

RADA NAUKOWA DYSCYPLINY
INFORMATYKA TECHNICZNA I TELEKOMUNIKACJA POLITECHNIKI WARSZAWSKIEJ
zaprasza na
OBRONĘ ROZPRAWY DOKTORSKIEJ

mgr. inż. Kamili Bogny Mateli,
która odbędzie się w dniu **1 grudnia 2023 roku**, o godzinie **10:00** w trybie hybrydowym
Temat rozprawy:
„Big data w systemach rozpoznania wojskowego”

Promotor: dr hab. inż. Andrzej Stachurski, prof. uczelni – Politechnika Warszawska

Recenzenci: dr hab. inż. Roman Stanisław Deniziak, prof. uczelni – Politechnika Świętokrzyska

prof. dr hab. inż. Mateusz Pasternak – Wojskowa Akademia Techniczna

dr hab. Marek Sikora, prof. uczelni – Politechnika Śląska

Obrona odbędzie się hybrydowo - w Sali nr 116 Gmachu Elektroniki Politechniki Warszawskiej oraz na platformie MS Teams. Osoby zainteresowane uczestnictwem w obronie zdalnie proszone są o zgłoszenie chęci uczestnictwa w formie elektronicznej na adres sekretarza komisji: dr hab. inż. Jacek Misiurewicz – email: jacek.misiurewicz@pw.edu.pl, do dnia 30 listopada godz. 12:00.

Z rozprawą doktorską i recenzjami można zapoznać się w Czytelni Biblioteki Głównej Politechniki Warszawskiej, Warszawa, Plac Politechniki 1.

Streszczenie rozprawy doktorskiej i recenzje są zamieszczone na stronie internetowej: <https://www.bip.pw.edu.pl/Postepowania-w-sprawie-nadania-stopnia-naukowego/Doktoraty/Wszczete-po-30-kwietnia-2019-r/Rada-Naukowa-Dyscypliny-Informatyka-Techniczna-i-Telekomunikacja/mgr-Kamila-Bogna-Matela>

Przewodniczący Rady Naukowej Dyscypliny
Informatyka Techniczna i Telekomunikacja
Politechniki Warszawskiej
dr hab. inż. Jarosław Arabas, prof. uczelni

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 istotne¹.

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 treningu². Z uwagi na przedstawioną przez autorów implementację w technologii Tensorflow, która statystycznie zaczyna ustępować nowoczesniejszemu framework'owi Pytorch³, 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,

¹ A. Wierzbicki, Teoria i Praktyka Wspomagania Decyzji, p. 27

² 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.

³ [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.

Dr hab. inż. Roman Stanisław Deniziak, prof. PŚk
Katedra Systemów Informatycznych
Politechnika Świętokrzyska
ul. 1000-lecia Państwa Polskiego 7
25-314 Kielce

Kielce, 12.09.2023

Rada Naukowa Dyscypliny
INFORMATYKA TECHNICZNA
I TELEKOMUNIKACJA
Sekretariat
Data wpływu...15.09.23r...
Numer.....

Recenzja rozprawy doktorskiej dla Rady Naukowej Dyscypliny Informatyka Techniczna i Telekomunikacja Politechniki Warszawskiej

Tytuł rozprawy: Big data w systemach rozpoznania wojskowego

Autor rozprawy: mgr inż. Kamila Matela

Promotor rozprawy: dr hab. inż. Andrzej Stachurski

1. Cel, zakres, charakter i teza rozprawy

Rozprawa dotyczy problematyki klasyfikacji obrazów. Punktem wyjścia jest metoda wielokryterialnego aktywnego uczenia maszynowego MCADL, opracowana przez chińskich naukowców w 2019 roku. Autorka skupiła się na metodach opartych na aktywnym uczeniu maszynowym, co ukierunkowuje tematykę pracy na problemy, w których trudno jest wybrać reprezentatywny zbiór treningowy na etapie uczenia nadzorowanego. Celem pracy było uzyskanie większej dokładności niż w metodzie MCADL poprzez opracowanie skuteczniejszej metody doboru próbek uczących. Autorka zaproponowała metodę punktów odniesienia, znaną z optymalizacji wielokryterialnej w teorii wspomagania decyzji. Zostało to sformułowane w postaci następującej tezy pracy:

Zastosowanie metody punktów odniesienia w algorytmie „Multi-criteria active deep learning for image classification (MCADL)”, zwiększa dokładność analizy obrazu i wykazuje wyższość nad wykorzystywaną w tymże algorytmie metodą ważenia kryteriów.

Tak sformułowana teza jasno określa cel pracy, chociaż użycie pojęcia „dokładność analizy obrazu” wydaje się zbyt uogólnieniem celu opracowywanej metody, bardziej precyzyjne byłoby użycie zwrotu „klasyfikacji obrazów”, co bezpośrednio odnosi się do celu tej metody oraz pojęcia dokładności.

Cel pracy został określony jako 7 celów szczegółowych, opisujących poszczególne etapy metodyki badawczej. Na podstawie analizy słabych stron metody MCADL zakładano opracowanie bardziej skutecznych metod wyboru próbek uczących, a następnie weryfikację dokładności opracowanej metody dla 2 standardowych zbiorów obrazów. Wykazanie tezy odbyło się poprzez porównanie uzyskanych wyników z wynikami uzyskanymi za pomocą oryginalnej metody.

Praca ma charakter projektowo-doświadczalny. Autorka zaproponowała metody inicjalizacji uczenia, metody analiz koszt-efekt oraz metody doboru próbek uczących wraz ze strategią wyboru punktów odniesienia. Następnie, zaimplementowano opracowane metody i wykonano szereg eksperymentów oceniających skuteczność zaproponowanych metod dla przykładowych zestawów danych.

2. Analiza źródeł

Bibliografia obejmuje 109 pozycji w tym 2 publikacje naukowe własnego autorstwa. Jednak 25 pozycji dotyczy stron lub dokumentacji internetowych, które nie posiadają tytułu ani autora i trudno je uznać za pozycje bibliograficzne. Można zauważyć, że tematyka wykorzystanej literatury jest zbyt szeroka i wiele pozycji wykracza poza tematykę pracy lub jest przestarzała. Biorąc pod uwagę problematykę pracy, bibliografia powinna być skupiona na tematyce klasyfikacji obrazów, w szczególności z wykorzystaniem aktywnego uczenia maszynowego. Brakuje również bibliografii z zakresu metod analizy obrazów dedykowanych dla zastosowań wojskowych. Przykładowo publikacja przeglądowa dotycząca aktywnego uczenia maszynowego z 2009 roku (pozycja 45) nie prezentuje najbardziej aktualnego stanu wiedzy. Bardziej adekwatne byłyby takie pozycje jak:

- Yang, M., Nazir, S., Xu, Q., & Ali, S. (2020). Deep learning algorithms and multicriteria decision-making used in big data: a systematic literature review. *Complexity*, 2020,
- Liu, P., Wang, L., Ranjan, R., He, G., & Zhao, L. (2022). A survey on active deep learning: from model driven to data driven. *ACM Computing Surveys (CSUR)*, 54(10s), 1-34,
- Bengar, J. Z., van de Weijer, J., Fuentes, L. L., & Raducanu, B. (2022). Class-balanced active learning for image classification. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 1536-1545).

które nie zostały uwzględnione w bibliografii.

Przegląd literatury z zakresu big data został przedstawiony w rozdziale 1. Przegląd ten ma raczej charakter podręcznikowy, przedstawiający najbardziej znane rozwiązania z zakresu big data, brakuje tu przedstawienia najnowszych rozwiązań, szczególnie z zakresu klasyfikacji obrazów.

Również rozdział 2 zawiera przegląd literatury, przy czym tutaj dotyczy to zagadnień aktywnego uczenia maszynowego i sieci neuronowych. Rozdział ten zawiera też opis metody MCADL.

Przegląd rozwiązań z zakresu optymalizacji jest przedstawiony w p. 1 rozdziału 3. Również tutaj, podobnie jak w rozdziale 1, tematyka jest przedstawiona zbyt szeroko i wykracza poza główną tematykę pracy. Nie ma potrzeby przedstawienia przeglądu różnych metod optymalizacji jedno- i wielo-kryterialnej, skoro praca jest ograniczona do konkretnej metody podanej w tezie.

Autorka przedstawiła również krytyczną ocenę niektórych przedstawianych rozwiązań, np. różnych strategii aktywnego uczenia. Biorąc pod uwagę cel pracy, pomimo pewnych braków, przedstawiony przegląd literatury można uznać za wystarczający w kontekście

przedstawienia zagadnień, które są wykorzystywane w opracowywanej metodzie. Natomiast nie przedstawia w sposób kompletny aktualnego stanu wiedzy w zakresie klasyfikacji obrazów.

3. Metodyka badań

Przyjęta metodyka badań zakładała eksperymentalną ocenę metody MCADL, następnie modyfikację tej metody poprzez:

- różne metody inicjalizacji,
- nowej metody wyboru zbioru próbek do etykietowania opartej na punktach odniesienia.

Skuteczność tak opracowanej metody została oceniona na drodze eksperymentalnej dla 2 standardowych zbiorów danych MNIST i CIFAR-10. Te same zbiory były wykorzystywane przez autorów metody MCADL. Jako kryterium oceny skuteczności zastosowano metrykę dokładności stosowaną w ocenie metod uczenia maszynowego. Takie podejście należy uznać za poprawne i właściwe z punktu widzenia celu pracy.

Autorka formułując tezę założyła, że zastosowanie punktów odniesienia na etapie wyboru zbioru próbek do etykietowania pozwoli na zwiększenie skuteczności klasyfikacji obrazów w porównaniu ze stosowaną metodą ważenia kryteriów, przy tych samych kryteriach oceny próbek. Takie założenie nie jest oczywiste ale na podstawie doświadczeń uzyskanych w zastosowaniu tej metody do optymalizacji procesów decyzyjnych można było postawić taką tezę, że metoda punktów odniesienia będzie również skuteczna w zakresie wyboru zbiorów danych dla aktywnego uczenia maszynowego.

Autorka uzyskała zamierzony cel pracy. Dowodem tezy są uzyskane wyniki wykonanych eksperymentów. Dla 2 standardowych zbiorów danych uzyskano wyniki znacząco lepsze niż wyniki otrzymane za pomocą metody MCADL. Wykonane zostało również wiele eksperymentów dodatkowych pokazujących szczegóły działania opracowanej metody. W szczególności wartościowe są wyniki pokazujące wybór próbek za pomocą poszczególnych kryteriów, a także wpływ różnych metod inicjalizacji na jakość uzyskanych wyników.

4. Oryginalność uzyskanych wyników

Najważniejsze oryginalne osiągnięcia autorki przedstawione w pracy to:

1. Opracowanie metody stosującej punkty odniesienia do wyboru zbiorów treningowych dla potrzeb klasyfikacji obrazów metodą aktywnego uczenia maszynowego.
2. Opracowanie i wykonanie badań z zakresu różnych metod inicjalizacji metody klasyfikacji obrazów.
3. Wbudowanie w algorytm uczenia maszynowego metody margin sampling.
4. Wykonanie eksperymentów dla standardowych zbiorów obrazów, pokazujących słabość metody MCADL i jednocześnie skuteczność zaproponowanej metody.

Ważnym rezultatem pracy jest również implementacja opracowanych metod w postaci oryginalnych narzędzi umożliwiających uczenie i tworzenie klasyfikatora obrazów poprzez aktywne uczenie maszynowe.

W odniesieniu do aktualnego stanu wiedzy rozwiązania zaproponowane przez Autorkę, bazujące na wyborze próbek uczących metodą punktów odniesienia, są innowacyjne i stanowią samodzielny i oryginalny dorobek Autorki.

5. Organizacja i redakcja rozprawy

Rozprawa składa się z 6 rozdziałów, bibliografii oraz spisów tabel i rysunków. Pierwszym rozdziałem jest wstęp, stanowiący wprowadzenie do tematyki pracy i obejmuje motywację do podjęcia tematyki badań oraz sformułowanie celu i tezy pracy. W rozdziale 1 Autorka przedstawiła przegląd rozwiązań z zakresu big data, widzenia komputerowego i klasyfikacji obrazów. Rozdział 2 zawiera opis zastosowania metody aktywnego uczenia w klasyfikacji obrazów. W rozdziale 3 opisano metody optymalizacji wielokryterialnej w tym metody zaproponowane przez Autorkę. Rozdział 4 przedstawia opis wykonanych badań oraz omówienie tematyki rozpoznania wojskowego. Ostatni rozdział zawiera podsumowanie pracy oraz wnioski. Ogólnie organizacja pracy jest poprawna i stanowi logiczny układ treści, jednak zastrzeżenia budzi umieszczenie wprowadzenia do tematyki rozpoznania wojskowego w rozdziale 4. Biorąc pod uwagę temat pracy wydaje się, że ta tematyka powinna być przedstawiona na początku pracy, opisując aktualne problemy i stanowiąc punkt wyjścia do podjęcia tematyki pracy.

Autorka opisała większość omawianych zagadnień w sposób zwięzły i zrozumiały. Chociaż niektóre pojęcia i definicje nie są zbyt precyzyjne. Przykładowo opisy do wielu równań przedstawionych w p. 1 rozdziału 2 zawierają wielokrotnie powtórzone definicje symboli, różne oznaczenia dla tych samych pojęć (np. $\argmax$), brak wyjaśnień (np. str. 37 - zamiast $\argmin$ opisano $\argmax$, w równaniu (8) nie wyjaśniono znaczenia symbolu C) lub błędne opisy np. str 39 etykieta y nie występuje (tylko y_i), y_i to i -ta etykieta a nie zbiór wszystkich możliwych etykiet. Bardziej czytelne byłoby wprowadzenie wykazu oznaczeń lub podanie w rozdziale jednego wspólnego opisu dla wszystkich równań. Również notacja przyjęta w równaniach wymaga komentarza i wyjaśnień, bo w wielu przypadkach jest niejednoznaczna.

Praca jest starannie zredagowana, tekst pracy jest przejrzysty, chociaż niektóre rysunki nie są zbyt czytelne. Praca zawiera też nieliczne błędy redakcyjne i nieścisłości takie jak:

- str.26: w macierzy na rys. 6 w pierwszej kolumnie i drugim wierszu zamiast „fałszywie negatywna” oraz „FN” powinno być „fałszywie pozytywna” i „FP”;
- do niektórych rysunków i tabel brakuje odwołania w tekście (np. Rys. 1, czy do rys. 18-21);
- nie jest opisane czym się różnią eksperymenty, których wyniki przedstawiono na rys. 13-16, oraz czym się różni metoda losowa RL od metody RD;
- str. 63: równanie (22) nie ma opisu (co to jest m , Q ?);
- str. 64: brakuje opisu użytych symboli ($g(x)$, $f(x)$, m , p);
- str. 66: „Strzałki pokazują ...” nie jest jasne o jakie strzałki chodzi;
- str. 71: „prowadzono” powinno być „doprowadzono”;
- str. 75: wzór (28) jest powtórzeniem wzoru (22);

- str. 81/82: opisy do rysunków 29 i 30 są zamienione;
- str. 84: „zbirach” powinno być „zbiorach”;
- str. 93: opis osi X na rysunkach 44-47 jest nieodpowiedni, użyto liczb rzeczywistych zamiast całkowitych;
- pozycja 56 w bibliografii jest powtórzeniem pozycji 2.

Odwołania do literatury czasem odnoszą się nie do źródeł ale do stron internetowych lub poprzez cytowanie pośrednie. Również dla wielu źródeł nie podano danych bibliograficznych a jedynie adres internetowy publikacji online. Nie jest to zgodne z ogólnie stosowanymi zasadami tworzenia wykazu bibliografii w publikacjach naukowych.

Pomimo ww. drobnych uwag rozprawę należy uznać za poprawnie zredagowaną i uważam, że Autorka potrafi w sposób poprawny i przekonujący przedstawić uzyskane wyniki.

6. Uwagi krytyczne, wady i słabe strony rozprawy

Oprócz wcześniej przedstawionych uwag dotyczących redakcji rozprawy oraz bibliografii pracy wydaje się, że niektóre zagadnienia powinny być dokładniej przedyskutowane lub szerzej opisane. Dotyczy to następujących problemów:

1. Temat pracy sugeruje problematykę specyficzną dla zastosowań analityki big data w rozpoznaniu wojskowym. Tymczasem tematyka pracy z jednej strony dotyczy problemów klasyfikacji obrazów, a z drugiej problemów ogólnych nie ukierunkowanych na zastosowania wojskowe. Zatem powstaje pytanie czy w zastosowaniach wojskowych istnieją specyficzne problemy z zakresu tematyki pracy, które wymagałyby podjęcia badań naukowych? Dlaczego praca nie została ukierunkowana na zastosowania wojskowe np. rozpoznawanie obiektów wojskowych?
2. Uzyskane wyniki odnoszone były jedynie do metody MCADL. Aby ocenić rzeczywistą przydatność opracowanej metody należałoby porównać tę metodę do aktualnie najlepszych metod klasyfikacji obrazów. Jakie są wady i zalety proponowanej metody w odniesieniu do najlepszych metod klasyfikacji obrazów?
3. W pracy pominięto zagadnienia związane ze złożonością obliczeniową metod. Jest to niezwykle istotne szczególnie w kontekście wykorzystania w systemach czasu rzeczywistego i kwestii uczenia maszynowego. Zatem warto by wyniki uzupełnić o informacje dotyczącą czasu uczenia systemu, wydajności opracowanej metody.
4. W pracy skupiono się jedynie na metryce dokładności, w eksperymentach pokazano wzrost wartości tej metryki w kolejnych rundach. Aby ocenić jakość opracowanej metody interesujące byłoby pokazanie również wartości innych metryk i porównanie ich z wynikami uzyskanymi innymi metodami.
5. Praca zawiera jedynie statystyczną ocenę skuteczności opracowanej metody, jest to wystarczające do wykazania słuszności tezy pracy. Jednak brakuje krytycznej oceny działania metody, analizy przypadków dla których metoda jest mniej skuteczna, pokazania słabych stron metody, które wymagają ulepszenia. Przydatne byłoby też

pokazanie przykładów, dla których metoda nie jest skuteczna np. błędnie sklasyfikowane obrazy.

Wyżej wymienione uwagi nie podważają poprawności metodologii badawczej i wartości uzyskanych wyników badań. Ale omówienie tych zagadnień pozwoliłoby na lepszą ocenę opracowanej metody, wskazałoby na możliwości praktycznego znaczenia opracowanych rozwiązań, podkreśliłoby zalety rozwiązania w porównaniu z istniejącymi metodami.

7. Znaczenie uzyskanych wyników

Praktycznym efektem pracy jest opracowany algorytm oraz oprogramowanie do klasyfikacji obrazów, które mogą być wykorzystane w zastosowaniach, gdzie trudno jest znaleźć reprezentatywny zbiór treningowy. Takim zastosowaniem mogą być systemy rozpoznania wojskowego. Opracowany algorytm jest skuteczniejszy niż prezentowane w literaturze metody bazujące na aktywnym uczeniu maszynowym.

Opracowane rozwiązanie może stanowić również punkt wyjścia do dalszych badań z zakresu klasyfikacji obrazów. Na bazie zaproponowanych rozwiązań mogą być opracowywane kolejne rozwiązania zwiększające dokładność klasyfikacji obrazów.

8. Ocena końcowa rozprawy

Podsumowując, uważam że rozprawa doktorska przedstawia oryginalne rozwiązanie zaprezentowanego w niej zagadnienia naukowego i projektowego. Autorka podjęła w niej problem, który ma istotne znaczenie w dziedzinie informatyki. Trafnie określiła założenia dotyczące jego analizy i uzyskane wyniki potwierdziła wykonanymi eksperymentami. Wykazała się dobrą znajomością ogólnej wiedzy teoretycznej i praktycznej z zakresu tematyki pracy, a także umiejętnością samodzielnego prowadzenia pracy naukowej. Stwierdzam, że recenzowana praca spełnia wymogi stawiane rozprawom doktorskim i niniejszym wnoszę o dopuszczenie jej do publicznej obrony.



Warszawa, 08. 08. 2023 r.

prof. dr hab. inż. Mateusz Pasternak
Wydział Elektroniki
Wojskowa Akademia Techniczna
ul. Sylwestra Kaliskiego 2
00-908 Warszawa

**Recenzja rozprawy doktorskiej sporządzona dla
Rady Dyscypliny Naukowej
„Informatyka Techniczna i Telekomunikacja”
Politechniki Warszawskiej**

Tytuł rozprawy: Big data w systemach rozpoznania wojskowego

Autorka rozprawy: mgr Kamila Matela

1. Teza rozprawy i cel badań

Teza recenzowanej rozprawy doktorskiej brzmi następująco: *„Zastosowanie metody punktów odniesienia w algorytmie „Multi-criteria active deep learning for image classification (MCADL)”, zwiększa dokładność analizy obrazu i wykazuje wyższość nad wykorzystywaną w tymże algorytmie metodą ważenia kryteriów.*

Kierując się treścią postawionej tezy Doktorantka przeprowadziła analizę wybranych zagadnień badawczych skupiających się wokół problematyki:

- automatycznego rozpoznawania obrazów,
- uczenia maszynowego,
- automatycznej klasyfikacji obrazów.

W ramach tejże problematyki Doktorantka sformułowała siedem celów szczegółowych dotyczących:

- analizy aktualnego stanu zaawansowania wiedzy technicznej związanej z tzw. widzeniem komputerowym oraz procesami uczenia maszynowego,
- analizy skuteczności wymienionej w tezie metody MCADL,
- propozycji modyfikacji ww. metody oraz analizy uzyskanych efektów,
- opracowania algorytmu opartego o metodę punktów odniesienia w miejsce stosowanego ważenia kryteriów,
- określenia strategii wyboru punktów odniesienia w proponowanym algorytmie,
- weryfikacji poprawności działania zaproponowanego algorytmu z wykorzystaniem bazy MNIST (Modified National Institute of Standards and Technology database),

- potwierdzenia poprawności działania tegoż algorytmu z wykorzystaniem bazy CIFAR-10 (Canadian Institute for Advanced Research).

Postawiona teza pracy wydaje się jasna, a przytoczone tu cele szczegółowe sformułowane w sposób do niej dobrze przystający. Kolejność ich realizacji jest logiczna, a zaproponowane metody walidacji zmodyfikowanego algorytmu można uznać za prawidłowe.

2. Charakter rozprawy

Rozprawa ma charakter użyteczny. Metody rozpoznawania i klasyfikacji obrazów mają bardzo dużą liczbę ważnych zastosowań w różnych gałęziach nauki i techniki. Są one też niezwykle istotne z militarnego punktu widzenia, co Autorka wyraziła wprost w tytule rozprawy. Każdy zatem nowy algorytm czy też modyfikacja w tym zakresie znajdują natychmiast szereg zastosowań, jeśli tylko okażą się skuteczniejsze od wcześniej stosowanych. Co istotnie, wdrożenie do użytku każdej innowacji w tym zakresie odbywa się w sposób programowy, a zatem szybki i nie wymagający czasochłonnych oraz kosztownych zmian sprzętowych. Należy też podkreślić, że przy obecnie osiąganym skuteczności automatycznego rozpoznawania obrazów nawet niewielka poprawa tego parametru może mieć istotne znaczenie.

Charakter użyteczny pracy podkreślony został w rozdziale czwartym, gdzie Doktorantka dość wyczerpująco i precyzyjnie scharakteryzowała obszary potencjalnych wdrożeń zaproponowanego algorytmu w Siłach Zbrojnych Rzeczypospolitej Polskiej. Zmodyfikowany algorytm wzbogaca ofertę Grupy Kapitałowej PGZ, a w szczególności należącego do niej Ośrodka Badawczo-Rozwojowego Centrum Techniki Morskiej, partycypującego obecnie w postępowaniu na dostawę do SZ RP Systemu Analiz Obrazowych w ramach szerszego projektu pn. „Bałtyk Cyfrowy”. Wobec powyższego można przyjąć, że zawartość merytoryczna rozprawy w wystarczającym stopniu odpowiada przyjętej przez Główny Urząd Statystyczny RP definicji pracy wdrożeniowej. Należy tu podkreślić, że proces wdrażania nowych rozwiązań do użytku w SZ RP jest zwykle bardzo złożony i rozciągnięty w czasie, daleko bardziej niżli ustawowo zakładane ramy trwania przewodów doktorskich.

3. Sposób przeprowadzenia analizy źródeł oraz formułowania wynikających z niej wniosków

W przedstawionej do recenzji pracy Autorka przedstawiła w dość uogólniony sposób analizę stanu wiedzy w zakresie rozpoznawania i klasyfikacji obrazów. Opisała funkcjonowanie wybranych metod w tym zakresie, a w szczególności algorytmu MCADL. Zaproponowała też jego modyfikację polegającą na zastąpieniu metody ważenia kryteriów metodą punktów odniesienia oraz uzupełnienie algorytmu o technikę *margin sampling*.

W rozdziale pierwszym Doktorantka opisuje wybrane aspekty historyczne oraz stan wiedzy z zakresu „big data”, widzenia maszynowego oraz algorytmów klasyfikacji obrazów. Rozdział drugi ujmuje strategię aktywnego uczenia maszynowego, w tym ww. metodę wielokryterialną w jej klasycznej postaci wraz z opisem najważniejszych cech. Zawiera on także opisy najczęściej wykorzystywanych sieci neuronowych i możliwe metody ich modyfikacji pod kątem realizowanej pracy.

Rozdział trzeci skupia się na algorytmie MCADL i zaproponowanym jego modyfikacjom.

Rozdział czwarty poświęcony został weryfikacji rezultatów działania zmodyfikowanego algorytmu przy zastosowaniu dwóch różnych baz obrazów. Pierwsza z nich (MNIST) zawiera obszerny, standaryzowany zbiór odręcznie pisanych cyfr, zaś druga (CIFAR-10) sześćdziesięciotysięczny zbiór kolorowych obrazów różnych obiektów należących do dziesięciu odrębnych klas. Reprezentują one zarówno obiekty techniczne jak i zwierzęta. Zbiór ten jest często wykorzystywany do badania algorytmów rozpoznawania obrazów i uczenia maszynowego. W części drugiej tegoż rozdziału Doktorantka zamieściła wspomniany już opis potencjalnych obszarów wdrożeń zaproponowanego algorytmu w systemach rozpoznawczych przeznaczonych dla wojska.

Zamieszczony na końcu spis literatury liczy 109 pozycji, z których 23 są odnośnikami do stron internetowych. Duża część tych źródeł ma wartość wyłącznie historyczną, jednak w spisie tym nie brakuje publikacji nowych i najnowszych. Niestety tylko dwie z nich są autorstwa Doktorantki i mają raczej niewielki zasięg oddziaływania. Druga z nich jest obszernie cytowana w rozdziale czwartym rozprawy.

Zarówno wybór źródeł, jak i analiza ich zawartości są prawidłowe i obejmują najistotniejsze, ogólnodostępne pozycje literaturowe. Wnioski formułowane podczas tych analiz wydają się być trafne i konstruktywne z punktu widzenia uprawianej tematyki, a w szczególności proponowanych w niej modyfikacji algorytmu MCADL pod kątem zastosowań wojskowych.

4. Rozwiązanie przedstawionego zadania, poprawność przyjętych założeń i metod

Zasadnicza część rozprawy jest zawarta w podrozdziale drugim rozdziału drugiego. Na jego wstępie Doktorantka zarysowała trzy główne składowe wybranej metody poprawy efektywności algorytmu MCADL. Przede wszystkim starała się Ona znaleźć odpowiedź na pytanie dotyczące najlepszego sposobu doboru próbek treningowych pod kątem aktywnego maszynowego uczenia się z wykorzystaniem metody punktów odniesienia. Poszukiwała następnie sposobów modyfikacji rezultatów działania algorytmu i wreszcie wiarygodnych metod ich weryfikacji. Do przeprowadzenia swych eksperymentów Doktorantka wybrała przytoczone w pkt. 3. niniejszej recenzji dwie bazy obrazów oraz zastosowane do rozpoznawania zgromadzonych w nich obiektów konwolucyjne sieci neuronowe o odpowiednio zmodyfikowanej architekturze. Autorka wprowadziła także kombinowaną metodę wyboru puli inicjującej, łącząc ze sobą znane techniki k -średnich i analizy głównych składowych (PCA). W rezultacie tego zabiegu poprawiła stabilność treningu sieci neuronowej bez pogarszania wyników działania algorytmu w porównaniu z inicjalizacją opartą o pulę losową. Trzeba jednak podkreślić, że podejście to zwiększyło zapotrzebowanie na moc obliczeniową.

Do poprawy algorytmu rozpoznawania obrazów Doktorantka wybrała metodę punktów odniesienia bazującą na maksiminowym kryterium Walda, zakładającym sytuację najmniej korzystną dla podjęcia decyzji. Główną motywacją takiego podejścia był, jak się wydaje obiektywizm i powtarzalność tej metody oraz założenie, że w pewnych sytuacjach algorytm może dążyć do osiągnięcia dwóch sprzecznych celów. Sposób działania zmodyfikowanej wersji algorytmu MCADL oraz funkcjonująca w jego ramach iteracyjna metoda doboru punktów odniesienia zostały zilustrowane kolejno na rys. 27. i 28. Dodatkowo do poprawy działania algorytmu Doktorantka zastosowała technikę *margin sampling* polegającą na selekcji próbek

lokujących się na granicy decyzyjnej. Podejście takie na ogół redukuje niepożądaną tendencję modelu do dopasowywania się do stałego zbioru cech. Całość zaproponowanego podejścia została zilustrowana na rys. 37.

Przyjęte założenia i metody modyfikacji można uznać za poprawne, a uzyskane wyniki za wystarczająco zadowalające.

5. Oryginalność rozprawy, samodzielny dorobek autora, pozycja rozprawy w stosunku do stanu wiedzy (poziomu techniki) prezentowanego w literaturze światowej

Do najważniejszych elementów stanowiących oryginalny i twórczy wkład Doktorantki do aktualnego stanu wiedzy w zakresie automatycznego rozpoznawania i klasyfikacji obrazów należy zaliczyć:

- analizę i porównania funkcjonowanie różnych technik stosowanych w tym zakresie;
- modyfikację architektur konwolucyjnych sieci neuronowych pod kątem wybranych zastosowań;
- poprawę funkcjonowania algorytmu MCADL poprzez:
 - kombinowaną metodę doboru puli inicjującej,
 - zastąpienie metody ważenia kryteriów metodą iteracyjnie ustalanych punktów odniesienia,
 - zastosowanie techniki *margin sampling* do poprawy jakości klasyfikacji obiektów.

Wykorzystane w przedstawionej do recenzji rozprawie metody i techniki są ogólnie znane i nie stanowią elementu nowości. Oryginalność polega tu na odpowiednim ich zestawieniu w jeden funkcjonalny algorytm oferujący w pewnych sytuacjach wyższą skuteczność w porównaniu z algorytmami stosowanymi dotychczas. Takie podejście do zagadnienia nie lokuje treści rozprawy w światowej, europejskiej czy nawet krajowej czołówce. Należy raczej uznać, że swym poziomem przystaje ona do całego szeregu prac o charakterze utylitarnym zmierzających do osiągnięcia konkretnych rezultatów i zaspokojenia bardzo specyficznych potrzeb. Trzeba jednak zaznaczyć, że fakt ten nie stanowi dostatecznie ważkiego powodu do uznania, że nie zasługuje ona na dopuszczenie do publicznej obrony.

Dorobek publikacyjny Doktorantki również nie jest imponujący. Dwie pozycje widoczne w spisie literatury zostały zamieszczone w wydawnictwach nie należących do głównego nurtu i mających raczej skromny zasięg. Trzeba jednak podkreślić, że są to prace samodzielne, które przy nieco większym wysiłku ze strony Doktorantki mogłyby się ukazać w wydawnictwach o szerszym zasięgu. Można zatem uznać, iż minimalne wymogi w zakresie publikacyjności zostały spełnione.

6. Poprawność przedstawienia uzyskanych wyników (zwięzłość, jasność, umiejętność przekonywania, poprawność redakcyjna)

Wyniki działania algorytmów proponowanego oraz uznanych przez Doktorantkę jako referencyjne zostały przedstawione w sposób poprawny i zwięzły, choć trzeba przyznać, że miejscami mało przekonujący i dość zawiły. Praca została napisana w miarę starannie, jednak

stosunkowo łatwo wskazać w niej szereg usterek i błędów redakcyjnych oraz edycyjnych. Z obowiązku recenzenta pragnę tu wymienić najważniejsze z nich.

Należy zacząć od tego, że przecinek wstawiony do sformułowanej tezy wydaje się zupełnie zbędny.

Autorka w swej pracy zamieściła szereg sformułowań, w których posługuje się skrótami myślowymi. Cytuję tu kilka przykładów:

„*wydobywanie informacji z danych*” na str. 16,

„*techniki przetwarzania obrazów [...] obejmują optykę, astronomię, statystykę [...]*” na str. 21,

„*[...] w którym model jest najmniej pewny [...], jego poziom prawdopodobieństwa jest najniższy.*” na str. 35,

„*Zapis maksymalizacji w modelu wielokryterialnym [...]*” na str. 64 i in.

W wielu miejscach Doktorantka posługuje się konsekwentnie żargonowym określeniem „zdjęcie” choć w zasadzie nie ma do czynienia ze zbiorem fotografii, ale ustandaryzowanymi obrazami (mapami bitowymi).

W opisie wyrażenia (5) Autorka wyjaśnia w nawiasie, że pod nazwą najbardziej informacyjnej instancji rozumie najlepsze zapytanie. Nie budzi to większych wątpliwości, jednak nie wiedzieć czemu wyjaśnienie to powtarza później pod kolejnymi wyrażeniami (6), (7), (8), (9) i (12).

W wielu miejscach Autorka wprowadza różnorakie i dość złożone pojęcia bez ich wcześniejszego zdefiniowania, co dla czytelnika mniej zaznajomionego z tego rodzaju tematyką może stanowić pewien problem. Jako przykłady podam tu wprowadzenie terminu nierównowagi klas czy też odległości kosinusowej. W tym ostatnim przypadku szczególnie wyraźnie odczuwa się brak definicji z uwagi na fakt, że w rozdziale drugim Autorka podaje ściśle definicje odległości Minkowskiego, Manhattan czy nawet Euklidesowej, a także pisze o odległości kosinusowej jako najbardziej przydatnej do analizy rzadkich wektorów cech. Ścisłej definicji tego ważnego pojęcia jednak nie podaje. Jest to tym bardziej niezrozumiałe, że ze zdefiniowanych odległości Minkowskiego i Manhattan nie korzysta w dalszej części pracy.

W wielu miejscach można też znaleźć termin „ilość” odnoszący się do rzeczowników policzalnych. W języku polskim nie jest to wielki błąd, jednak w pracach technicznych, w których sformułowania powinny być zwięzłe i maksymalnie precyzyjne powinno się na to zwracać większą uwagę.

Począwszy od str. 78 pojawiają się zagadkowe liczby umieszczone w cudzysłowie. Dla przykładu na tejże stronie znajduje się fragment: „- dla bazy MNIST: w eksperymencie ε wszystkie na poziomie „0”, w eksperymencie ϕ wszystkie na poziomie „1”, w eksperymencie γ kryteria gęstości i podobieństwa operujące na danych z etykietami na 0,1 [...], 0,15 natomiast kryteria niepewności i oparte na etykietach operujące na danych nieoznakowanych na 0,9 i 0,8”. Autorka w żaden sposób nie wyjaśnia znaczenia owego cudzysłowu. Z kontekstu można się jedynie domyślić, że jest on zupełnie zbędny, a powód jego zastosowania dosyć zagadkowy.

Przedstawiona do recenzji praca jest napisana w języku polskim. Oczywiście w tekstach o charakterze technicznym zwykle nie da się uniknąć zwrotów angielskich, jednak trudno zrozumieć fakt ich stosowania w miejscach, gdzie można wykorzystać utarte już określenia polskie. Dla przykładu rys. 11. mógłby być z powodzeniem opisany po polsku, podobnie jak tytuły podrozdziałów 1.5 i 1.6. Nawiasem mówiąc dzielenie tekstu na podrozdziały złożone z dwóch czy też trzech zdań nie ma większego sensu, a taka sytuacja występuje w przytoczonych tu fragmentach pracy.

Kontrowersje budzą też niektóre tłumaczenia z języka angielskiego. Na stronach 24 i 25 można znaleźć niecodziennie brzmiące określenia *presampling* i *undersampling* jako tłumaczenia angielskich terminów *oversampling* i *undersampling*. W polskiej literaturze zwykło się stosować odpowiednio nazwy nadpróbkowanie oraz podpróbkowanie i to w zasadzie bez względu na rodzaj próbek.

Uwagi redakcyjne można także sformułować w odniesieniu do wyrażen matematycznych, które zawierają znaki pisane kursywą. W wielu jednak miejscach tekstu odnoszące się do nich symbole są pisane czcionką prostą. Tego rodzaju niekonsekwencja nie powinna mieć miejsca w pracach technicznych.

Pewne negatywne spostrzeżenia odnoszą się także do zamieszczonych w pracy grafik. Na rys. 6. można znaleźć dwie klasy fałszywie negatywne, natomiast wyraźnie brak jest klasy fałszywie pozytywnej, chociaż występuje ona w widniejących tam definicjach precyzji, dokładności i swoistości.

Wiele z zamieszczonych rysunków nie ma odpowiedniego wyglądu technicznego, a niektóre z nich, tak jak rys. 7, 8, 9 i 10 zdecydowanie bardziej przypominają grafiki z czasopism popularnonaukowych niż rysunki spotykane zwykle w tekstach naukowo-technicznych.

W dość niecodzienny sposób podpisane są rys. od 44 do 47. Można się jedynie domyślić, że podane w nawiasie określenie „plik gif” odnosi się do wykresów skupień widocznych po lewych stronach tychże rysunków. Jego użycie jest tu dość niefortunne i w tym przypadku nie ma zastosowania. Termin ten oznacza bowiem mapę bitową lub sekwencję map bitowych zapisanych na elektronicznym nośniku pamięci.

Sformułowane wnioski w większości zawierają opisy tego co zostało zrealizowane w ramach pracy i tylko niewielka ich część ma charakter końcowych konkluzji. Zdaniem recenzenta proporcje te powinny być odwrócone.

Zamieszczony pod koniec rozprawy spis źródeł jest niejednolity. W szczególności dotyczy to stron internetowych, gdzie Doktorantka zastosowała aż trzy różne formaty zapisu (por. np. poz. [3], [72], i [75]) nie podając przy niektórych z nich daty ostatniego dostępu.

7. Słabe strony rozprawy, jej główne wady

Przedstawiona do recenzji rozprawa ma niestety kilka słabych stron. Obok wymienionych już usterek redakcyjnych i edycyjnych należy wymienić jej dość zawiły sposób prezentacji, zarówno rozważanego problemu technicznego jak i metod jego rozwiązania. W tym wypadku rozwiązanie to nie polega na oryginalnym podejściu do problemu ani też opracowaniu zupełnie nowego algorytmu rozpoznawania i klasyfikacji obrazów, ale na odpowiednim zestawieniu znanych już metod. Nosi to pewne cechy oryginalności, jednak nie lokuje pracy wśród szczególnych osiągnięć myśli naukowo-technicznej.

Autorka posługuje się licznymi terminami, specyficznymi dla przedmiotowej dziedziny bez głębszego wyjaśniania ich sensu, co w wielu miejscach pracy sprawia wrażenie jej powierzchowności. Nie ma raczej wątpliwości co do tego, że Doktorantka ma wiedzę na temat tego o czym pisze, jednak czytelnik mniej zaznajomiony z wykorzystywaną nomenklaturą będzie się czuł podczas lektury rozprawy dość zagubiony. Ponieważ praca nie jest specjalnie obszerna Doktorantka miała wystarczającą ilość miejsca na zamieszczenie bardziej szczegółowych opisów stosowanych terminów.

Do weryfikacji zmodyfikowanego algorytmu Autorka wykorzystała dwie ogólnodostępne bazy obrazów. Pierwsza z nich zawiera odręcznie pisane cyfry i jest monochromatyczna, zaś druga różnorakie obiekty w kolorze. Doktorantkę zdaje się martwić fakt, że algorytm osiąga lepsze rezultaty dla bazy monochromatycznej, o czym można przeczytać na str. 100, gdzie pisze Ona o konieczności jego dalszego rozwijania. W tym jednak przypadku lepsze rezultaty dla zobrazowań monochromatycznych są raczej zaletą, a nie wadą algorytmu, a potwierdzanie uzyskanych rezultatów przy użyciu bazy obrazów kolorowych nie wydaje się działaniem szczególnie trafnym. Jeśli bowiem algorytm ma być wdrożony do pracy w systemach rozpoznawania obiektów morskich, to w większości przypadków będą one reprezentowane na obrazach monochromatycznych lub zbliżonych do monochromatycznych, głównie z uwagi na dość jednolite tło i z reguły mało urozmaiconą kolorystykę tychże obiektów. W wielu przypadkach jest ona specjalnie tak dobrana, aby zlewała się z otoczeniem i dla podniesienia kontrastu zobrazowań często zamiast fotografii w świetle widzialnym stosuje się techniki z wykorzystaniem dalekiej podczerwieni. W tym wypadku baza MNIST wydaje się lepszym wyborem, aczkolwiek obarczonym małym urozmaicheniem i nadmierną prostotą obiektów. Do potwierdzenia przydatności zmodyfikowanego algorytmu znacznie lepsza byłaby monochromatyczna baza danych zawierająca dostatecznie duży zbiór zobrazowań realnych obiektów morskich. Należy jedna zdać sobie sprawę z faktu, że dostęp do tego rodzaju zbiorów jest dość utrudniony.

8. Przydatność rozprawy dla nauk technicznych, przemysłu, obronności kraju, itp.

Największą ilość informacji o świecie zewnętrznym dostarcza człowiekowi zmysł wzroku. Pomaga on centralnemu układowi nerwowemu generować pamięć zdarzeń, kształtów i kolorów. Jest to podstawowy powód, dla którego maszynowe rozpoznawanie i klasyfikacja obrazów mają kluczowe znaczenie w wielu gałęziach działalności człowieka. Ich dobre opanowanie pozwoli na całkowitą automatyzację bardzo wielu procesów wytwórczych, logistycznych, diagnostycznych i in. Sprawia to, że badania w tym kierunku prowadzone są intensywnie w wielu konkurujących ze sobą laboratoriach badawczych. Choć osiągnięto już znaczne sukcesy, to jednak wciąż nie można powiedzieć, że ludzie dysponują aparatem maszynowego rozpoznawania dowolnych obrazów. Z tego powodu poszukiwanie nowych algorytmów czy też ulepszanie już istniejących jest działalnością bardzo pożądaną. Wpisuje się ona w treść pierwszych trzech punktów przyjętego Decyzją nr 2/DIn Ministra Obrony Narodowej z dnia 10 stycznia 2023 r. dokumentu pt. „Priorytetowe kierunki badań naukowych w resorcie obrony narodowej w latach 2021–2035 (PKB)”.

Jak już zaznaczono Doktorantka scharakteryzowała szereg obszarów potencjalnych wdrożeń rozwijanego przez siebie algorytmu w Siłach Zbrojnych Rzeczypospolitej Polskiej, a w szczególności w Systemie Analiz Obrazowych budowanym w ramach projektu

pn. „Bałtyk Cyfrowy”. Należy podkreślić, że są to obszary najbardziej oczywiste. Algorytmy rozpoznawania obrazów monochromatycznych mogą też znaleźć szereg zastosowań w echolokacji zarówno w wydaniu cywilnym jak i wojskowym. Jako przykłady można podać rozpoznawanie min lądowych na falogramach georadarowych czy też identyfikację różnego rodzaju schorzeń na medycznych zobrazowaniach rentgenowskich lub ultrasonograficznych. Automatyzacja rozpoznawania wzorców w przytoczonych tutaj przykładowych dziedzinach wciąż jeszcze znajduje się w fazie rozwoju, a każda praca z tego zakresu przyczynia się do jego postępu.

9. Podsumowanie

Przedstawiona do recenzji rozprawa doktorska mgr Kamili Mateli pt. „*Big data w systemach rozpoznania wojskowego*” pomimo wskazanych dość licznych usterek spełnia wymagania stawiane przez aktualnie obowiązującą Ustawę z dnia 20 lipca 2018 r. „Prawo o szkolnictwie wyższym i nauce”. Zgodnie z tą ustawą przedstawioną do recenzji rozprawę zaliczam do kategorii: spełniająca wymagania.

Ocenę tę uzasadniam:

- wystarczającym poziomem merytorycznym pracy, świadczącym o odpowiednich kompetencjach Doktorantki w uprawianej w jej ramach tematyce,
- dostatecznie spójną i logiczną kompozycją dysertacji, ściśle trzymającą się jej tematu i przejętej tezy,
- dość wyczerpującą analizą literatury tematu, w tym znanych algorytmów oraz metod w zakresie rozpoznania i klasyfikacji obrazów,
- zaproponowaną przez Doktorantkę, zgodnie z przyjętą tezą, modyfikacją algorytmu MCADL z zastosowaniem metod punktów odniesienia oraz *margin sampling*,
- weryfikacją działania algorytmu przy zastosowaniu dostępnych baz obrazów,
- porównaniem wyników działania zmodyfikowanego algorytmu z wybranymi algorytmami konkurencyjnymi – pomyślny wynik tego procesu można uznać za wystarczający dowód słuszności przyjętej tezy,
- szczegółowym opisem potencjalnych obszarów wdrożeń, ze wskazaniem na podmiot wdrażający.

Na podstawie analizy pracy oraz powyższego uzasadnienia można stwierdzić, że Doktorantka posiada wystarczająco rozległą wiedzę w zakresie algorytmów rozpoznawania i klasyfikacji obrazów, a tym samym spełnia wymagania stawiane kandydatom do stopnia naukowego doktora nauk technicznych. W związku z powyższym wnoszę o dopuszczenie rozprawy mgr Kamili Mateli do publicznej obrony.

prof. dr hab. inż. Mateusz Pasternak

Dr hab. Marek Sikora, prof. PŚ
Katedra Sieci i Systemów Komputerowych
Politechnika Śląska
ul. Akademicka 16
44-100 Gliwice
Email: marek.sikora@polsl.pl

Recenzja rozprawy doktorskiej

Tytuł rozprawy: Big data w systemach rozpoznania wojskowego

Autor rozprawy: mgr Kamila Matela

Promotor rozprawy: dr hab. inż. Andrzej Stachurski

Dziedzina: nauki inżyniersko-techniczne

Dyscyplina: informatyka techniczna i telekomunikacja

1. Temat i cel rozprawy

Tematyka rozprawy obejmuje zagadnienia zastosowania metody aktywnego uczenia do oznaczania (tagowania) przykładów w problemach klasyfikacji obrazów. Cele pracy zdefiniowane przez autorkę to między innymi: zaprezentowanie wielokryterialnej strategii wyboru przykładów do oznaczania – Autorka bazuje w tym zakresie głównie na publikacji, jaka ukazała się w 2019 roku w uznanym czasopiśmie Knowledge Based Systems, przedstawienie modyfikacji tej strategii poprzez zastosowanie metody optymalizacji wielokryterialnej, bazującej na metodzie punktu odniesienia oraz weryfikacja przedstawionej propozycji na podstawie analizy dwóch benchmarkowych zbiorów danych. Weryfikacja obejmuje głównie badanie sprawności klasyfikacji klasyfikatorów trenowanych na oznaczanych zbiorach przykładów. Badanie zawiera analizę jak zmienia się ta sprawność w kolejnych rundach oznaczania.

Tłem dla prowadzonych badań są rozważania na temat systemów rozpoznania wojskowego oraz roli klasyfikacji obrazów w tego typu systemach. Główny nacisk położono tutaj na rozpoznawanie obiektów, chociaż Autorka wspomina także o monitorowaniu zmian i prognozowaniu zjawisk.

Uzasadnienie wyboru tematu nie budzi wątpliwości, Autorka dosyć trafnie uzasadnia celowość podjęcia badań opisanych w rozprawie. Dysponowanie dobrze oznaczonymi (otagowanymi) zbiorami danych jest niezwykle ważne z punktu widzenia trenowania systemów klasyfikacji i nie dotyczy jedynie klasyfikacji obrazów. W przypadku dużych zbiorów danych, dobra metoda wyboru „reprezentatywnej” próbki poprawnie oznaczonych danych pozwala zazwyczaj na znaczne przyspieszenie budowy klasyfikatora o dobrych zdolnościach klasyfikacji. Ponadto, ograniczenie liczby przykładów do tych najistotniejszych powoduje, że wymagana jest mniejsza liczba ekspertów oznaczających (tagujących) dane.

2. Zawartość i charakter rozprawy

Rozprawa składa się z czterech rozdziałów oraz spisu literatury.

We wstępie przedstawiono krótko motywację podjęcia badań wraz z głównymi celami pracy. Wstęp zawiera również zdefiniowaną przez Doktorantkę tezę.

Rozdział pierwszy obejmuje tematycznie szeroki wachlarz zagadnień. W rozdziale tym przedstawiono definicję i zastosowania koncepcji Big Data, omówiono zagadnienia związane z wizją komputerową oraz algorytmami klasyfikacji i miarami oceny jakości klasyfikatorów. Tematyka rozdziału jest szeroka. Powoduje to, że poruszane w nim zagadnienia omawiane są dosyć lakonicznie. Najwięcej uwagi poświęcono algorytmom klasyfikacji, przy czym Autorka koncentruje się na standardowych algorytmach, które poza SVM, niekoniecznie dedykowane

są do celu klasyfikacji obrazów. Dobrze przedstawione są zagadnienia weryfikacji jakości klasyfikacji, przy czym w rozdziale w ogóle nie poruszono kwestii metodyk oceny eksperymentalnej (podziałów na zbiory treningowe, testowe i ew. walidacyjne). Nie wspomniano w ogóle o metodach porównania klasyfikatorów, chociaż zagadnienie to jest ważne dla wyników prezentowanych w dalszej części pracy.

Rozdział drugi koncentruje się na metodach aktywnego uczenia. Autorka przedstawia kilka strategii aktywnego uczenia i na końcu tego przeglądu prezentuje pracę *Multi-criteria active deep learning for image classification* (MCADL), która ukazała się w 2019 w czasopiśmie Knowledge Based Systems. Autorka tę właśnie pracę i opisaną w niej metodę wzięła jako punkt odniesienia do swoich badań. W rozdziale przedstawiono szczegółowo zasady działania metody MCADL. Autorka chcąc upewnić się, że wyniki osiągnęte przez metodę są rzeczywiście konkurencyjne lub lepsze do znanych metod, przeprowadza szereg eksperymentów obliczeniowych związanych z zastosowaniem własnej implementacji MCADL do benchmarkowego zbioru danych MNIST. Uzyskane wyniki nie są jednoznaczne, co uczciwie Autorka spostrzega. Metoda MCADL na tle losowej inicjalizacji i wyboru przykładów czasem nie wykazuje swojej przewagi zarówno w szybkości dochodzenia do wysokiej sprawności (dokładności) klasyfikacji końcowego modelu, jak również w trakcie kolejnych rund uczenia. Autorka nie przedstawia pogłębionej analizy przyczyn takiego stanu rzeczy. Dziwi również, że Autorka nie przedstawia wyników MCADL na tle innych znanych metod aktywnego uczenia, o których wspomina w rozdziale. W ogólnie dostępnych bibliotekach programistycznych metody takie są dostępne.

Rozdział III poświęcony jest zagadnieniom analizy i optymalizacji wielokryterialnej. Sekcja 1 zawiera opis/przegląd wybranych zagadnień związanych z tą tematyką. Sekcja 2 jest najważniejszą częścią ocenianej rozprawy, gdyż zawiera opis modyfikacji MCADL proponowanych przez Autorkę. Ponieważ tę część pracy uważam za największe i najwartościowsze osiągnięcie, opiszę je szczegółowo w sekcji Oryginalne wyniki i ich znaczenie. W początkowej części rozdziału III – przed przedstawieniem oryginalnych metod proponowanych przez Autorkę – zamieszczono również opis dwóch benchmarkowych zbiorów danych, jakich użyto w eksperymentach obliczeniowych. Paradoksalnie, zbiory te nie mają wiele wspólnego z obszarem wojskowości. Pewną wskazówkę dotyczącą takiego stanu rzeczy jest umieszczona na początku rozprawy wzmianka o tym, że postępowanie na dostawę elementów systemu rozpoznania wojskowego, w ramach którego zamierzano zgromadzić również dane niezbędne do realizacji ocenianej pracy został odwołany. Sytuacja taka jest niezależna od Doktorantki, a zakres i temat rozprawy realizowanej w trybie doktoratu wdrożeniowego niezwykle trudno zmienić, recenzent zna tę sytuację jako promotor z autopsji. Doktorantka rozważa dwa zbiory danych: MNIST (użycie go można wytłumaczyć chęcią odniesienia się do wyników metody MCADL – wyniki te dla oryginalnej implementacji autorów prezentowane są w przywoływanej już w recenzji publikacji) oraz CAF AR-10. Ten drugi z użytych zbiorów danych dedykowany jest do klasyfikacji – rozpoznania – obiektów

różnych typów (nie są to jednak obiekty wojskowe). W rozdziale przedstawiono również architektury sieci głębokich, jakie stosowane były do klasyfikacji obiektów. Sieci trenowane były na danych dostarczanych/wybieanych przez metodę aktywnego uczenia.

Rozdział IV składa się z dwóch części. W pierwszej części prezentowane są wyniki działania – w kontekście dokładności klasyfikacji na tle liczby rund uczenia – propozycji przedstawionych przez Doktorantkę. Punktem odniesienia jest metoda MCADL, stosowana jest metodyka train-and-test, wnioski definiowane są na podstawie porównań pomiędzy dokładnością poszczególnych metod. Wobec przyjętej metodyki testowania nie sposób oczywiście sprawdzić istotności różnic pomiędzy metodami lub metodą uruchamianą z różnymi wartościami hiperparametrów za pomocą testu statystycznego. Przed prezentacją wyników swojej metody Autorka przytacza jeszcze raz wyniki metody MCADL, w szczególności przedstawia interesującą moim zdaniem analizę – wizualizację – polegającą na oznaczeniu na wykresie 2d przykładów z poszczególnych klas wybranych przez metodę MCADL do uczenia. Niestety czytelnik nie dowiaduje się bezpośrednio jak zrealizowano redukcję wymiarów – można to wywnioskować pośrednio z nazwy pliku, w jakim przechowywane są prezentowane grafiki. Analiza – jak pisze Autorka – ma na celu „zbadanie zachowania różnych kryteriów” stosowanych w MCADL, w celu znalezienia wzorca pozwalającego na zdefiniowanie poziomów referencji dla kryteriów stosowanych w MCADL. Wzorzec ten zostałby wykorzystany w metodzie punktów odniesienia. Autorka konkluduje jednak, że wzorców takich nie znaleziono. Druga część rozdziału IV przedstawia aspekty wdrożeniowe systemu rozpoznania wojskowego. Jest to opis bardzo ogólny, nie przedstawiający architektury systemu rozpoznania, jaki w dalszym ciągu planowany jest do wdrożenia w praktyce. Interesujące w tej części rozdziału jest uzasadnienie konieczności szybkiego oznaczania (tagowania) danych (w tym obrazów) dla celów trenowania klasyfikatorów, będących elementami większych systemów wspomagania podejmowania decyzji dedykowanych dla zastosowań wojskowych. Na zakończenie Autorka opisuje działania Polskiej Grupy Zbrojeniowej, mające na celu doprowadzenie do budowy Systemu Analiz Obrazowych. Na tym tle wskazuje miejsce potencjalnego zastosowania prezentowanego przez nią rozwiązania – szerzej, systemów wspomagających oznaczenie przykładów.

Ostatni rozdział zawiera podsumowanie wyników oraz odniesienie się do tezy rozprawy. W podsumowaniu Autorka nie przedstawiła możliwych kierunków dalszych prac. Stwierdzam to z ubolewaniem, bo czytelnik czuje pewien niedosyt, zwłaszcza w zakresie przedstawienia bardziej szczegółowej architektury planowanego systemu rozpoznania wojskowego i miejsca, jakie w tej architekturze (w elemencie/module klasyfikacji obiektów) zajmie rozwiązanie proponowane przez autorkę.

Teza rozprawy

We wstępie Doktorantka przedstawia kilka celów rozprawy i na tym tle stawia następującą tezę:

Zastosowanie punktów odniesienia w algorytmie Multi-criteri active deep learning for image classification, zwiększa dokładność analizy obrazu i wykazuje wyższość nad wykorzystywaną w tymże algorytmie metodą ważenia kryteriów.

Teza została postawiona jasno i czytelnie, a badania opisane w rozprawie pokazują dążenie do jej weryfikacji empirycznej. Uzyskane wyniki nie pozwalają w sposób wysoce prawdopodobny na wnioskowanie o prawdziwości tej tezy. Recenzent odniesie się do tego aspektu w sekcji Słabe strony i uwagi krytyczne/dyskusyjne. Ważne jest, że w pracy przedstawiono cele rozprawy, teza jest tutaj moim zdaniem mniej istotna, gdyż w pracach związanych

z metodami wnioskowania indukcyjnego powinniśmy raczej definiować cele niż tezy, których prawdziwości lub nieprawdziwości zależy silnie od rozważanych danych.

Pewne zdziwienie budzi fakt, że teza rozprawy w luźny sposób nawiązuje do jej tytułu. Z treści rozprawy wnioskujemy, że główny cel badań i związana z nim teza stanowi jedynie niewielki element postulowanego systemu rozpoznania wojskowego.

3. Analiza źródeł i zastany stan wiedzy

Bibliografia recenzowanej rozprawy doktorskiej składa się ze 109 pozycji. Autorka cytuje je w odpowiednim kontekście. Źródła te dobrze przedstawiają bieżący stan wiedzy w obszarze tematyki rozprawy. Liczba pozycji literatury jest w mojej opinii odpowiednia i wystarczająca. Tematyka przywoływanych prac dotyczy zarówno aktywnego uczenia, jak również klasyfikacji obrazów, optymalizacji i systemów wsparcia/rozpoznania wojskowego. Przywoływane prace są w dużej części nowe, opublikowane w okresie ostatnich dziesięciu lat. Autorka przywołuje również swoje publikacje związane z tematyką pracy – głównie z systemami rozpoznania wojskowego.

W spisie literatury jest dużo odnośników do publikacji zamieszczonych w serwisie arxiv. Zastrzeżenia budzi sposób przywoływania części z tych prac, zamiast podawania tytułu pracy i listy autorów, Autorka podaje jedynie link do dokumentu źródłowego. Taki sposób prezentowania referencji utrudnia czytelnikowi analizę źródeł.

4. Oryginalne wyniki i ich znaczenie

Doktorantka podejmuje ważny problem poprawy wyników metody – strategii – aktywnego uczenia poprzez wielokryterialną, stosowaną iteracyjnie, analizę przykładów kandydujących

do kolejnych rund uczenia. Doktorantka adaptuje metodę punktów odniesienia do metody MCADL i porównuje uzyskane wyniki z bazową metodą MCADL oraz strategią losową. Doktorantka wykazuje wiele zalet takiego podejścia, z których za najważniejsze uważam wsparcie w procesie ustalania granic pomiędzy przykładami. Autorka proponuje również pewien systematyczny sposób wyboru próbki inicjującej – zamiast wyboru losowego bazuje on na wynikach grupowania danych wykonywanego na przekształconym (metoda PCA) zbiorze przykładów i zastosowaniu algorytmu k-średnich.

Punkty odniesienia ustalane są dla czterech kryteriów – gęstości podobieństwa, niepewności i, jak to definiuje Autorka, kryterium opartego na etykietach przykładów. W zakresie wpływu wartości kryteriów na wyniki trenowania modelu Doktorantka przeprowadza dosyć szczegółową analizę eksperymentalną.

Dobrze oceniam też krytyczną analizę zbalansowania wyników (dokładności klasyfikacji) na zbiorach treningowych i walidacyjnych oraz próbę ich lepszego zbalansowania (zniwelowania nadmiernych różnic). Doktorantka stosuje metodę margin sampling, modyfikując proces wyboru próbek – metoda margin sampling bazuje na próbkach wybranych uprzednio przez metodę wielokryterialną.

Mając na uwadze aspekt wdrożeniowy, ważnym wynikiem prowadzonych prac jest przygotowana implementacja zarówno metody odniesienia, jak i proponowanych przez Autorkę innowacji.

5. Redakcja rozprawy i prezentacja wyników

Rozprawa zredagowana jest w sposób poprawny. Doktorantka nie ustrzegła się jednak mniejszych i większych błędów – zwłaszcza w zakresie prezentacji wyników eksperymentów. Wyniki prezentowane są głównie w postaci wykresów dokładności klasyfikacji na tle kolejnych rund uczenia. Interpretacja tak prezentowanych wyników jest trudna, nie zawsze wiadomo czy wykres przedstawia wynik uzyskane na danych treningowych, czy testowych. W pracy brakuje także bardziej formalnego opisu używanych metod, w szczególności metod proponowanych przez Autorkę.

Pozostałe rozdziały zredagowane są poprawnie, indeksy, spisy, tabele, etc. ułatwiają czytanie i zrozumienie prezentowanego materiału. W podpisach pod rysunkami Autorka w miarę dokładnie opisuje ich (rysunków) zawartość. W przypadku reprodukcji zaczerpniętych z prac innych autorów (sporadyczne przypadki) Doktorantka wskazuje wyraźnie prace źródłową.

Kolejne rozdziały tworzą logiczną całość – wyjątkiem są: sekcja 2 rozdziału VI, która moim zdaniem powinna być umieszczona w początkowej części pracy oraz część sekcji 3 rozdziału II, zawierające krótki opis zasady działania sztucznej sieci neuronowej – ta część pracy powinna znaleźć się w rozdziale I obok opisów innych metod klasyfikacji.

6. Słabe strony i uwagi krytyczne/dyskusyjne

Uwagi krytyczne dotyczą dwóch głównych aspektów: weryfikacji metody oraz osadzenia rozwiązania w systemie rozpoznania wojskowego. Poniżej przedstawiono najważniejsze z uwag krytycznych.

1. W doktoracie brak jest wystarczającego uzasadnienia, że podejście wielokryterialne ma znaczenie dla rozważanego obszaru zastosowania. Wybór jednej konkretnej metody odniesienia był ryzykowany, zwłaszcza w kontekście przedstawionych uczciwie przez Doktorantkę badań weryfikacyjnych.
 - a. Dlaczego Doktorantka kontynuowała prace nad poprawą wyników działania metody, skoro Jej badania weryfikujące wykazały, że metoda nie posiada zdecydowanych przewag nad metodami znanymi?
 - b. Dlaczego oparto się na własnej implementacji, a nie na implementacji udostępnionej w repozytorium github?
 - c. Skąd wynika konieczność stosowania metod wielokryterialnych LUB jakie teoretycznie korzyści metody te mogą przynieść w zadaniu active learning?
2. Dlaczego Autorka nie porównała wyników swoich badań z innymi – co najmniej jedną – znanymi metodami Active Learning?
3. Dlaczego nie zastosowano lepszej metodyki testowania np. wielokrotny trian-and-test lub walidacja krzyżowa? Czy zdaniem Autorki pozwoliłoby to na lepszą/dokładniejszą weryfikację jakości porównywanych metod?
4. W sekcji 2.4.3 rozdziału II przedstawiono warunek stopu algorytmu dla konkretnego zbioru danych. Wydaje się, że propozycja ta po pierwsze jest bardzo ograniczona utylitarnie (a moim zdaniem ma potencjał praktyczny), po drugie z rysunku 37 wynika, że możemy mieć do czynienia z wyciekami danych – ostatni etap losowania przykładów ze zbioru walidacyjnego do procesu uczenia – a co za tym idzie, prezentowane wyniki są zbyt optymistyczne.
 - a. Czy metoda może być również stosowana do innych zbiorów danych?
 - b. Czy rzeczywiście dobrze identyfikują wyciek danych?
5. Warstwa prezentacji wyników jest uboga, bazuje jedynie na dosyć, moim zdaniem, nieczytelnych wykresach. Wyniki eksperymentów rozmieszczone są trochę chaotycznie w rozdziałach III i IV. Brakuje zestawienia tabelarycznego z rozbiciem na rundy oraz wyniki na zbiorze treningowym i testowym. Trudno jednoznacznie wywnioskować czy badania w świetle postawionej tezy się powiodły, czy nie (przy czym wynik negatywny też uznawałbym za cenny).

6. Jedynie z części wykresów dowiemy się czy wyniki dotyczą zbiorów treningowego czy testowego/walidacyjnego.
7. Nie doszukałem się jednoznacznego opisu przyjętej metodyki eksperymentów – ile przykładów było prezentowanych algorytmowi w kolejnych rundach?
8. Autorzy oryginalnej metody piszą, że sprawuje się ona dobrze dla danych niezbalansowanych, Autorka w ogóle nie adresuje tego problemu. Moim zdaniem zbiory danych, na których przeprowadzono eksperymenty nie są niezbalansowane, co może tłumaczyć brak jednoznacznych konkluzji dotyczących efektywności metody.

W aspekcie wdrożeniowym – jak już pisałem – brakuje mi uzasadnienia, że proces oznaczania danych ma znaczenie w rozważanej dziedzinie zastosowania oraz że wybór wielokryterialny jest tutaj ważny – niekoniecznie szczególnie ważny, ale ważny. Brak mi również – pomimo tego, że wiem, iż realizacja prac wdrożeniowych w dużej mierze uzależniona była od wyników przetargu – propozycji ogólnej architektury systemu wsparcia rozpoznania z wyszczególnieniem elementu rozpoznania obiektów.

Mniej istotne uwagi odnoszą się do pewnej liczby błędów gramatycznych, jakie zauważano w pracy oraz bardzo mało sformalizowanego opisu. Brakuje mi trochę wzorów, algorytmów, schematów blokowych, etc.

7. Podsumowanie i wniosek końcowy

Po analizie rozprawy mogę stwierdzić, że zamieszczone w niej rezultaty prezentują oryginalne rozwiązanie w zakresie zastosowania wyników badań naukowych Doktorantki w obszarze udoskonalania metod active learning dla celów wyboru przykładów dla klasyfikacji obrazów. Rozwiązanie to może być stosowane również w systemach rozpoznania wojskowego. Nie lekceważąc dosyć poważnych uwag krytycznych i dyskusyjnych, jakie podniosłem w niniejszej recenzji, stwierdzam jednak, że unikalne osiągnięcie przedstawione w rozdziale III.2 skłania mnie do umiarkowanie pozytywnej oceny pracy. Reasumując, moja konkluzja dotycząca rozprawy na obecnym etapie postępowania jest pozytywna. Z niecierpliwością czekam na możliwość dyskusji z Doktorantką podczas publicznej obrony. Warto nadmienić, że pewną część wątpliwości dotyczących ocenianej pracy rozwiązałem podczas spotkania seminaryjnego z Doktorantką.

Stwierdzam, że recenzowana rozprawa pt. „Big data w systemach rozpoznania wojskowego” przygotowana przez mgr Kamilę Matełę spełnia wymagania i warunki określone w ustawie z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (jednolity tekst Dz. U. z 2023 r. z późn. zm.) i wnoszę o jej dopuszczenie do publicznej obrony i dalszych etapów postępowania doktorskiego.

