

Pokładowy system identyfikacji kamuflażu „swój- obcy” dedykowany BSP rozpoznawczym

Streszczenie. Niniejszy artykuł przedstawia możliwość rozpoznania obrazowego przynależności personelu wojskowego w systemie „swój- obcy” dedykowany dla bezzałogowego statku powietrznego (BSP), który wykorzystuje sztuczną inteligencję do klasyfikacji kamuflażu. Rozpoznanie i identyfikacja personelu wojskowego polega na przetworzeniu i wyseparowaniu próbki obrazu, a następnie rozróżnieniu charakterystycznego dla każdego rodzaju wojsk wzoru kamuflażu za pomocą wyuczonej wcześniej sztucznej inteligencji. W artykule zawarto wstępną analizę działania stworzonego oprogramowania.

Abstract. This article presents the possibility of image recognition of the affiliation of military personnel in the “friend- foe” system dedicated to an unmanned aerial vehicle (UAV), which uses artificial intelligence to classify camouflage. Recognition and identification of military personnel involves processing and separating an image sample, and then distinguishing the camouflage pattern characteristic of each type of army using previously learned artificial intelligence. The article contains a preliminary analysis of the operation of the created software. (On-board “friend- foe” camouflage identification system dedicated to reconnaissance UAVs).

Słowa kluczowe: BSP, sztuczna inteligencja, rozpoznanie obrazowe, kamuflaż.

Keywords: UAV, artificial intelligence, image reconnaissance, camouflage.

Wstęp

Na nowoczesnym polu walki rozpoznanie obrazowe w celach zwiadowczych jest prowadzone głównie za pomocą zdjęć satelitarnych oraz obrazów pozyskanych za pomocą bezzałogowych statków powietrznych (BSP) [1]. Obecnie szeroko wykorzystuje się mikrokomputery pokładowe do realizacji zadań przetwarzania i transmisji obrazu. Mimo małych rozmiarów i małej masy, mikrokomputery pokładowe posiadają wystarczającą moc obliczeniową do obsługi i wykonywania niezłożonych modeli uczenia maszynowego [2]. Sztuczna inteligencja wykonywana na pokładowym mikrokomputerze, bez konieczności komunikacji z zewnętrznymi zasobami i internetem, może wspomagać pracę operatora BSP rozpoznawczego.

Jednym z zadań postawionych przed rozpoznawczymi bezzałogowymi systemami powietrznymi i ich operatorami jest identyfikacja obserwowanego personelu wojskowego i określenie ich przynależności. W przypadku operatorów, identyfikacja personelu wojskowego w czasie rzeczywistym na transmitowanym przez BSP obrazie jest utrudniona ze względu na jednoczesne sterowanie i kontrolę bezzałogowca i nie są w pełni skupieni na analizie transmitowanego obrazu. Jednakże, dzięki zastosowaniu systemu wspomagania analizy obrazu „swój- obcy” możliwe jest częściowe odciążenie osoby kontrolującej lot BSP z zadań analitycznych. System automatycznie identyfikuje obrazy personelu wojskowego dzięki wykorzystaniu sztucznej inteligencji klasyfikującej obrazy.

System wspomagania analizy obrazu „swój- obcy”

Głównym celem powstania tego oprogramowania jest wspomaganie pracy operatora podczas misji rozpoznawczych i służy do wspomnienia procesu identyfikacji personelu wojskowego pod kątem przynależności do danego rodzaju wojsk. Jest to istotne zadanie, gdyż na tej podstawie prowadzi się ocenę koncentracji wojsk własnych i nieprzyjaciela oraz możliwa jest analiza rozlokowania personelu. Ponadto wspomnienie operatora zmniejsza ryzyko prowadzenia tak zwanego ognia przyjacielskiego (ang. *friendly fire*) podczas dynamicznie zmieniającej się sytuacji na polu walki.

System wspomagania analizy obrazu „swój- obcy” jest oprogramowaniem złożonym z:

- modułu przetwarzania obrazu,
- modułu uczenia maszynowego zawierający autorskie ułożenie warstw sieci neuronowej dostosowanych do opracowywanego problemu,
- modułu wykonywania modelu uczenia maszynowego,
- modułu oznaczania personelu na wyświetlanym obrazie.

Oprogramowanie powstało w języku programowania Python w wersji interpretera 3.10 z wykorzystaniem pakietów takich jak Tensorflow, Keras, PIL oraz Numpy.

Tensorflow jest to otwarty-źródłowa (ang. *open source*) biblioteka programistyczna. Została stworzona przez Google Brain Team i wydana w 2015 roku. Biblioteka ta jest wykorzystywana w głębokich sieciach neuronowych i uczeniu maszynowym [3]. Posiada możliwość wykorzystania gotowych modeli sieci neuronowej i tworzenia własnej, dedykowanej sieci. W celu zwiększenia wydajności silnik wykonawczy został napisany w języku programowania C++, jednakże posiada interfejsy w innych językach, między innymi w języku Python [3].

Keras jest wysokopoziomową warstwą API (ang. *Application Programming Interface*, tłum. *Interfejs Programu Aplikacyjnego*) która służy ułatwieniu użytkownikowi tworzenia modelu uczenia maszynowego [3]. Posiada prostą i intuicyjną składnię tworzenia kolejnych warstw sieci neuronowej oraz ustalania ich parametrów.

Python Imaging Library (PIL) to otwarty-źródłowa biblioteka programistyczna Pythona, która umożliwia obsługę grafiki w programie. Jej funkcjonalności to przykładowo otwieranie, zapisywanie i modyfikowanie plików graficznych. Do dostępnych w bibliotece modyfikacji obrazów należą między innymi zmiana rozdzielczości, kanałów kolorów, obrót grafiki czy nakładanie filtrów. Obecnie popularne jest „rozgałęzienie” (ang. *fork*) PIL - Pillow [4].

Numpy to otwarty-źródłowa biblioteka programistyczna Pythona. Umożliwia dodanie do oprogramowania w tym języku obsługi dużych, wielowymiarowych macierzy i tabel w celach prowadzenia między innymi obliczeń numerycznych i przechowywania danych [5].

Wyżej opisane biblioteki i pakiety zostały wykorzystane do budowy oprogramowania, którego zadania i funkcjonalności kształtują się następująco:

- wczytanie zapisywanych z kamery BSP obrazów,
- wyseparowanie przybliżonego obrazu kamuflażu,
- przekształcenie kanału kolorów RGB na obraz czarno-biały uwzględniając kontrast i saturację modyfikowanego obrazu,
- przekształcanie obrazów do odpowiedniej rozdzielczości,
- wykonanie wyuczonego modelu uczenia maszynowego dla każdego obrazu,
- klasyfikacja obrazu jako „swój” lub „obcy”,
- wskazanie operatorowi klasyfikacji obrazu poprzez podświetlenie celu na kolor zielony („swój”), żółty (niepewność oceny) bądź kolor czerwony („obcy”).

Odpowiednia klasyfikacja obrazu jest najważniejszym i kluczowym elementem oprogramowania systemu wspomagania analizy obrazu „swój- obcy”.

Klasyfikacja obrazu

Problem odpowiedniej klasyfikacji obrazu ma największy wpływ na przydatność i skuteczność zastosowania oprogramowania „swój- obcy” na dynamicznie zmieniającym się polu walki. Klasyfikacja jednoetykietowa jest najczęstszym zadaniem klasyfikacyjnym w klasyfikacji obrazów nadzorowanych. Każdy obraz w klasyfikacji z pojedynczą etykietą ma jedną etykietę lub adnotację. Model generuje pojedynczą wartość lub prognozę dla każdego widzianego obrazu. Wynikiem modelu jest wektor o długości równej liczbie klas i wartości wskazującej ocenę przynależności obrazu do tej klasy. Funkcja aktywacji Softmax skaluje logity do wartości prawdopodobieństwa (prawdopodobieństwo klasyfikacji obrazu w zakresie od 0% do 100%) i służy do zapewnienia, że wyniki sumują się do jedności (100%), a maksymalna liczba wyników jest brana pod uwagę przy tworzeniu wyniku modelu [6, 7]:

$$(1) \quad S(z)_i = \frac{e^{z_i}}{\sum_j^n e^{z_j}}$$

gdzie: $S(z)_i$ – wartość funkcji aktywacji Softmax, z – wektor wejściowy do funkcji softmax składający się z n elementów przynależących do n klas, z_i – i -ty element wektora z , $\sum_j^n e^{z_j}$ – człon normalizacyjny.

Identyfikacja obrazu polega na zaklasyfikowaniu obrazu do odpowiedniej etykiety. W analizie przedstawionej w tym artykule etykiety są dwie – „swój” i „obcy”. Na potrzeby analizy wstępnej określono, że podświetlenie operatorowi jednostki personelu wojskowego na kolor zielony (etykieta „swój”) następuje po osiągnięciu 65% prawdopodobieństwa. Podświetlenie na kolor żółty (niepewność oceny) następuje po osiągnięciu prawdopodobieństwa mniejszego niż 65% i większego niż 35%. Podświetlenie jednostki personelu wojskowego na kolor czerwony następuje po osiągnięciu prawdopodobieństwa poniżej 35%.

Analiza wstępna klasyfikacji obrazu, przedstawiona w niniejszym artykule, służy do zidentyfikowania słabych punktów funkcjonalności programu oraz problemów klasyfikacyjnych i nie należy jej rozumieć jako ramy działania finalnej wersji oprogramowania.


Zbiór danych służących do uczenia maszynowego

Największy wpływ na skuteczność klasyfikacji wykonywanego modelu uczenia maszynowego ma zbiór danych jakim jest uczony model uczenia maszynowego. Do stworzenia wstępnego zbioru danych do uczenia maszynowego wykorzystano dwa wzory kamuflażu - wz. 93 „Pantera”, który jest etatowym wzorem kamuflażu Wojska

Polskiego oraz kamuflażu EMR (ros. Единая маскировочная расцветка) [9]. Wz. 93 składa się z charakterystycznych plam w kolorze ciemnozielonym, brązowym i czarnym nadrukowanych na oliwkowozielonym tle (rysunek 1.) [8]. EMR to pikselowana wersja czarnych, brązowych i ciemnozielonych pikseli na jasnozielonym tle (rysunek 2.).



Rys. 1. Wzór kamuflażu wz. 93 „Pantera” [10]



Rys. 2. Wzór kamuflażu EMR [9]

Na podstawie rysunku 1. oraz rysunku 2. Został wygenerowany sztucznie zbiór danych do uczenia maszynowego modelu sieci neuronowej opisywanego oprogramowania. Do stworzenia zmodyfikowanych wersji obrazów poddanych obrotom, zmianie kontrastu i nasycenia barw, zmiany kąta widzenia wzoru kamuflażu i oddalenia lub zbliżenia obrazu został wykorzystany pakiet Augmentor [11]. Kanał RGB obrazu został przekształcony do czarno-białego. Określono odpowiednie poziomy prawdopodobieństwa wystąpienia modyfikacji obrazu i poziomy graniczne saturacji barw oraz wygenerowano 2000 sztucznych próbek obrazu do każdej etykiety – „swój” oraz „obcy”. Na rysunku 3. oraz rysunku 4. Przedstawiono po jednym z przykładów zmodyfikowanych wzorów kamuflażu dla każdej z etykiet. Każdy z obrazów, który jest używany do uczenia maszynowego jest unikalny.



Rys. 3. Przykład zmodyfikowanego wzoru kamuflażu wz. 93 „Pantera” pochodzący ze sztucznie wygenerowanego zbioru danych do uczenia maszynowego



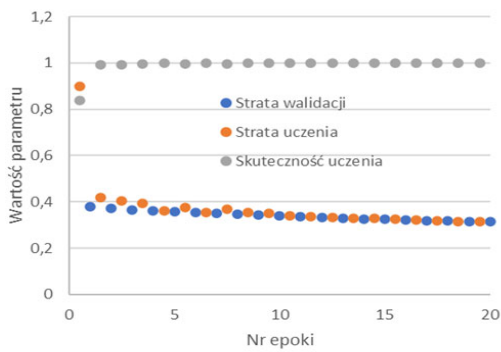
Rys. 4. Przykład zmodyfikowanego wzoru kamuflażu EMR pochodzący ze sztucznie wygenerowanego zbioru danych do uczenia maszynowego

Zbiór walidacyjny do uczenia maszynowego został określony na poziomie 50%. Rozdzielczość obrazu do uczenia maszynowego została zredukowana do poziomu 100 pikseli na 100 pikseli w paczkach (ang. *batch size*) po 32 sztuki.

Wyniki

Oprogramowanie testowano na rzeczywistych obiektach takich jak zdjęcie żołnierza (oraz dwóch przybliżeń na mundur), hełmu będącego na wyposażeniu wojska polskiego, Puszczy Białowiejskiej oraz munduru w kamuflażu EMR.

Skuteczność modelu uczenia maszynowego na zbiorze walidacyjnym wyniosła 100%. Na rysunku 5. pokazano przebieg straty uczenia oraz walidacji w funkcji liczby epok.



Rys. 5. Wartości parametrów uczenia maszynowego


Następnym krokiem było przebadania modelu uczenia maszynowego było sprawdzenie skuteczności klasyfikacji na obrazach pochodzących spoza zbioru walidacyjnego. Na rysunkach 6., 7., 8., 9., 10. oraz 11. Przedstawiono obrazy pochodzące spoza zbioru walidacyjnego oraz zbioru uczenia maszynowego.



Rys. 6. Zdjęcie stojącego żołnierza. Oryginalny obraz został przycięty ze względu na ochronę danych osobowych



Rys. 7. Zbliżenie na klatkę piersiową żołnierza



Rys. 8. Zdjęcie pleców żołnierza



Rys. 9. Zdjęcie hełmu będącego na wyposażeniu WP



Rys. 10. Zdjęcie Puszczy Białowiejskiej



Rys. 11. Zdjęcie koszulki w kamuflażu EMR

Wyniki klasyfikacji dla obrazów znajdujących się na rysunkach 6. – 11. znajdują się w tabeli 1.

Tabela 1. Parametry klasyfikacji

Obraz	Prawdopodobieństwo „obcy”, %	Prawdopodobieństwo „swój”, %
Rys. 6.	34	66
Rys. 7.	24	76
Rys. 8.	23	77
Rys. 9.	27	73
Rys. 10.	48	52
Rys. 11.	54	46

Wnioski

Najlepsze wyniki klasyfikacji obrazów spoza zbioru uczenia i walidacji dają zbliżenia obrazów na mundur. Charakterystyczny wzór kamuflażu wz. 93 jest łatwo rozpoznawalny przez sztuczną inteligencję. „Pantera” była projektowana tak, aby kamuflowała się pośród polskiej szaty roślinności, jednakże obrazy Puszczy Białowieskiej są klasyfikowane jako znacznie różne od wz. 93. W przypadku kamuflażu EMR wymagane są dalsze prace nad klasyfikacją. W tej, wczesniej wersji oprogramowania personel wojskowy Wojska Polskiego byłby podświetlany na zielono jako „swój”, natomiast pozostałe obrazy byłyby podświetlone na żółto jako obraz z niepewną oceną. Zauważono, że ze względu na pikselizację kamuflażu EMR może być wymagane zwiększenie rozdzielczości w jakiej obraz jest przetwarzany przez model uczenia maszynowego. Testowany model sieci neuronowej pozwala na wykonanie programu na platformie mobilnej takiej jak BSP. Zużycie zasobów mikrokomputera wskazuje na możliwość zwiększenia rozdzielczości przetwarzanych obrazów. Przedstawiony w artykule model uczenia maszynowego będący elementem systemu wspomaganie analizy obrazu „swój – obcy” wykazuje znaczny potencjał do dalszego rozwoju.

Dalsze prace

Ze względu na duży potencjał rozwoju i późniejszego wykorzystania systemu wspomaganie analizy obrazu „swój-obcy” prace będą kontynuowane. Planowane jest zwiększenie rozdzielczości przetwarzanych przez model uczenia maszynowego obrazów. Granica maksymalnej rozdzielczości zostanie wyznaczona poprzez sprawdzenie maksymalnego obciążenia pokładowego mikrokomputera BSP. Po wyznaczeniu zakresu rozdzielczości, określone zostanie maksymalna odległość z jakiej może być identyfikowany obiekt za pomocą dostępnych na rynku kamer dedykowanych BSP. Określone zostanie prawdopodobieństwo fałszywych sygnałów i identyfikacji. Następnie zostaną wyuczone kolejne rodzaje kamuflażu i zostaną sprawdzone dalsze ograniczenia systemu wspomaganie analizy obrazu „swój- obcy” dedykowanego dla BSP.

Autorzy: mgr inż. Korneliusz Sierpowski, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: korneliusz.sierpowski@awl.edu.pl; dr inż. Grzegorz Debita, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: grzegorz.debita@awl.edu.pl; mgr Tomasz Śliwak-Orlicki, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: tomasz.sliwak-orlicki@awl.edu.pl; inż. Monika Zamłyńska, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: monika.zamlynska@awl.edu.pl; inż. Igor Mielczarek, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: igor.mielczarek@awl.edu.pl; inż. Jakub Grzesiak, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: jakub.grzesiak@awl.edu.pl; inż. Sebastian Szymański, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: sebastian.szymanski@awl.edu.pl; kpt. dr inż. Krzysztof Górski, Akademia Wojsk Lądowych im. gen. Tadeusza Kościuszki we Wrocławiu, Katedra Informatyki, ul. Piotra Czajkowskiego 109, 51-147 Wrocław, E-mail: krzysztof.gorski@awl.edu.pl.

LITERATURA

- [1] Kanat Ö., *The Significance of Unmanned Aerial Vehicles (UAVs) in Strategic Contexts*. Journal of Anadolu Strategy (2023), 5, 75-87.
- [2] Ahmed F., Jenihin M., *A Survey on UAV Computing Platforms: A Hardware Reliability Perspective*, Sensors (2022), doi: 10.3390/s22166286.
- [3] Oficjalne repozytorium biblioteki Tensorflow w serwisie GitHub. github.com/tensorflow (dostęp 14.04.2024).
- [4] Oficjalna dokumentacja pakietu Pillow. <https://pillow.readthedocs.io/en/stable/reference/Image.html> (dostęp 14.04.2024).
- [5] Oficjalne repozytorium biblioteki Numpy w serwisie GitHub. github.com/numpy/numpy (dostęp 14.04.2024).
- [6] Goodfellow I., Bengio Y., Courville A., 6.2.2.3 Softmax Units for Multinoulli Output Distributions, *Deep Learning* (2016), MIT Press, 180- 184. ISBN 978-0-26203561-3.
- [7] Bishop C. M., *Pattern Recognition and Machine Learning* (2006), Springer, ISBN 0-387-31073-8.
- [8] Królikowski H., *Specjalna Formacja Wojskowa GROM im. Ciecociemnych Spadochroniarzy Armii Krajowej* (2001), ISBN 83-915131-0-6.
- [9] Виды камуфляжа - ОБЗОР | ГОРЯЧАЯ ТОЧКА. <https://web.archive.org/web/20210417150939/https://goryachaya-tochka.ru/novosti/zapis-dva.html> (dostęp 14.04.2024).
- [10] Kamuflaż „Pantera”. https://pl.wikipedia.org/wiki/Kamufla%C5%BC_wz._93_%E2%80%9EPantera%E2%80%9D#/media/Plik:Wz._93_Pantera.png (dostęp 14.04.2024).
- [11] Oficjalne repozytorium pakietu Augmentor. <https://github.com/mbloice/Augmentor> (dostęp 14.04.2024).