

**STRESZCZENIE ROZPRAWY DOKTORSKIEJ**  
**„Big data w systemach rozpoznania wojskowego”**  
**Kamila MATELA**

Odpowiedni system wspomagania decyzji, dostosowany do wymogów danego pola walki winien być opracowany we współpracy z przyszłymi jego użytkownikami – i to nie tylko (choć szczególnie) w zakresie interfejsu użytkownika, lecz także wszystkich innych jego modułów. Dlatego też specjalizowane, przetestowane systemy wspomagania decyzji dla niektórych zastosowań są niezwykle istotne<sup>1</sup>.

Punktem wyjścia do stworzenia opracowania jest wyjaśnienie w pierwszym rozdziale kluczowych zagadnień z zakresu *big data*, widzenia komputerowego oraz algorytmów klasyfikacji. Z uwagi na fakt, że dane wizualne stanowią największą część globalnego obiegu informacyjnego, praca koncentruje się na algorytmach analizy obrazu, która jednocześnie stanowi istotną część obszaru rozpoznania wojskowego.

W rozdziale drugim przedstawione zostały strategie aktywnego uczenia się (ang. *active learning*) przez maszynę, w tym wyjaśniona została metoda MCADL (*Multi-criteria active deep learning for image classification*) stanowiąca opracowanie naukowców z Uniwersytetów Hunan i Shandong, którzy deklarują, iż jako pierwsi na świecie opracowali metodę wielokryterialnego doboru próbek do treningu<sup>2</sup>. Z uwagi na przedstawioną przez autorów implementację w technologii Tensorflow, która statystycznie zaczyna ustępować nowocześniejszemu framework'owi Pytorch<sup>3</sup>, zdecydowano o przeprowadzeniu implementacji metody MCADL również z wykorzystaniem własnego kodu, opracowanego w technologii Pytorch, w oparciu o bazę danych MINST (ang. *Modified National Institute of Standards and Technology*).

Rozdział trzeci przedstawia najważniejsze aspekty z zakresu analizy wielokryterialnej związane z realizacją prac w obszarze klasyfikacji obrazu, w tym w szczególności sposób implementacji analizy wielokryterialnej bazującej na metodzie punktu odniesienia, oraz zakres interaktywnego wyznaczenia rozwiązań efektywnych w algorytmie i powstałe w ich wyniku nowe rozwiązanie. W celach wykazania skuteczności przyjętego sposobu optymalizacji zaimplementowano dodatkowo kolejną metodę, którą zintegrowano z wypracowanym rozwiązaniem i dzięki temu osiągnięto najlepsze rezultaty.

W rozdziale czwartym odtworzono przebieg eksperymentów zrealizowanych w pracy doktorskiej. Przedstawiono charakterystykę obszaru wdrożenia - rozpoznania wojskowego. Mając to na względzie szczególne miejsce zostało zapewnione eksperymentom przeprowadzonym na bazie CIFAR-10, która ze względu na swą różnorodność może być traktowana analogicznie do zbiorów tworzonych w ośrodkach zobrazowania wojskowego. Tryb *active learningu* wzmacnia efekt wykorzystania zbiorów, w których występują braki danych,

---

<sup>1</sup> A. Wierzbiński, Teoria i Praktyka Wspomagania Decyzji, p. 27

<sup>2</sup> J. Yuan, X. Hou, Y. Xiao, D. Cao, W. Guan i L. Nie, „Multi-criteria active deep learning for image classification”, Knowledge-Based Systems 172, p. s. 86–94, 2019.

<sup>3</sup> [Online]. Available: <https://www.projectpro.io/article/pytorch-vs-tensorflow-2021-a-head-to-head-comparison/416>. [Data uzyskania dostępu: 16 10 2022].

gdyż zakłada uczenie się modelu na ograniczonej puli etykiet. Ponadto podsumowano poczynione obserwacje wraz z porównaniem z opracowanymi i zaimplementowanymi metodami dokonującymi klasyfikacji obiektów na obrazie.

Wnioski zawierają opis najważniejszych faktów dla opracowanej nowej metody klasyfikacji obiektów na obrazie, w ramach niniejszej pracy doktorskiej.