

**YOLOV5 NEIRONU TĪKLA APMĀCĪBA AUGU SUGU UN SLIMĪBU  
ATPAZĪŠANAI PĒC AUGU LAPU FOTOGRAFĪJĀM**  
*TRAINING OF YOLOV5 NEURAL NETWORK FOR CLASSIFICATION OF  
PLANT SPECIES AND DISEASES BY PHOTOGRAPHS OF PLANT LEAVES*

Autores: **Ērika Dmitrijeva**, e-pasts: erika5002@inbox.lv

**Arina Amālija Belova**, e-pasts: benyalatvia@gmail.com

Zinātniskā darba vadītājs: **Sergejs Kodors, Dr.sc.ing.**, e-pasts: sergejs.kodors@rta.lv

Rēzeknes Tehnoloģiju akadēmija

Atbrīvošanas aleja 115, Rēzekne

---

**Abstract.** 40% percent of crops are lost every year due to plant diseases. It is physically difficult for people to detect plant diseases in large-scale fields, especially at an early stage. The paper deals with the YoloV5 neural network training using different technologies. The neural network is trained to classify plant species and their diseases using photographs. The open access dataset PlantDoc was used for training. PlantDoc provides 2,569 images of 13 plant species and 27 classes for image classification and object detection. For the purity of the experiment, training was performed 10 times without changing the parameters. As a result of each training, we had obtained testing data on which we could draw conclusions.

**Keywords:** diseases, neural network, plants, object detection, RoboFlow, YoLoV5

---

### Ievads

Augu produktiem ir liela loma pasaulē, un tie vienmēr būs ļoti pieprasīti. Kultūraugu aizsardzība pret augu slimībām vienmēr ir aktuāla, jo slimību dēļ tiek zaudēts liels ražas daudzums, liels skaits augu iet bojā, kā rezultātā tiek zaudēta liela nauda. Saskaņā ar 2021. gada datiem, katru gadu augu slimības pasaules ekonomikai izmaksā vairāk nekā 220 miljardus dolāru, jo tiek zaudēti 40% no pasaules ražas [1]. Visām šīm slimībām ir plašas ekonomiskas, sociālas un vides sekas. Savlaicīga augu slimību atklāšana joprojām ir izaicinājums lauksaimniekiem. Lai atklātu slimības, pat ne agrīnā stadijā, ir vajadzīgs daudz laika un daudz cilvēku pūļu. Un ne vienmēr cilvēka acs var pamanīt slimu augu, it īpaši, ja nepieciešams izpētīt liela mēroga lauku.

Neironu tīkli pēdējo desmit gadu laikā ir guvuši lielus panākumus, un tagad tos izmanto dažādās nozarēs. Neskatoties uz to, ka parasti neironu tīkli nerisina problēmu kopumā, tiem ir daudz priekšrocību, piemēram, tie palīdz mums klasificēt un grupēt. Bet ir arī trūkumi, piemēram, lielu neironu tīklu apmācība aizņem daudz laika, un precizitātes paaugstināšanai jāveic vairāki eksperimenti un neironu tīkla tūnings.

Šajā rakstā mēs pētām iespēju izmantot mākslīgo intelektu, lai, izmantojot fotogrāfijas, noteikt augu sugas un augu slimības. Spēja atpazīt augu slimības palīdzēs noteikt augu slimības agrīnās stadijās, kas palīdzēs lauksaimniecībai laikus izārstēt augu un nezaudēt ražu. Lai precīzi noteiktu slimības, nepieciešama augstas izšķirtspējas fotogrāfija. Lai gan šobrīd gandrīz visām kamerām ir iespēja uzņemt šādu fotoattēlu, datu kopā ir fotogrāfijas ar dažādu izšķirtspēju, apgaismojumu un ar dažādiem fona trokšņiem, kas uzlabos neironu tīkla slimību atpazīšanu.


**Pētījuma mērķis:** izstrādāt neironu tīklu, kas spēj meklēt augu slimības fotogrāfijās.

## Uzdevumi:

- 1) sagatavot datu kopu neironu tīkla apmācīšanai;
- 2) apmācīt neironu tīklus;
- 3) novērtēt apmācītu neironu tīklu atpazīšanas kvalitāti.

## Materiāli un metodes

Lai apmācītu *YoLoV5* neironu tīklu, tika izmantota datu kopa ar nosaukumu *PlantDoc*, ko publicējuši Indijas Tehnoloģiju institūta pētnieki [2]. Datu kopa sastāv no 2569 attēliem, kuros redzamas 13 augu sugas un 27 augu klases (17 slimas un 10 veselas). Kā anotācijas tips tika izmantota robežkaste jeb *Bounding Box*. Failos ar nosaukumu *\_annotations* ir 8851 augu lapu marķējumi (*labels*) [3], kas norāda, kur atrodas auga lapa un kāda suga un slimība tai ir. Attēli ir iepriekš sakārtoti divās mapēs - apmācībai un pārbaudei, bet, lai apmācītu neironu tīklu, ir vajadzīga vēl viena mape – derīgs. Attēli tika augšupielādēti vienā mapē, lai vēlāk, izmantojot *RoboFlow* rīku, tie automātiski sadalītos trīs mapēs. Piemērs ar trim attēliem no datu kopas ir redzams zemāk (skat. 1 att.).




1. attēls. Piemēri no *PlantDoc* datu kopas

Neironu tīklu apmācīšanai tika izmantoti šādi rīki un tehnoloģijas – *RoboFlow*, *Google Colab* (*GPU*), *YoLoV5*, *Python*. Sākumā tika lejupielādēta iepriekš aprakstītā *PlantDoc* datu kopa, kas atrodama *RoboFlow* vietnē. Pielietojot *RoboFlow* rīku [4], tika izveidots projekts ar anotācijas tipu - objektu meklēšana (*Object Detection* jeb *Bounding Box*), kurā tika augšupielādēta *PlantDoc* datu kopa. Augšupielādējot attēlus, tika mainīts *train/valid/test* (treniņš/derīgs/pārbaudījums) sadalījums (*train* - 70%, *valid* – 15%, *test* – 15%), jo datu kopā nebija nepieciešamos neironu tīklu apmācībai “*valid*” attēlu. Sadalījums nepieciešams, lai apmācīt, un pēc tam pārbaudīt modeļa veiktspēju. Projektā tika izveidota jauna versija, kura bija augmentēta, pievienojot šādus parametrus: pagrieziena vertikāli un horizontāli, 90° rotācija pulksteņa kustības virzienā, pretēji pulksteņrādītāja virzienam un augšpēdus, papildu rotācija no -25° līdz +25° un bīde ±15° horizontāli un ±15° vertikāli. Lai treniņa rezultāts būtu labāks, augmentēta versija tika palielināta trīs reizes. Kad versija tika uzģenerēta, tā tika eksportēta *YoLoV5 PyTorch* formātā, lai turpmāk izmantotu neironu tīklu apmācībā.

Nākamais solis bija apmācīt *YoLoV5* [5] neironu tīkla modeli, izmantojot *Google Colab* vidi [6], pielietojot *GPU* (*Graphics Processing Unit*) skaitļošanu. Kodols *YoLoV5* tika pielietots apmācīšanas laikā. Lai apmācītu *YoLoV5* neironu tīklu, tika veiktas šādas darbības: instalētas *YoLoV5* pakotnes (atkarības), importēta datu kopa, definēta modeļa konfigurācija un arhitektūra, apmācīts *YoLoV5*, novērtēta *YoLoV5* veiktspēja, vizualizēti *YoLoV5* treniņu dati, pārbaudīti treniņi ar testa attēliem un eksportēti *YoLoV5* rezultāti turpmākiem secinājumiem. Lai iegūtu precīzākus treniņa rezultātus, visas šīs darbības tika veiktas 10 reizes.

## Rezultāti un to izvērtējums

Lai vēlāk piefiksētu precizitāti, neironu tīklu apmācība tika veikta 10 reizes. Pēc katras apmācības mēs saņēmām grafikus ar dažādiem rezultātiem. Turpmākajiem aprēķiniem mēs saglabājām testēšanas grafikus, jo šie grafiki satur mums nepieciešamus datus. Zemāk ir parādīti labākie apmācību rezultāti (skat. 2 att.). Attēlā var redzēt piecus grafikus ar zaudējuma un precizitātes funkcijām.



2. attēls. Labāko apmācības rezultātu grafiki

Kļūdu funkcijas:

- **val Box** – kļūda, ka lauka prognoze nosedz objektu neprecīzi;
- **val Objectness** – kļūda no nepareizas *IoU* (*Intersection over Union*) prognozes priekš robežkastes. *IoU* mēra pārklāšanos starp divām robežām. Tas tiek izmantots, lai izmērītu, cik stipri atrasta objekta robežas pārklājas ar gaidītajām robežām;
- **val Classification** – kļūda, kas radusies novirzes no prognozēšanas “1” pareizajām klasēm un “0” visām pārējām klasēm objektam šajā laukā.

Precizitātes funkcijas:

*mAP* (mean Average Precision) salīdzina pamata patiesības robežlauku ar noteiktu lauku un vidējo rezultātu. Jo augstāks rādītājs, jo precīzāks modelis ir tā noteikšanā.

- ***mAP@0.5*** - ja *IoU* ir iestatīts uz 0,5, tiek aprēķināta vidēja precizitāte katras kategorijas visiem attēliem, un tad tiek aprēķināts visu kategoriju vidējais rādītājs: *mAP*. Vidējā precizitāte ir populāra metrika objektu detektoru precizitātes mērīšanai. Tas aprēķina vidējo precizitātes vērtību atsauksmes vērtībai no 0 līdz 1;
- ***mAP@0.5:0.95*** – pārstāv vidējo *mAP* pie dažādiem *IoU* limitiem. (no 0,5 līdz 0,95 ar soli 0,05) [7].

Lai saprastu, cik labi modelis atpazīst objektus, un piefiksētu precizitāti, pētījumos izmantosim *mAP@ 0.5:0.95* maksimālās vērtības. Zemāk var redzēt tabulu ar *mAP@ 0.5:0.95* maksimālām vērtībām no visām 10 apmācībām (sk. 1. tab.).

1. tabula

***mAP@ 0.5:0.95* maksimālās vērtības pēc katras apmācības**

Nr	1	2	3	4	5	6	7	8	9	10
Vērtība	0,292	0,196	0,293	0,304	0,198	0,211	0,293	0,194	0,284	0,198

Izmantojot vērtības no tabulām, mēs noteiksim minimālo vērtību, maksimālo vērtību, vidējo vērtību un mediānu, lai izteiktu izvēlēta risinājuma un apmācības procesa kvalitāti.

Lai būtu vieglāk atrastu minimālo vērtību, maksimālo vērtību un mediānu, sakārtosim vērtības augošā secībā (sk. 2. tab.).

2. tabula

***mAP@ 0.5:0.95* maksimālās vērtības augošā secībā**

Nr	1	2	3	4	5	6	7	8	9	10
Vērtība	0,194	0,196	0,198	0,198	0,211	0,284	0,292	0,293	0,293	0,304

Pēc vērtību sakārtošanas varam secināt, ka

- Minimālā  $mAP@ 0.5:0.95$  vērtība – 0,194;
- Maksimālā  $mAP@ 0.5:0.95$  vērtība – 0,304.

Mediāna tiek aprēķināta pielietojot nepāra skaitļa formulu (1), iegūstot rezultātā vērtību – 0,248.

$$Me = \frac{\left( X \left[ \frac{n-1}{2} \right] + X \left[ \frac{n+1}{2} \right] \right)}{2}, \text{ kur} \quad (1)$$

$X$  – sakārtots vērtību saraksts;

$n$  – vērtību skaits datu kopā.

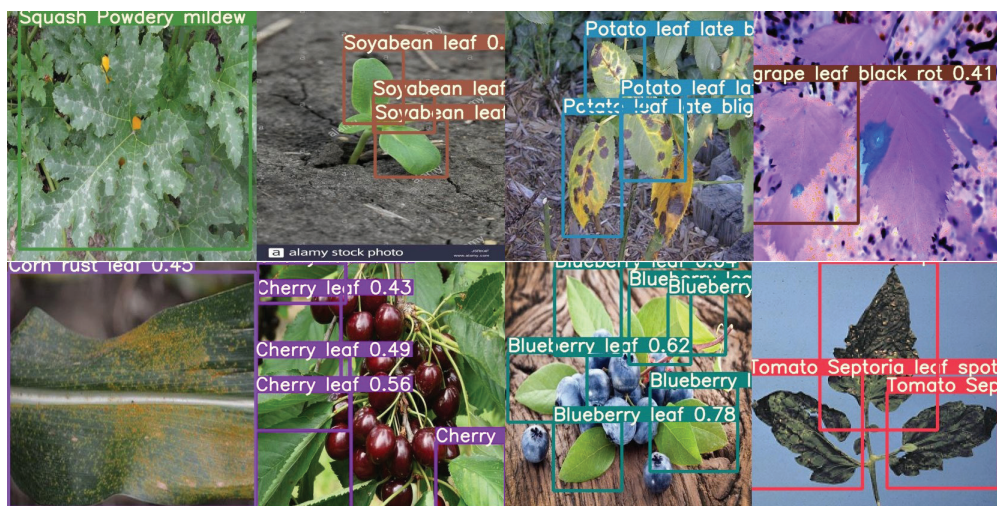
Lai atrastu vidējo vērtību izmantojam nepieciešamo formulu (2) un iegūstam rezultātu – 0,246.

$$V = \frac{x_1 + x_2 + \dots + x_n}{n}, \text{ kur} \quad (2)$$

$x$  – vērtība no datu kopas;

$n$  – vērtību skaits datu kopā.

Izpētot visus attēlus, kas tika augšupielādēti, lai pārbaudītu vislabāk apmācīto neironu tīklu, mēs pamanījām, ka dažos attēlos neironu tīkls neatklāja lapas, dažos atklāja nepareizu augu sugu vai slimību. Piemērs ar šādiem attēliem ir redzams zemāk (sk. 3. att.).



3. attēls. Ar neironu tīklu pareizi identificēti attēli

### Secinājumi

Izmantojot *Roboflow* rīku un *Google Colab* vidi, 10 reizes tika apmācīts *YoLoV5* neironu tīkls, kas atpazīst augu lapu sugas un slimības pēc fotogrāfijām. Apmācībām tika izmantota internetā publicēta datu kopa *PlantDoc*, kas sastāv no 2569 attēliem. Pēc katras apmācības saņēmām grafikus ar zaudējuma un precizitātes funkcijām, bet pētījumā izmantojam  $mAP@0.5:0.95$  maksimālās vērtības, jo šī vērtība palīdz piefiksēt modeļa precizitāti. Pētījuma rezultātā tika iegūtas 10 dažādas vērtības, kur minimālā vērtība bija 0,194 un maksimālā vērtība bija 0,304. Tāpat, izmantojot formulas, tika atrasta mediāna – 0,248 un vidējā vērtība – 0,246. Izmantojot *Google Colab* piezīmju grāmatu un testa attēlus, tika pārbaudīta labākā neironu tīkla noteikšanas precizitāte, kur neironu tīkls mēģināja noteikt augu lapu sugas un slimības. Izpētot šos attēlus, mēs secinājām, ka dažās attēlos neironu tīkls neatklāja lapas, dažās – atklāja nepareizi, bet dažās pareizi atklāja gan augu sugu, gan slimību.

Vērts pieminēt, ka modeļa precizitāti var uzlabot, palielinot versiju nevis trīs reizes, bet vairāk. Bet tam ir trūkums, neironu tīkla apmācība prasīs daudz vairāk laika un resursu.



## Acknowledgment

This research is funded by the Latvian Council of Science, project “Development of autonomous unmanned aerial vehicles based decision-making system for smart fruit growing”, project No. lzp-2021/1-0134.

## Summary

Food products will always have an important role in the world. Farmers still face the problem of plant diseases and end up losing a large amount of their crops, along with money. The human eye is unable to detect plant diseases in the early stages, especially if these are large fields.

Nowadays, neural networks have made great progress and are used in a wide variety of industries. With the help of neural networks, it is possible to recognize and classify images, but for this you need to spend a lot of time on training. In this article, we explored the possibility of using YoLoV5 artificial intelligence to identify plant species and plant diseases from photographs.

To train the neural network, we used the Google Colab environment and the PlantDoc dataset uploaded to Roboflow, which was available for free on the Internet. The data set has 2569 pictures. A project was created in Roboflow, where all the pictures were uploaded, and a new version was created in it, which was later augmented. To make the result better augmented version was increased by 3 times. Using the Google Colab environment, where the Roboflow project was added, the neural network was trained 10 times.

After each training, we obtained graphs with loss and accuracy functions, but in the research, we use the maximum values of  $mAP@0.5$ : 0.95, because this value helps to capture the accuracy of the model. As a result of the research, 10 different values were obtained, where the minimum value was 0.194 and the maximum value was 0.304. Also, using the formulas, a median of 0.248 and average of 0.246 were found. Using Google Colab's notebook and test images, the best accuracy of neural network detection was tested, where the neural network tried to detect plant leaf species and diseases. Examining these images, we found that in some images, the neural network did not detect the leaves, in some, it detected incorrectly, and in some, it detected both the plant species and the disease correctly.

## Literatūras un avotu saraksts

1. World Economic Forum. *What effect to insects and diseases have on crop production?* <https://www.weforum.org/agenda/2021/06/climate-change-insects-pests-crops-agriculture/#:~:text=Up%20to%2040%25%20of%20global,cost%20at%20least%20%2470%20billion,sk>, sk. 13.04.2022;
2. Davinder Singh. Naman Jain. Pranjali Jain, Pratik Kayal, Sudhakar Kumawat and Nipun Batra. *PlantDoc: A Dataset for Visual Plant Disease Detection*, 2019. <https://public.roboflow.com/object-detection/plantdoc>, sk. 11.02.2022.
3. Roboflow. *LabelImg for Labeling Object Detection Data*. <https://blog.roboflow.com/labelimg/>, sk. 25.02.2022.
4. Roboflow. <https://app.roboflow.com/>, sk. 13.02.2022.
5. GitHub. *How to train Custom Data with YoLoV5*. <https://github.com/ultralytics/yolov5/wiki/Train-Custom-Data>, sk. 13.02.2022.
6. Colabatory. *Train YOLOv5 on Custom Objects*. <https://colab.research.google.com/drive/1gDZ2xcTOgR39tGGs-EZ6i3RTs16wmzZQ>, sk. 13.02.2022.
7. OVHcloud. *Object detection: train YOLOv5 on a custom dataset*. <https://blog.ovhcloud.com/object-detection-train-yolov5-on-a-custom-dataset/>, sk. 20.03.2022.