

Prepoznavanje aktivnosti čebel na panjskem žrelu s pomočjo strojnega vida in drugih metod

Detection of Bee Activity in the Hive Entrance Using Machine Vision and Other Methods


Oskar Rotar
oskar.rotar@dijak.gjp.si
Gimnazija Jožeta Plečnika, Ljubljana
Šubičeva ulica 1
Ljubljana, Slovenija

Maks Žnidaršič
maks.znidarsic@dijak.gjp.si
Gimnazija Jožeta Plečnika, Ljubljana
Šubičeva ulica 1
Ljubljana, Slovenija

Tian Vesel
tian.vesel@dijak.gjp.si
Gimnazija Jožeta Plečnika, Ljubljana
Šubičeva ulica 1
Ljubljana, Slovenija

Mag. Darja Silan
darja.silan@gjp.si
Gimnazija Jožeta Plečnika, Ljubljana
Šubičeva ulica 1
Ljubljana, Slovenija

Dr. Janko Božič
janko.bozic@bf.uni-lj.si
Biotehniška fakulteta - Univerza v
Ljubljani
Jamnikarjeva ulica 101
Ljubljana, Slovenija



Slika 1: Zaznave čebel narejene z uporabo YOLOv5 modela.

POVZETEK

V tem delu smo raziskovali možnost uporabe najnaprednejših tehnologij pri analizi gibanja čebel med vhom v panj. Čebele imajo ključno vlogo pri opravljanju in so bistvene za ohranjanje uravnoteženega ekosistema, vendar je njihovo proučevanje zaradi majhne velikosti in hitrega gibanja zahtevno. Z uporabo strojnega vida, tehnologije, ki omogoča računalniško interpretacijo in razumevanje vizualnih podatkov ter metod sledenja večim objektom (MOT) nam je uspelo razviti moderno rešitev za njihovo proučevanje. Raziskava je pokazala, da uporaba teh tehnologij ponuja nov, obetaven pristop k zbiranju velikega števila natančnih podatkov o gibanju čebel.

ABSTRACT

In this article we researched the possible use of advanced technologies for the analysis of bee movement in front of a beehive. Bees play a key role in the pollination of plants, they have an immense part in keeping our ecosystem balanced. However, due

to their small size and fast movements, it is challenging for researchers to study them. With the use of computer vision, a technology that interprets and understands visual information, as well as Multi Object Tracking (MOT), we were able to develop a modern solution to the otherwise difficult task of bee tracking. With this, the study of bees becomes less constrained and far more effective. The research shows that the use of numerous modern technologies offer a promising new approach to the collection of a large number of accurate data on bee movement.

KLJUČNE BESEDE

zaznava čebel, računalniški vid, MOT, YOLO, *Apis mellifera carnica*

KEYWORDS

bee detection, computer vision, MOT, YOLO, *Apis mellifera carnica*

1 UVOD

V nedavni zgodovini smo bili priča velikim tehnološkim dosežkom in inovacijam. Svet hitro napreduje, vendar nekatera področja še zmeraj ostajajo nespremenjena. V Sloveniji je čebelarstvo velik del naše bogate zgodovine in kulture. Zaradi podnebni sprememb, porasta parazitov in boleznih čebel ni bilo čebelarstvo

nikoli tako zahtevno, zato želimo z uporabo sodobnih metod in moderne tehnologije prispevati k uspešnejšemu uvajanju informacijske tehnologije za upravljanje čebeljih družin in uspešnejše delo čebelarjev in raziskovalcev. Želeli smo razviti učinkovit, stabilen in splošen model strojnega učenja za zaznavo čebel, ki vzdrži visoko natančnost tudi v primerih, ko so algoritmične metode neuspešne. Model te podatke nato poda algoritmu za sledenje večim objektom, ki natančno sledi gibanju čebel. Ves program omogoča samodejno zbiranje velikih količin podatkov o gibanju na panjskem žrelu.

2 METODOLOGIJA

2.1 Izbira modela zaznavanja objektov

V nalogi smo za zaznavo čebel uporabili konvolucijske nevronske mreže. Pri usposabljanju modela zaznave čebel smo uporabili modele dveh družin predusposobljenih nevronskih mrež, namenjenih zaznavi objektov. To sta YOLOv5[3], ki je eden najbolj razširjenih in najboljših modelov za zaznavanje objektov in YOLOv7[8], ki je novejša arhitektura. YOLOv7 domnevno opisuje boljše rezultate, kot YOLOv5. Modele teh dveh družin modelov smo dodatno usposabljali na lastnih podatkih. Usposabljali smo predusposobljene modele YOLOv5s, YOLOv5m, YOLOv5x in modela YOLOv7 ter YOLOv7x.

2.1.1 Poimenovanje modelov. Imena vseh modelov smo začeli z akronimom BDM (model zaznave čebel - *angl. Bee Detection Model*). Temu sledita identifikacijska številka modela. Za tem je oznaka za vrsto modela. Modeli YOLOv5s imajo oznako s, YOLOv5m oznako m, YOLOv5x oznako x, YOLOv7 oznako 7 in YOLOv7x oznako 7x. Primer poimenovanja modela je **BDM1-s**. To je model z identifikacijsko številko 1, ki je usposobljen na predusposobljenem modelu YOLOv5s (Tabela 1, stolpec za ime).

2.2 Obdelava posnetkov

Uporabljali smo 10 različnih posnetkov panjskega žrela. Izbrali smo zahtevne in raznolike posnetke (različna povečava, osvetljenost, barva panja, gostota čebel), da bi dosegli čim bolj splošene modele. Posnetki so posneti na Urbanem učnem čebelnjaku botaničnega vrta v Ljubljani[7]. Označili smo 2100 slik iz posnetkov.

2.3 Usposabljanje modelov

Vse modele smo lahko usposabljali na istih podatkih, saj YOLOv5 in YOLOv7 uporabljata isti format za označevanje slik. Da bi prišli do čim boljšega končnega modela, smo usposobili več modelov. Pri usposabljanju modelov smo spreminjali velikost serije (*Batch size*), število prehodov (*epochov*), izbiro predusposobljenega modela in število slik. Ostale hiperparametre smo ohranili na standardni nastavitvi.

Velikost serije, pri kateri smo lahko usposabljali, je neposredno omejena z velikostjo grafičnega pomnilnika na grafični kartici (8 GB). Ob usposabljanju manjših modelov (posebej YOLOv5s) se proces samodejno predčasno konča, ko se uspešnost modela ne spreminja, kar omeji pretreniranje.

Uporabljali smo tri predusposobljene YOLOv5 modele, in sicer YOLOv5s, YOLOv5m in YOLOv5x. Uporabljali smo tudi dva YOLOv7 modela, YOLOv7 in YOLOv7-X. Usposobili smo več YOLOv5 modelov, saj je njihovo usposabljanje potekalo hitreje, kot v7 modelov. Skupaj smo usposabljali 15 modelov, štiri iz družine YOLOv7 in 11 iz družine YOLOv5 (Tabela 1).

Pri izdelavi modelov smo imeli dva glavna cilja - hitrost izvajanja in natančnost zaznavanja.

Tabela 1: Specifikacije usposobljenih modelov. Negativna velikost serije označuje samodejno izbiro

ime	epochi	velikost serije	model	resolucija
BDM1-s	100	16	v5s	640
BDM2-s	100	16	v5s	416
BDM3-s	100	16	v5s	640
BDM4-s	174	-1	v5s	640
BDM5-m	268	-1	v5m	640
BDM6-s	174	-1	v5s	640
BDM7-x	27	-1	v5x	640
BDM8-s	20	32	v5s	640
BDM9-s	184	42	v5s	640
BDM10-7x	87	8	v7x	640
BDM11-7	166	10	v7	640
BDM12-7	150	11	v7	640
BDM13-7x	150	11	v7x	640
BDM14-m	135	16	v5m	640
BDM15-m	163	-1	v5m	640

Večinoma smo usposabljali manjše, YOLOv5s modele. Za to smo imeli dva razloga: hitrejšo usposabljanje teh modelov in majhno število usposobnih podatkov. Po prvih testnih usposabljanjih smo ugotovili, da so modeli že zelo hitro začeli zaznavati velik delež čebel. Kljub temu smo usposabljali tudi nekaj v5m modelov in en v5x model. Usposabljali smo tudi YOLOv7 modele, saj smo upali, da bodo nudili višjo hitrost in kvaliteto.

Pri usposabljanju model računa svojo uspešnost s funkcijo izgube. Pri YOLOv5 in YOLOv7 modelih je ta funkcija seštevek (pri YOLOv7 obtežen seštevek) funkcije izgube objektnosti, regresijske funkcije izgube omejevalnega okvira in funkcije izgube klasifikacije. Slednji je v našem primeru 0, ker uporabljamo le en razred objektov.

$$loss = l_{obj} + l_{box} + l_{cls}$$

2.4 Sledenje gibanju čebel

Za sledenje smo uporabili knjižnici Norfair[6] ter ByteTrack[9]. Sledenje gibanja čebel smo izvedli s pomočjo podatkov, ki nam jih je vrnil model. Pridobljene vrednosti iz modela in sledilca smo primerjali ter vsakemu objektu določili identifikacijsko številko. Knjižnica Norfair[6] je to opravila sama, pri knjižnici ByteTrack[9] pa smo to dosegli z zunanjo knjižnico Onemetric[5].

2.5 Analiza modelov

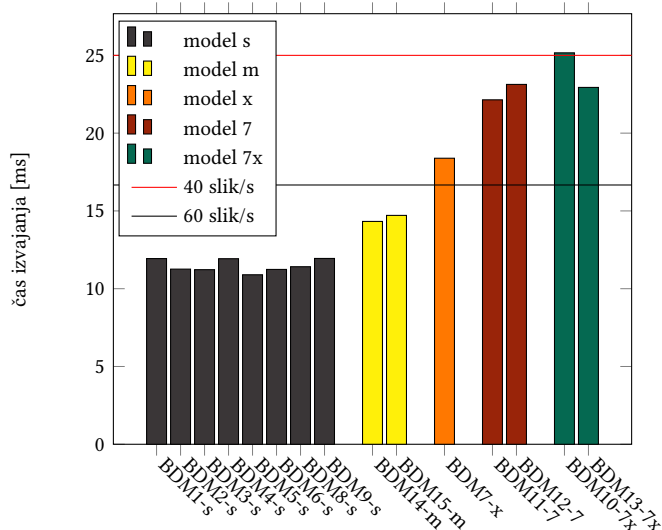
Hitrost delovanja modelov smo testirali na dveh posnetkih. Izbrali smo posnetek, ki ima majhno število čebel in počasno gibanje ter posnetek, ki ima več čebel ter bolj kaotično gibanje. Po usposabljanju nam je program vrnil dve verziji modela - tisto, ki je usposobljena zadnja in tisto z najvišjo natančnostjo. Vedno smo uporabili model z najvišjo natančnostjo, saj smo se s tem izognili preusposabljanju.

2.5.1 Natančnost zaznavanja modelov. Pri izračunu natančnosti modela se uporablja več metod in funkcij[1]. Modele smo primerjali po natančnosti, priklicu, mAP@0.5 in mAP@[0.5:0.95]. Merila smo izračunali na validacijskih slikah, torej slikah na katerih modeli niso bili usposobljeni (Slika 3).

2.6 Analiza metod sledenja premikanja čebel

Pri analizi premikanja čebel smo, kot pri analizi modelov, uporabili dva posnetka. Za zaznavo čebel smo uporabljali model BDM15-m, saj se ta model izvaja hitro z dobro natančnostjo. Za ocenjevanje natančnosti zaznave smo z obema knjižnicama prešteli čebele, ki so približale vходу v panj. Te podatke smo nato primerjali z ročno preštetimi količinami.

3 REZULTATI



Slika 2: Povprečne hitrosti modelov združene po predusposobljenem modelu. Testiranje je potekalo na RTX 3070 Ti

3.1 Hitrost izvajanja modelov

Pri primerjavi modelov lahko vidimo, da gostota čebel na posnetku ne vpliva na hitrost zaznav. Na hitrost je imela bistven vpliv le velikost predusposobljenega modela. Najhitrejši so bili vsi modeli predusposobljenega modela YOLOv5s, ki so tudi najmanjši, najpočasnejši pa modeli YOLOv7x (Slika 2). Vsi modeli so dovolj hitri, da z zmogljivo grafično kartico posnetke procesirajo v živo.

3.2 Natančnost modelov

Pri primerjavi modelov po priklicu in natančnosti (Slika 4) vidimo, da bistveno izstopata modela BDM1-s in BDM3-s, saj več kot tretjine slik ne zaznata, petina zaznav je pa napačnih. Slabi rezultati so očitni tudi po merilu mAP (Slika 5). Merilo $mAP@{.5:.95}$ najbolje prikaže dejansko razliko med modeli (Slika 5).

Vsi slabši modeli imajo arhitekturo YOLOv5s, vendar imajo drugi YOLOv5s modeli (BDM4-s, BDM5-s in BDM6-s) dobro natančnost. Ni neposredne povezave med arhitekturo in kvaliteto modela. Najbolje se je izkazal model BDM11-7. 8 modelov ima podoben $mAP@{.5:.95}$, malo nad 0.6. Kljub močno počasnejšemu času izvajanja (Slika 2), je kvaliteta zaznav YOLOv7 primerljiva z modeli YOLOv5.

Pri slabših modelih je najpogostejša napaka, ki se pojavlja združevanje več čebel v eno in zaznavanje grč. To lahko najlažje vidimo na primerjavi med najboljšim in najslabšim modelom (Slika 3).




(a) Zaznave najboljšega modela BDM11-7



(b) Zaznava najslabšega modela BDM1-s


Slika 3: Primerjava boljšega in slabšega modela



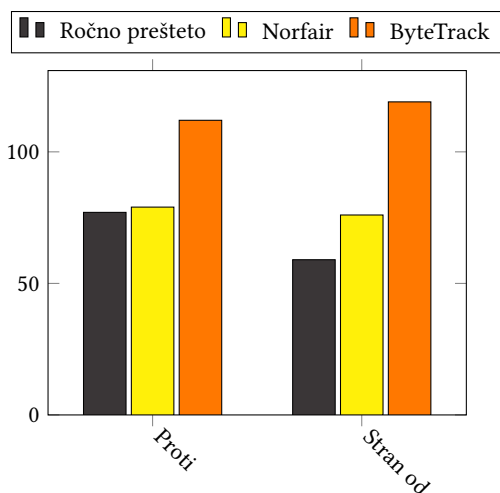
Slika 4: Natančnost in priklic modelov strojnega učenja

3.3 Natančnost sledenja čebelarom

Pri primerjavi natančnosti štetja knjižnic vidimo, da je Norfair bolj natančen od ByteTracka. Norfair[6] se je še posebej izkazal pri štetju čebel, ki vstopajo v panj, saj na posnetku z več čebelami od realnih rezultatov odstopa le za 2,5%. Obe knjižnici zaznamuje slabše štetje čebel, ko se oddaljujejo od panja.



Slika 5: Kvaliteta zaznavanja modelov strojnega učenja $mAP@[.5:.95]$



Slika 6: Število letov prešteti na posnetku z več čebelami

3.4 Hitrost sledenja čebelam

Skupno sledenje je bilo v vseh primerih hitrejše od 50 slik/sekundo (20 ms na sliko). Norfair je rahlo počasnejši na posnetku z več čebelami in rahlo hitrejši na posnetku z manj čebelami, vendar je ta razlika majhna, okoli 0,8 milisekunde.

4 DISKUSIJA

Obstajajo različni načini opazovanja gibanja, od preprostega sistematičnega opazovanja do uporabe modelov strojnega vida. Kljub sorazmerno visoki natančnosti modelov, ki smo jih usposobili menimo, da bi se dalo usposobiti še bolj natančne modele. Večje število podatkov in boljše eksperimentalno okolje (grafična kartica z več grafičnega pomnilnika), bi omogočila še boljše rezultate. Ena od možnosti predstavlja uporaba tudi novejših arhitektur YOLOv8[2], ki je bila objavljena med izdelovanjem naloge in je zato še nismo uporabljali. Obstaja tudi možnost izvajanja programa na preprostejši, specializirani strojni opremi, kar bi omogočilo zaznavo na kraju, kjer so bili posnetki pridobljeni[4]. Tudi s sestavo

poligona, ki omeji hitrost gibanja čebel na posnetem območju ali samo s postavitvijo kamere bližje panju, bi lahko povečali uspešnost zaznave in sledenja. Z vključitvijo termalne kamere v zaznavo, bi lahko model še izboljšali. Nenazadnje, bi lahko natančnost algoritmičnega sledenja gibanja izboljšali tudi z uporabo umetne inteligence, z usposobitvijo nevronske mreže, ki bi zagotavljala boljšo časovno doslednost sledenja.

5 ZAKLJUČEK

Avtomatizirano zbiranje podatkov o čebelah ni uporabno le za čebelarje, ampak lahko tudi podpira mnogo drugih raziskav o vedenju in delovanju teh čudovitih živali. Z uporabo računalniškega vida in metodami sledenja večim objektom (MOT) nam je uspelo dokazati, da je taka avtomatizacija mogoča, natančna in uporabna.

ZAHVALA

Zahvalili bi se radi naši mentorici Mag. Darji Silan, ki nam je nudila podporo in pomagala organizirati celotno izdelavo naloge. Radi bi se tudi zahvalili somentorju Dr. Janku Božiču, ki nam je pomagal s strokovno literaturo in splošnim znanjem na tem področju ter za posnetke čebel.

LITERATURA

- [1] Mark Everingham in John Winn. 2011. The pascal visual object classes challenge 2011 (voc2011) development kit. *Pattern Analysis, Statistical Modelling and Computational Learning, Tech. Rep.*, 8.
- [2] Rač. prog. Glenn Jocher, Ayush Chaurasia in Jing Qiu, YOLO by Ultralytics ver. 8.0.0, jan. 2023. URL: <https://github.com/ultralytics/ultralytics> Retrieved 26. feb. 2023 from.
- [3] Rač. prog. Glenn Jocher in sod., ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation nov. 2022. DOI: 10.5281/zenodo.3908559, URL: <https://github.com/ultralytics/yolov5> Retrieved 26. feb. 2023 from.
- [4] Ratko Pilipović, Vladimir Risojević, Janko Božič, Patricio Bulić in Uroš Lotrič. 2021. An approximate gemm unit for energy-efficient object detection. *Sensors*, 21, 12. DOI: 10.3390/s21124195.
- [5] Piotr Skalski. 2021. onemetric. <https://github.com/SkalskiP/onemetric/>. (2021). Retrieved 26. feb. 2023 from <https://github.com/SkalskiP/onemetric/>.
- [6] Rač. prog. Tryolabs, Norfair. URL: <https://github.com/tryolabs/norfair> Retrieved 26. feb. 2023 from.
- [7] [n. d.] Urbani učni čebeljak, botanični vrt Ljubljana. (). Retrieved 28. feb. 2023 from <http://www.botanicni-vrt.si/urbani-ucni-cebeljak>.
- [8] Chien-Yao Wang, Alexey Bochkovskiy in Hong-Yuan Mark Liao. 2022. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors, (jul. 2022). DOI: 10.48550/ARXIV.2207.02696.
- [9] Yifu Zhang, Peize Sun, Yi Jiang, Dongdong Yu, Fucheng Weng, Zehuan Yuan, Ping Luo, Wenyu Liu in Xinggang Wang. 2022. Bytetrack: multi-object tracking by associating every detection box.