevišķi atkārtotot apmācības procesu, rezultāti tika iegūti arī ViT arhitektūras modelim (4.7. tabula).

ViT modeļa novērtējums

Modeļa arhitektūra	Novērtētais sensors mērījums (Izejas mērījums)	Modeļa precizitātes novērtēšanas metrikas
ViT (ViTiny arhitektūra)	Temperatūra (°C)	MAE = 0.905 RMSE = 1.219 R <sup>2</sup> = 0.933 Epochas = 30
	Relatīvais gaisa mitrums (RH %)	MAE = 8.271 RMSE = 11.713 R <sup>2</sup> = 0.443 Epochas = 60
	Gaismas intensitāte (lux)	MAE = 705.76 RMSE = 1000.21 R <sup>2</sup> = 0.647 Epochas = 65

Gaisa temperatūras novērtēšanas rezultāts ir līdzīgs, salīdzinot to ar CNN arhitektūras rezultātiem, sasniedzot augstu koeficientu ( $R^2 = 0,933$ ) ar absolūto kļūdu  $MAE = 0,905$  °C pēc 30 epochām, kas norāda uz strauju konverģenci un salīdzinošu labu modeļa vispārināšanos temperatūras mērījumiem.

Relatīvā gaisa mitruma prognoze ir salīdzinoši vairāk neprecīza nekā temperatūras mērījumi. Gan novirze ( $MAE = 8,271$  RH%), gan dispersija ( $RMSE = 11,713$  %) ir augstāka nekā temperatūras mērījumiem, un salīdzinot ar zemu  $R^2 = 0,443$  var teikt, ka mazāk nekā puse no dispersijas tiek izskaidrota tikai pēc 60 epochām.

Gaismas intensitātes mērījumu novērtējumiem ir salīdzinoši lielas absolūtās kļūdas ar  $MAE$  706 luksi, lai gan modelis joprojām spēj uztvert mērenu dispersijas daļu ( $R^2 = 0,647$ ). Ņemot vērā mērījumu diapazonu, kas ir 0 līdz 167000 luksi, kļūdas daļa ir salīdzinoši neliela un varētu būt pieļaujama reālā vidē. Tomēr salīdzinoši ilgā apmācība, 65 epochas, lai sasniegtu salīdzinoši augstāko precizitāti, liecina, ka ViT nespēj ātri stabilizēties šajā mērķa novērtējumā.

Lai gan *ViT-Tiny* arhitektūrā balstītais modelis spēj iegūt informatīvas pazīmes temperatūrai, tā veikspēja ievērojami pasliktinās gaismas intensitātes un īpaši relatīvā gaisa

mitruma mērijumu novērtēšanas gadījumos, kas norāda uz jutību pret mērķa atribūta specifiskām datu raksturiezīmēm. Salīdzinot ar iepriekš novērtēto CNN modeli, transformera modelis sasniedz salīdzināmu  $R^2$  temperatūrai, bet salīdzinoši lielākas absolūtās kļūdas visos mainīgajos, un tā precizitāte strauji samazinās mitruma un gaismas intensitātes novērtējumos.

Pēdējo reizi atkārtojot apmācības procesu, rezultāti tika iegūti arī CvT arhitektūras modelim (4.8. tabula).

**4.8. tabula**

**CvT modeļa novērtējums**

Modeļa arhitektūra	Novērtētais sensora mērījums (Izejas mērījums)	Modeļa precizitātes novērtēšanas metrikas
CvT (ConvitTiny arhitektūra)	Temperatūra (°C)	MAE = 0.905 RMSE = 1.111 $R^2 = 0.945$ Epohas = 40
	Relatīvais gaisa mitrums (RH %)	MAE = 9.963 RMSE = 13.973 $R^2 = 0.207$ Epohas = 50
	Gaismas intensitāte (lux)	MAE = 869.717 RMSE = 1155.98 $R^2 = 0.528$ Epohas = 60

Temperatūras novērtēšanā, līdzīgi kā iepriekš, tiek sasniegti salīdzinoši precīzākie novērtējumi. CvT sasniedz augstu noteikšanas koeficientu ( $R^2 = 0,945$ ), vienlaikus saglabājot absolūto kļūdu zem  $1^\circ\text{C}$  pēc 40 epohām, kas norāda, ka hibrīdā konvolūcijas transformeru arhitektūra spēj salīdzinoši efektīvāk veikt mērijumu novērtējumus.

Relatīvā mitruma novērtēšanas precizitāte šai arhitektūrai ir salīdzinoši zemākā. Abi kļūdu rādītāji ir lielāki nekā temperatūras rādītāji, un  $R^2$  sarūk līdz 0,207, kas parāda, ka pat pēc ilgstošas apmācības modelis spēj izskaidrot mazāk nekā ceturtdaļu dispersijas.

Gaismas intensitātes novērtējums, līdzīgi kā ViT arhitektūras gadījumā, uzrādīja salīdzinoši lielas absolūtās kļūdas – 870 luks, bet mērenu atbilstības koeficientu ( $R^2 = 0,528$ ),


kas liecina, ka modelis spēj noteikt mērījuma vispārīgas tendences, bet tomēr salīdzinoši nekonkrēti.

*CvT-Tiny* manto gan konvolūciju tīklu lokālās uztveres, gan transformeru globālā konteksta priekšrocības, kas dod augstas precizitātes temperatūras prognozes. Tomēr tā priekšrocības nav iespējams izmantot dotajā datu kopā novērtējot mitruma un gaismas intensitātes mērķa atribūtus. Salīdzinot ar iepriekš apskatīto VGG CNN un ViT-Tiny, CvT pēc precizitātes ieņem otro vietu temperatūras novērtēšanā, taču nespēj samazināt lielo kļūdu starpību citiem atribūtiem. Šīs nelīdzsvarotības novēršanai var būt nepieciešama datu kopas papildināšana vai arhitektūras pielāgojumi. VGG balstītais CNN modelis uzrādīja salīdzinoši augstāko precizitāti starp visiem 3 izmantotajiem modeļiem, (RMSE = 2,29 °C, 0,075 % RH%, 0,059 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 gaismas intensitātes mērījumu novērtēšanā.

Ņemot vērā salīdzinoši zemākas precizitātes rezultātus transformeru modeļiem un datu kopas apjomu (1053 mērījumi), nolemts vairākas reizes atkārtot eksperimentus ar atšķirīgiem apmācības datiem, nemainot epohu skaitu. Eksperimentu atkārtošānā izmantota šķērsvalidācijas metode, katrā eksperimentā mainot apmācības un validācijas kopu izlases. Papildus eksperimentu ietvaros modeļu apmācība tiek atkārtota, izmantojot K-locījuma šķērsvalidācijas pieeju, lai nodrošinātu objektīvu modeļu veikspējas novērtējumu. K-locījuma metode paredz, ka sākotnējā datu kopa tiek sadalīta K vienādās daļās (piemēram, K = 5, kas tiek salīdzinoši bieži izvēlēta, jo nodrošina līdzsvaru starp efektivitāti un precizitāti pie šādas datu kopas apjoma) un katrā iterācijā viena no tām ir testa kopa, bet atlikušās daļas ir apmācības kopa. Rezultātā katra apakškopa tiek izmantota testēšanai tieši vienu reizi, un gala veikspējas rādītāji tiek iegūti, vidēji aprēķinot visu iterāciju rezultātus (rezultātu apkopojums redzams 4. pielikumā). Tas nodrošina, ka modelis tiek pārbaudīts uz dažādām datu kombinācijām un samazina riska iespēju, ka novērtējums būs atkarīgs no vienas konkrētas datu sadalījuma versijas. Papildus bija nepieciešams izmantot stratificētu k-locījuma šķērsvalidāciju, jo gaismas intensitātes novērtēšanas modeļa apmācībā būtu svarīgi, lai katrā apmācības kopā eksistētu gan augsti, gan zemi gaismas intensitātes mērījumi (datus atspoguļojot diennakts režīmu).

Lai būtu iespējams objektīvāk salīdzināt modeļu veikspēju, veikta analīze par modeļu apmācības veikspēju pie mainīga apmācības datu apjoma. Piemēram, starp visiem gaismas intensitātes novērtējuma modeļiem (4.3. att.) redzams, ka visi modeļi demonstrē pastāvīgu

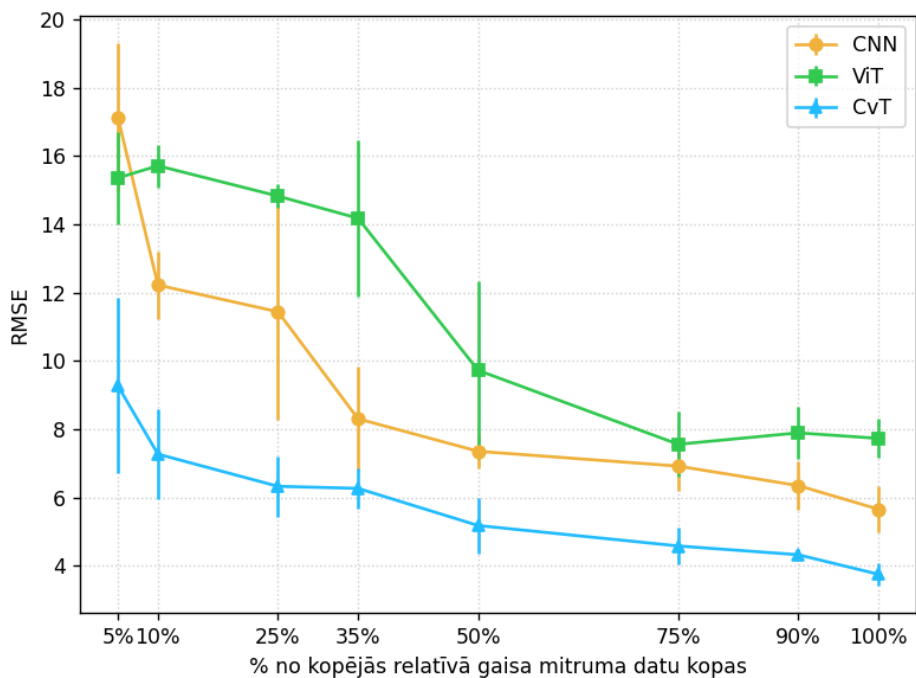
RMSE samazinājumu, palielinoties apmācības datu daļai, kas norāda uz novērtēšanas precizitātes uzlabošanu, palielinot apmācības datu kopas apjomu.



#### 4.3. att. Gaismas intensitātes novērtējuma modeļu apmācības salīdzinājums


Ērtākai rezultātu interpretācijai gaismas intensitātes mērījumu maksimālā vērtība: 7952.5 lux, minimālā vērtība: 0.0 lux, vidējā vērtība: 1828.94 lux un standartnovirze: 1684.49 lux. 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, demonstrējot augstāku apmācības datu izmantošanas efektivitāti un vispārīnāšanas spēju. ViT modelis uzrāda vājāku rezultātu un salīdzinoši lielāku mainīgumu pie mazākiem datu kopas apjomiem. CNN modelis stabilizējas agrāk, bet ar augstāku kļūdu.

Līdzīgi novērojumi veicot relatīvā gaisa mitruma novērtējumu modeļu salīdzinājumu (4.4. att.), kur CvT sasniedz zemāko RMSE visos gadījumos pie katras datu kopas daļas. ViT modelis sasniedz salīdzinoši vājāku rezultātu un stabilizējas vēlāk, kā pārējie modeļi.



**4.4. att. Relatīvā gaisa mitruma novērtējuma modeļu apmācības salīdzinājums**

Mazliet atšķirīgi rezultāti iegūti gaisa temperatūras novērtējumu modeļu salīdzinājumā kur, CvT modelis uzrāda zemāko RMSE, kas liecina par augstu vispārināšanas spēju un apmācības datu izmantošanas efektivitāti. ViT modelis uzrāda viduvēju veikspēju, ar stabilu kļūdas samazinājumu, palielinoties datu apjomam, bet CNN modelis saglabā lielāko RMSE kļūdu un salīdzinoši lēnāk stabilizējas par pārējiem modeļiem. Kopumā CvT modelis demonstrē visaugstāko spēju efektīvi mācīties no ierobežota datu apjoma, vienlaikus saglabājot stabilu veikspēju, izmantojot pilnu datu kopu.




#### 4.5. att. Gaisa temperatūras novērtējuma modeļu apmācības salīdzinājums

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


Pēc eksperimentu atkārtošanas un šķērsvalidācijas metodes pielietošanas abu transformeru modeļu salīdzinājums liecina, ka CvT uzrāda augstāku precizitāti nekā ViT visos trīs mērījumu veidos (gaismas intensitāte, gaisa temperatūra, relatīvais gaisa mitrums). Lielākās uzlabojuma atšķirības vērojamas gaismas intensitātes 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 norāda, ka konvolūcijas elementu integrācija transformera arhitektūrā uzlabo modeļa spēju novērtēt dotos mērījumus.

Iegūtie rezultāti apkopoti un salīdzināti arī citām kļūdu metrikām (4.6. 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 novērojamās standartnovirzes ir nelielas.



**4.6. att. Kļūdu un precizitātes metrikas gaisa temperatūras novērtēšanas modeļiem**


Arī relatīvā mitruma novērtējumā (4.7. att.) CvT viennozīmīgi pārspēj pārējos modeļus, kuram ir būtiski zemāks MAE/RMSE un augstāks  $R^2$ , turklāt ar mazāku variāciju starp ločījumiem, kas norāda uz salīdzinoši labāku vispārināmību. CNN pēc precizitātes ieņem otro vietu un sasniedz salīdzinoši augstāku precizitāti nekā ViT, kura kļūdas ir augstākas un  $R^2$  zemāks.




**4.7. att. Kļūdu un precizitātes metrikas relatīvā gaisa mitruma novērtēšanas modeļiem**

Gaismas intensitātes novērtējumos (4.8. att. un 4.9. 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.



**4.8. att. MAE, RMSE salīdzinājums gaismas intensitātes novērtēšanas modeļiem**




**4.9. att.  $R^2$  salīdzinājums gaismas intensitātes novērtēšanas modeļiem**

Kopumā CvT veikspēja dominē visu trīs mērījumu novērtēšanā. CvT sasniedz zemākās kļūdas un augstāko  $R^2$ , kā arī mazāku starplocījumu dispersiju. CNN sniedz reālistiskus un divos uzdevumos (relatīvā gaisa mitruma, gaismas intensitātes novērtējumos) salīdzinoši labākus rezultātus nekā ViT, bet temperatūras novērtējumos atpaliek no ViT. ViT ieņem vidēju pozīciju temperatūras novērtējumos un atpaliek relatīvā gaisa mitruma un gaismas intensitātes novērtējuma uzdevumos. 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, José, et al., 2024). Viens no variantiem, kā imitēt sensora nolietojumu ir izmantot Gausa troksni (Chowdhury, Debkumar, 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, kuras rodas sensora termiskā trokšņa ietekmē (Wantao, Qinyu, et al., 2025). Termālajos attēlos Gausa troksnis ar standartnovirzi  $\sigma$  rada aptuveni  $\pm \sigma$  °C neskaidrību katram pikselim, kas izmantots trokšņaino datu kopu izveidē (4.10. att.).




**4.10. att. Dažāda līmeņa trokšņaino datu piemērs**

Piemēram, gaismas intensitātes novērtējumos, modeļa ieejā dodot gadījuma veidā atlasītus oriģinālos termokameras attēlus iegūti sekojoši novērtējumi (4.11. att.).



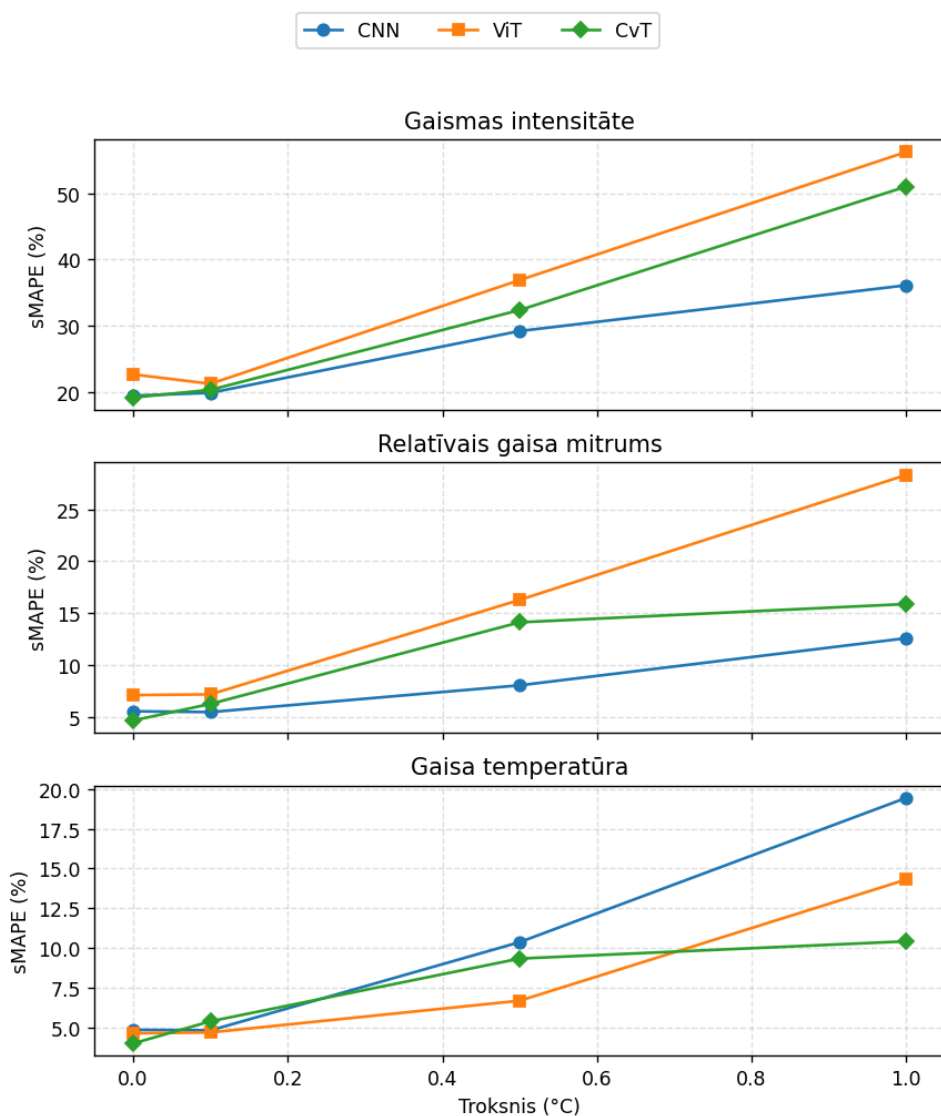
**4.11. att. Konvolūciju redzes transformera gaismas intensitātes novērtējumi no termoattēliem bez trokšņa**

Analizējot rezultātus iespējams redzēt, ka šajā gadījumā kļūdu metrikas ir sekojošas: RMSE: 561.329, MAE: 391.218, SMAPE: 19.23%. Tas pats atkārtots, ģenerējot vairāk trokšņainus datus ieejas attēlos, kur temperatūras svārstības tiek simulētas ar 1 Celsija grāda nobīdi (4.12. att.).



**4.12. att. Konvolūciju redzes transformera gaismas intensitātes novērtējumi no termoattēliem ar Gausa trokšni 1.0 °C**

Analizējot rezultātus, kur ieejas termoattēlos ir vairāk trokšņaini dati, iespējams redzēt, ka kļūdu metrikas ir sekojošas: RMSE: 1310.141, MAE: 1037.078, SMAPE: 51.01%. Analizējot un salīdzinot pārējo modeļu veiktspēju pie dažāda trokšņu līmeņa (kopējie rezultāti 5. pielikumā) iespējams secināt, ka salīdzinoši lielākā noturība pret trokšņainiem ieejas datiem ir CNN modelim, novērtējot 2 no 3 jeb gaismas intensitātes un relatīvā gaisa mitruma mērījumus (4.13. att.).



**4.13. att. Modeļu salīdzinājums pie dažādiem trokšņu līmeņiem katram mērījuma veidam**

CNN modelis saglabāja zemāko relatīvo kļūdu gan gaismas intensitātei, gan relatīvajam gaisa mitrumam, ar lēnāku SMAPE pieaugumu, palielinoties trokšņa līmenim, kas liecina par konvolūcijas arhitektūras noturību pret trokšņa pieaugumu.

Konvolūciju redzes transformers saglabā salīdzinoši augstāku noturību pret trokšņa pieaugumu attēlos. ViT ir salīdzinoši jutīgākais pret troksni no visiem modeļiem. CvT modelis sasniedza augstāko precizitāti gaisa temperatūras novērtēšanā, salīdzinot to ar CNN un ViT visos trokšņaino datu līmeņos.

## 4.7 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 pielietotas lauksaimniecībās, metodika galvenokārt balstīta uz pieejas integrēšanu 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 sekojošus 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 tīklus, izvietojuma 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 tie netiek atsevišķi aprakstīti šī darba ietvaros.

### 4.7.1 Mērījumu novērtēšanas vadlīniju definēšana

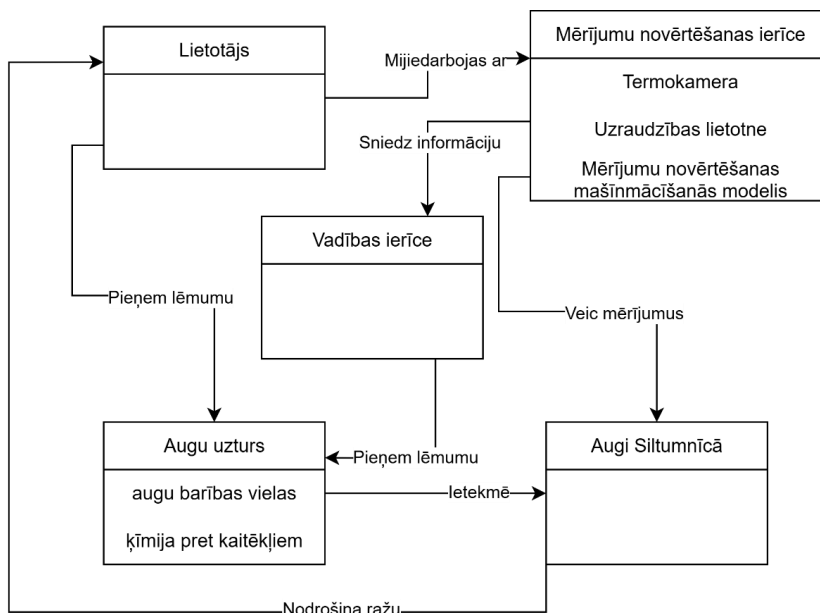
Pirmais pieejas ieviešanas posms ir skaidri noteikt, kam mērījumu novērtēšanas pieeja ir paredzēta un kādi uzdevumi šai pieejai jāveic. Šajā posmā tiek definēts pieejas mērķis un darbības principi, kā arī visas galvenās vadlīnijas, kas ietver datu vākšanu, analīzi, sistēmas pārvaldību, datu privātumu un drošību, lietotāja saskarnes un citas vadlīnijas.

Mērījumu novērtēšanas pieejas mērķi un vadlīnijas var formulēt šādi:

- Mērķis: Nodrošināt mērījumu ievākšanu, kas ļauj lietotājiem attālināti uzraudzīt augšanas procesu siltumnīcā. Lietotājs šajā gadījumā var būt jebkurš lauksaimniecības darbinieks vai tās digitālo procesu pārvaldnieks.
- Prototipa mērījumu ievākšanas modulim jāstrādā automatizētā režīmā un jāmēra audzēšanā salīdzinoši kritiskākie mērījumi – gaisa temperatūra, relatīvais gaisa mitrums un apkārtējais apgaismojums. Iespējams mērīt arī citus vides parametrus, atkarībā no augu specifikas. Prototipa aparatūras modulim diennakts tumšajā laikā, kad augšanas procesos ir vismazākā aktivitāte, jāspēj automātiski restartēt operētājsistēmu, lai attīrītu kešatmiņu un nodrošinātu uzticamāku attālinātu piekļuvi vismaz reizi diennaktī. Atsevišķos gadījumos, restartēšana jāveic automātiski, ja aparatūras darbībā konstatēti traucējumi mērījumu ievākšanas vai novērtēšanas procesos.
- Prototipa pārvaldības vadlīnijas nosaka, ka ir jānodrošina attālinātas uzraudzības un vadības funkcijas.
- Datu analīzes vadlīnijas nosaka, ka datu apstrāde jāveic lokāli uz ierīces.
- Lietotnes izvietojšanas vadlīnijas nosaka, ka tīmekļa lietotnei jādarbojas lokāli uz pašas ierīces, taču tai jābūt pieejamai arī attālināti. Lietotne ietver informāciju par uzkrātajiem datiem un dod iespēju sekot mērījumu novērtēšanas procesiem reāllaikā.
- Attālinātas vai fiziskas piekļuves gadījumā prototipam jānodrošina pamatlīmeņa lietotāja autentifikācija informācijas aizsardzībai.

### 4.7.2 Konceptuālais modelis

Konceptuālais modelis apraksta galvenos jēdzienus, entītijas un objektus, kas iesaistīti pieejas realizācijā. Tas nosaka objektu atribūtus un to savstarpējās attiecības. Konceptuālais modelis nodrošina tehnoloģiski un platformu ziņā neatkarīgu šo elementu abstraktu attēlojumu. Izmantojot šo modeli, sistēmu projektētāji un izstrādātāji iegūst izpratni arī par jomu un tās specifiku, kurai prototips tiek izstrādāts. Mērījumu novērtēšanas pieejas ieviešanas gadījumā minimāli eksistē vismaz 3 pamata entītijas (4.14. att.), kas ir mērījumu novērtēšanas ierīce, lietotājs un augi siltumnīcā.



**4.14. att. Mērījumu novērtēšanas pieejas konceptuālais modelis**

Papildus trim pamata entītijām, reālā vidē bieži integrē arī lietotāja lēmumu pieņemšanas par nepieciešajām barības un citām vielām, kas jānodrošina, piemēram, ražas maksimizēšanai. Lēmumu var pieņemt lietotājs, balsoties informācijā, ko sniedz mērījumu novērtēšanas ierīce, vai arī lēmumu pieņemšanu var uzticēt vadības ierīcei, vārstiem, kontrolieriem vai tamlīdzīgām ierīcēm, kas augu aprūpi spēj veikt automatizētā režīmā.

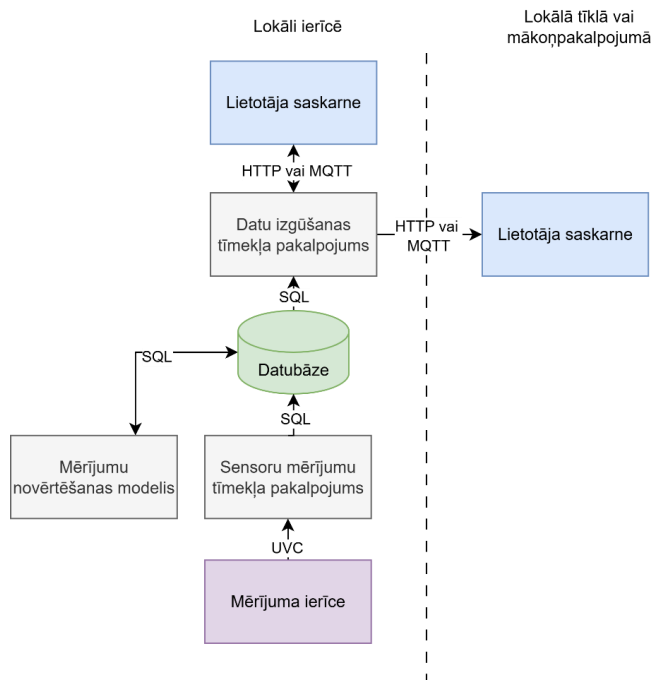
### 4.7.3 IoT komponentu definēšana

Vairumā gadījumu ieviešot IoT lauksaimniecībā, tās arhitektūra sastāv no šādām pamatkomponentēm:

- 1) Fiziska IoT ierīce, kuru var identificēt un kas nodrošina attālinātu sensoru datu iegūšanu, izpildmehānismu vadību vai uzraudzību.
- 2) Resursi jeb programmatūras komponentes uz fiziskas ierīces, kas nodrošina piekļuvi sensoriem, ļauj veikt sensoru datu apstrādi un glabāšanu, kā arī vadīt izpildmehānismus. Šī komponente iekļauj arī programmatūru, kas dod ierīcei tīkla piekļuvi.
- 3) Kontroliera pakalpojums, kas darbojas lokāli ierīcē un spēj sazināties ar tīmekļa pakalpojumiem. Tas nosūta datus un saņem lietotnes komandas (caur tīmekļa pakalpojumiem) ierīces vadībai, piemēram, augu barības vielu pievadīšanai augiem.

- 4) Datubāze, kas var atrasties lokāli uz ierīces vai mākoņpakalpojumā un glabā IoT ierīces ģenerētos datus.
- 5) Tīmekļa pakalpojums savieno IoT ierīci, lietotni, datubāzi un citas komponentes. To var īstenot, izmantojot, piemēram, *HTTP*, *WebSocket*, *MQTT* vai citus tīkla protokolus.
- 6) Analīzes komponente atbild par IoT datu analīzi un rezultātu formatēšanu lietotājam vienkārši saprotamā formā.
- 7) Lietotne nodrošina lietotāja saskarni IoT sistēmas dažādu aspektu kontrolei un uzraudzībai, kā arī sistēmas statusa un apstrādāto datu aplūkošanai.

Šajā darbā piedāvātās mērījumu novērtēšanas pieejas integrācijā pieļaujama salīdzinoši vienkāršākā risinājuma arhitektūra (4.15. att.), kur katra IoT tīkla ierīce darbojas autonomi un nodrošina piekļuvi datiem caur tīmekļa pakalpojumu. Mērījumu novērtēšanas modelis arī darbojas neatkarīgi un automātiski ik pēc noteikta laika intervāla paralēli datu ievākšanai no termokameras.



**4.15. att. Mērījumu novērtēšanas pieejā balstīta IoT risinājuma arhitektūra**

Ārējās piekļuves (ārpus ierīces) lietotāja saskarne nodrošina tikai datu izgūšanu. Veikt izmaiņas datubāzē, datu ievākšanas intervālos vai kontroliera vadībā iespējams tikai lokāli no

ierīces. Paplašinot ierīces funkcionalitāti ir iespējams izvērst vairāk funkciju, kas ļautu uzraudzīt un pārvaldīt arī vairākas ierīces vienlaicīgi.

#### 4.7.4 Funkcionālās vadlīnijas

Funkcionālās vadlīnijas nosaka mērījumu novērtēšanas pieejas funkcijas, sagrupējot tās funkcionālajās grupās. Katra funkcionālā grupa vai nu nodrošina mijiedarbību ar konceptuālajā modelī definēto konceptu instancēm, vai arī sniedz informāciju par šiem konceptuālajiem elementiem.

Mērījumu novērtēšanas pieejas integrācijas gadījumā funkcionālās grupas var izdalīt pēc to galvenajām funkcijām (4.9. tab.). Tabulā minētas saistītās koncepta klases ir galvenās instances, ar kurām saistīta attiecīgā funkciju grupa.

4.9. tabula

Prototipa funkcijas un funkcionālās grupas

Funkcionālā grupa	Galvenās funkcijas	Saistītā koncepta klase
<p><b>Sensoru mērījumu iegūšana</b></p>	<p><b>Izpilda mērījumu vaicājumu:</b></p> <ul style="list-style-type: none"> <li>– mikroklimata sensori (°C, %RH, lux) ne biežāk, kā reizi 15 min un vismaz reizi stundā.</li> <li>– termokameras kadri (°C matrica) ne biežāk, kā reizi 15 min un vismaz reizi stundā.</li> </ul> <p><b>Pārsūta datus</b> uz datu iegūšanas tīmekļa pakalpojumu, izmantojot HTTP / MQTT vai UVC</p>	<p>Sensors, mērījums, mērījumu novērtēšanas ierīce</p>
<p><b>Datu glabāšana un pārvaldība</b></p>	<p><b>Saglabā neapstrādātus mērījumus</b> relāciju datubāzē.</p> <p><b>Nodrošina katram mērījumam</b> laika zīmogu, sensora identifikatoru un vērtības glabāšanu.</p> <p><b>Piedāvā CRUD funkcionalitāti un meklēšanu</b> caur lietojumprogrammas saskarni.</p>	<p>Mērījums, Datubāze</p>


Funkcionālā grupa	Galvenās funkcijas	Saistītā koncepta klase
<p><b>Datu priekšapstrāde un validācija</b></p>	<p><b>Grupē datus</b> pa stundām</p> <p><b>Veic atbilstības pārbaudi</b> laiksritīgām vērtībām, kam jāatbilst termokameras uzņemtā kadra laikam</p> <p><b>Ģenerē katras dienas apvienotu datu failu</b> CSV formātā</p>	<p>Mērījums</p>
<p><b>Mašīnmācīšanās modeļa apmācība</b></p>	<p><b>Saņem apstrādātos datus</b> un lietotāja norādītos vai iestatītos parametrus.</p> <p><b>Apmāca mērījumu novērtēšanas regresijas modeli</b></p> <p><b>Automātiski atkārtu apmācību</b>, ja validācijas kļūda &gt; 10 %</p>	<p>Mērījumu novērtēšanas modelis</p>
<p><b>Reāllaika mērījumu novērtēšana</b></p>	<p><b>Pielieto jaunāko novērtēšanas modeļa versiju</b>, ienākošajiem termokameras mērījumiem.</p> <p><b>Novērtē, aprēķina mērījumu vērtības</b>, piemēram augsnes mitrumam, gaismas intensitātei.</p> <p><b>Saglabā rezultātu un nodod to</b> vadības ierīcei un lietotāja saskarnei</p>	<p>Mērījumu novērtēšanas modelis</p>

Funkcionālā grupa	Galvenās funkcijas	Saistītā koncepta klase
<p><b>Mašīnmācīšanās modeļa izvietošana</b></p>	<p><b>Eksportē modeli .tflite formātā</b>  <b>Palaiž modeli IoT malu skaitļošanas ierīcē</b>  <b>Saglabā modeļa jaunākās versijas</b></p>	<p>Mērījumu novērtēšanas modelis, IoT ierīce</p>
<p><b>Vadības apakšsistēma</b></p>	<p><b>Saņem mērījumus, balstoties uz tiem ģenerē lēmumus</b> (piemēram, apūdeņošana, barošana)  <b>Izpilda vadības komandas</b> (piemēram, atver vārstus uz noteiktu laiku)  <b>Saglabā lēmumu un izpildes statusu datubāzē</b></p>	<p>Vadības ierīce, Lēmums</p>
<p><b>Lietotāja saskarne</b></p>	<p><b>Reāllaika mērījumu un novērtējumu vizualizācija.</b>  <b>Modeļa pārskats</b> apmācības statusa, kļūdu un versijām.  <b>Manuāla kļūdas sliekšņu vai mērījuma režīmu korekcija.</b>  Mērījumu, CSV failu lejupielāde,  <b>Paziņojumu pārvaldība.</b></p>	<p>Lietotājs, Novērtējums, Lēmums</p>

#### 4.7.5 Ierīču un komponentu integrācija

Šajā posmā tiek integrētas ierīces un komponentes. Tajā nosaka, kā IoT sistēma tiks izvietota un darbināta, piemēram, izvēloties pakalpojumu mitināšanas risinājumus, datu glabāšanas iespējas, ierīču konfigurācijas, lietotņu mitināšanu un citus darbības aspektus.

Mērījumu novērtēšanas pieejā termokameras attēlu kadru uzņemšanu, saglabāšanu un mašīnmācīšanās modeļa darbību spēs nodrošināt šī darba ietvaros minētais datu ievākšanas prototips (4.16. att.).



4.16. att. Mērījumu novērtēšanas ierīces komponentu piemērs

Atkarībā no lietotāja saskarnes prasībām, var būt nepieciešams atbilstošs grafiskais procesors (iebūvēts vai ārējs), kas spēj nodrošināt saskarnes elementu vizualizāciju bez aizkaves, ļaujot paralēli izpildīt arī datu ievākšanas un mērījumu novērtēšanas procesus.

#### 4.7.6 Lietotāja saskarne

Lietotāja saskarnes izstrādes posmā definē, kā lietotāji mijiedarbosies ar IoT prototipu. Jānosaka lietotnes pamatfunkcijas, lietotāja saskarnes izkārtojumu un navigāciju, kā arī to, kā tiks attēlots statuss, brīdinājumi un dati. Lietojuma saskarnes dizainam jānodrošina intuitīvu vadību, ērtu uzraudzību un skaidru atgriezenisko saiti visās platformās, ko lietotāji izmantos.

### 4.8 Nodaļas kopsavilkums un secinājumi

Korelācijas analīze atklāja, ka termiskajiem pikseļiem ir augsta pozitīva saistība ar gaisa temperatūras mērījumiem ( $r = 0,9$ ), mērena negatīva saistība ar relatīvo mitrumu ( $r = -0,5$ ) un

pozitīva saistība ar gaismas intensitāti ( $r = 0,77$ ), apstiprinot visu trīs mainīgo secināšanas iespējamību no viena un tā paša termo attēla. Izmantojot šo analīzi, tika sagatavots un veikts eksperimentu komplekss, kurā četru eksperimentu laikā apmācīti un novērtēti vairāki modeļi no kuriem sākotnējos rezultātos secināts, ka CNN sasniedz augstāko precizitāti dotajā datu kopā. Rezultāti parādīja augstāku prognožu precizitāti relatīvā gaisa mitruma un augsnes mitruma līmeņa novērtēšanā, sasniedzot vidējo absolūto procentuālo kļūdu diapazonā no 10% līdz 12%. Savukārt gaismas intensitātes prognozēšana sākotnēji bija sarežģītāka un neprecīza. Otrs konvolūciju tīklu modelis ar papildus datu kopu deva izskaidrojamāku rezultātu, kur augstākā precizitāte bija visiem mērījumiem, salīdzinājumā ar zemāku precizitāti redzes transformeru modeļos, kas būtībā apstiprina abas ievadā izvirzītās darba tēzes.

Ņemot vērā zemās precizitātes rezultātus transformeru modeļiem, eksperimentu komplekss papildināts ar vēl trīs eksperimentiem, kuros, izmantojot šķērsvalidācijas metodi, novēroti precizitātes uzlabojumi konvolūciju redzes transformeru modeļiem visu trīs (relatīvā gaisa mitruma, temperatūras un gaismas intensitātes) mērījumu novērtēšanā. Sakarā ar potenciālu prognozēt arī citus augu labklājībai svarīgus sensoru mērījumus, līdzīgu eksperimentu veikšanai ar dažādu sensoru mērījumiem rada iespējas turpmākiem pētījumiem. Tomēr šādu prognožu precizitāte dažādos vides apstākļos un dažādiem augu veidiem vēl ir detalizēti jāpēta, jo jāņem vērā arī mērierīču ražotāja noteiktās kļūdas, darbības principi un precizitātes.

Izteiktās svārstības, kas novērotas *ViT-Tiny* un *CvT-Tiny* apmācības līknēs, izriet no to ievērojami lielākās parametru kopas (kas ir aptuveni 5.5 milj. parametru mazajos transformeru modeļos) un lokalitātes iezīmju trūkuma. Ierobežota apmācības datu apjoma apstākļos tiek iegūti lieli dispersijas gradienta novērtējumi, kā rezultātā modeļa pašuzmanība strauji mainās un zuduma funkcija rada straujas svārstības. Kā šīs problēmas risinājumu var ierosināt sintētisko datu izmantošanu, taču šī pieeja nav piemērota gadījumos, kad termālie attēli jātransformē mērījumos, kuriem pēc tam nepieciešama validācija ar reāliem mikroklimate mērījumiem. Darba ietvaros izpētīta modeļu apmācības veiktspēja analizējot kļūdu metrikas veicot apmācību pie dažādām datu kopas daļām, kas atklāja *CvT-Tiny* modeļa precizitātes pārkāpumu salīdzinājumu ar pārējiem modeļiem. Tomēr modeļu testos par noturību pret troksni datos CNN modelis tika ietekmēts salīdzinoši mazāk pieaugot troksnim nekā citi modeļi, ko varētu izskaidrot ar modeļa lokālo reģionu uztveres iezīmēm.

Pēc eksperimentu veikšanas un rezultātu analīzes, turpmāk nodaļā izklāstīta metodika mērījumu novērtēšanas pieejas integrēšanai esošajos lauksaimniecības IoT tīklos, aptverot

vadlīniju definēšanu, konceptuālo un IoT līmeņa modeli, funkcionālo grupēšanu, kā arī sensoru, malu skaitļošanu, datubāzu un tīmekļa lietotnes integrāciju. Pieejā balstītā metodika paredz automatizētu, lokāli apstrādātu datu ievākšanu (piemēram, mikroklimate mērījumus un termokameras attēlus), drošu attālinātu uzraudzību un mērogojamību vairāku siltumnīcu ierīcēs. Ņemot vērā metodikā minētos posmus, lauksaimniecības var ieviest automatizētu, uz datiem balstītu augu uzraudzības pieeju, kas uzlabo lēmumu pieņemšanu un izmanto jau esošo IoT infrastruktūru. Darbā piedāvātā pieeja paredz apvienot dažādu datu avotu analīzi, izmantojot jau esošo IoT infrastruktūru un papildinot to ar datu apstrādes un mašīnmācīšanās metodēm. Šāda pieeja nodrošina iespēju reāllaikā analizēt augu fizioloģisko stāvokli, identificēt augu stresa pazīmes agrīnā stadijā un pielāgot lauksaimniecības prakses, pirms negatīvās sekas, piemēram ražas zudumi, kļūst nenovēršami.

Lai gan šajā piedāvātajā pieejā izmantotas relatīvi dārgas un tehnoloģiski sarežģītas ierīces salīdzinājumā ar lētākām alternatīvām ierīcēm, to pielietojums kļūst pamatots noteiktos lietojumos. Piemēram, augstas vērtības augu kultūrās neliela ražas zuduma vai kvalitātes pasliktināšanās novēršana var ekonomiski atsvērt papildu ieguldījumus tehnoloģijās. Jaunākās datu analīzē un mašīnapmācībā balstītās pieejas ļauj identificēt faktorus, kas nav tieši novērojami ar cita veida sensoru ierīcēm, piemēram, mikroklimate ietekme uz augu transpirāciju vai augsnes mitruma izkliedi. Viedākas mērierīces nodrošina dziļāku izpratni par augu reakciju uz vides apstākļiem un ļauj prognozēt potenciālos riska faktorus.

Svarīgs aspekts ir arī esošās IoT infrastruktūras izmantošana, kas būtiski samazina ieviešanas izmaksas. Daudzās saimniecībās jau tiek izmantoti temperatūras, mitruma un apgaismojuma sensori, un piedāvātā pieeja paredz šo datu integrāciju ar mašīnmācīšanās modeļiem, nevis pilnīgi jaunas sistēmas izveidi. Pieeja neparedz visu ierīču aizstāšanu ar termokameras novērtējuma modeli, bet daļēju mērījumu ierīču aizstāšanu ar vienu ierīci, kas vairumā gadījumu varētu samazināt gan sensoru ierīču iegādes izmaksas, gan to uzturēšanas izmaksas. Modeļu daudzkārtēja un automatizēta apmācība, izmantojot esošos mērījumus uz vietas, piemēram, siltumnīcā, nozīmē, ka esošie mērījumi ar laiku saimniecībā var tikt veikti, izmantojot mazāk ierīču, tādējādi darbā piedāvātā pieeja izmanto jau pieejamos resursus efektīvākā veidā.

Kopumā šāda automatizēta, uz datiem balstīta augu uzraudzības pieeja piedāvā būtisku pievienoto vērtību. Tā uzlabo lēmumu pieņemšanas kvalitāti, samazina augu uzturēšanā nepieciešamo resursu patēriņu, var paaugstināt ražas apjomu stabilitāti un veicināt ilgtspējīgu lauksaimniecības praksi, kas ir aktuāla mūsdienās.

# 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 x 160 pikseli) un 4860 mikroklimata mērījumi (gaisa temperatūra, relatīvais gaisa mitrums, augsnes mitrums un gaismas intensitāte).

Veikta korelācijas analīze starp termoattēlu pikseliem un mikroklimata mērījumiem. Korelācijas analīzes rezultāti norādīja uz vairāku atsevišķu mērījumu savstarpēju 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 gaismas intensitāti ( $r = 0.77$ ).

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 rezultātus:

- gaisa temperatūras novērtējumos (RMSE = 0.86 °C,  $R^2 = 0.969$ ),
- relatīvā gaisa mitruma novērtējumos (RMSE = 3.75 RH%,  $R^2 = 0.943$ ),
- gaismas intensitātes novērtējumos (RMSE = 474 lux,  $R^2 = 0.920$ ).

Redzes transformeru modelis saglabāja arī salīdzinoši augstāko precizitāti veicot tā apmācību pie ierobežotām datu kopas apjoma daļām.

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

Rezultāti pierādīja augstu saistību starp termoattēlu radiometrisko attēlu vērtībām un vairākiem būtiskiem mikroklimata mērījumiem (gaisa temperatūru, relatīvo gaisa mitrumu, augsnes mitruma līmeņa, gaismas intensitāti). 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, gaismas intensitātes 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, gaismas intensitātes 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 gaismas intensitātes novērtēšanā, īpaši 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 tas 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, šis pētījums veic sistemātisku trīs dažādu dziļās mācīšanās modeļu salīdzinājumu ar īpašu uzsvāri 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, kas ir spēja tiešā veidā uztvert tikai virsmas temperatūru. Kā zināms gaisa temperatūras, gaismas intensitātes 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 papildus zināmus parametrus vietā, kur mērījumu novērtēšanas pieeja tiek izmantota, piemēram, par ēnojumu, saules gaismas lenķi, atspīdumu vai izmantojot meteoroloģisko staciju datus par vidējo gaisa temperatūru, nokrišņiem, vēja ātrumu un gaisa mitrumu reģionā un citus. 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 norāda uz nepieciešamību teorētiski un praktiski analizēt trokšņainu datu ietekmi uz modeļa stabilitāti un apmācību. Tāpēc varētu veikt datu paplašināšanas stratēģiju izpēti transformera arhitektūrās, piemēram pielietot trokšņainus datus modeļu apmācībā vai vairāku termoattēlu vēsturisko datu kopu modeļa apmācībā viena konkrēta mērījuma novērtēšanai, lai dotu mašīnmācīšanās modelim plašāku kontekstu precizitātes uzlabojumiem. Balstoties uz iespēju 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

- A. Berroukham, K. Housni and M. Lahraichi, "Vision Transformers: A Review of Architecture, Applications, and Future Directions," 2023 7th IEEE Congress on Information Science and Technology (CiSt), Agadir - Essaouira, Morocco, 2023, pp. 205-210, doi: 10.1109/CiSt56084.2023.10410015.
- A. Hassani, S. Walton, N. Shah, A. Abuduweili, J. Li and H. Shi, "Escaping the Big Data paradigm with compact transformers", 2021.
- A. K. Alkaff and B. Prasetyo, "Hyperparameter Optimization on CNN Using Hyperband on Tomato Leaf Disease Classification," 2022 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom), Malang, Indonesia, 2022, pp. 479-483, doi: 10.1109/CyberneticsCom55287.2022.9865317.
- A. Kempelis, A. Romanovs and A. 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, Ukraine, 2021b, pp. 71-76, doi: 10.1109/EUROCON52738.2021.9535556.
- A. Kempelis, A. Romanovs and A. Patlins, "Implementation of Machine Learning based Approach in IoT Network Prototype," 2021 IEEE 9th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), Riga, Latvia, 2021a, pp. 1-6, doi: 10.1109/AIEEE54188.2021.9670255.
- A. Kempelis, A. Romanovs and A. 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, Latvia, 2024, pp. 1-7, doi: 10.1109/AIEEE62837.2024.10586690.
- A. Kempelis, M. Narigina, E. Osadcis, A. Patlins and A. 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), Vilnius, Lithuania, 2023, pp. 1-6, doi: 10.1109/AIEEE58915.2023.10135031.
- A. Tabbakh and S. S. Barpanda, "A Deep Features Extraction Model Based on the Transfer Learning Model and Vision Transformer "TLMViT" for Plant Disease Classification," in IEEE Access, vol. 11, pp. 45377-45392, 2023, doi: 10.1109/ACCESS.2023.3273317.
- Abdelmoneim AA, Al Kalaany CM, Khadra R, Derardja B, Dragonetti G. Calibration of Low-Cost Capacitive Soil Moisture Sensors for Irrigation Management Applications.

- Sensors. 2025; 25(2):343. <https://doi.org/10.3390/s25020343>
- Abhishek Khanna, Sanmeet Kaur, An empirical analysis on adoption of precision agricultural techniques among farmers of Punjab for efficient land administration, *Land Use Policy*, Volume 126, 2023, 106533, ISSN 0264-8377, <https://doi.org/10.1016/j.landusepol.2022.106533>.
- Abobatta, Waleed. (2021). Precision Agriculture: A New Tool for Development. 10.4018/978-1-7998-5000-7.ch002
- Acosta, M., Quiñones, A., Munera, S., de Paz, J. M., & Blasco, J. (2023). Rapid Prediction of Nutrient Concentration in Citrus Leaves Using Vis-NIR Spectroscopy. *Sensors*, 23(14), 6530. <https://doi.org/10.3390/s23146530>
- Adeogun, R.; Rodriguez, I.; Razzaghpour, M.; Berardinelli, G.; Christensen, P.H.; Mogensen, P.E. Indoor occupancy detection and estimation using machine learning and measurements from an IoT LoRa-based monitoring system. In Proceedings of the 2019 Global IoT Summit (GIoTS), Aarhus, Denmark, 17–21 June 2019; pp. 1–5.
- AJ, agriplanting. Advantages and Disadvantages of Precision Farming [tiešsaiste]. [skatīts 2024 g. 11. decembrī]. Pieejams: <https://agriplanting.com/advantages-and-disadvantages-of-precision-farming>
- Al-hammuri, K., Gebali, F., Kanan, A. et al. Vision transformer architecture and applications in digital health: a tutorial and survey. *Vis. Comput. Ind. Biomed. Art* 6, 14 (2023). <https://doi.org/10.1186/s42492-023-00140-9>
- Alireza Sanaeifar, Mahamed Lamine Guindo, Adel Bakhshipour, Hassan Fazayeli, Xiaoli Li, Ce Yang, Advancing precision agriculture: The potential of deep learning for cereal plant head detection, *Computers and Electronics in Agriculture*, Volume 209, 2023, 107875, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2023.107875>.
- Almutawa, N.; Eid, W. Soil moisture content estimation using active infrared thermography technique: An exploratory laboratory study. *Kuwait J. Sci.* 2023, 50, 399–404.
- Arjunan, Gopalakrishnan. (2023). Optimizing Edge AI for Real-Time Data Processing in IoT Devices: Challenges and Solutions. *International Journal of Scientific Research and Management (IJSRM)*. 11. 944-953. 10.18535/ijsrm/v11i06.ec2.
- Athanasios Chourlias, John Violos, Aris Leivadreas, Virtual sensors for smart farming: An IoT- and AI-enabled approach, *Internet of Things*, Volume 32, 2025, 101611, ISSN 2542-6605, <https://doi.org/10.1016/j.iot.2025.101611>.
- Awais M, Wang X, Hussain S, Aziz F, Mahmood MQ. Advancing Precision Agriculture

- Through Digital Twins and Smart Farming Technologies: A Review. *AgriEngineering*. 2025; 7(5):137. <https://doi.org/10.3390/agriengineering7050137>
- Badidi, E. Edge AI for Early Detection of Chronic Diseases and the Spread of Infectious Diseases: Opportunities, Challenges, and Future Directions. *Future Internet* 2023, 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>
- Balasuriyage Thulangi Gayathma Balasuriya, Agneta Ghose, Shabbir H. Gheewala, Trakarn Prapasongsa, Assessment of eutrophication potential from fertiliser application in agricultural systems in Thailand, *Science of The Total Environment*, Volume 833, 2022, 154993, ISSN 0048-9697, <https://doi.org/10.1016/j.scitotenv.2022.154993>.
- BH1750 gaismas intensitātes sensora specifikācijas dokuments [tiešsaiste]. [skatīts 2025. g. 21. jūnijā.]. Pieejams: <https://www.handsontec.com/dataspecs/sensor/BH1750%20Light%20Sensor.pdf>
- C. Deisy, M. Francis, Image segmentation for feature extraction: A study on disease diagnosis in agricultural plants, in *Feature Dimension Reduction for Content-Based Image Identification*, pp. 232–257, IGI Global, 2018.
- C. El Hachimi, S. Belaqziz, S. Khabba and A. Chehbouni, "Towards precision agriculture in Morocco: A machine learning approach for recommending crops and forecasting weather" 2021 International Conference on Digital Age & Technological Advances for Sustainable Development (ICDATA), Marrakech, Morocco, 2021, pp. 88-95, doi: 10.1109/ICDATA52997.2021.00026.
- Catalbas, M.C.; Kobav, M.B. Measurement of correlated color temperature from RGB images by deep regression model. *Measurement* 2022, 195, 111053.
- Chai, J. J. K., Xu, J.-L., & O’Sullivan, C. (2023). Real-Time Detection of Strawberry Ripeness Using Augmented Reality and Deep Learning. *Sensors*, 23(17), 7639. <https://doi.org/10.3390/s23177639>
- Chowdhury, Debkumar & Gupta, Sayantan & Roy, Debkumar & Sarkar, Debanku & Chattopadhyay, Chiro & Das, Sreeloy. (2017). A quantum study on digital image noises and their in-depth clusterization. 1-7. 10.1109/OPTRONIX.2017.8349973.
- D. F. Rose Anandhi and S. Sathiamoorthy, "Maximum Entropy Thresholding with Deep Learning Model for Rice Plant Disease Segmentation and Classification," 2023

- International Conference on Research Methodologies in Knowledge Management, Artificial Intelligence and Telecommunication Engineering (RMKMATE), Chennai, India, 2023, pp. 1-6, doi: 10.1109/RMKMATE59243.2023.10368778
- D. Fukushima and T. Ishikawa, "Experiments And Discussions On Vision Transformer (ViT) Parameters For Object Tracking," 2022 Nicograph International (NicoInt), Tokyo, Japan, 2022, pp. 64-68, doi: 10.1109/NicoInt55861.2022.00020.
- De Silva, M.; Brown, D. Multispectral Plant Disease Detection with Vision Transformer–Convolutional Neural Network Hybrid Approaches. *Sensors* 2023, 23, 8531. <https://doi.org/10.3390/s23208531>
- Deke Xing, Qian Zhang, Yanyou Wu, Kuan Zhao, Jing Wang, Shizheng Yan, Zhenyi Li, Use of transpiration water and leaf intracellular retained water in tomato (*Solanum lycopersicum* L.) plants subjected to different water supply strategies, *Scientia Horticulturae*, Volume 337, 2024, 113520, ISSN 0304-4238, <https://doi.org/10.1016/j.scienta.2024.113520>.
- Dewi, A.L.; Suseno, J.E.; Soesanto, Q.M.B. Measurement Device of Nondestructive Testing (NDT) of Metanil Yellow Dye Waste Concentration Using Artificial Neural Network Based on Microcontroller. *IEEE Sens. Lett.* 2022, 6, 7500804.
- DFRobot augšnes mitruma līmeņa sensora specifikācijas dokuments. [tiešsaiste]. [skatīts 2025. g. 21. jūnijā.]. Pieejams: <https://www.farnell.com/datasheets/3216156.pdf>
- DhanushKumar. Max pooling. *Medium*. 2023. g. [tiešsaiste]. [skatīts 2025. g. 10. septembrī.]. Pieejams: <https://medium.com/@danushidk507/max-pooling-ef545993b6e4>
- DHT11 specifikācijas dokuments. [tiešsaiste]. [skatīts 2025. g. 21. jūnijā.]. Pieejams: <https://www.mouser.com/datasheet/2/758/DHT11-Technical-Data-Sheet-Translated-Version-1143054.pdf>
- DiMarket, Strategic Drivers and Barriers in Open-source Hardware Market 2025-2033 [tiešsaiste]. [skatīts 2025. g. 30. jūnijā.]. Pieejams: <https://www.datainsightsmarket.com/reports/open-source-hardware-1877232>
- Dosovitskiy, A., Beyler, 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 16x16 Words: Transformers for Image Recognition at Scale. *ArXiv*, abs/2010.11929.
- Dumitru Scutelnic, Riccardo Muradore, Claudia Daffara, A multispectral camera in the VIS–NIR equipped with thermal imaging and environmental sensors for non invasive

- analysis in precision agriculture, *HardwareX*, Volume 20, 2024, e00596, ISSN 2468-0672, <https://doi.org/10.1016/j.ohx.2024.e00596>.
- E. Ibrahimovic, "Optimizing Vision Transformer Performance with Customizable Parameters," 2023 46th MIPRO ICT and Electronics Convention (MIPRO), Opatija, Croatia, 2023, pp. 1721-1726, doi: 10.23919/MIPRO57284.2023.10159761.
- Elektrokit Adafruit VEMML7700 produkta vietne [tiešsaiste]. [skatīts 2025. g. 10. maijā.]. Pieejams: <https://www.elektrokit.com/en/adafruit-veml7700-ljsensor-i2c>
- Emogine Mamabolo, Makgabo Johanna Mashala, Ephias Mugari, Tlou Elizabeth Mogale, Norman Mathebula, Kabisheng Mabitsela, Kwabena Kingsley Ayisi, Application of precision agriculture technologies for crop protection and soil health, *Smart Agricultural Technology*, Volume 12, 2025, 101270, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2025.101270>.
- Ferreira, Pedro & Ruano, Antonio. (2002). Choice of RBF Model Structure for Predicting Greenhouse Inside Air Temperature.
- Francesco Bettucci, Marco Sozzi, Marco Benetti, Luigi Sartori, A data-driven approach to agricultural machinery working states analysis during ploughing operations, *Smart Agricultural Technology*, Volume 8, 2024, 100511, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2024.100511>.
- Fu Jiao, Fengjing Cao, Yuan Gao, Feng Shuang, Daming Dong, A biosensor based on a thermal camera using infrared radiance as the signal probe, *Talanta*, Volume 246, 2022, 123453, ISSN 0039-9140, <https://doi.org/10.1016/j.talanta.2022.123453>.
- G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 2261-2269, doi: 10.1109/CVPR.2017.243
- G. Sunitha, A. Sudeepthi, B. Sreedhar, A. B. Shaik and C. Farooq, "RetinaNet and Vision Transformer-Based Model for Wheat Head Detection," 2023 5th International Conference on Inventive Research in Computing Applications (ICIRCA), Coimbatore, India, 2023, pp. 151-156, doi: 10.1109/ICIRCA57980.2023.10220614.
- G. Patrizi, A. Bartolini, L. Ciani, V. Gallo, P. Sommella and M. Carratù, "A Virtual Soil Moisture Sensor for Smart Farming Using Deep Learning," in *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1-11, 2022, Art no. 2515411, doi: 10.1109/TIM.2022.3196446.

- G. Xu, Z. Hao, Y. Luo, H. Hu, J. An and S. Mao, "DeViT: Decomposing Vision Transformers for Collaborative Inference in Edge Devices," in *IEEE Transactions on Mobile Computing*, vol. 23, no. 5, pp. 5917-5932, May 2024, doi: 10.1109/TMC.2023.3315138.
- Gedi Liu, Keyang Zhong, Huilin Li, Tao Chen, Yang Wang, A state of art review on time series forecasting with machine learning for environmental parameters in agricultural greenhouses, *Information Processing in Agriculture*, Volume 11, Issue 2, 2024, Pages 143-162, ISSN 2214-3173, <https://doi.org/10.1016/j.inpa.2022.10.005>.
- Grandviewresearch, 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, 2023. g. [tiešsaiste]. [skatīts 2025. g. 29. jūnijā.]. Pieejams: <https://www.grandviewresearch.com/industry-analysis/agriculture-sensor-market-report>
- Grobotronics BH1750 produkta vietne [tiešsaiste]. [skatīts 2025. g. 10. maijā.]. Pieejams: <https://grobotronics.com/light-sensor-bh1750.html?sl=en>
- GroupGets PureThermal 2 specifikācijas dokuments [tiešsaiste]. [skatīts 2025. g. 10. maijā.]. Pieejams: <https://groupgets-files.s3.amazonaws.com/PT2/PureThermal%20%20-%20Datasheet%20-%201.7.pdf>
- GroupGets , FLIR Lepton 3.5 [tiešsaiste]. [skatīts 2025. g. 10. maijā.]. Pieejams: <https://groupgets.com/products/flir-lepton-3-5>
- Guebsi, Ridha & Mami, Sonia & Chokmani, Karem. (2024). Drones in Precision Agriculture: A Comprehensive Review of Applications, Technologies, and Challenges. *Drones*. 8. 686. 10.3390/drones8110686.
- Guilherme Fernando Capristo Silva, Antonio Carlos Andrade Goncalves, Carlos Antonio da Silva Junior, Marcos Rafael Nanni, Cassiele Uliana Facco, Everson Cezar and Anderson Antonio da Silva, 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>
- Gümüser, M. A., Pichlhöfer, A., & Korjenic, A. (2025). A Comparison of Capacitive Soil Moisture Sensors in Different Substrates for Use in Irrigation Systems. *Sensors*, 25(5), 1461. <https://doi.org/10.3390/s25051461>
- H. Touvron, M. Cord, M. Douze, F. Massa, A. Sablayrolles and H. Jégou, "Training data-

- efficient image transformers & distillation through attention", Proc. 38th Int. Conf. Mach. Learn., pp. 10347-10357, 2021.
- Habib, T.; Raza, D.M.; Islam, M.; Victor, D.B.; Arif, A.I. 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), Kottayam, India, 12–13 February 2022; pp. 1–5.
- Haller, Manju. (2024). DHT11 Sensor: A Comprehensive Study on Temperature and Humidity Sensor. *Interantional Journal Of Scientific Research In Engineering And Management*. 08. 1-11. 10.55041/IJSREM29310.
- Ham, Y.-G.; Kim, J.-H.; Luo, J.-J. Deep learning for multi-year ENSO forecasts. *Nature* 2019, 573, 568–572.
- Han, K.A.M.; Watchareeruetai, U. Black gram plant nutrient deficiency classification in combined images using convolutional neural network. In Proceedings of the 2020 8th International Electrical Engineering Congress (iEECON), Chiang Mai, Thailand, 4–6 March 2020; pp. 1–4.
- Hari Haran B, Swetha A, R Chitra, Vishwa M, "Advanced NDRE Techniques for Precision Crop Monitoring and Analysis," 2025 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS), Bhopal, India, 2025, pp. 1-4, doi: 10.1109/SCEECS64059.2025.10941496.
- HDC1080 specifikācijas dokuments. [tiešsaiste]. [skatīts 2025. g. 21. jūnijā.]. Pieejams: <https://www.ti.com/lit/ds/symlink/hdc1080.pdf>
- Henrichs E, Noack T, Pinzon Piedrahita AM, Salem MA, Stolz J, Krupitzer C. Can a Byte Improve Our Bite? An Analysis of Digital Twins in the Food Industry. *Sensors*. 2022; 22(1):115. <https://doi.org/10.3390/s22010115>
- Howard, Andrew & Zhu, Menglong & Chen, Bo & Kalenichenko, Dmitry & Wang, Weijun & Weyand, Tobias & Andreetto, Marco & Adam, Hartwig. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. 10.48550/arXiv.1704.04861.
- Hsieh, C.-T. 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), Taipei, Taiwan, 21–23 December 2021; pp. 248–251.
- InstTools, pH measurement, 2018a. [tiešsaiste]. [skatīts 2025. g. 20. jūnijā.]. Pieejams:

- <https://instrumentationtools.com/ph-measurement/>
- InstTools, Two Electrode Conductivity Probes Principle, 2018b. [tiešsaiste]. [skatīts 2025. g. 20. jūnijā.]. Pieejams: <https://instrumentationtools.com/two-electrode-conductivity-probes-principle/>
- Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in Proceedings of the IEEE, vol. 86, no. 11, pp. 2278-2324, Nov. 1998, doi: 10.1109/5.726791.
- Y. Wang, H. Li, Z. Cai, X. Tang and Y. Yang, "CNN Hyperparameter Optimization Based on CNN Visualization and Perception Hash Algorithm," 2020 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES), Xuzhou, China, 2020, pp. 78-82, doi: 10.1109/DCABES50732.2020.00029.
- Yin, Heyu & Cao, Yunteng & Marelli, Benedetto & Zeng, Xiangqun & Mason, Andrew & Cao, Changyong. (2021). Smart Agriculture Systems: Soil Sensors and Plant Wearables for Smart and Precision Agriculture (Adv. Mater. 20/2021). Advanced Materials. 33. 2170156. 10.1002/adma.202170156.
- Yuwen Pang, Aleksi Räsänen, Franziska Wolff, Teemu Tahvanainen, Milja Männikkö, Mika Aurela, Pasi Korpelainen, Timo Kumpula, Tarmo Virtanen, Comparing multispectral and hyperspectral UAV data for detecting peatland vegetation patterns, International Journal of Applied Earth Observation and Geoinformation, Volume 132, 2024, 104043, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2024.104043>.
- J. Mei, K. Sun and X. Xu, "Combing Color Index and Region Growing with Simple Non-iterative Clustering for Plant Segmentation," 2021 6th International Conference on Image, Vision and Computing (ICIVC), Qingdao, China, 2021, pp. 119-123, doi: 10.1109/ICIVC52351.2021.9526949.
- J. Park, C. Cho, K. Lee and J. Kwak, "A Method on Neural Network Optimization Deployment Frameworks for Lightweight Target Devices," 2023 14th International Conference on Information and Communication Technology Convergence (ICTC), Jeju Island, Korea, Republic of, 2023, pp. 1286-1288, doi: 10.1109/ICTC58733.2023.10392914.
- J. Qi, J. Du, S. M. Siniscalchi, X. Ma and C. -H. Lee, "On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression," in IEEE Signal Processing Letters, vol. 27, pp. 1485-1489, 2020, doi: 10.1109/LSP.2020.3016837.
- James Kobina Mensah Biney, Verifying the predictive performance for soil organic carbon

- when employing field Vis-NIR spectroscopy and satellite imagery obtained using two different sampling methods, *Computers and Electronics in Agriculture*, Volume 194, 2022, 106796, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2022.106796>.
- Jelena Vuletić, Marsela Car, Matko Orsag, Close-range multispectral imaging with Multispectral-Depth (MS-D) system, *Biosystems Engineering*, Volume 231, 2023, Pages 178-194, ISSN 1537-5110, <https://doi.org/10.1016/j.biosystemseng.2023.06.002>.
- Joshua Hrisiko, Capacitive Soil Moisture Sensor Calibration with Arduino, 2020.g. [tiešsaiste]. [skatīts 2024. g. 11. martā.]. Pieejams: <https://makersportal.com/blog/2020/5/26/capacitive-soil-moisture-calibration-with-arduino>
- K. H. Nugroho, R. Wahyudi, W. M. Baihaqi and Nurfaizah, "NDVI Method for Near-Infrared Image Analysis for Health Monitoring of Ornamental Plants *Spathiphyllum Wallisii* Mauna Loa," 2021 IEEE 5th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE), Purwokerto, Indonesia, 2021, pp. 61-65, doi: 10.1109/ICITISEE53823.2021.9655944.
- K. Syamala Devi, & Swapna Raghunath. (2021). A Review On Precision Agriculture For Sustainable Living. <https://doi.org/10.5281/zenodo.8049961>
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. (2015). Deep Residual Learning for Image Recognition.
- Kaspars Sudars, Ivars Namatevs, Arturs Nikulins, Rihards Balass, Astile Peter, Sarmite Strautina, Edite Kaufmane, Ieva Kalnina, "Semantic Segmentation Using U-Net Deep Learning Network for Quince Phenotyping on RGB and HyperSpectral Images," 2023 27th International Conference Electronics, Palanga, Lithuania, 2023, pp. 1-4, doi: 10.1109/IEEECONF58372.2023.10177638.
- Katz L, Ben-Gal A, Litaor MI, Naor A, Peeters A, Goldshtein E, Lidor G, Keisar O, Marzuk S, Alchanatis V, et al. How Sensitive Is Thermal Image-Based Orchard Water Status Estimation to Canopy Extraction Quality? *Remote Sensing*. 2023; 15(5):1448. <https://doi.org/10.3390/rs15051448>
- Kbvresearch, 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 2022. g. [tiešsaiste]. [skatīts 2025. g. 29. jūnijā.]. Pieejams:

- <https://www.kbvresearch.com/agriculture-sensor-market/amp/>
- Kempelis, A., Polaka, I., Romanovs, A., & Patlins, A. (2024). Computer Vision and Machine Learning-Based Predictive Analysis for Urban Agricultural Systems. *Future Internet*, 16(2), 44. <https://doi.org/10.3390/fi16020044>
- Kempelis, A.; Romanovs, A.; Patlins, A. 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)*, Riga, Latvia, 6–7 October 2022; pp. 1–6.
- Khadas, Khadas VIM 1S product page, 2022. g. [tiešsaiste]. [skatīts 2025. g. 3. februārī.]. Pieejams: <https://www.khadas.com/product-page/vim1s>
- Krizhevsky, Alex & Sutskever, Ilya & Hinton, Geoffrey. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*. 25. 10.1145/3065386.
- L. Gai, W. Chen, R. Gao, Y. -W. Chen and X. Qiao, "Using Vision Transformers in 3-D Medical Image Classifications," 2022 IEEE International Conference on Image Processing (ICIP), Bordeaux, France, 2022, pp. 696-700, doi: 10.1109/ICIP46576.2022.9897966.
- Li G, Wang Y, Zhao Q, Yuan P, Chang B. PMVT: a lightweight vision transformer for plant disease identification on mobile devices. *Front Plant Sci*. 2023 Sep 26;14:1256773. doi: 10.3389/fpls.2023.1256773. PMID: 37822342; PMCID: PMC10562605.
- Lining Song, Jiaojun Zhu, Xin Liu, Jinxin Zhang, Xiao Zheng, Yirong Sun, Guochen Wang, Linyou Lü, Transpiration and water use sources of poplar (*Populus × xiaozhuanica*) plantations with 7-years vs. 20-years old in a semiarid sandy region of Northeast China, *Agricultural and Forest Meteorology*, Volume 356, 2024, 110171, ISSN 0168-1923, <https://doi.org/10.1016/j.agrformet.2024.110171>.
- Liu, J.; Jiang, W.; Han, H.; He, M.; Gu, W. 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)*, Madrid, Spain, 11–14 September 2023; pp. 66–71.
- M. Chen, J. Gao and W. Yu, "Lightweight and Optimization Acceleration Methods for Vision Transformer: A Review," 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC), Macau, China, 2022, pp. 2154-2160, doi:

- 10.1109/ITSC55140.2022.9921989.
- M. K. Saini and R. K. Saini, "Agriculture monitoring and prediction using Internet of Things (IoT)," 2020 Sixth International Conference on Parallel, Distributed and Grid Computing (PDGC), Waknaghat, India, 2020, pp. 53-56, doi: 10.1109/PDGC50313.2020.9315836.
- M. Ravishankar, S. Siddharth, A. A. Yadav and S. R. Kassa, "Integrating IoT and Sensor Technologies for Smart Agriculture: Optimizing Crop Yield and Resource Management," 2023 IEEE Technology & Engineering Management Conference - Asia Pacific (TEMSCON-ASPAC), Bengaluru, India, 2023, pp. 1-5, doi: 10.1109/TEMSCON-ASPAC59527.2023.10531339.
- M. S. M. Asaari, S. Mertens, S. Dhondt, N. Wuyts and P. Scheunders, "Detection of Plant Responses to Drought using Close-Range Hyperspectral Imaging in a High-Throughput Phenotyping Platform," 2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Amsterdam, Netherlands, 2018, pp. 1-5, doi: 10.1109/WHISPERS.2018.8747228.
- M. S. M. C. K. B. Attanayka and M. C. Malkanthi, "Performance Comparison of Neural Network Models on Edge Devices Using Face Mask Detection System," 2022 International Research Conference on Smart Computing and Systems Engineering (SCSE), Colombo, Sri Lanka, 2022, pp. 83-87, doi: 10.1109/SCSE56529.2022.9905086.
- M.R. González, M.E. Martínez-Rosas, C.A. Brizuela, Comparison of CNN architectures for single grape detection, *Computers and Electronics in Agriculture*, Volume 231, 2025,109930,ISSN 0168-1699,https://doi.org/10.1016/j.compag.2025.109930.
- Md Rakib Hasan, Arafat Rahman, Yeasmin Nahar Jolly, Shoumik Zubyer, A.S.M. Mohiuddin, Comparative analysis of water quality forecasting for the urban turag river using enhanced and hybrid deep learning architectures, *Next Research*, Volume 2, Issue 3, 2025, 100597, ISSN 3050-4759, https://doi.org/10.1016/j.nexres.2025.100597.
- Maimunah Mohd Ali, Norhashila Hashim, Samsuzana Abd Aziz, Ola Lasekan, Emerging non-destructive thermal imaging technique coupled with chemometrics on quality and safety inspection in food and agriculture, *Trends in Food Science & Technology*, Volume 105, 2020, Pages 176-185, ISSN 0924-2244, https://doi.org/10.1016/j.tifs.2020.09.003.
- Maya Olalla, E., Lopez Flores, A., Zambrano, M., Domínguez Limaico, M., Diaz Iza, H., & Vasquez Ayala, C. (2023). Fuzzy Control Application to an Irrigation System of

- Hydroponic Crops under Greenhouse: Case Cultivation of Strawberries (*Fragaria Vesca*). *Sensors*, 23(8), 4088. <https://doi.org/10.3390/s23084088>
- Martell, M., Castilla, M., Rodríguez, F., Berenguel, M. (2019). An Indoor Illuminance Prediction Model Based on Neural Networks for Visual Comfort and Energy Efficiency Optimization Purposes. In: Ferrández Vicente, J., Álvarez-Sánchez, J., de la Paz López, F., Toledo Moreo, J., Adeli, H. (eds) *From Bioinspired Systems and Biomedical Applications to Machine Learning*. IWINAC 2019. *Lecture Notes in Computer Science()*, vol 11487. Springer, Cham. [https://doi.org/10.1007/978-3-030-19651-6\\_15](https://doi.org/10.1007/978-3-030-19651-6_15)
- Martin, D., Köhl, N. & Satzger, G. Virtual Sensors. *Bus Inf Syst Eng* 63, 315–323 (2021). <https://doi.org/10.1007/s12599-021-00689-w>
- Martín, Juan & Sáez, José A. & Corchado, Emilio. (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. [10.1016/j.eswa.2023.121608](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.; Miller, J. Deepti: Deep-Learning-Based Tropical Cyclone Intensity Estimation System. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 2020, 13, 4271–4281.
- Md Toukir Ahmed, Arthur Villordon, Mohammed Kamruzzaman, Comparative analysis of hyperspectral Image reconstruction using deep learning for agricultural and biological applications, *Results in Engineering*, Volume 23, 2024, 102623, ISSN 2590-1230, <https://doi.org/10.1016/j.rineng.2024.102623>.
- Miletiev, Rosen & Damyanov, Iliyan & Iontchev, Emil & Yordanov, Rumen. (2020). Smart in-vehicle environment monitoring system. 1-4. [10.1109/ET50336.2020.9238166](https://doi.org/10.1109/ET50336.2020.9238166).
- Mohamed Zarboubi, Abdelaaziz Bellout, Samira Chabaa, Azzedine Dliou, CustomBottleneck-VGGNet: Advanced tomato leaf disease identification for sustainable agriculture, *Computers and Electronics in Agriculture*, Volume 232, 2025, 110066, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2025.110066>.
- 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>
- Mrutyunjay Padhiary, Debapam Saha, Raushan Kumar, Laxmi Narayan Sethi, Avinash Kumar, Enhancing precision agriculture: A comprehensive review of machine learning and AI

- vision applications in all-terrain vehicle for farm automation, *Smart Agricultural Technology*, Volume 8, 2024, 100483, ISSN 2772-3755, <https://doi.org/10.1016/j.atech.2024.100483>.
- Mughair Aslam Bhatti, M.S. Syam, Huafeng Chen, Yurong Hu, Li Wai Keung, Zeeshan Zeeshan, Yasser A. Ali, Nadia Sarhan, Utilizing convolutional neural networks (CNN) and U-Net architecture for precise crop and weed segmentation in agricultural imagery: A deep learning approach, *Big Data Research*, Volume 36, 2024, 100465, ISSN 2214-5796, <https://doi.org/10.1016/j.bdr.2024.100465>.
- N. A. A. Rauf, A. M. Zaid, S. Saon, A. K. Mahamad, M. A. Bin Ahmadon and S. Yamaguchi, "Malaysian Food Recognition and Calories Estimation Using CNN With TensorFlow," 2023 IEEE 12th Global Conference on Consumer Electronics (GCCE), Nara, Japan, 2023, pp. 493-497, doi: 10.1109/GCCE59613.2023.10315482.
- N. Makondo, H. I. Kobo, T. E. Mathonsi and L. Mamushiane, "A Review on Edge Computing in 5G-Enabled IoT for Agricultural Applications: Opportunities and Challenges," 2023 International Conference on Electrical, Computer and Energy Technologies (ICECET), Cape Town, South Africa, 2023, pp. 1-6, doi: 10.1109/ICECET58911.2023.10389349.
- N. Rajeswari and D. Kavitha, "Fertilizer Spraying using Active Learning in Precision Agriculture to Improve the Crop Yield," 2022 International Conference on Automation, Computing and Renewable Systems (ICACRS), Pudukkottai, India, 2022, pp. 925-931, doi: 10.1109/ICACRS55517.2022.10028741.
- Narigina, M., K̇empelis, A., Romānovs, A. Machine Learning-based Forecasting of Sensor Data for Enhanced Environmental Sensing. *WSEAS Transactions on Systems*, 2023, Vol. 22, 543.-555.lpp. ISSN 1109-2777. e-ISSN 2224-2678. Pieejams: doi:10.37394/23202.2023.22.55
- Narmilan Amarasingam, Kevin Powell, Juan Sandino, Dmitry Bratanov, Arachchige Surantha Ashan Salgadoe, Felipe Gonzalez, Mapping of insect pest infestation for precision agriculture: A UAV-based multispectral imaging and deep learning techniques, *International Journal of Applied Earth Observation and Geoinformation*, Volume 137, 2025, 104413, ISSN 1569-8432, <https://doi.org/10.1016/j.jag.2025.104413>.
- Naznin, Ishra & Islam, Md. (2023). Age Estimation from Face Image Leveraging Concatenated Features of Vision Transformer Along with Resnet-50. 1-6. 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. 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*, Semarang, Indonesia, 21–22 September 2018; pp. 83–86.
- Nurhopipah, A. and Larasati, N. A. . (2021) “CNN Hyperparameter Optimization using Random Grid Coarse-to-fine Search for Face Classification”, *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 6(1), pp. 19-26. doi: 10.22219/kinetik.v6i1.1185.
- Nvidia Jetson Nano, 2022, [tiešsaiste] Pieejams: <https://www.nvidia.com/en-eu/autonomous-machines/embedded-systems/jetson-nano/product-development/>
- O. Jouini, K. Sethom and R. Bouallegue, "Wheat leaf disease detection using CNN in Smart Agriculture," 2023 International Wireless Communications and Mobile Computing (IWCMC), Marrakesh, Morocco, 2023, pp. 1660-1665, doi: 10.1109/IWCMC58020.2023.10183348.
- P. Dhiman, V. Kukreja and A. Kaur, "Citrus Fruits Classification and Evaluation using Deep Convolution Neural Networks: An Input Layer Resizing Approach," 2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), 2021, pp. 1-4, doi: 10.1109/ICRITO51393.2021.9596357.
- P. Lv, W. Wu, Y. Zhong and L. Zhang, "Review of Vision Transformer Models for Remote Sensing Image Scene Classification," *IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium*, Kuala Lumpur, Malaysia, 2022, pp. 2231-2234, doi: 10.1109/IGARSS46834.2022.9883054.
- Padhiary, Mrutyunjay & Hoque, Azmirul & Prasad, Gajendra & Kumar, Kundan & Sahu, Bhabashankar. (2025). Precision Agriculture and AI-Driven Resource Optimization for Sustainable Land and Resource Management. 10.4018/979-8-3693-8074-1.ch009.
- Parmar, Kanak & Parker, Jeffrey & Guzzetti, Davide. (2023). Applications of Regression Vision Transformers for Autonomous Spacecraft Optical Navigation in Simulated Orbital Environments.
- Plevris, Vagelis & Solorzano, German & Bakas, Nikolaos & Ben Seghier, Mohamed. (2022). Investigation of performance metrics in regression analysis and machine learning-based

- prediction models. 10.23967/eccomas.2022.155.
- Polo Rodríguez, Aurora & Montoro-Lendinez, Alicia & Espinilla, Macarena & Medina, J. (2022). Classifying Sport-Related Human Activity from Thermal Vision Sensors Using CNN and LSTM. 10.1007/978-3-031-13321-3\_4.
- Priya, V.; Balambica, V. IoT based agriculture robot using neural networks. In Proceedings of the 2023 3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), Greater Noida, India, 12–13 May 2023; pp. 251–255.
- Priva. Wireless sensors for enhanced monitoring and control, 2024. g. [tiešsaiste]. [skatīts 2024 g. 11. decembrī]. Pieejams: <https://www.priva.com/horticulture/solutions/greenhouse-sensors/wireless-sensors>
- Ratnak Sok, Arravind Jeyamoorthy, Jin Kusaka, Novel virtual sensors development based on machine learning combined with convolutional neural-network image processing-translation for feedback control systems of internal combustion engines, Applied Energy, Volume 365, 2024, 123224, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2024.123224>.
- R. Krishnamurthi, R. Maheshwari and R. Gulati, "Deploying Deep Learning Models via IOT Deployment Tools," 2019 Twelfth International Conference on Contemporary Computing (IC3), Noida, India, 2019, pp. 1-6, doi: 10.1109/IC3.2019.8844946.
- R. Nirthika, S. Manivannan and A. Ramanan, "An experimental study on convolutional neural network-based pooling techniques for the classification of HEp-2 cell images," *2021 10th International Conference on Information and Automation for Sustainability (ICIAfS)*, Negambo, Sri Lanka, 2021, pp. 281-286, doi: 10.1109/ICIAfS52090.2021.9606157.
- R. R. Chandrapu, C. Pal, A. T. Nimbekar and A. Acharyya, "SqueezeVGGNet: A Methodology for designing low complexity VGG Architecture for Resource Constraint Edge Applications," 2022 20th IEEE Interregional NEWCAS Conference (NEWCAS), Quebec City, QC, Canada, 2022, pp. 109-113, doi: 10.1109/NEWCAS52662.2022.9841955.
- Radi; Murtiningrum; Ngadisih; Muzdrikah, F.S.; Nuha, M.S.; Rizqi, F.A. Calibration of capacitive soil moisture sensor (SKU:SEN0193). In Proceedings of the 2018 4th International Conference on Science and Technology (ICST), Yogyakarta, Indonesia, 7–8 August 2018; pp.

- Ryu S, Song JJ, Lee G. Interpolation of Temperature in a Mountainous Region Using Heterogeneous Observation Networks. *Atmosphere*. 2024; 15(8):1018. <https://doi.org/10.3390/atmos15081018>
- Roy Sadeh, Victor Alchanatis, Roi Ben-David, Ittai Herrmann, Zvi Peleg, UAV-borne hyperspectral and thermal imagery integration empowers genetic dissection of wheat stomatal conductance, *Computers and Electronics in Agriculture*, Volume 235, 2025, 110411, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2025.110411>.
- Ross Wightman, timm bibliotēkas dokumentācija [tiešsaiste]. [skatīts 2025. g. 19. maijā.]. Pieejams: <https://timm.fast.ai/>
- S. Das, J. Christopher, A. Apan, M. Roy Choudhury, S. Chapman, N. W. Menzies, Y. P. Dang, "UAV-Thermal Imaging: A Robust Technology to Evaluate in-field Crop Water Stress and Yield Variation of Wheat Genotypes," 2020 IEEE India Geoscience and Remote Sensing Symposium (InGARSS), Ahmedabad, India, 2020, pp. 138-141, doi: 10.1109/InGARSS48198.2020.9358955.
- S. Kido, Y. Hirano and N. Hashimoto, "Detection and classification of lung abnormalities by use of convolutional neural network (CNN) and regions with CNN features (R-CNN)," 2018 International Workshop on Advanced Image Technology (IWAIT), Chiang Mai, Thailand, 2018, pp. 1-4, doi: 10.1109/IWAIT.2018.8369798
- S. Puengsungwan, "IoT based Soil Moisture Sensor for Smart Farming," 2020 International Conference on Power, Energy and Innovations (ICPEI), Chiangmai, Thailand, 2020, pp. 221-224, doi: 10.1109/ICPEI49860.2020.9431455.
- Sathian Dananjayan, Yu Tang, Jiajun Zhuang, Chaojun Hou, Shaoming Luo, Assessment of state-of-the-art deep learning based citrus disease detection techniques using annotated optical leaf images, *Computers and Electronics in Agriculture*, Volume 193, 2022, 106658, ISSN 0168-1699, <https://doi.org/10.1016/j.compag.2021.106658>.
- Senthilnathan, Samithamby. (2019). Usefulness of Correlation Analysis. *SSRN Electronic Journal*. 10.2139/ssrn.3416918.
- Shan Ke, Guowei Dai, Hui Pan, Bowen Jin, Intelligent vineyard blade density measurement method incorporating a lightweight vision transformer, *Egyptian Informatics Journal*, Volume 26, 2024, 100456, ISSN 1110-8665, <https://doi.org/10.1016/j.eij.2024.100456>.
- Siddhesh Bangar, VGG-Net Architecture Explained, 2022. g. [tiešsaiste]. [skatīts 2024. g. 13. oktobrī.]. Pieejams: <https://medium.com/@siddheshb008/vgg-net-architecture-explained-71179310050f>

- Sungil Kim, Heeyoung Kim, A new metric of absolute percentage error for intermittent demand forecasts, *International Journal of Forecasting*, Volume 32, Issue 3, 2016, Pages 669-679, ISSN 0169-2070, <https://doi.org/10.1016/j.ijforecast.2015.12.003>.
- T. Akilan, K.M. Baalamurugan, Automated weather forecasting and field monitoring using GRU-CNN model along with IoT to support precision agriculture, *Expert Systems with Applications*, Volume 249, Part A, 2024, 123468, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2024.123468>.
- Tan, Mingxing & Le, Quoc. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. 10.48550/arXiv.1905.11946.
- Terven, Juan & Cordova-Esparza, Diana-Margarita & Ramirez-Pedraza, Alfonso & Chávez Urbiola, Edgar. (2023). Loss Functions and Metrics in Deep Learning. A Review. 10.48550/arXiv.2307.02694.
- Tuğçe Kazanasmaz, Murat Günaydin, Selcen Bino1, Artificial neural networks to predict daylight illuminance in office buildings, *Building and Environment*, Volume 44, Issue 8, 2009, Pages 1751-1757, ISSN 0360-1323, <https://doi.org/10.1016/j.buildenv.2008.11.012>.
- Touvron H, Cord M, Douze M, Massa F, Sablayrolles A, Jégou H. Training data-efficient image transformers and distillation through attention. arXiv, 2021. doi:10.48550/arXiv.2012.12877.
- Uzdevumi.lv, Virtuālā skola Fizika 12. klase Elektromagnētiskās svārstības un viļņi [tiešsaiste]. [skatīts 2025. g. 8. febr.]. Pieejams: <https://www.uzdevumi.lv/p/fizika/12-klase/elektromagnetiskas-svarstibas-un-vilni-7460/re-271b4192-2c8c-4db1-a821-c38b45c318ce>
- Vaswani A, Shazeer N, Parmar N, et al. Attention Is All You Need. arXiv. Preprint posted June 12, 2017. Updated August 2, 2023. doi:10.48550/arXiv.1706.03762.
- VEML7700 sensora dokumentācija [tiešsaiste]. [skatīts 2025. g. 21. jūnijā.]. Pieejams: [https://cdn.sparkfun.com/assets/a/2/b/a/4/VEML7700\\_Datasheet.pdf](https://cdn.sparkfun.com/assets/a/2/b/a/4/VEML7700_Datasheet.pdf)
- Vieira, G.H.S.; Ferrarezi, R.S. Use of Thermal Imaging to Assess Water Status in Citrus Plants in Greenhouses. *Horticulturae* 2021, 7, 249.
- Wang H, Lao L, Zhang H, Tang Z, Qian P, He Q. Structural Fault Detection and Diagnosis for Combine Harvesters: A Critical Review. *Sensors*. 2025; 25(13):3851. <https://doi.org/10.3390/s25133851>
- Wantao Jia, Qinyu Guo, Mengze Lyu, Wanrong Zan, Dynamic reliability analysis of systems

- under combined Gaussian and Poisson white noise by time-varying extreme value process, *Reliability Engineering & System Safety*, Volume 265, Part B, 2026, 111514, ISSN 0951-8320, <https://doi.org/10.1016/j.ress.2025.111514>.
- Wei Wang, Bo Li, Jin Han, Shuhui Zhang, Jianming Li, The role of light intensity in water transport and homeostasis across different vapor pressure deficit conditions, *Environmental and Experimental Botany*, Volume 227, 2024,105943, ISSN 0098-8472, <https://doi.org/10.1016/j.envexpbot.2024.105943>.
- Wu, H., Xiao, B., Codella, N., Liu, M., Dai, X., Yuan, L., & Zhang, L. (2021). CvT: Introducing Convolutions to Vision Transformers. *IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, QC, Canada, 2021, pp. 22-31, doi: 10.1109/ICCV48922.2021.00009.
- Xing, D., Wang, Y., Sun, P. et al. A CNN-LSTM-att hybrid model for classification and evaluation of growth status under drought and heat stress in chinese fir (*Cunninghamia lanceolata*). *Plant Methods* 19, 66 (2023). <https://doi.org/10.1186/s13007-023-01044-8>
- Z. Wang, W. Yan and T. Oates, "Time series classification from scratch with deep neural networks: A strong baseline," 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA, 2017, pp. 1578-1585, doi: 10.1109/IJCNN.2017.7966039
- Zhao, W.; Dong, X.; Wu, Z.; Wei, C.; Li, L.; Yu, D.; Fan, X.; Ma, Y. Using infrared thermal imaging technology to estimate the transpiration rate of citrus trees and evaluate plant water status. *J. Hydrol.* 2022, 615 Pt A, 128671.
- Zheng, W.; Zheng, K.; Gao, L.; Zhangzhong, L.; Lan, R.; Xu, L.; Yu, J. GRU-Transformer: A Novel Hybrid Model for Predicting Soil Moisture Content in Root Zones. *Agronomy* 2024, 14, 432. <https://doi.org/10.3390/agronomy14030432>.

## **PIELIKUMI**

**1. pielikums****Konkrētā dienā ievākto mērījumu datu piemērs 2024. gadā**

time	light 2	temperatur e2	humidit y2	light 1	humidit y1	temperatur e1
04/06/2024 00:05	0	16.7	99.77	0	99.99	16.7
04/06/2024 00:25	0	16.44	99.99	0	99.99	16.46
04/06/2024 00:45	1	16.27	99.99	0	99.99	16.29
04/06/2024 01:05	4	16.2	99.99	2	99.99	16.21
04/06/2024 01:25	26	16.16	99.99	17	99.99	16.21
04/06/2024 01:45	107	16.27	99.99	71	99.99	16.32
04/06/2024 02:05	289	16.26	99.99	189	99.99	16.32
04/06/2024 02:25	473	16.56	99.99	318	99.99	16.58
04/06/2024 02:45	597	17.17	99.84	416	99.99	17.14
04/06/2024 03:05	933	17.74	99.99	649	99.99	17.73
04/06/2024 03:25	1334	18.49	96.98	985	99.99	18.57
04/06/2024 03:45	1657	19.2	95.03	1141	99.21	19.27
04/06/2024 04:05	2042	20.65	93.71	1467	98.22	20.67
04/06/2024 04:25	2389	21.24	85.11	1931	89.48	21.3
04/06/2024 04:45	2249	22.38	80.11	1976	84.27	22.49

04/06/2024 05:05	2046	21.85	80.49	1722	84.35	22.06
04/06/2024 05:25	3212	22.54	75.09	3839	80.41	22.27
04/06/2024 05:45	4326	27.58	61.88	6051	70.58	25.96
04/06/2024 06:05	3388	22.57	75.68	2562	80.18	22.59
04/06/2024 06:25	3423	22.35	76.82	2800	82.11	22.16
04/06/2024 06:45	4016	23.17	75.21	3770	80.9	22.85
04/06/2024 07:05	3398	22.62	75.78	2761	80.77	22.55
04/06/2024 07:25	3209	23.77	72.91	2471	77.99	23.63
04/06/2024 07:45	3687	24.88	70.29	3310	77.42	24.18
04/06/2024 08:05	3608	23.43	73.98	2750	77.99	23.55
04/06/2024 08:25	2551	23.83	73.81	1969	78.45	23.89
04/06/2024 08:45	4385	29.31	58.51	3636	64.19	28.77
04/06/2024 09:05	4594	28.46	63.37	4015	67.18	28.53
04/06/2024 09:25	4991	26.83	67.11	4080	71.27	26.83
04/06/2024 09:45	2915	25.5	65.72	2337	70.29	25.41
04/06/2024 10:05	2124	25.09	66.88	1486	70.92	25.21
04/06/2024 10:25	4552	28.07	61.13	3703	62.88	28.9

04/06/2024 10:45	4607	30.07	54.69	4791	55.19	31.57
04/06/2024 11:05	4471	28.73	58.4	6016	58.4	30.13
04/06/2024 11:25	3927	27.46	60.22	3407	64.08	27.26
04/06/2024 11:45	3875	27.59	59.2	4804	62.63	27.73
04/06/2024 12:05	2950	26.76	60.21	1921	63.95	26.8
04/06/2024 12:25	3990	27.16	58.37	3447	59.61	28.31
04/06/2024 12:45	2621	25.72	60.33	1917	64.17	25.73
04/06/2024 13:05	3410	25.44	59.36	2138	62.91	25.53
04/06/2024 13:25	3305	25.52	56.19	2278	59.83	25.52
04/06/2024 13:45	3141	25.59	56.09	2039	59.83	25.61
04/06/2024 14:05	5466	27.35	51.92	5129	55.28	27.37
04/06/2024 14:25	1972	26.24	54.42	1202	57.86	26.26
04/06/2024 14:45	4432	27.51	52.41	3088	55.85	27.57
04/06/2024 15:05	4179	27.09	53.13	3096	56.27	27.27
04/06/2024 15:25	6607	27.46	51.82	4978	54.96	27.57
04/06/2024 15:45	2157	25.32	56.71	1243	60.36	25.37
04/06/2024 16:05	4849	26.81	54.37	3975	56.86	27.23


04/06/2024 16:25	5956	27.19	54.52	4776	57.75	27.37
04/06/2024 16:45	8310	33.94	40.7	4639	44.55	33.41
04/06/2024 17:05	7781	31.23	44.74	2420	48.4	30.93
04/06/2024 17:25	2323	26.21	55.32	1263	58.98	26.12
04/06/2024 17:45	1870	25.3	57.11	790	60.98	25.16
04/06/2024 18:05	2496	23.68	64.48	692	68.23	23.74
04/06/2024 18:25	708	22.14	69.76	340	73.86	22.13
04/06/2024 18:45	393	21.74	70.62	193	74.79	21.74
04/06/2024 19:05	180	21.21	79.71	87	83.87	21.23
04/06/2024 19:25	60	20.62	87.14	28	91.41	20.65
04/06/2024 19:45	13	20.12	91.44	6	95.71	20.15
04/06/2024 20:05	2	19.65	93.23	0	97.61	19.71
04/06/2024 20:25	0	19.23	95.43	0	99.81	19.26
04/06/2024 20:45	0	18.83	97.09	0	99.99	18.89
04/06/2024 21:05	0	18.46	96.58	0	99.99	18.49
04/06/2024 21:25	0	18.06	97.58	0	99.99	18.09
04/06/2024 21:45	0	17.7	97.72	0	99.99	17.71


04/06/2024 22:05	0	17.3	98.22	0	99.99	17.35
04/06/2024 22:25	0	17.03	98.27	0	99.99	17.09
04/06/2024 22:45	0	16.73	98.51	0	99.99	16.76
04/06/2024 23:05	0	16.48	98.46	0	99.99	16.51
04/06/2024 23:25	0	16.15	98.75	0	99.99	16.21
04/06/2024 23:45	0	15.86	98.9	0	99.99	15.91





### 3. pielikums



Konkrētā dienā (1. Jūnijs 2024. gads) ievākto termoattēlu piemērs











#### 4. pielikums

Modeļu apmācība ar šķērsvalidācijas metodi rezultāti, izmantojot 100% n ooriģinālās datu datu kopas

##### CNN gaismas intensitātes mērījumu novērtējuma rezultāti

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	400.617004	686.319509	0.826859
2. locījums	373.840485	595.052991	0.880149
3. locījums	388.863525	608.608171	0.864338
4. locījums	437.148743	658.584348	0.847845
5. locījums	364.656769	565.277835	0.890502
Vidējā vērtība	393.025299	622.768571	0.861938
Standartnovirze	28.260677	48.97792	0.025409

##### CNN gaisa temperatūras mērījumu novērtējuma rezultāti

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	1.205061	1.684799	0.87652
2. locījums	1.174477	1.542166	0.899936
3. locījums	1.123984	1.580787	0.895641
4. locījums	1.232565	1.711876	0.886203
5. locījums	1.075222	1.524858	0.902276
Vidējā vērtība	1.162262	1.608897	0.892115
Standartnovirze	0.063176	0.084663	0.010665

**CNN relatīvā gaisa mitruma mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	3.895361	5.444965	0.881292
2. locījums	4.906905	6.971726	0.809824
3. locījums	3.838859	5.429159	0.881454
4. locījums	4.005702	5.672272	0.869966
5. locījums	4.192465	5.540438	0.874611
Vidējā vērtība	4.167859	5.811712	0.86343
Standartnovirze	0.434622	0.655651	0.030353

**ViT gaismas intensitātes mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	418.473572	641.989875	0.851375
2. locījums	437.198975	741.886868	0.808704
3. locījums	419.036835	626.187921	0.856108
4. locījums	406.623169	651.312137	0.856309
5. locījums	409.583557	617.091768	0.866206
Vidējā vērtība	418.183197	655.693714	0.84774
Standartnovirze	10.677086	44.714551	0.020107

**ViT gaisa temperatūras mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	0.948591	1.309099	0.926523
2. locījums	1.101712	1.524152	0.906518
3. locījums	0.99811	1.353023	0.923795
4. locījums	1.00293	1.299998	0.933418
5. locījums	0.810808	1.165874	0.940031
Vidējā vērtība	0.97243	1.330429	0.926057
Standartnovirze	0.094862	0.115325	0.011283

**ViT relatīvā gaisa mitruma mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	4.591678	7.193912	0.793064
2. locījums	5.345337	8.24948	0.732157
3. locījums	5.190197	8.424656	0.71536
4. locījums	5.319929	7.840127	0.751881
5. locījums	4.644457	6.937901	0.803488
Vidējā vērtība	5.018319	7.729215	0.75919
Standartnovirze	0.331435	0.579542	0.034103

**CvT gaismas intensitātes mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	301.551849	556.761787	0.888218
2. locījums	275.709534	447.394436	0.930432
3. locījums	261.285065	426.836528	0.933142
4. locījums	296.226776	510.16203	0.911841
5. locījums	261.046387	429.126602	0.9353
Vidējā vērtība	279.16391	474.056277	0.919786
Standartnovirze	17.042252	51.191915	0.017844

**CvT gaisa temperatūras mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	0.596519	0.9275	0.963116
2. locījums	0.718522	1.100865	0.951232
3. locījums	0.574877	0.801868	0.973234
4. locījums	0.515213	0.709308	0.980178
5. locījums	0.526145	0.743245	0.975628
Vidējā vērtība	0.586255	0.856557	0.968678
Standartnovirze	0.072649	0.142991	0.01036

**CvT relatīvā gaisa mitruma mērījumu novērtējuma rezultāti**

	<b>MAE</b>	<b>RMSE</b>	<b>R2</b>
1. locījums	2.306765079	3.713625928	0.944855503
2. locījums	2.569037437	4.304876029	0.927062851
3. locījums	2.256201982	3.76368087	0.943190922
4. locījums	2.345096111	3.751680506	0.943184747
5. locījums	2.00296855	3.228050203	0.957458534
Vidējā vērtība	2.296013832	3.752382707	0.943150512
Standartnovirze	0.181398495	0.341116894	0.009658593

## 5. pielikums

### Modeļu veiktspējas salīdzinājums pie dažāda līmeņa trokšņainiem termoattēliem

Troksnis	CNN	ViT	CvT
Oriģināls termokameras attēls	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 602.199   MAE: 396.055   NMAE: 0.211   SMAPE: 19.51%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 5.500   MAE: 3.903   NMAE: 0.047   SMAPE: 5.54%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.338   MAE: 1.048   NMAE: 0.050   SMAPE: 4.90%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 691.451   MAE: 372.422   NMAE: 0.198   SMAPE: 22.72%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 7.304   MAE: 5.077   NMAE: 0.061   SMAPE: 7.10%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.483   MAE: 1.012   NMAE: 0.048   SMAPE: 4.68%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 455.919   MAE: 266.272   NMAE: 0.142   SMAPE: 19.23%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 5.339   MAE: 3.285   NMAE: 0.039   SMAPE: 4.65%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.190   MAE: 0.894   NMAE: 0.042   SMAPE: 4.04%</p>
Troksnis 0.1 °C	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 603.429   MAE: 402.986   NMAE: 0.215   SMAPE: 19.94%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 687.675   MAE: 367.185   NMAE: 0.196   SMAPE: 21.30%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 438.974   MAE: 273.214   NMAE: 0.146   SMAPE: 20.39%</p>

Troksnis	CNN	ViT	CvT
	<p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 5.381   MAE: 3.969   NMAE: 0.047   SMAPE: 5.46%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.363   MAE: 1.039   NMAE: 0.049   SMAPE: 4.86%</p>	<p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 7.234   MAE: 5.144   NMAE: 0.061   SMAPE: 7.17%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.481   MAE: 1.019   NMAE: 0.048   SMAPE: 4.73%</p>	<p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 6.552   MAE: 4.542   NMAE: 0.054   SMAPE: 6.25%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 1.387   MAE: 1.150   NMAE: 0.054   SMAPE: 5.43%</p>
Troksnis 0.5 °C	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 650.285   MAE: 507.850   NMAE: 0.271   SMAPE: 29.25%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 7.662   MAE: 6.549   NMAE: 0.078   SMAPE: 8.04%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 960.379   MAE: 661.714   NMAE: 0.353   SMAPE: 36.92%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 15.882   MAE: 12.578   NMAE: 0.150   SMAPE: 16.27%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 919.337   MAE: 725.357   NMAE: 0.386   SMAPE: 32.41%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 12.987   MAE: 11.381   NMAE: 0.136   SMAPE: 14.11%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p>

Troksnis	CNN	ViT	CvT
	RMSE: 2.810   MAE: 2.091   NMAE: 0.099   SMAPE: 10.39%	RMSE: 1.613   MAE: 1.359   NMAE: 0.064   SMAPE: 6.72%	RMSE: 2.132   MAE: 1.818   NMAE: 0.086   SMAPE: 9.36%
Troksnis 1.0 °C	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 928.797   MAE: 742.723   NMAE: 0.396   SMAPE: 36.14%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 11.863   MAE: 10.212   NMAE: 0.122   SMAPE: 12.58%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 5.046   MAE: 4.035   NMAE: 0.191   SMAPE: 19.43%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 2063.773   MAE: 1722.483   NMAE: 0.918   SMAPE: 56.22%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 26.011   MAE: 21.643   NMAE: 0.259   SMAPE: 28.31%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 3.151   MAE: 2.840   NMAE: 0.134   SMAPE: 14.31%</p>	<p><b>Gaismas intensitātes novērtējumi:</b></p> <p>RMSE: 1355.408   MAE: 1162.222   NMAE: 0.619   SMAPE: 51.01%</p> <p><b>Relatīvā gaisa mitruma novērtējumi:</b></p> <p>RMSE: 14.542   MAE: 12.757   NMAE: 0.152   SMAPE: 15.87%</p> <p><b>Gaisa temperatūras novērtējumi:</b></p> <p>RMSE: 2.409   MAE: 2.064   NMAE: 0.098   SMAPE: 10.44%</p>



**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.