

ZAZNAVA IN KLASIFIKACIJA BREZPILOTNIH LETALNIKOV S KAMERO IN RADARJEM

PANE ANDOV, PRIMOŽ SMOGAVEC, DUŠAN GLEICH

Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko,
Maribor, Slovenija
pane.andov@um.si, primoz.smogavec@um.si, dusan.gleich@um.si

V prispevku je predstavljen realnočasovni sistem za zaznavo brezpilotnih letalnikov, ki združuje vizualno detekcijo na osnovi globokega učenja in napredno radarsko obdelavo Range-Doppler signalov FMCW. Vizualni del temelji na modelu YOLOv8, implementiranem na platformi NVIDIA Jetson Orin Nano z uporabo industrijske kamere Basler. Radarski podsistem, izveden na Raspberry Pi, vključuje Gaussovo glajenje, odštevanje ozadja ter detekcijo ciljev z uporabo pragovne metode in gručenja DBSCAN v prostoru razdalje. Med podsistemoma je vzpostavljena komunikacija UDP, ki omogoča časovno usklajevanje zaznav in njihovo združevanje znotraj definirane časovnega intervala. Eksperimentalni rezultati potrjujejo, da kombinirani pristop izboljša zanesljivost zaznave v primerjavi s posameznimi metodami, zlasti v zahtevnih okoljskih pogojih. Prispevek analizira arhitekturo sistema, zmogljivost izvajanja na robnih napravah ter omejitve in možnosti nadaljnjih izboljšav.

DOI
[https://doi.org/
10.18690/um.feri.4.2026.11](https://doi.org/10.18690/um.feri.4.2026.11)

ISBN
978-961-299-111-1

Ključne besede:
dron,
detekcija dronov,
radar,
Dopplerjev radar,
YOLOv8



Univerzitetna založba
Univerze v Mariboru

DOI
[https://doi.org/
10.18690/um.feri.4.2026.11](https://doi.org/10.18690/um.feri.4.2026.11)

ISBN
978-961-299-111-1

Keywords:

drone,
drone detection,
radar,
Doppler radar,
YOLOv8

DETECTION AND CLASSIFICATION OF UNMANNED AERIAL VEHICLES WITH CAMERA AND RADAR

PANE ANDOV, PRIMOŽ SMOGAVEC, DUŠAN GLEICH

University of Maribor, Faculty of Electrical Engineering and Computer Science,
Maribor, Slovenia
pane.andov@um.si, primoz.smogavec@um.si, dusan.gleich@um.si

This paper presents a real-time system for unmanned aerial vehicle (UAV) detection that combines vision-based deep learning with advanced FMCW Range–Doppler radar processing. The visual subsystem is based on the YOLOv8 model deployed on the NVIDIA Jetson Orin Nano platform using an industrial Basler camera. The radar subsystem, implemented on a Raspberry Pi, performs Gaussian smoothing, background subtraction, and target detection using threshold-based segmentation followed by DBSCAN clustering in the range domain. UDP communication between the subsystems enables temporal synchronization of detections and their fusion within a predefined time window. Experimental results demonstrate that the combined approach improves detection reliability compared to individual sensing modalities, particularly under challenging environmental conditions. The paper analyzes the system architecture, computational performance on edge devices, and discusses current limitations and potential directions for further improvements.



University of Maribor Press

1 Uvod

V zadnjih letih se je uporaba brezpilotnih letalnikov močno povečala na področjih, kot so logistika, nadzor infrastrukture, kmetijstvo in rekreativna raba. Hkrati pa se pojavljajo tudi varnostni izzivi, povezani z nedovoljeno uporabo dronov v bližini kritične infrastrukture, letališč ali javnih prireditev (Obaid idr., 2025). Zaradi majhnih dimenzij, nizke radarske odbojnosti in pogosto nepredvidljivega gibanja predstavlja zanesljiva detekcija takšnih ciljev tehnični izziv.

Vizualni sistemi na osnovi globokega učenja, kot so sodobni enostopenjski detektorji objektov, kot je YOLO (angl. *You Only Look Once*), omogočajo učinkovito zaznavo objektov v realnem času. Vendar je njihova zanesljivost močno odvisna od svetlobnih pogojev, vremenskih vplivov in oviranosti vidnega polja. Po drugi strani radarski sistemi, zlasti Dopplerjevi radarji, omogočajo zaznavo ciljev neodvisno od osvetlitve ter zagotavljajo neposredno informacijo o razdalji in radialni hitrosti. Kljub temu pa so radarske meritve lahko obremenjene s šumom, motnjami okolja in stacionarnim ozadjem.

Zaradi komplementarnih lastnosti obeh pristopov se v zadnjem času vse bolj uveljavlja večmodalna fuzija podatkov, ki združuje vizualne in radarske informacije z namenom izboljšanja robustnosti zaznave.

V tem prispevku predstavljamo realnočasovni večmodalni sistem za detekcijo brezpilotnih letalnikov, ki združuje vizualno detekcijo na osnovi modela YOLOv8 z napredno Range–Dopplerjevo radarsko obdelavo FMCW (Zhou idr., 2019). Radarski podsistem vključuje Gaussovo glajenje, odštevanje ozadja ter detekcijo ciljev z uporabo pragovne metode in gručenja DBSCAN (angl. *Density-Based Spatial Clustering of Applications with Noise*) (Ester idr., 1996). Vizualni in radarski podsistem sta povezana prek komunikacije UDP (angl. *User Datagram Protocol*), ki omogoča časovno usklajevanje zaznav in njihovo združevanje znotraj definirane časovnega intervala.

2 Teoretični pregled

2.1 Algoritem YOLO

Za vizualno detekcijo je bil uporabljen algoritem YOLO (angl. *You Only Look Once*) (Redmon idr. 2016), ki spada med enostopenjske detektorje objektov. To pomeni, da model v enem prehodu skozi nevronske mreže napove razred objekta, položaj in velikost omejitvenega okvirja, kar omogoča hitro izvajanje v realnem času.

Arhitektura algoritma YOLO temelji na modularni zasnovi, ki je razdeljena na tri glavne sklope: osnovno omrežje (angl. *Backbone*), povezovalni del (angl. *Neck*) in izhodni del (angl. *Head*).

Osnovno omrežje predstavlja globoka konvolucijska mreža, katere naloga je iz vhodne slike izvleči značilnice.

Povezovalni del združuje značilnice iz različnih nivojev. Izhodni del je zaključni del modela, ki izvaja končno napoved. Ima tri izhode za zaznavanje objektov različnih velikosti: en izhod za majhne objekte, enega za srednje velike objekte in enega za velike objekte.


2.2 Radar

Radar deluje na principu oddajanja elektromagnetnega signala ter analize odbitega vala. Pri zaznavanju premikajočih se objektov ima ključno vlogo Dopplerjev pojav, pri katerem se frekvenca odbitega signala spremeni glede na relativno hitrost tarče.

V obravnavanem sistemu je uporabljen radar s frekvenčno moduliranim zveznim signalom (angl. *Frequency Modulated Continuous Wave*), ki oddaja linearno frekvenčno modulirane čirike (Eiadkaew idr., 2022). Razlika med oddanim in prejetim signalom omogoča določitev razdalje do cilja, medtem ko analiza spremembe faze med zaporednimi čiriki omogoča oceno radialne hitrosti. Z uporabo dvodimenzionalne Fourierjeve transformacije se izračuna Range-Dopplerjev spekter, ki prikazuje porazdelitev odbojev glede na razdaljo in hitrost.

3 Zasnova in izvedba sistema

Sistem, predstavljen v tej nalogi (glej sliko 1), je namenjen zaznavi brezpilotnih zrakoplovov s kombinacijo strojnega vida in Dopplerjevega radarja (Jian idr., 2018). Celotni sistem deluje kot kombinacija dveh neodvisnih vej, kjer je prva namenjena vizualni zaznavi brezpilotnih zrakoplovov z uporabo algoritma YOLO, druga pa predstavlja radarski sistem, ki temelji na Dopplerjevem pojavu za zaznavo premikajočih se objektov. Na koncu se rezultati obeh vej združijo in primerjajo. Če se zaznave iz obeh sistemov časovno ujemajo, zaznavo brezpilotnega zrakoplova štejejo za uspešno.




Slika 1: Zgradba celotnega sistema

Vir: lasten

3.1 Vizualni podsistem

Za optično zaznavo je bil uporabljen algoritem YOLOv8, ki spada med enostopenjske detektorje. To pomeni, da algoritem v enem samem koraku napove razred objekta, njegovo lokacijo in velikost. Tak pristop omogoča hitro obdelavo in je primeren za delovanje v realnem času.

Ena izmed prednosti YOLOv8 je, da se dobro obnese tudi pri zaznavanju majhnih in hitro premikajočih se objektov, kar je ključno pri detekciji dronov.




Slika 2: Zgradba vizualnega podsistema

Vir: lasten

Za zajem podatkov (slika 2) je bila uporabljena industrijska kamera Basler ace, ki omogoča stabilen zajem slik v realnem času in je primerna za robustne testne pogoje.

3.2 Radarski podsistem

Za zaznavo je bil uporabljen Dopplerjev radar FMCW, ki na podlagi frekvenčnega zamika odbitega signala določa razdaljo in radialno hitrost ciljev. Sistem sestavljajo ADALM-PLUTO SDR, razvojna plošča CN0566 in mikroračunalnik Raspberry Pi 4. ADALM-PLUTO deluje kot oddajno-sprejemni vmesnik RF (angl. *Radio Frequency*), CN0566 generira frekvenčno modulirane čirike, Raspberry Pi pa izvaja izračun Range-Dopplerjevega spektra z uporabo 2D Fourierjeve transformacije. Sistem deluje v realnem času ter omogoča konfiguracijo radarja, zajem in obdelavo podatkov (glej sliko 3).



Slika 3: Zgradba radarskega podsistema


Vir: lasten

4 Eksperimentalni rezultati

4.1 Detekcija drona s kamero


Za vizualno detekcijo drona je bil uporabljen model YOLOv8n (nano), ki je bil treniran na podatkovnem naboru z več kot 9000 označenimi slikami dronov. Učenje je potekalo 70 epoh pri vhodni ločljivosti 640 pik (slika 4).

Na krivuljah izgub vidimo, da te kažejo stabilno konvergenco brez izrazitega preučanja (angl. *Overfitting*). Končni rezultati so dosegli približno 95 % natančnost ter mAP nad 97 %, kar je več kot zadostno za realnočasovno uporabo (glej slike 5 in 6).



Slika 4: Rezultati učenja modela

Vir: lasten



Slika 5: Krivulja PR

Vir: lasten



Slika 6: Primer detekcije z algoritmom YOLO

Vir: lasten


4.2 Detekcija drona z radarjem

Radar je zanesljivo zaznal premikajoči se dron, ki se je v spektru RD pojavil kot izrazit lokalni maksimum pri določeni razdalji in radialni hitrosti. Prisotni so bili tudi odboji statičnih objektov, zato je bil za zmanjšanje njihovega vpliva kot referenčno ozadje uporabljen prvi časovni okvir, zajet brez cilja, ki je bil odštet od vseh nadaljnjih meritev.

Na logaritmčno skalirani spekter RD je bil uporabljen prag, pri čemer so bile kot potencialne detekcije obravnavane točke nad izbranim pragom. Dodatne fizikalne omejitve (minimalna hitrost in omejeno območje razdalje) so zmanjšale število lažnih alarmov (glej sliko 7).


Ker se tarča v prostoru RD pojavi kot skupina energijskih elementov, je bil uporabljen algoritem DBSCAN za gostotno gručenje zaznanih točk. Za vsak grozd je bil izračunan uteženi centroid kot ocena razdalje in hitrosti cilja, pri čemer je bil kot primarna detekcija izbran grozd z največjo energijo (slika 8).

Rezultati potrjujejo robustnost radarskega podsistema pri zaznavanju brezpilotnega letalnika neodvisno od svetlobnih pogojev.



Slika 7: Zgradba vizualnega podsistema


Vir: lasten



Slika 8: Primer detekcije v diagramu Range-Doppler
Vir: lasten


4.3 Časovna sinhronizacija obeh sistemov

Radar in vizualni sistem sta bila časovno usklajena z uporabo časovnih žigov (slika 9). Če je bila razlika med zaznavama manjša od 1 s, je bila zaznava klasificirana kot kombinirana. Sistem je razlikoval med tremi primeri: samo YOLO, samo radar ali kombinirana zaznava (glej sliko 10).



Slika 9: Diagrama poteka sinhronizacije radarske in optične sinhronizacije

Vir: lasten






Slika 10: Sočasna detekcija z optičnim in radarskim sistemom
Vir: lasten

4.4 Klasifikacija na podlagi mikro-Dopplerjevih odtisov

Prisotnost drona se v sprejetem signalu odraža kot sprememba spektralne vsebine zaradi Dopplerjevega premika in mikro-Dopplerjevih pojavov, ki nastanejo zaradi rotacije propelerjev ter vibracij in gibanja strukture drona. Ti pojavi ustvarjajo značilne frekvenčne podpise, ki jih je mogoče uporabiti za detekcijo ali klasifikacijo.

V tem delu predstavimo sistem za zaznavanje prisotnosti drona na podlagi radarsko zajetih podatkov. Problem obravnavamo kot binarno klasifikacijo, kjer sistem odloča med dvema razredoma: prisotnost drona in odsotnost drona. Predstavlja osnovni korak, ki omogoča validacijo metodologije in bo v nadaljnjem delu raziskave razširjen na večrazredno klasifikacijo med več različnimi tipi dronov. Signal obdelamo s kratkočasovno Fourierjevo transformacijo (STFT), nato pa izvedemo klasifikacijo z dvema pristopoma z uporabo klasifikatorja SVM in 1D konvolucijske nevronske mreže (CNN), ki se uči neposredno iz spektralnih odtisih.


Prvi pristop temelji na ročno definiranih značilkah, izračunanih iz magnitude pozitivnega spektra STFT okvirja, in metodi podpornih vektorjev (SVM). Da zmanjšamo dimenzionalnost in se osredotočimo na relevantne komponente, značilke računamo le v območju 0–5000 Hz. V tem področju izberemo naslednje značilke: spektralno težišče, spektralno razpršenost, mejo spektralne energije (angl. roll-off, 85%), spektralno ravnost, spektralno entropijo, dominantno frekvenco in amplitudo vrha pri tej frekvenci. Spektralne značilke so prikazane na sliki 11.



Slika 11: Izbrane spektralne značilke

Vir: lasten

Podatki so razdeljeni na učno in testno množico s stratificirano delitvijo (70/30), da sta v obeh množicah enakomerno zastopana oba razreda (glej sliko 12).




Slika 12: Matrika zmede pri učenju modela SVM.

Vir: lasten

Drugi pristop uporablja konvolucijsko nevronske mrežo, ki se uči neposredno iz spektra. Vhodni vektor sestavljajo magnitudni spektralni bini v območju 0–5000 Hz. Vhod CNN je oblike (1, F), kjer je F število frekvenčnih binov.

Uporabljena je enodimenzionalna konvolucijska nevronska mreža, sestavljena iz treh zaporednih konvolucijskih blokov ter zaključne polno povezane plasti. Prvi blok vključuje plast Conv1d (1→16, k=9), aktivacijsko funkcijo ReLU in operacijo MaxPool(2). Drugi blok je sestavljen iz Conv1d (16→32, k=9), ReLU in MaxPool(2). Tretji blok vsebuje Conv1d (32→64, k=9), ReLU ter prilagodljivo povprečno združevanje AdaptiveAvgPool(1). Končna reprezentacija se nato splošči (angl. Flatten) in posreduje v polno povezano plast Linear (64→1) za binarno klasifikacijo.

Mreža vrača napovedi (angl. logit) z, verjetnost dobimo s funkcijo sigmoid. Model učimo z optimizatorjem Adam ($\text{lr} = 1\text{e-}3$) ter funkcijo izgube BCEWithLogitsLoss. Učenje poteka 20 epoh.



Slika 13: Matrika zmede pri učenju modela CNN.

Vir: lasten

Matrika zmede za model CNN kaže zelo visoko uspešnost binarne klasifikacije. Model pravilno klasificira 754 primerov razreda 'brez drona' in 1113 primerov razreda 'dron' (slika 13). Zabeleženi so bili 3 lažno pozitivni primeri, medtem ko

lažno negativnih primerov ni bilo. Rezultati kažejo, da model CNN zelo učinkovito prepozna mikro-Dopplerjeve značilnosti drona in hkrati ohranja nizko stopnjo lažnih alarmov. Posebej pomembna je odsotnost lažnih negativnih primerov, saj ti v varnostnih aplikacijah predstavljajo kritično napako. Ta osnovna modela bosta služila kot osnova za večrazredno klasifikacijo med različnimi tipi dronov. Oba pristopa sta primerna za implementacijo v realnočasovni slapovni prikaz.

Takšna skoraj popolna ločitev med dvema razredoma potrjuje, da spektralni podatki vsebujejo dovolj diskriminativnih informacij za zanesljivo detekcijo prisotnosti drona. Vendar gre v tem primeru za binarni klasifikacijski problem. Pri razširitvi sistema na večrazredno klasifikacijo med različnimi tipi dronov ali drugimi zračnimi objekti bi se kompleksnost problema povečala, kar bi lahko vodilo do rahlega znižanja skupne točnosti ter več napačnih klasifikacij med medsebojno podobnimi razredi. Kljub temu trenutni rezultati predstavljajo trdno osnovo za nadaljnji razvoj večrazrednega modela, saj kažejo, da CNN in SVM uspešno zajameta ključne mikro-Dopplerjeve vzorce, na katerih je mogoče graditi naprednejše razločevanje.

7 Zaključek

V prispevku smo predstavili realnočasovni sistem za detekcijo brezpilotnih letalnikov, ki združuje vizualno zaznavo na osnovi globokega učenja in radarsko Range-Dopplerjevo obdelavo. Vizualni podsistem temelji na modelu YOLOv8, ki omogoča učinkovito detekcijo dronov v realnem času, medtem ko radarski podsistem z uporabo Dopplerjeve analize omogoča zaznavo premikajočih se objektov neodvisno od svetlobnih pogojev.

Radarski del vključuje Gaussovo glajenje, odštevanje referenčnega ozadja, pragovno segmentacijo ter gostotno gručenje z algoritmom DBSCAN, kar omogoča stabilno in robustno oceno razdalje in hitrosti tarče. Eksperimentalni rezultati potrjujejo, da kombinacija obeh pristopov poveča zanesljivost zaznave v primerjavi s posameznim sistemom, saj radar kompenzira omejitve vizualne detekcije pri slabših svetlobnih pogojih, medtem ko kamera omogoča klasifikacijo tipov objekta.

Možne nadaljnje izboljšave vključujejo razširitev sistema za zaznavo več tarč hkrati ter klasifikacijo različnih tipov brezpilotnih letalnikov na podlagi mikro-Dopplerjevih značilk.

Viri in literatura

- Eiadkaew S., Boonpoonga A., Phaebua K., Athikulwongse K., & Shutimarrungson N. (2022). Design and Experiment of FMCW Radar System for Drone Detection, *37th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC)*.
- Ester, M., Kriegel, H., Sander, J., & Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *KDD'96: Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*. (str. 226 – 231).
- Jian, M., Lu, Z., & Chen, V. C. (2018). Drone detection and tracking based on phase-interferometric Doppler radar, *2018 IEEE Radar Conference (RadarConf18)*
- Obaid, L., Hamad, K., Al-Ruzouq R. (2025). State-of-the-art review of unmanned aerial vehicles (UAVs) and artificial intelligence (AI) for traffic and safety analyses: Recent progress, applications, challenges, and opportunities. *Transportation Research Interdisciplinary Perspectives*.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection. *ArXiv*, <https://arxiv.org/abs/1506.02640> .
- Zhou, L. et.al. (2019). YOLO-RD: A lightweight object detection network for range doppler radar images. *IOP Conf. Ser.: Mater. Sci. Eng.* 563 042027.

