

PRAĆENJE AKTIVNOSTI PČELA PRIMENOM RAČUNARSKE VIZIJE

Sladana Đurašević¹, Uroš Pešović¹, Dejan Vujičić¹, Dušan Marković², Snežana Tanasković², Dalibor Tomić², Vladeta Stevović²

Izvod: Računarska vizija kao alat omogućava automatizovanu obradu vizuelnih informacija i daje mogućnost značajnog unapređenja procesa poljoprivredne proizvodnje. U ovom radu prikazani su rezultati primene YOLO algoritma za praćenje pčela na ulazu u košnicu. Primenjeni model postizao je preciznost detekcije od 92,86% i implementiran je na Raspberry PI 4 računarskom sistemu. Ovaj računarski sistem malih dimenzija se može koristiti za dalja testiranja na terenu, pri čemu se aktivnost pčela na ulazu u košnicu prati preko snimka sa video kamere.

Ključne reči: pčele, računarska vizija, YOLO algoritam, detekcija objekata

Uvod

Računarska vizija (eng. Computer Vision – CV) je oblast računarstva čiji je osnovni zadatak obuka računara da izdvajaju korisne informacije iz digitalnih slika ili video snimka. Vizuelni sistem čoveka je jedno od najrazvijenih čula, putem koje čovek dobija najveći broj informacija iz svoje okoline. U masovnim proizvodnjama različitih privrednih delatnosti, oslanjanje na čoveka kao vizuelnog kontrolora procesa proizvodnje za čoveka je izuzetno naporno, zbog velike brzine i brojnosti proizvoda. Zadatak računarske vizije je da se korišćenjem računarskih algoritama automatizuju zadaci koje vizuelni sistem čoveka može da obradi. Računarska vizija koristi sliku ili niz slika u slučaju video snimka, kao ulaznu veličinu, pri čemu ona može biti snimljena pomoću jedne kamere, niza prostorno pomerenih kamera (stereovizija), kamera koje prikazuju različite delove spektra (multispektralna vizija) i višedimenzionalni podaci kao u slučaju medicinskog skenera.

U današnjoj industrijskoj proizvodnji, računarska vizija je u velikoj meri zamenila čoveka u vizuelnoj kontroli kvaliteta proizvoda na pokretnim trakama, pri čemu je jedan ovakav sistem u stanju da zameni desetine ljudi, a da pri tome postiže i znatno veću tačnost donošenja odluka od čoveka. U ovakvim sistemima proizvodnje, računarska vizija se oslanja na poređenje industrijskih proizvoda sa predefinisanim šablonima kako bi se utvrdilo da li proizvod zadovoljava određene kriterijume kvaliteta (praćenje markera na proizvodima, prisustvo defekata u proizvodu analizom oblika i boje proizvoda). Čak i ovako jednostavnii zadaci zahtevaju značajne računarske resurse, pa su upravo i oni bili glavni ograničavajući faktor ubrzanog razvoja ove oblasti. Zahvaljujući značajnom unapređenju

¹Univerzitet u Kragujevcu, Fakultet tehničkih nauka u Čačku, Svetog Save 65, Čačak, Srbija (sladjana.djurasevic@ftn.kg.ac.rs, uros.pesovic@ftn.kg.ac.rs, dejan.vujicic@ftn.kg.ac.rs);

²Univerzitet u Kragujevcu, Agronomski fakultet u Čačku, Cara Dušana 34, Čačak, Srbija (dusan.markovic@kg.ac.rs, stansko@kg.ac.rs, dalibort@kg.ac.rs, vladeta@kg.ac.rs).

performansi računarskih sistema i savremenim algoritama računarske vizije oni omogućavaju realizaciju znatno kompleksnijih zadataka računarske vizije kao što su: detekciju događaja, praćenje putanje objekata, klasifikacija objekata, čime se znatno proširuju oblasti njene primene.

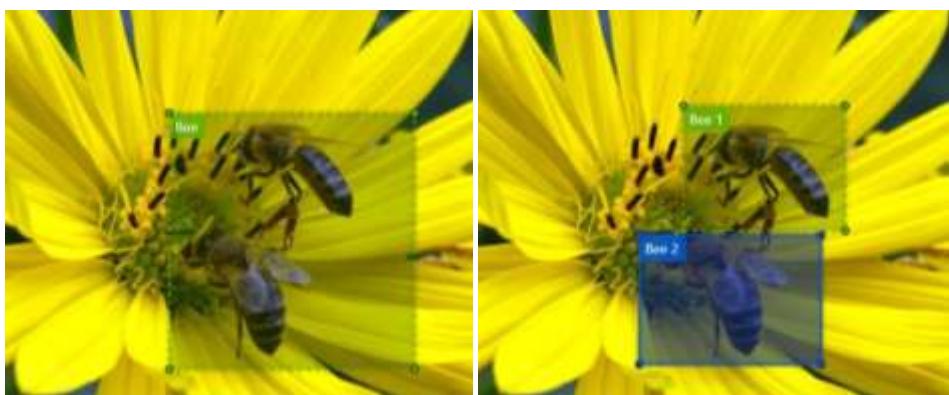
U poljoprivrednoj delatnosti, čovek se u najvećoj meri oslanja na čulo vida u donošenju odluka, kao što su klasiranje proizvoda, detekcija korova, utvrđivanje vegetativnog stanja biljaka, praćenje domaćih životinja, detekcija štetočina, korisnih organizama (Kamilaris i Prenafeta-Boldú, 2018.). Zahvaljujući napretku računarske vizije pruža se mogućnost značajnom unapređenju efikasnosti poljoprivredne proizvodnje njenom automatizacijom (Medojević i sar., 2019).

U ovom radu predstavljena je upotreba YOLO algoritma računarske vizije koji je iskorišćen za praćenje brojnosti pčela na ulazu u košnicu. Ovaj algoritam je u prethodnim istraživanjima korišćen kod autonomnih robota namenjenih za branje jabuka (Kuznetsova et al., 2020.) i paradajza (Lawal, 2021.).

Materijal i metode rada

Detekcija objekata u oblasti računarske vizije oslanja se na sledeće koncepte:

1. Klasifikacija određuje verovatnoću da se na slici nalazi objekat određene klase (automobil, pas, mačka,...), odnosno daje odgovor na pitanje šta se nalazi na slici 1.a. Klasifikacija objekta može predvideti samo jednu klasu za jednu sliku.
2. Lokalizacija kombinuje klasifikaciju objekta i njegovu lokaciju na slici, odnosno daje odgovor na pitanje šta i gde se nalazi na slici 1.a.
3. Detekcija objekata prevazilazi zadatak prethodne dve metode koje se samo brinu o jednom objektu i njegovoj lokaciji. Detekcija objekata pruža informaciju o svim objektima na slici 1.b koje obeležava pomoću okvira.



Slika. 1. a) Klasifikacija i lokalizacija b) detekcija objekata na slici
Figure. 1. a) Classification and localization b) object detection

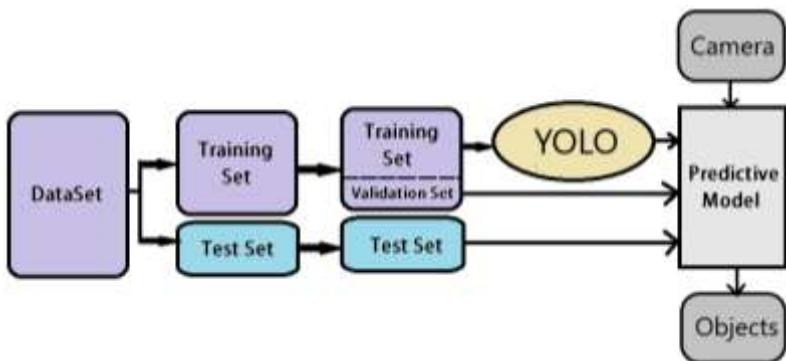
YOLO (eng. You Only Look Once) predstavlja algoritam računarske vizije koji omogućava detekciju i praćenje objekata snimljenih kamerom u realnom vremenu (Redmon and Farhadi, 2018.). Za razliku od prethodno razvijenih algoritama koji su bazirani na principu kretanja prozora po slici, YOLO algoritam analizira kompletну sliku u jednom prolazu čime se znatno poboljšava tačnost i brzine detekcije objekata. Prva verzija algoritma predstavljena je 2015. godine, a nedavno je predstavljena i peta verzija algoritma. YOLO algoritmi prvenstveno su namenjeni za izvršavanje na računarskim sistemima visokih performansi, kao što su radne stanice. U ovom radu korišćena je verzija algoritma YOLO v3 Tiny namenjena za implementaciju na računarskim sistemima sa ograničenim procesnim resursima, i ona je implementirana na Raspberry PI 4 miniračunaru.

Ovaj algoritam pripada oblasti nadgledanog učenja, koja zahteva obuku (treniranje) algoritma nad poznatim skupom ulaznih podataka za koje je poznat ishod detekcije (klase objekata), kako bi se algoritam sposobio da donosi ispravne odluke kada se susretnе sa nepoznatim skupom ulaznih podataka. Ulazni skup podataka predstavlja skup slika na kojima su obeleženi objekti od interesa koji se pojavljuju na slici. Objekti se mogu obeležiti kao skup objekata iste klase ili različitih klasa. Slike su izdvojene iz video zapisa snimljenog digitalnom kamerom rezolucije 1280 x 720 piksela koja je postavljena na ulazu u košnicu. Objekti se obeležavaju tako što se svaka pčela na slici 2. ručno uokviruje pravougaonikom kojem se pridružuje oznaka klase Bee. Da bi se algoritam što bolje obučio potrebno je obezbediti dovoljan broj obeleženih slika koji je reda od nekoliko desetina do nekoliko hiljada obeleženih slika, u zavisnosti od očekivane tačnosti obuke algoritma. Za potrebe obeležavanja koriste se alati za označavanje slika kao što su Vott ili LabelImg. Obeležene slike se eksportuju zajedno sa informacijama o poziciji i klasi objekta na slici u formi XML fajla koji je pridružen uz svaku obeleženu sliku. Za potrebe obuke algoritma skup slika se deli na deo slika za treniranje i testiranje (slika 3). Skup za treniranje sadrži 80% slika i koristi se za obuku modela, dok se skup za testiranje koji sadrži preostalih 20% slika koristi za procenu tačnosti treniranog algoritma.



Slika. 2. Obeležavanje objekata

Figure. 2. Object annotation



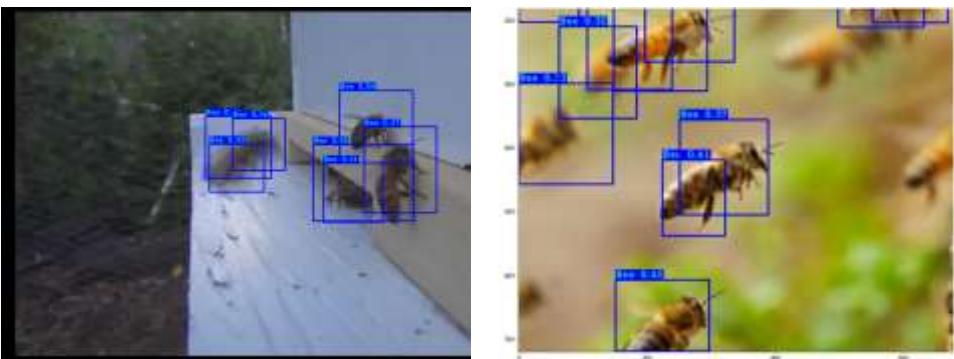
Slika. 3. Proces treniranja i testiranja modela
Figure. 3. Process of model training and testing

Treniranje algoritma je računarski intenzivan posao koji je potrebno uraditi samo jednom, pa se ono se može obaviti na računarima visokih performansi kako bi se trenirani algoritam preneo na ciljni računar gde bi samo vršio prepoznavanje objekata koje je procesno znatno jednostavnije. Za potrebe treniranja algoritma korišćen je Google Colab (Colaboratory) servis koji omogućava besplatno izvršavanje Python koda na računaru visokih performansi u trajanju od maksimalno 12 časova. Na ovom servisu dostupan je računarski sistem sledeće konfiguracije: dvojezgarni procesor Intel Xeon @ 2.30GHz sa 13 GB RAM memorije, grafički procesor NVidia Tesla T4@ 1.6GHz sa 16 GB memorije. Treniranje algoritma se izvodi korišćenjem grafičkog procesora čije su performanse 8.1 TFLOPSa to jest 8.1 biliona operacija u pokretnom zarezu u sekundi. Korisniku je na raspolaganju i 64 GB prostora na hard disku udaljenog računara za skladištenje skupova podataka koji se koriste za treniranje algoritma.

YOLO algoritam deli sliku na $S \times S$ celija, pri čemu je svaka celija zadužena za detekciju jednog objekta čiji je centar lociran unutar celije. Objekat koji je identifikovan u toj celiji klasifikuje se u jednu od kategorija, sa pratećom informacijom o verovatnoći te klasifikacije. Korišćenjem B regresionih konvolutivnih modela, svaka celija generiše pravougaonike, koji predviđaju granice detektovanog objekta. Pouzdanost predviđanja se ocenjuje kao proizvod verovatnoće klasifikacije za predloženu klasu objekta i IoU (eng. Intersection Over Union) količnika površina preseka i unije predviđenog pravougaonika i stvarnog pravougaonika koji obuhvata objekat na slici. YOLO algoritam koristi parametar dobijen kombinovanjem pouzdanosti klasifikacije i preciznosti detekcije koji vrednuje ukupan kvalitet detekcije. Objekat može biti detektovan većim brojem pravougaonika koji se preklapaju ali sa različitim pouzdanostima. Kako bi se otklonio ovaj problem, odabira se pravougaonik sa najvećom pouzdanošću detekcije, dok se ostali pravougaonici za detektovani objekat odbacuju.

Rezultati istraživanja i diskusija

Prvobitno je izvršeno obeležavanje skupa slika na kojima su označene sve pčele na slici sa klasom Bee. Skup označenih slika u XML formatu je podeljen u dva dela, koji uključuju skup za treniranje sa 20 slika i skup za testiranje sa 6 slika. Korišćenjem Google Colab platforme izvršeno je treniranje YOLO v3 Tiny modela kojim je postignuta tačnost mAP (eng. mean Average Precision) predikcije od 92,86%. Istrenirani model je eksportovan u formi datoteke koja sadrži sve parametre modela na Raspberry PI 4 računarski sistem na kojem je izvršeno realno testiranje. Model je testiran tako što je vršio detekciju pčela na nezavisnom skupu ulaznih podataka na kojima je postizao preciznost detekcije u opsegu od 0.3 do 0.7 u zavisnosti od brzine kretanja pčela na snimku.



Slika. 4. Detekcija pčela a) testni scenario b) nezavisni scenario (orig.)
Figure. 4. Bee detection a) test scenario b) independent scenario(orig.)

Na slici 4.a prikazan je test detekcije u scenariju treniranog modela, dok je na slici 4.b prikazana detekcija u slučaju potpuno nezavisnog scenarija. Rezultati testiranja pokazuju da je moguće postići zadovoljavajuću preciznost detekcije koja omogućava praćenje kretanja pčela pomoću računarske vizije. Na preciznost detekcije prvenstveno utiče kvalitet slika ili video zapisa, pa je potrebno koristiti veće brzine snimanja u odnosu na standardne video zapise od 25 FPS. Preciznost detekcije se može poboljšati i obukom modela sa većim brojem obeleženih slika, snimljenim u različitim scenarijima i u različitim uslovima osvetljenja i pozadine.

Zaključak

Računarska vizija predstavlja jednu od značajnih oblasti koja doprinosi unapređenju efikasnosti poljoprivredne proizvodnje to jest značajno smanjuje direktnu uključenost ljudskih resursa u realizaciji potrebnih aktivnosti nadgledanja i/ili kontrole procesa. U ovom radu prikazan je primer primene YOLO algoritma računarske vizije koji je korišćen u praćenju kretanja pčela na ulazu u

košnicu. Sistem je implementiran na Raspberry PI 4 računarskom sistemu na kojem je postigao zadovoljavajuću preciznost detekcije.

Napomena

Istraživanja u ovom radu deo su projekta 451-03-9/2021-14 koji finansira Ministarstvo prosvete, nauke i tehnološkog razvija Republike Srbije.

Literatura

- Kamilaris, A., Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computer and Electronics in Agriculture* 147, 70–90.
- Medojević I., Marković D., Simonović V., Joksimović A., Šakota Rosić J. (2019). Konvolucijske neuronske mreže – primena u preciznoj poljoprivredi, *Poljoprivredna tehnika*, godina XLIV, Broj 1, 2019, Strane: 1 – 9
- Lawal M. O. (2021). Tomato detection based on modified YOLOv3 framework, *Scientific Reports* volume 11, Article number: 1447 (2021)
- Kuznetsova A., Maleva T., Soloviev V. (2020). Using YOLOv3 Algorithm with Pre- and Post-Processing for Apple Detection in Fruit-Harvesting Robot, *Agronomy*, Volume 10, Issue 7
- Redmon J., Farhadi, A. (2018). YOLOv3: An Incremental Improvement, Technical report, [https://arxiv.org/pdf/1804.02767](https://arxiv.org/pdf/1804.02767.pdf),

MONITORING OF BEE ACTIVITY USING COMPUTER VISION

Sladana Đurašević¹, Uroš Pešović¹, Dejan Vujičić¹, Dušan Marković², Snežana Tanasković², Dalibor Tomić², Vladeta Stevović²

Abstract

Computer vision as a tool enables automated processing of visual information and provides the possibility of significant improvement of the agricultural production process. This paper presents the results of the application of the YOLO algorithm for monitoring bees at the entrance to the hive. The applied model achieved a detection accuracy of 92.86% and was implemented on a Raspberry PI 4 computer system. This small computer system can be used for further field testing, where the activity of bees at the entrance to the hive is monitored via video recording.

Key words: honeybees, computer vision, YOLO algorithm, object detection

¹University of Kragujevac, Faculty of technical sciences Čačak, Svetog Save 65, Čačak, Serbia (sladjana.djurasevic@ftn.kg.ac.rs, uros.pesovic@ftn.kg.ac.rs, dejan.vujicic@ftn.kg.ac.rs)

²University of Kragujevac, Faculty of Agronomy Čačak, Cara Dušana 34, Čačak, Serbia (dusan.markovic@kg.ac.rs, stansko@kg.ac.rs, dalibort@kg.ac.rs, vladeta@kg.ac.rs)