

**D priedas.** Pranešimo 26-ojoje Lietuvos jaunųjų mokslininkų konferencijoje medžiaga

The image shows a presentation slide with a blue background. In the top left corner is the Vilnius Tech logo, which consists of a stylized white 'U' shape followed by the text 'VILNIUS TECH' and 'VILNIAUS TECHNOLOGIJŲ UNIVERSITETAS' in smaller text below it. The main content of the slide is enclosed in a white rectangular frame. Inside the frame, the text 'Anita Kušlevič' is at the top, followed by 'Darbo vadovas dr. Ivan Suzdalev'. Below this, the title 'Taikinių sekimo sistemos tyrimas' is written in a large, bold, white font. In the bottom right corner of the slide, outside the frame, the date '2023 04 12' is displayed.

# Įvadas



## Darbo uždaviniai:

- Išanalizuoti literatūros šaltinius ir iširti esamus taikinių sekimo algoritmus.
- Išsirinkti metodus, tinkamus naujo taikinių sekimo algoritmo, paremto konvoliucinių neuroninių tinklų algoritmais, sinteze.
- Sukurti vizualinio taikinių sekimo metodą ir tuo metodu paremtą algoritmą.
- Aprobuoti sukurktą algoritmą.

## Taikoma metodika:

- Duomenų rinkinio paruošymas ir vaizdų žymėjimas, naudojant „Roboflow“ platformą.
- Pasirinktos vertinimo metrikos: nuostolių funkcija, preciziškumas, vidutinio tikslumo vidurkis (mAP), išvedimo greitis.
- Bėpliočių orlaivių aptikimui naudojamas apmokytas „YOLOv8“ tinklas.
- Bėpliočių orlaivių sekimui naudojamas „ByteTrack“ paketas.

Taikinių sekimo sistemos lygties

# Vieno ir dviejų etapų algoritmai



- 1) Dviejų etapų algoritmai** (pavyzdžiui, RCNN, greitis ir greitesnysis RCNN):
  - gaunamas pasiūlymo regionas,
  - pasiūlymo regiono klasifikacija ir regresija.
- 2) Vieno etapo algoritmai** (pavyzdžiui, SDD, YOLO):
  - paprastesnė architektūra,
  - tinka objektų aptikimui realiuoju laiku.

# Literatūros apžvalga

**1 lentelė.** Skirtingų metodų pasiekto bėgliųjų orlaivų apskaitimo preciziškumo palyginimas (sudaryta autorės, remiantis Al-Qubayshi et al., 2022)

| Metodas    | Duomenų rinkinio dydis | Preciziškumas |
|------------|------------------------|---------------|
| CNN        | 712                    | 95 %          |
| SVM        | 712                    | 88 %          |
| KNN        | 712                    | 80 %          |
| „YOLOv2“   | 215                    | 90 %          |
| VGG16      | 2 717                  | 66 %          |
| „MaskRCNN“ | 1 359                  | 93,6 %        |
| „YOLOv5“   | 1 359                  | 94,7 %        |

**2 lentelė.** Palyginimas dviejų siūlomų modelių (sudaryta autorės, remiantis Aydin ir Singha, 2023)

| Modelis  | Preciziškumas | Jautrumas | mAP50  | Vaidzo įrašas                              | Vieno kadro apdorojimo laikas |
|----------|---------------|-----------|--------|--------------------------------------------|-------------------------------|
| „YOLOv4“ | 0,95          | 0,68      | 0,7436 | Su „DJI Mavic Pro“<br>Su „DJI Phantom III“ | 19 ms<br>20,5 ms              |
| „YOLOv5“ | 0,918         | 0,875     | 0,904  | Su „DJI Mavic Pro“<br>Su „DJI Phantom III“ | 23,9 ms<br>31,2 ms            |

Talpinis autorius: andrius.lysnis


5

[illegible]

## Duomenų rinkinio paruošimas




**1 pav.** Failo su informacija apie žymėtą vaizdą pavyzdys (sudaryta autorės)




2 pav. „Drone\_dataset“ duomenų rinkinys  
(sudaryta autorės)

## Duomenų rinkinio paruošimas



**3 pav.** „Drones“ duomenų rinkinio vaizdų pavyzdžiai (sudaryta autorės)




**4 pav.** „Drones\_test“ duomenų rinkinio vaizdų pavyzdžiai (sudaryta autorės)

## „YOLOv8“ tinklo apmokymas (I modelis)



**5 pav.** Pirmojo bandymo bepiločio orlaivio aptikimo rezultatai (sudaryta autorės)

## „YOLOv8“ tinklo apmokymas (I modelis)



**6 pav.** Pirmojo bandymo tinklo apmokymo pabaiga  
(sudaryta autorės)

7 pav. Pirmojo bandymo tinklo apmokymo rezultatai (sudaryta autorės)

### „YOLOv8“ tinklo apmokymo rezultatai

**3 lentelė.** Tinklo apmokymo rezultatai (sudaryta autorės)

| Modelio versija | Apmokymo laikas         | Apmokymui naudoti duomenų rinkiniai                  | Tinklo tikslumas po apmokymo    | Aptikta bepiločių orlaivių testavimo metu (iš 20) | Aptikimo greitis vaizdo įrašė (vienam kadru) |
|-----------------|-------------------------|------------------------------------------------------|---------------------------------|---------------------------------------------------|----------------------------------------------|
| I               | 80,1 min. (50 epochų)   | „Drone_dataset“ (50 epochų)                          | 94,5 % mAP50<br>66,3 % mAP50–95 | 10                                                | 11,9 ms                                      |
| II              | 92,7 min. (200 epochų)  | „Drone_dataset“ (50 epochų)<br>„Drones“ (150 epochų) | 99,5 % mAP50<br>53,3 % mAP50–95 | 18                                                | 13 ms                                        |
| III             | 81,84 min. (155 epochų) | „Drones“ (100 epochų)<br>„Drone_dataset“ (55 epochų) | 94,3 % mAP50<br>66 % mAP50–95   | 15                                                | 12,7 ms                                      |

## Sekimo rezultatai

**4 lentelė.** Sekimo rezultatai, naudojant „ByteTrack“ (sudaryta autorės)

| Modelio versija | Tinklo tikslumas po apmokymo    | Kadrai, kuriuose aptiktas nepilnas orlaivis (iš 301 kadro) | Atpažinta skirtingų nepilnųjų orlaivių |
|-----------------|---------------------------------|------------------------------------------------------------|----------------------------------------|
| I               | 94,5 % mAP50<br>66,3 % mAP50-95 | 244                                                        | 3                                      |
| II              | 99,5 % mAP50<br>53,3 % mAP50-95 | 292                                                        | 1                                      |
| III             | 94,3 % mAP50<br>66 % mAP50-95   | 244                                                        | 3 (indeksas pasikeitė per 5 žingsnius) |

## Sekimo rezultatai (I modelis)

VILNIUS TECH

8 pav. Pirmojo apmokyto tinklo sekimo rezultatai (sudaryta autorės)

Talpinų valdoma sistema įprastai

13

## Sekimo rezultatai (III modelis)

VILNIUS TECH

9 pav. Trečiojo apmokyto tinklo sekimo rezultatai (sudaryta autorės)

Talpinų valdoma sistema įprastai

14

## Sekimo rezultatai (II modelis)

VILNIUS TECH

10 pav. Antrojo apmokyto tinklo sekimo rezultatai (sudaryta autorės)

Talpinų valdoma sistema įprastai

15

## Sekimo rezultatai (I ir II modeliai)

VILNIUS TECH

Talpinų valdoma sistema įprastai

16

## Sekimo rezultatai (II ir III modeliai)

VILNIUS TECH

Talpinų valdoma sistema įprastai

17

## Sekimo rezultatai

VILNIUS TECH

11 pav. Apmokytų tinklų bepiločio orlaivio aptikimo tikslumo pasiskirstymas sekimo metu (sudaryta autorės)

Talpinų valdoma sistema įprastai

18

## Išvados



- Taikinio sekimo algoritmo uždavimas – užtikrinti tikslų taikinio sekimą, atsižvelgiant į algoritmo realizavimo laiką ir veikimą realiuoju laiku.
- Sprendžiant vizualinio taikinių sekimo uždavimą, gilieji neuroniniai tinklai turi surinkti daugybę žymėtų vaizdų. Siekiant išspręsti duomenų stygiaus problemą, gilieji požymiai gali būti perkelti iš anksčiau apmokyto giliojo neuroninio tinklo į didelį pagaibinį duomenų rinkinį.
- Diskriminacinio metodo modelis taikomas dažniau, nes yra tikslesnis ir patvaresnis. Modelyje yra informacijos apie foną, tai suteikia sekimo galimybę, pavyzdžiui, kai taikinytis yra uždegtas.
- Dėl nenusipėjamo sekimo algoritmas gali būti paveikiamas. Vyksta tyrimai ir ieškoma būdų, kaip padaryti CNN modelį tinkamesnį sudėtingų taikinių aptikimui, esant įvairiems scenarijams. Atsižvelgiant į judančių objektų sekimo sudėtingumą (šviesos pokyčiai, objekto uždegtumas, greitas judėjimas, sudėtingas fonas), mokslininkai į CNN modelį integruoja filtrus (pavyzdžiui, Kalmano ar dalelių) – algoritmai yra nuolat tobulinami.
- YOLO šeimos algoritmų populiarumą lemia objektų aptikimo greitis ir aptikimo tikslumo kompromisas. Šie algoritmai leidžia aptikti objektus realiuoju laiku, todėl gali būti naudojami įvairioms uždavims.
- Eksperimentiniu būdu, atsižvelgiant į literatūroje siūlomus algoritmus ir patarimus, buvo siekiama gauti geriausių rezultatą, kuriant vizualinio taikinių sekimo algoritmą, kuriame naudojami konvoliuciniai neuroniniai tinklai.

Taikinių sekimo sistemos tyrimas

19

## Literatūros sąrašas



- Aydin, B., & Singha, S. (2023). Drone Detection Using YOLOv5. *Eng.* 4(1), 416–433. <https://doi.org/10.3390/eng4010025>.
- Al-Qubaydhi, N., Alenezi, A., Alanazi, T., Senyor, A., Alenezi, N., Alotaibi, B., Alotaibi, M., Razaque, A., Abdelhamid, A. A., & Alotaibi, A. (2022). Detection of Unauthorized Unmanned Aerial Vehicles Using YOLOv5 and Transfer Learning. *Electronics*, 11(17), 2669. <https://doi.org/10.3390/electronics11172669>.
- Tan, L., Huangfu, T., Wu, L., & Chen, W. (2021). Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. *BMC Medical Informatics and Decision Making*, 21(324).

Taikinių sekimo sistemos tyrimas

20



Anita Kušlevičė  
Darbo vadovas dr. Ivan Suzdalev

## Taikinių sekimo sistemos tyrimas

2023 04 12