

KOLORADO VABOĻU ATPAZĪŠANA, IZMANTOJOT YOLOV5 *IDENTIFICATION OF COLORADO BEETLES USING YOLOV5*

Autori: **Jānis Dembovskis**, e-pasts: jd22029@edu.rta.lv, telefona nr.: 28935600
Kaspars Rudzusiņš, e-pasts: kr22043@edu.rta.lv, telefona nr.: 25768008
Zinātniskā darba vadītājs: **Sergejs Kodors, Dr.sc.ing.**, e-pasts: sergejs.kodors@rta.lv
Rēzeknes Tehnoloģiju akadēmija
Atbrīvošanas aleja 115, Rēzekne

Abstract. *The monitoring of Colorado potato beetles in large fields is a complex and time-consuming process that requires accurate data collection, analysis, and interpretation. The use of artificial intelligence (AI) can greatly simplify this complex process by automatically monitoring fields and detecting beetles marking locations of their location. We trained an object detection neural network using YOLOv5 framework using the dataset with 150 images of the Colorado potato beetles photographed in the natural conditions. We trained YOLOv5s model and got the most perfect result that was 0.995 mAP. Using the best trained neural network, we can now put videos and image files in the code and the neural network will run and detect all the Colorado potato beetles in the given files automatically.*

Keywords: *artificial intelligence, Colorado potato beetle, neural network, object detection, YOLOv5.*

Ievads

Kolorado kartupeļu vaboļu invāzijas monitorings lielos kartupeļu laukos ir sarežģīts un laukietilpīgs process. Mākslīgā intelekta (AI) izmantošana var ievērojami vienkāršot šo procesu, automātiski uzraugot laukus un identificējot inficētas rindas un lauka kvartālus. Tas ļauj lauksaimniekiem iegūt savlaicīgus datus par kartupeļu laukiem un savlaicīgi cīnīties ar Kolorado vabolēm. Turklāt AI nodarbināšana varbūt izdevīga no ekonomiskā viedokļa, jo ietaupīto laiku un resursus var novirzīt citiem uzdevumiem, uzlabojot kartupeļu audzēšanas efektivitāti un rentabilitāti.

Neironu tīkli ir viens no modernās datorzinātnes progresīvākajiem un strauji attīstošākajiem tehnoloģiskajiem risinājumiem, kas spēj apstrādāt un interpretēt datus dažādās jomās, tostarp gudrā lauksaimniecībā. Šī pētījuma objekts ir neironu tīklu izmantošana Kolorado vaboļu atpazīšanai laukos, piedāvājot daudzsološu risinājumu kartupeļu ražas aizsardzībai.

Pētījuma mērķis: apmācīt mākslīgo intelektu, lai tas spētu atpazīt Kolorado vaboli attēlā vai video.

Uzdevumi:

- 1) Sagatavot attēlu datu kopu ar kolorado vabolēm.
- 2) Izpildīt datu kopas anotāciju.
- 3) Apmācīt neironu tīklu atpazīt Kolorado vaboles, pielietojot YOLOv5s modeli.
- 4) Pārbaudīt modeļa atpazīšanas kvalitāti ar citām bildēm un video failiem.

Materiāli un metodes

YOLOv5s [1] apmācībai tika atlasītas un izvēlētas 150 bildes no interneta vietnes *INaturalist* [5], kuras satur Kolorado vaboles (sk. 1. attēlu). Izmantojot jau gatavo servisu *INaturalist Open Data*, tika lejupielādētas bildes.



1. attēls. Kolorado vaboļu bilžu piemēri

Kad bildes bija veiksmīgi ielādētas, tika izveidota mape un tajā iekšā vēl divas apakšmapes, pirmā ar nosaukumu “images” un otrā ar nosaukumu “labels”. Abās mapēs tika izveidotas vēl divas mapes ar nosaukumiem “train” un “val”. Bilžu mapē “train” tika ievietotas 100 bildes un “val” mapē atlikuās 50.

Lai apmācītu YOLOv5s modeli, vispirms veicām datu kopas anotācijas YOLO formātā, un šo procesu veicām, izmantojot tīmekļa vietni "makesense.ai" [2]. Ielādējām attēlus un manuāli marķējām katru redzamo kolorado vaboli (sk. 2. attēlu). Kad visās 150 bildēs tika iezīmētas kolorado vaboles tika eksportēta .zip pakotne ar YOLO formāta failiem. (*Actions > Export Annotations > A .zip package containing files in YOLO format*). Kad faili tika izvilkti no .zip pakotnes, tos ievietojām mapē “labels”, “train”.



2. attēls. Marķētas Kolorado vaboles

Tālāk tika atvērta oficiālā YOLOv5 GitHub lapa [1], tajā var atrast saiti uz Google Colab [3], kur ar gataviem koda piemēriem ir parādīts kā apmācīt YOLOv5.

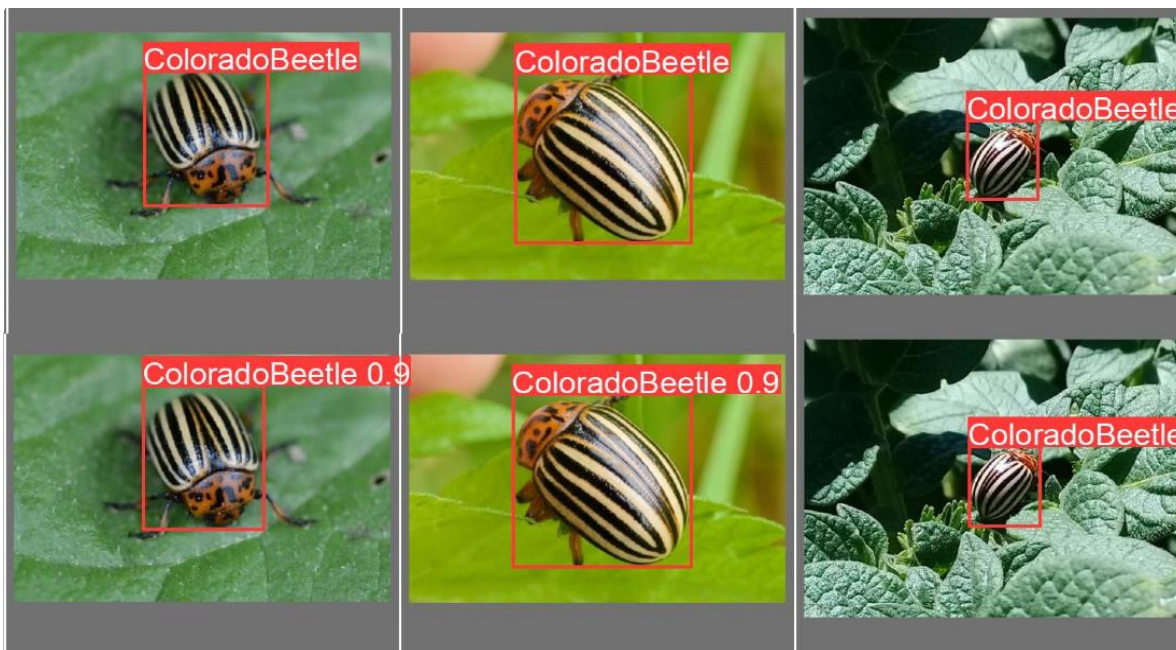
Python kodā, izmantojot iepriekš uztaisīto mapi ar bildēm un YOLO formāta teksta failiem, tika veikta mākslīgā intelekta neirona tīkla trenēšana ar priekš apmācītu YOLOv5s modeli uz COCO128 datu kopas (sk 3. attēlu). Trenēšanas procesā tika izmantots 50 epochu daudzums.

```
!python train.py --img 640 --batch 16 --epochs 50 --data coco128.yaml --weights yolov5s.pt --cache
```

3. attēls. Python kods, lai trenētu mākslīgo intelektu

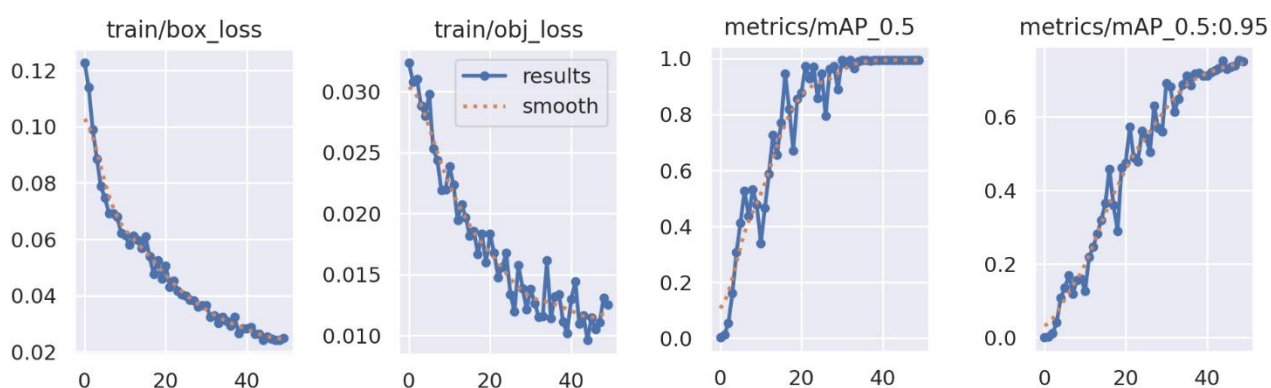
Rezultāti un diskusija

Labākais trenēšanas rezultāts bija 0.995 mAP (*mean Average Precision*), kas ir gandrīz perfekts precizitātes rezultāts. Zemāk attēlā (sk. 4. attēlu) ir parādīts salīdzinājums starp manuāli apvilktajām bildēm (augšējā rinda) un YOLOv5 apvilktajām bildēm (apakšējā rindā), kā arī YOLOv5s pie nosaukuma blakus pievienojs pārliecības rādītājs (*confidence score*) no 0,1 līdz 0,9, kā var redzēt neironitīkls bija ļoti pārliecināts par rezultātiem un apvilktās vaboles robežkastes var teikt ir identiskas un pārliecības rādītājs, ka bildē ir redzama kolorado vabole ir uz maksimālā.



4. attēls. Salīdzinājums starp kolorado vaboļu bildēm (Augšējā rinda – manuāli apvilktās robežkastes, apakšējā – YOLOv5s apvilktās robežkastes)

Zemāk ir parādīti grafiki (sk. 5. attēlu), kuros ir redzami zaudējuma un precizitātes rādītāji.



5. attēls. Grafiki ar precizitātes un zaudējumu rādītājiem

train/box_loss – tas grafiks norāda uz zaudējumiem, kas saistīti ar prognozēšanu, kas saistīti ar ierobežojošo kastu (*bounding box*) koordinātu prognozēšanu trenēšanas laikā. Tas parāda, cik precīzi modelis regresē ierobežojošo kastu koordinātas. Zemākas vērtības norāda uz labāku veikspēju, precīzi lokalizējot objektus attēlos [4].

train/obj_loss – tas grafiks norāda uz zaudējumiem, kas saistīti ar objektu detektēšanu trenēšanas laikā. Tas parāda, cik precīzi modelis identificē un klasificē objektus attēlos. Tieši

tāpat kā iepriekšējam grafikam zemākas vērtības norāda uz labāku veiktspēju, precīzi atpazīstot objektus [4].

metrics/mAP_0.5 – tas grafiks norāda uz vidējo precizitāti (*mean Average Precision - mAP*), kas aprēķināta pie Krustpunkta pār Savienošānu (*Intersection over Union - IoU*) sliekšņa 0,5 novērtējuma laikā. Šis grafiks kvantificē objektu detektēšanas precizitāti, ņemot vērā gan precizitāti (cik daudz no paredzētajiem noteikumiem ir pareizi), gan atgriešanu (cik daudz no patiesajiem objektiem ir konstatēti) pie konkrēta *IoU* sliekšņa. Augstākas vērtības *metrics/mAP_0.5* norāda uz labāku veiktspēju [4].

metrics/mAP_0.5:0.95 – tas grafiks norāda uz vidējo precizitāti (*mean Average Precision - mAP*), kas aprēķināta pie dažādiem Krustpunkta pār Savienošānu (*Intersection over Union - IoU*) sliekšņiem, kas svārstās no 0,5 līdz 0,95 novērtējuma laikā. Šis grafiks nodrošina visaptverošu novērtējumu par objektu detektēšanas veiktspēju, ņemot vērā precizitāti un atgriešanu dažādos *IoU* sliekšņos. Augstākas vērtības *metrics/mAP_0.5:0.95* norāda uz kopējo labāku veiktspēju, precīzi atpazīstot un lokalizējot objektus dažādos *IoU* sliekšņos [4].

Secinājumi

Izmantojot *MakeSense* rīku un *Google Colab* vidi tika apmācīts mākslīgā intelekta YOLOv5s modelis, kurš var atpazīt un iezīmēt bilžu vai video failos Kolorado vaboles. Bilde, kas tika izmantota apmācībai, tika izvēlēta no interneta vietnes *INaturalist*. Neirona tīkla apmācīšanai izmantojām 50 epochu skaitu. Mēs konstatējām skatoties mūsu datu kopas apjomu, ka 50 epochu skaits bija pietiekošs apmācīšanas procesam, jo pēdējie rezultāti bija ar vērtību 0,995 mAP. Pēc veiksmīgas neirona tīkla apmācības saņēmām kļūdu un precizitātes grafikus, kuros tika parādīts kā neirona tīkls mācās un kā ar katru nākošo apmācības epochu mAP pieaug.

Vērts pieminēt, ka modeļa precizitāti var uzlabot palielinot datu kopas apjomu, lai neirona tīklam būtu vairāk bilžu piemēru ar Kolorado vabolēm no kurām varētu precīzāk noteikt kur atrodas objekts un tādēļ precīzāk iezīmējot robežkastes. Bet ja tiek palielināts datu kopas apjoms attiecīgi ir jāpalielina apmācības epochu skaits un apmācīšanas process būs ilgāks.

Acknowledgement

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

Summary: The YOLOv5 model was trained to recognize Colorado potato beetles using a dataset comprising 150 images sourced from the INaturalist website. These images were downloaded using the INaturalist Open Data server. The dataset was divided into training and validation sets, with 100 images in the training set and 50 images in the validation set.

The training process involved marking the Colorado potato beetles in each image using the "makesense.ai" website. Annotations were exported in YOLO format, and the training was conducted using Python code. The training utilized 50 epochs to achieve high precision results, with the best mean Average Precision (mAP) of 0.995, indicating near-perfect accuracy.

Evaluation of the model included comparing the annotated images with those annotated by YOLOv5, showing high confidence scores for the detected beetles. Graphs depicting loss and precision metrics were also provided, including box loss, object loss, mAP at IoU 0.5, and mAP across various IoU thresholds (0.5 to 0.95), demonstrating the model's robust performance in detecting and localizing Colorado potato beetles.

Overall, the YOLOv5 model demonstrated exceptional accuracy in recognizing Colorado potato beetles, with precise localization and high confidence scores, as evidenced by the evaluation metrics and comparison with manually annotated images.

Literatūras un avotu saraksts

1. Train Custom Data with YOLOv5 - <https://github.com/ultralytics/yolov5/wiki/Train-Custom-Data> sk. 21.03.2024
2. Data annotation platform for machine learning projects - <https://www.makesense.ai/> sk. 21.02.2024
3. YOLOv5 tutorial Google Colab - <https://colab.research.google.com/github/ultralytics/yolov5/blob/master/tutorial.ipynb> sk. 21.03.2024
4. Understanding of the YOLOv5 graphs - https://www.researchgate.net/publication/373744977_Automatic_Cell_Counting_With_YOLOv5_A_Fluorescence_Microscopy_Approach#pf5 sk. 21.03.2024
5. INaturalist Nature observation platform - <https://www.inaturalist.org/observations> sk. 21.03.2024