

Sistem za detekciju i klasifikaciju niskoletećih besposadnih platformi – dronova (SDKNBP)

Mohammed Mokhtari, Jovan Bajčetić i Boban Sazdić-Jotić

Apstrakt—Istraživanje predstavljeno u ovom radu prikazuje mogućnosti planiranog koncepta sistema za detekciju i klasifikaciju niskoletećih besposadnih platformi (dronova) zasnovanom na metodama dubokog učenja. Cilj projekta predstavlja razvoj upotrebljivog sistema koji će u realnom vremenu vršiti detekciju i klasifikaciju dronova na bazi karakteristika njihovih radio emisija. Metode detekcije i klasifikacije primenjene u ovom istraživanju zasnivaju se na konvolucionoj neuronskoj mreži istreniranoj upotrebom formirane baze snimaka radio emisija sa nekoliko vrsta komercijalno dostupnih dronova. U početnoj fazi istraživanja sistem pokazuje verovatnoću detekcije i klasifikacije od 100 % za ukupno četiri nezavisne klase – nema drona, dron 1, dron 2 i dron 3 što predstavlja osnovu za dalji razvoj sistema za detaljniju klasifikaciju.

Ključne reči—Duboko učenje; Detekcija; Klasifikacija; Radio emisija; Dron.

I. UVOD

JEDNA od najaktuuelnijih oblasti tehnološkog i industrijskog razvoja današnjice je oblast razvoja i unapređenja besposadnih platformi. S obzirom na to da se autonomna vozila smatraju zamajcem četvrte industrijske revolucije, posebnu pažnju nauke, tehnologije i industrije privlače leteće besposadne platforme. One će, beskompromisno u skorijoj budućnosti zauzeti vrlo veliki i važan deo ljudske delatnosti primarno u oblasti transporta, ali i u okviru ostalih oblasti delovanja.

Terminologija označavanja niskoletećih besposadnih platformi je pretežno kod nas zastupljena na engleskom jeziku, tako da se u literaturi može naći više različitih terminoloških izraza, kao što su:

- UAS (Unmanned Aircraft System), [1];
- RPAS (Remotely Piloted Aircraft System), [2];
- UAV (Unmanned Aerial Vehicle).

U dokumentu koji koristi francuski direktorat za civilnu avijaciju [2], a taj izraz je široko prihvaćen u svetskoj naučnoj zajednici, leteća besposadna platforma je definisana kao dron, pa će se u tom kontekstu u daljem radu upravo tako i označavati.

Mohammed Mokhtari – Vojna Akademija, Univerzitet odbrane u Beogradu, Veljka Lukića Kurjaka 33, 11042 Beograd, Srbija (e-mail: mokhtari.med91@gmail.com).

Jovan Bajčetić – Vojna Akademija, Univerzitet odbrane u Beogradu, Veljka Lukića Kurjaka 33, 11042 Beograd, Srbija (e-mail: bajce05@gmail.com).

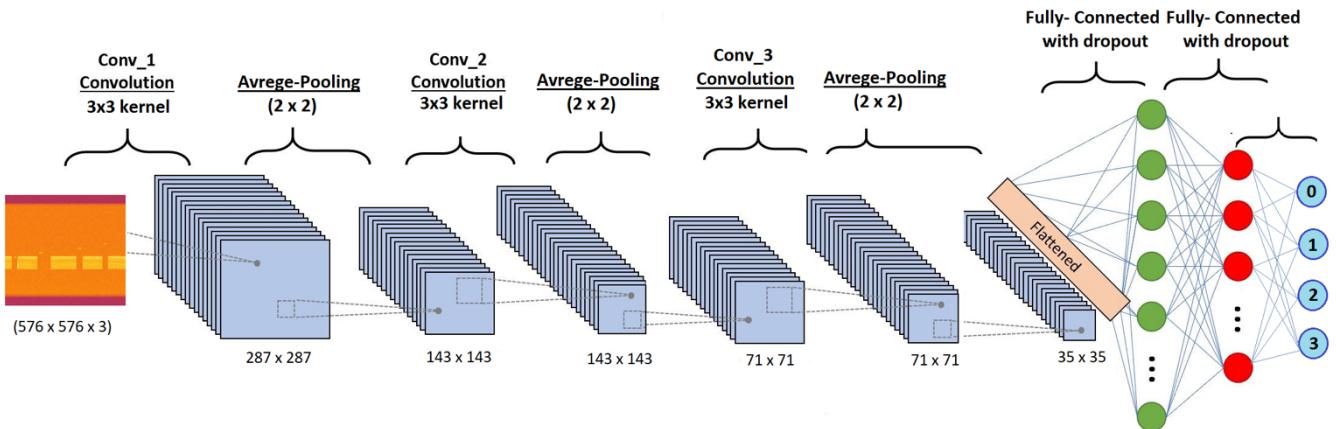
Boban Sazdić-Jotić – Vojna Akademija, Univerzitet odbrane u Beogradu, Veljka Lukića Kurjaka 33, 11042 Beograd, Srbija (e-mail: boban.sazdic.jotic@vs.rs).

U uslovima kada dronovi dobijaju sve više uloga – od snimanja terena, preko prenošenja male količine tereta (dostave), pa sve do mogućnosti prenosa eksplozivnih naprava, nameće se imperativ bolje kontrole ovih letelica koja se može sprovesti kroz kontrolu dela elektromagnetskog spektra u kojem dronovi vrše prenos informacije komandnim i kanalom za prenos slike. Do sada se išlo u više pravaca detekcije i klasifikacije dronova na bazi karakteristika radio emisija koje bi ih izdvajile iz velikog broja ostalih uređaja koji koriste isti frekvencijski opseg:

- Detekcija na bazi MAC (Media Access Control) adrese uređaja [3];
- Detekcija na bazi korišćenih komunikacionih protokola [4];
- Detekcija na bazi „otiska prsta“ radio emisije [5].

Svaka od navedenih metoda primenjena u anti-dron sistemu (ADRO) usled svojih ograničenja i zahteva ima prednosti i nedostatke, pa bi mogućnost implementacije više prikazanih različitih pristupa omogućilo da se dronovi u realnom vremenu detektuju, klasifikuju, lokalizuju i eventualno sprovedu protivmere ukoliko za time postoji potreba. Ovakav pristup zahteva kompromis između pravovremene detekcije, veličine prostornog okvira detekcije, verovatnoće detekcije, kao i kvaliteta i preciznosti upotrebljenih senzora. Do sada se vrlo daleko otišlo u pravcu detekcije i klasifikacije dronova na osnovu karakteristika radio signala u komunikaciji između drona i upravljačke konzole korišćenjem specifičnosti obeležja kompletног radio saobraćaja, kao jedne u pogledu optimizacije resursa najisplativije metode. U tom pogledu postoji mnogo različitih rešenja korišćenjem metoda dubokog učenja (Deep Learning – DL) koja upotrebljavaju raznovrsne algoritme u zavisnosti od toga za koji problem detekcije i klasifikacije se traži optimalno rešenje – klasifikacija slika [6], 3D objekata [7,8], radio emisija [9, 10, 11], radarskih ciljeva [12], govora i rečenica [13, 14], gasova [15], predviđanje vrednosti akcija [16], itd.

S obzirom na činjenicu da je obučena neuronska mreža utoliko efikasnija u klasifikaciji više različitih radio emisija ukoliko je veća baza podataka pomoću koje se obučava [17], metoda na bazi dubokog učenja oslonjena na snimanjima emisija koji su praktično sprovedeni će biti predstavljena u ovom radu. Da bi se realizovalo istraživanje i razvoj sistema na bazi detekcije i klasifikacije, upotrebljavajući metode dubokog učenja, bilo je potrebno imati na raspolaganju bazu snimaka radio emisija upotrebom kojih bi se izvršio kvalitetan trening i provera (validacija) razvijenog modela koji bi kasnije bio sposoban da sa vrlo visokom verovatnoćom detektuje i klasificuje dronove na bazi njihove radio emisije.



Sl. 1. Neuronska mreža upotrebljena za detekciju i klasifikaciju dronova (Prva konfiguracija)

Baza snimaka koja je korišćena u ovu svrhu [18] javno je dostupna i sadrži snimke radio emisija dronova u različitim operativnim stanjima, frekvencijskim opsezima (2,4 i 5,8 GHz), kao i snimke radio emisija kada dva i više dronova zajednički deluju na istom prostoru i u istom frekvencijskom opsegu što je čini za sada jedinom te vrste javno dostupnom.

Prikaz istraživanja u ovom radu će se sastojati iz opisa razvijenog modela na bazi dubokog učenja (poglavlje II), prikaza mogućnosti razvijenog modela (poglavlje III), opisa informacionog sistema (poglavlje IV), a na kraju, u okviru zaključka (poglavlje V) će biti rezimirane najbitnije tačke istraživanja i date smernice za buduće istraživanje.

II. OPIS MODELA ZA DETEKCIJU I KLASIFIKACIJU

Model za detekciju i klasifikaciju koji je razvijen u okviru istraživanja za početni cilj je imao da obezbedi mogućnost jednostavne detekcije i klasifikacije u okviru četiri klase događaja – nema drona, dron 1, dron 2 i dron 3. S obzirom na uslov nadograđivanja sistema za mogućnost složenije klasifikacije, polazna neuronska mreža je projektovana da bude složenija od toga da zadovolji kriterijum prvog definisanog cilja. Iz tog razloga, razvijeni model sadrži neuronsku mrežu od pet slojeva (Sl. 1.) koja je bila testirana po kriterijumu tačnosti treninga (training accuracy), gubitaka u toku treninga (training loss), provere tačnosti (validation accuracy) i gubitaka u toku provere tačnosti (validation loss) za različite slučajeve kompleksnosti ulaznih podataka. Neuronska mreža korišćena u istraživanju pripada tipu konvolucione neuronske mreže (Convolutional Neural Network – CNN), kao ulazne podatke koristi 2D slike spektrograma i predstavlja adaptaciju funkcionalne mreže sa strukturom za klasifikaciju audio signala [19]. Optimizacija mreže za slučaj klasifikacije koji je naveden svodio se na pronađenje optimalnog odnosa između kompleksnosti i veličine ulaznih podataka (slika), verovatnoće detekcije i klasifikacije i vremena potrebnog za treniranje modela neuronske mreže. Shodno tome, vršena je optimizacija na osnovu broja odbiraka sirovog snimka i na taj način vršen uticaj na rezoluciju spektrograma i dimenzije njegove slike.

Uticaj rezolucije slike na performanse CNN je proučavan u literaturi [20], kao i arhitektura jednodimenzionalne konvolucione neuronske mreže (1DCNN) za detekciju i klasifikaciju UAV [21].

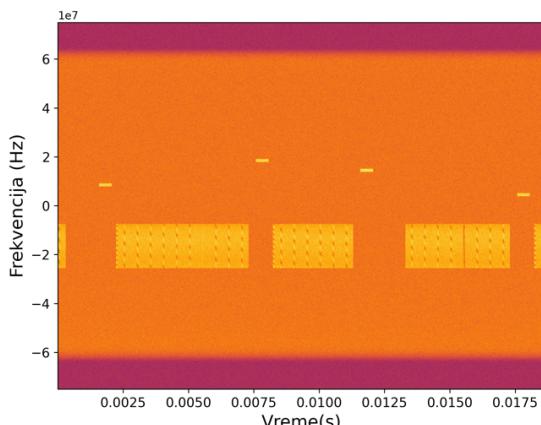
Formirana mreža je prilagođavana formatu ulaznih podataka (adaptirani su slojevi posledično veličini podataka koji se koriste) čije su vrednosti dobijane segmentacijom sirovih podataka iz navedene baze snimljenih radio emisija sa dronova, a vrednosti dobijene nakon segmentacije su prikazane u Tabeli I. Za svaku od četiri moguće konfiguracije je biran adekvatan broj odbiraka po segmentu čime je definisano trajanje svakog segmenta, kao i ukupan broj segmenata proistekao iz sirovog snimka. Raspodela ukupnog broja segmenata po klasama (Nema drona, Dron 1, Dron 2 i Dron 3) je predstavljena u donjem delu Tabele I. Eksperiment se svodio na četiri različita slučaja (konfiguracije), a dronovi 1, 2 i 3 su bili, respektabilno DJI Phantom IV, DJI Mavic 2 Zoom i DJI Mavic 2 Enterprise.

TABELA I
ULAZNI PODACI – SEGMENTACIJA

Konfiguracija	Broj odbiraka po segmentu	Trajanje segmenta (ms)	Ukupan broj segmenata
Prva	2796128	18.64	360
Druga	1398064	9.32	720
Treća	699032	4.66	1440
Četvrta	200319	1.34	5025
Nema drona	Dron 1	Dron 2	Dron 3
72	96	96	96
144	192	192	192
288	384	384	384
1005	1340	1340	1340

Od dobijenih segmentiranih podataka su nakon izračunavanja Furijeove transformacije (Hanning tip prozora, 2048 tačaka za FFT, 128 tačaka preklapanja, amplituda predstavljena u dB) kreirane slike spektrograma u .png

formatu (Sl. 2.) prilagođene za ulaz u svaku od konfiguracija neuronske mreže (Tabela II).



Sl. 2. Primer izgleda spektrograma

TABELA II
KARAKTERISTIKE SLIKA SPEKTROGRAMA

Konfiguracija	Rezultujuća matrica spektrograma	Rezultujuća slika (pixels)
Prva	2048 x 1456	576 x 576
Druga	2048 x 727	406 x 406
Treća	2048 x 364	288 x 288
Četvrta	2048 x 104	154 x 154

Od ukupnog broja segmentiranih podataka, 70 % je iskorišćeno za treniranje modela, a 30 % za proveru. Raspodela broja slika po skupovima, za svaku konfiguraciju je predstavljena u Tabelama III i IV. Tabela III predstavlja raspodelu slika po četiri definisane klase (Nema drona, Dron 1, Dron 2, Dron 3) za sve četiri trenirane konfiguracije. Tabela IV prikazuje raspodelu broja slika za iste četiri klase, ali za proveru tačnosti istreniranih modela za sve četiri konfiguracije.

TABELA III
PARAMETRI ZA TRENIRANJE MODELAA

Konfiguracija	Ukupno slika	Nema drona	Dron 1	Dron 2	Dron 3
Prva	251	50	67	67	67
Druga	502	100	134	134	134
Treća	1005	201	268	268	268
Četvrta	3514	703	937	937	937

TABELA IV
PARAMETRI ZA PROVERU MODELAA

Konfiguracija	Ukupno slika	Nema drona	Dron 1	Dron 2	Dron 3
Prva	109	22	29	29	29
Druga	218	44	58	58	58
Treća	435	87	116	116	116
Četvrta	1511	302	403	403	403

III. MOGUĆNOSTI MODELA ZA DETEKCIJU I KLASIFIKACIJU

Treniranje modela dubokog učenja izvršeno je po već navedenim podacima u ukupno 30 epoha za svaku od konfiguracija. Rezultati neimenovane jedinice tačnosti treninga (training accuracy) čija vrednost može biti od 0 do 1, a koji predstavlja odnos između broja tačnih predikcija i ukupnog broja predikcija u funkciji od broja epoha, za sve četiri konfiguracije dati su na Sl. 3. Neimenovana jedinica gubitaka u toku treninga (training loss) u funkciji od broja epoha čija vrednost može pripadati skupu $[0, \infty]$, a čija manja vrednost implicira bolju predikciju predstavljeni su na Sl. 4.

Krajnja tačnost treninga, kao i gubitaka u toku treninga za svaku od konfiguracija su predstavljeni u Tabeli V.

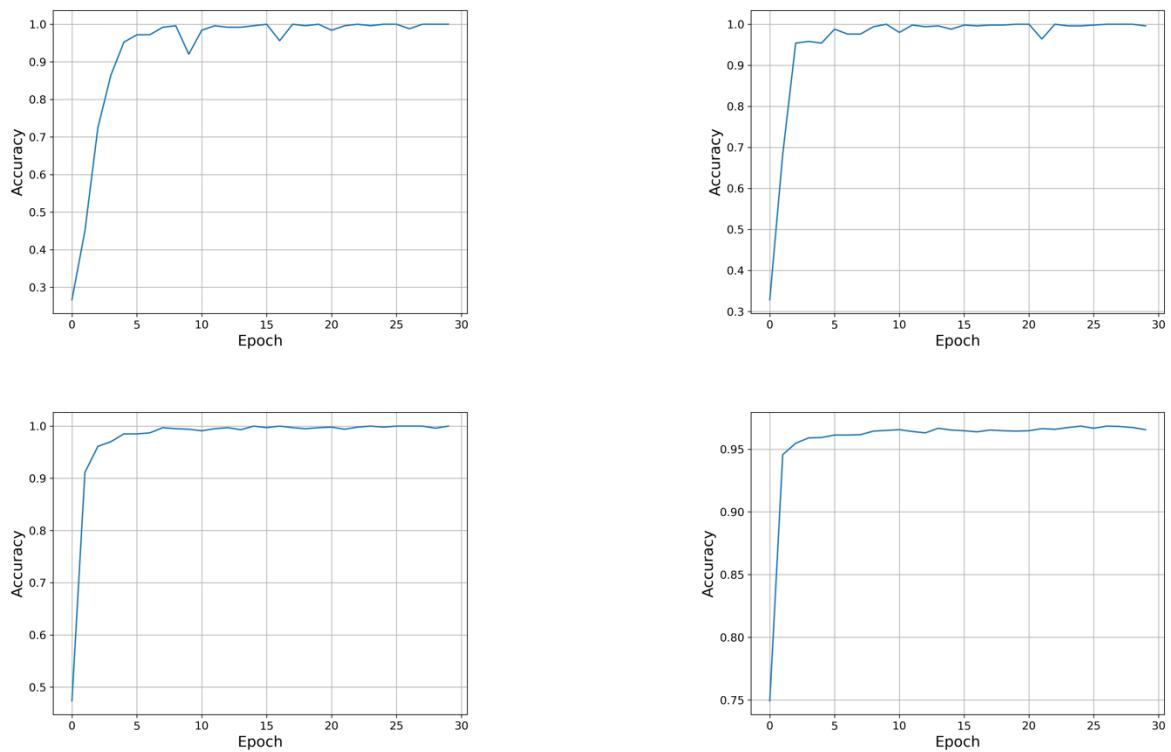
TABELA V
VREDNOSTI TRENIRANJA ZA SVAKU KONFIGURACIJU

Konf.	Broj epoha	Tačnost treninga	Gubici u toku treninga	Provera tačnosti	Gubici u toku provere tačnosti
Prva	30	1.00	$2.64 \cdot 10^{-6}$	1.00	$1.01 \cdot 10^{-5}$
Druga	30	1.00	$6.23 \cdot 10^{-4}$	0.99	0.01
Treća	30	1.00	$2.65 \cdot 10^{-6}$	1.00	$2.23 \cdot 10^{-6}$
Četvrta	30	0.97	0.11	0.97	0.12

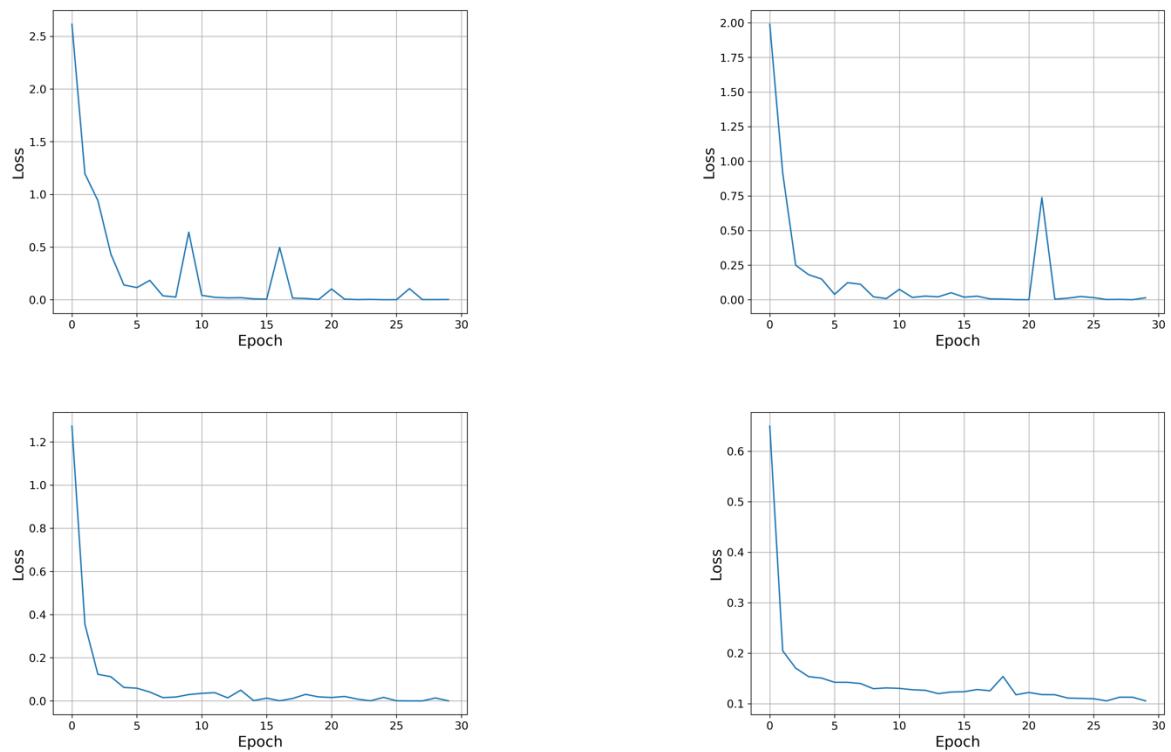
Na osnovu prikazanog se može zaključiti:

1. Uzimajući u obzir kriterijum tačnosti treninga, prve tri konfiguracije omogućavaju klasifikaciju sa najvišom mogućom verovatnoćom, kao i sa vrlo malim gubicima u toku treninga (reda veličine 10^{-5}) što se može videti u Tabeli V;
2. U pogledu provere tačnosti, kao i u pogledu gubitaka u toku provere tačnosti, prva i treća konfiguracija daju dobre i približno slične rezultate.
3. Četvrta konfiguracija je po pitanju sva četiri kriterijuma lošija od prve tri, sa krajnjom tačnošću treninga i provere tačnosti od 0,97.
4. Model (konfiguracija) koji bi predstavljao kompromis između brzine treniranja, tačnosti i kompleksnosti (veličine) ulaznih podataka i na taj način bio optimalan za korišćenje u informacionom sistemu koji bi funkcionisao u realnom vremenu bi bio Treći model.

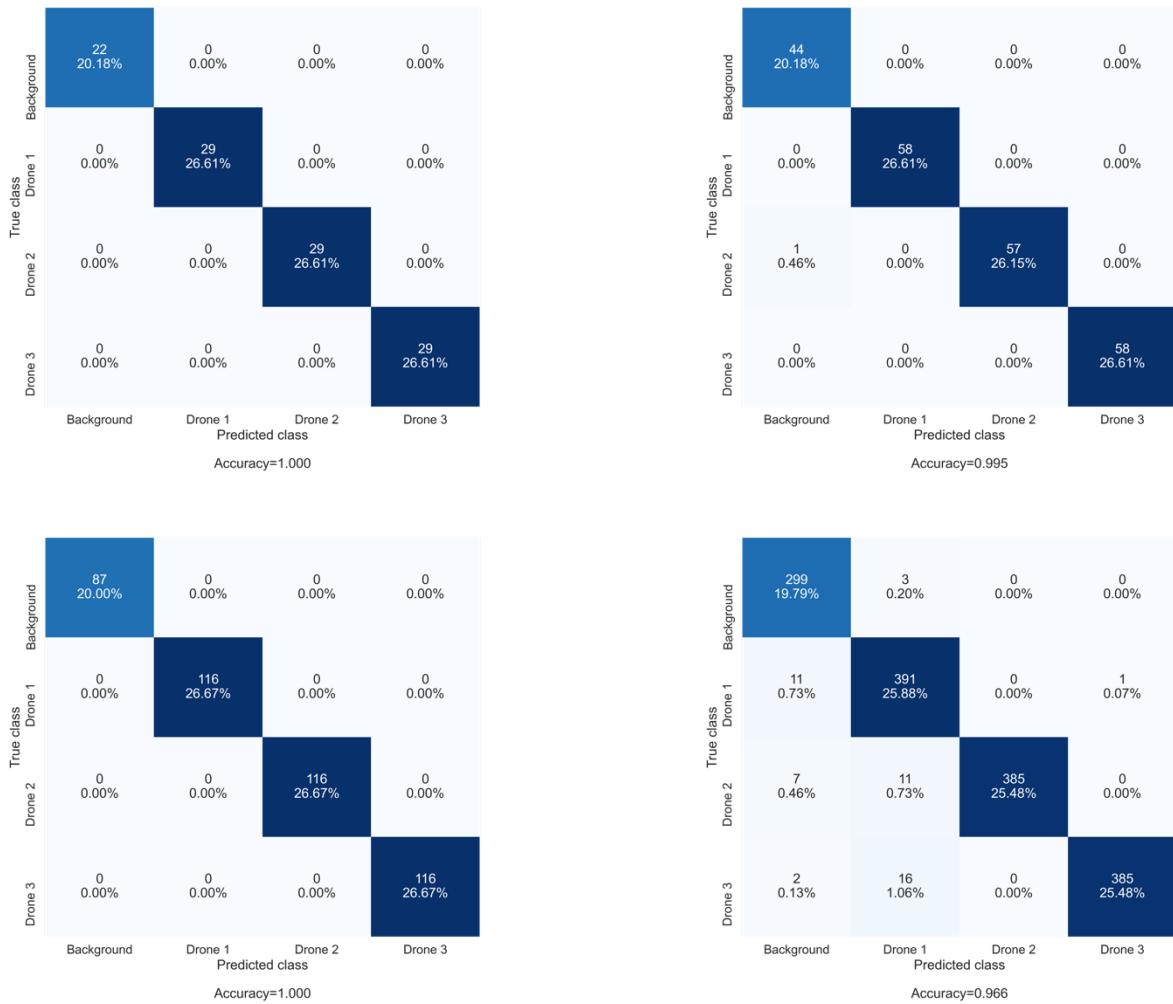
Matrice konfuzije na osnovu kojih se mogu ustanoviti kompletne performanse sve četiri konfiguracije, predstavljene su na Sl. 5. Ove matrice predstavljaju grafički prikaz klasifikacije po broju slika i njihovom procentualnom udelu u ukupnom broju slika koje su svrstane u određenu kategoriju (klasu). Ova klasifikacija može biti pozitivna (tačna) ili negativna (netačna), pa se na osnovu toga može zaključiti da je konfiguracija 4 najviše grešaka napravila prilikom klasifikacije emisije Dron 1 koju je svrstala u kategoriju Dron 3.



Sl. 3. Tačnost treninga (training accuracy) za konfiguracije: 1 (gore levo), 2 (gore desno), 3 (dole levo) i 4 (dole desno)



Sl. 4. Gubici u toku treninga (training loss) za konfiguracije: 1 (gore levo), 2 (gore desno), 3 (dole levo) i 4 (dole desno)



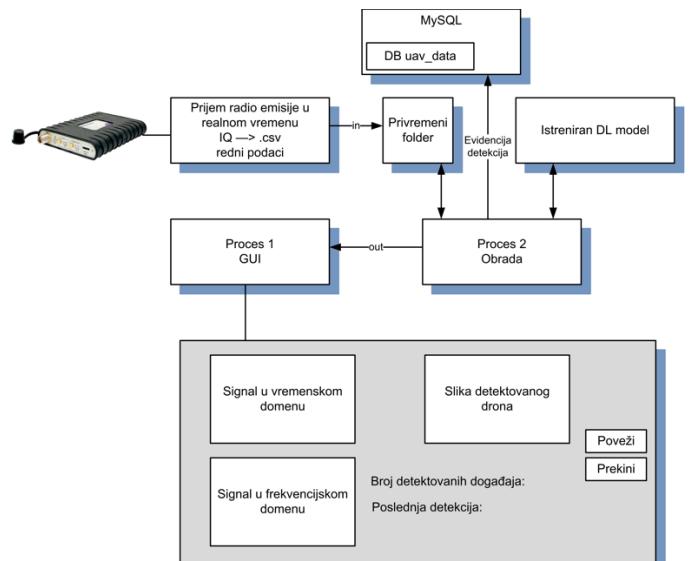
Sl. 5. Matrice konfuzije (confusion matrix) za konfiguracije: 1 (gore levo), 2 (gore desno), 3 (dole levo) i 4 (dole desno)

IV. INFORMACIONI SISTEM ZA DETEKCIJU I KLASIFIKACIJU

Prodot predstavljenog istraživanja je operativni informacioni sistem koji omogućava detekciju i klasifikaciju dronova u realnom vremenu. Ovaj jednostavni sistem je razvijen u Python programskom okruženju, proširiv je i nadogradiv za buduću upotrebu i uvezivanje sa ostalim komponentama, u skladu sa potrebama. Blok šema informacionog sistema predstavljena je na Sl. 6.

Akvizicija podataka u realnom vremenu realizuje se analizatorom spektra Tektronix RSA306B USB, a pomoću programa koji priprema i segmentuje podatke za upotrebu u Procesu 2 aplikacije – Obrada. Proses obrade koristi istreniran DL model konfiguracije 3 i u toku rada, paralelno sa prikazom detekcije u GUI (Graphic User Interface) procesu, vrši upis detekcije u MySQL bazu radi evidencije i kasnije analize.

Ovaj sistem predstavlja osnovu za razvoj kompleksnijeg informacionog sistema koji će u skladu sa klasom detekcije, vršiti određene protivmere radi zaštite ili efikasnije upotrebe dostupnog elektromagnetskog spektra u slučaju koegzistencije više besposadnih niskoletećih platformi na istom području.



Sl. 6. Blok šema informacionog sistema za detekciju i klasifikaciju niskoletećih besposadnih platformi (SDKNPB)

V. ZAKLJUČAK

Istraživanjem predstavljenom u ovom radu došlo se do formiranja optimalnog modela dubokog učenja sposobnog da sa maksimalnom mogućom verovatnoćom klasifikuje detekcije emisija sa dronova u četiri moguće klase. Optimizacijom ulaznih parametara po strukturi i veličini, omogućena je detekcija i klasifikacija u realnom vremenu upotrebom „Real-Time“ analizatora spektra. Informacioni sistem koji je razvijen na bazi optimalnog DL modela ima mogućnost prikaza i zapisa detektovanih događaja, kao i mogućnost nadgradnje radi daljeg razvoja u željenom smeru.

Predstavljene konfiguracije predstavljaju adaptacije neuronske mreže od pet slojeva koja će u budućem istraživanju biti proširena i primenjena u razvijenom informacionom sistemu za mogućnost klasifikacije tri vrste drona u pet različitih scenarija upotrebe – nema drona (pozadinski šum), dron je povezan sa konzolom za upravljanje, dron lebdi, dron leti, dron leti i prenosi sliku.

ZAHVALNICA

Ovo istraživanje je izvedeno u okviru projekta VA-TT/3/20-22 koje finansira Univerzitet odbrane u Beogradu.

LITERATURA

- [1] E. Mitka and S. G. Mouroutsos, “Classification of Drones,” *Am. J. Enginnering Res.*, vol. 6, no. 7, pp. 36–41, 2017.
- [2] Altigator, “Drone, UAV, UAS, RPA or RPAS.” [Online]. Available: <https://altigator.com/drone-uav-uas-rpa-or-rpas/>. [Accessed: 25-Jun-2021].
- [3] Peacock, M., & Johnstone, M. N. (2013). Towards detection and control of civilian Unmanned Aerial Vehicles. *Australian Information Warfare and Security Conference*, June, 1–8. <https://doi.org/10.4225/75/57a847dfbefb5>
- [4] D-Fend. (2021). *D-Fend Solutions A.D. Ltd.* <https://www.d-fendsolutions.com/>
- [5] Nguyen, P., Ravindranatha, M., Nguyen, A., Han, R., & Vu, T. (2016). Investigating cost-effective RF-based detection of drones. *Proceedings of the 2nd Workshop on Micro Aerial Vehicle Networks, Systems, and Applications for Civilian Use*, October 2018, 17–22. <https://doi.org/10.1145/2935620.2935632>
- [6] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- [7] Nair, V., & Hinton, G. E. (2009). 3D Object Recognition with Deep Belief Nets. *Advances in Neural Information Processing Systems 22 - Proceedings of the 2009 Conference*, 22, 1339–1347. <https://proceedings.neurips.cc/paper/2009/file/6e7b33fdea3adc80ebd648ffb665bb8-Paper.pdf>
- [8] Pathak, A. R., Pandey, M., & Rautaray, S. (2018). Application of Deep Learning for object detection. *Procedia Computer Science*, 132, 1706–1717. <https://doi.org/10.1016/j.procs.2018.05.144>
- [9] Peng, S., Jiang, H., Wang, H., Alwageed, H., Zhou, Y., Sebdani, M. M., & Yao, Y.-D. (2019). Modulation classification based on signal constellation diagrams and Deep Learning. *IEEE Transactions on Neural Networks and Learning Systems*, 30(3), 718–727. <https://doi.org/10.1109/TNNLS.2018.2850703>
- [10] Zha, X., Peng, H., Qin, X., Li, G., & Yang, S. (2019). A Deep Learning framework for signal detection and modulation classification. *Sensors*, 19(18), 4042. <https://doi.org/10.3390/s19184042>
- [11] Zhou, S., Yin, Z., Wu, Z., Chen, Y., Zhao, N., & Yang, Z. (2019). A robust modulation classification method using convolutional neural networks. *EURASIP Journal on Advances in Signal Processing*, 2019(1), 21. <https://doi.org/10.1186/s13634-019-0616-6>
- [12] Alhadhrami, E., Al-Mufti, M., Taha, B., & Werghi, N. (2019). Learned micro-Doppler representations for targets classification based on spectrogram images. *IEEE Access*, 7, 139377–139387. <https://doi.org/10.1109/ACCESS.2019.2943567>
- [13] Karita, S., Watanabe, S., Iwata, T., Ogawa, A., & Delcroix, M. (2018). Semi-Supervised End-to-End Speech Recognition. *Interspeech 2018*, 2–6. <https://doi.org/10.21437/Interspeech.2018-1746>
- [14] Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1746–1751. <https://doi.org/10.3115/v1/D14-1181>
- [15] Narkhede, P., Walambe, R., Mandaokar, S., Chandel, P., Kotecha, K., & Ghinea, G. (2021). Gas detection and identification using multimodal artificial intelligence based sensor fusion. *Applied System Innovation*, 4(1), 1–14. <https://doi.org/10.3390/asi4010003>
- [16] Patel, J., Shah, S., Thakkar, P., & Kotecha, K. (2015). Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. *Expert Systems with Applications*, 42(1), 259–268. <https://doi.org/10.1016/j.eswa.2014.07.040>
- [17] Mohammad F. Al-Sa'd, Abdulla Al-Ali, Amr Mohamed, Tamer Khattab, Aiman Erbad, (2019). RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database, *Future Generation Computer Systems*, 100, 86–97, ISSN 0167-739X, <https://doi.org/10.1016/j.future.2019.05.007>
- [18] Sazdić-Jotić, B. M., Pokrajac, I., Bajčetić, J., Bondžulić, B. P., Joksimović, V., Šević, T., & Obradović, D. (2020). *VTI_DroneSET_FFT*. Mendeley Data. <https://doi.org/10.17632/s6tgnnp5n2.1>
- [19] <https://github.com/nageshsinghc4/Audio-Data-Analysis-Using-Deep-Learning>
- [20] Kannojia, S.P., & Jaiswal, G. (2018). Effects of Varying Resolution on Performance of CNN based Image Classification An Experimental Study, *International Journal of Computer Sciences and Engineering*, 6 (9), 451-456, E-ISSN 2347-2693, <https://doi.org/10.26438/ijcse/v6i9.451456>
- [21] Al-Emadi, S., Al-Senaid, F. (2020). Drone Detection Approach Based on Radio-Frequency Using Convolutional Neural Network, *2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT)*, 29-34, <https://doi.org/10.1109/ICIoT48696.2020.9089489>

ABSTRACT

The research which is described in this paper presents the potentials of the Drone Detection and Classification System (DDCS) proposed concept which is based on Deep Learning (DL) methods. The aim of the project is the development of the operational system which would be capable of real time drone detection and classification based on their radio emission characteristics. Detection and classification methods used in this research are built with developed convolutional neural network which is trained using the formed radio emission database consisted of recordings originated from several commercially available drones. The initial testing of the research results shows 100 % detection and classification probability for four independent classes – no drone, drone 1, drone 2 and drone 3 which is a good basis for a future more detailed classification development.

Drone Detection and Classification System (DDCS)

Mohammed Mokhtari, Jovan Bajcetic and Boban Sazdic-Jotic