

Białystok 14 maja 2025 r.

Dr hab. inż. Ewa Świercz
Emerytowany prof. PB
Wydział Elektryczny Politechniki Białostockiej
ul. Wiejska 45D, 15-351 Białystok

KWESIONARIUSZ-RECENZJA ROZPRAWY DOKTORSKIEJ DLA RADY DYSCYPLINY
Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne
Wojskowej Akademii Technicznej w Warszawie

Tytuł rozprawy:

**ZASTOSOWANIE KONWOLUCYJNYCH SIECI NEURONOWYCH
DO ROZPOZNAWANIA OBIEKTÓW W RADIOLOKACJI**

Autor rozprawy:

kpt. mgr inż. Błażej Ślesicki

1. Opis podstawowych aspektów rozprawy, jej zakres tematyczny oraz zamierzony cel

Rozprawa doktorska mgr inż. Błażeja Ślesickiego zawiera łącznie 120 stron i składa się z następujących części:

Streszczenia pracy w języku polskim i angielskim;

Spisu treści, zawierającego:

- Listę skrótów,
- Listę symboli;

Wstępu z podrozdziałami o tytułach:

- Wprowadzenie,
- Motywacja,
- Cel i teza pracy,
- Wkład własny,
- Układ pracy;

Trzech rozdziałów teoretycznych o tytułach:

- Sztuczna Inteligencja, w którym Autor krótko prezentuje tematykę rozwoju sztucznej inteligencji, omawia budowę neuronu, i sieci neuronowych, opisuje podstawową strukturę sieci konwolucyjnych, proponuje ocenę klasyfikacji obiektów w postaci macierzy pomyłek i dodatkowych metryk, takich jak: dokładność, czułość, swoistość, precyzja,
- Konwolucyjne Sieci Neuronowe w Radiolokacji z ogólnymi informacjami wynikającymi z obszernego przeglądu literatury dotyczącymi radaru jako sensora, informacjami o rodzaju danych analizowanych przez radar i informacjami o możliwym zastosowaniu sieci konwolucyjnych w aplikacjach radarowych,
- Analiza Radaru FMCW oraz Transformacji STFT, w którym Autor przedstawia

Ewa Świercz

ogólne właściwości radaru pracującego z modulacją częstotliwości i konkretnego radaru uRAD USB v1.2 wykorzystywanego do badań i prezentuje ogólnie wybrane cechy przekształcenia STFT;

Dwóch rozdziałów merytorycznych, które stanowią opis działań Doktoranta prowadzących do obrony postawionej tezy rozprawy doktorskiej o tytułach:

- Analiza opracowanych metod, w którym Doktorant przedstawił modele symulacyjne obiektów poddanych klasyfikacji, środowisko symulacji, parametry symulowanych radarów, schemat blokowy przygotowania danych do symulacji klasyfikacji, sposób przygotowania danych do klasyfikacji w rzeczywistych warunkach środowiskowych i zaproponowaną strukturę sieci konwulucyjnej podanej późniejszej ocenie skuteczności,
- Walidacja Eksperymentalna obejmująca ocenę eksperymentów klasyfikacji numerycznej, jak i ocenę eksperymentów praktycznych w środowisku rzeczywistego ruchu ulicznego z wykorzystaniem zaprojektowanych baz danych i zaproponowaną architekturą sieci konwulucyjnej;

Podsumowania i kierunków dalszych badań;

Bibliografii zawierającej 77 pozycji;

Spisu rysunków;

Spisu tabel;

Wykazu najważniejszych publikacji Autora zawierającego 8 pozycji;

Kodów źródłowych opracowanych programów.

Tematyka rozprawy doktorskiej dotyczy klasyfikacji typowych obiektów (pieszych, samochodów, rowerów), które mogą stwarzać sytuacje spotykane w ruchu drogowym, z wykorzystaniem klasyfikatora opartego o konwulucyjne sieci spłotowe, oznaczane dalej skrótowo (CNN) i stacjonarnego radaru generującego dane wejściowe do klasyfikatora. Istnieje wiele architektur modeli głębokiego uczenia (DL) się, które wykazują doskonałą wydajność w różnych aplikacjach, ale są one zazwyczaj używane z czujnikami wejściowymi, takimi jak kamera i lidar. Radar jako czujnik jest jeszcze rzadko wykorzystywany w procesie klasyfikacji, w połączeniu z nowoczesnymi metodami głębokiego uczenia. Pomimo tego, że technologie radarowe rozwijają się intensywnie, to nadal głównie opierają się na tradycyjnych technikach przetwarzania sygnałów.

Doktorant podjął aktualny, niebanalny problem badawczy dotyczący klasyfikacji za pomocą sieci CNN w środowisku radarowym, który potencjalnie ma znaczenie praktyczne i który nie został dotychczas rozwiązany w sposób ostateczny i jednoznaczny.

Obiekty zostały przypisane do 10 klas, a w drugim wariancie badań do 6 klas, które podlegały klasyfikacji w scenariuszu zaproponowanym przez Doktoranta. Środowisko klasyfikacji składa się ze stacjonarnego radaru FMCW (77 GHz i 24 GHz) i obiektów podlegających klasyfikacji. Nie jest to więc sytuacja spotykana w radarze samochodowym, gdzie czujniki radarowe umieszczone w poruszającym się samochodzie są wykorzystane do wykrywania innych pojazdów, rowerzystów, pieszych i oceny dynamicznie zmieniającej się sytuacji drogowej. Należy więc oczekiwać nieco innych warunków klasyfikacji.

W rozprawie doktorskiej Doktorant powiązał klasyfikację obiektów z przetwarzaniem czasowo-częstotliwościowym sygnałów odebranych przez radar w taki sposób, aby wyodrębnić szczególne cechy ruchu obiektów, które są użyteczne w klasyfikacji. Zdefiniowane i badane przez Doktoranta klasy dla radaru FMCW 77 GHz obejmują:

1. pojedynczy pieszy,

2. dwoje pieszych,
3. troje pieszych,
4. pojedynczy rowerzysta,
5. pojedynczy samochód,
6. pojedynczy pieszy oraz pojedynczy samochód,
7. pojedynczy pieszy oraz pojedynczy rowerzysta,
8. pojedynczy samochód oraz pojedynczy rowerzysta,
9. dwoje pieszych oraz pojedynczy samochód,
10. dwoje pieszych oraz pojedynczy rowerzysta.

Dla radaru FMCW 24 GHz liczba klas została zredukowana do 6 i są to klasy wyszczególnione poniżej:

1. pieszy,
2. dwoje pieszych,
3. rowerzysta,
4. samochód,
5. pieszy oraz samochód,
6. pieszy oraz rowerzysta.

Należy zauważyć, że klasy są złożone i zawierają jeden obiekt, albo kombinację dwóch lub trzech pojedynczych obiektów np. pojedynczy pieszy oraz pojedynczy rowerzysta lub dwoje pieszych i pojedynczy rowerzysta. Tak postawiony problem klasyfikacji generuje znacznie większe trudności niż klasyfikacja odrębnych, pojedynczych obiektów i wymaga znacznie większej i zróżnicowanej bazy danych dla każdej z 10 klas. Uwzględnić należy specyficzne właściwości obiektów wewnątrz klasy np. pieszy spacerujący, pieszy biegnący to ciągle jest tylko pieszy, ale z różnymi cechami ruchu. Co więcej, obiekt jednej klasy może być obiektem w innej klasie np. pieszy i samochód czy pieszy i rowerzysta. Doktorant podjął niebanalny problem klasyfikacji, gdzie dyskryminacja pomiędzy klasami z obiektami jest oparta o dynamikę obiektów, a dokładniej mikroruchów tych obiektów. Dynamika mikroruchów obiektów wytwarza modulacje częstotliwości w sygnale odbitym od obiektu, a następnie odebrany przez radar i może wywołać dodatkowe lokalne zmiany częstotliwości Dopplera. W przypadku obiektu, który ma tylko ruch ze stałą prędkością (stałą translacją), przesunięcie częstotliwości Dopplera wywołane przez translację jest stałe, tzn. jest funkcją niezmienną w czasie. Mikroruchy dają nowe cechy w sygnaturze obiektu, które są istotnie różne od sygnatury w przypadku braku mikroruchów.

Do oceny sygnatury mikro-Dopplera (MD) Doktorant zaproponował wykorzystanie spektrogramu pozyskanego z sygnału echa radarowego. Sygnatura mikro-Dopplera obiektów z różną mikro-dynamiką daje charakterystyczny ślad w spektrogramie w postaci widocznej modulacji częstotliwości. Nawet poprzez ocenę wizualną, możliwe jest zauważenie pewnych cech różnicujących różne obiekty. O ile w przypadku pojedynczych obiektów sygnatury MD są prostsze do interpretacji, o tyle w przypadku klasy z kilkoma obiektami mogą się pojawić wzajemne przenikania ruchów i pokrywanie się trajektorii modulacji wywołanych ruchem, co powoduje, że obraz klasy złożonej na obrazie spektrogramu może dawać trudno interpretowane wyniki. Ocena takiej złożonej klasyfikacji jest przedmiotem badań podjętych przez Doktoranta.

Doktorant dokonał klasyfikacji obiektów należących do 10 klas i 6 klas, wykorzystując dwa radary do oświetlania obiektów radar FMCW 77 GHz i radar FMCW 24 GHz, z emisją sygnałów oświetlających w postaci sygnałów z liniową modulacją częstotliwości (LFM).

Ewa Śmieszka

Radar o częstotliwości 77 GHz to nowoczesna technologia, która oferuje prawie trzykrotnie lepszą rozdzielczość i dokładność w porównaniu z tradycyjnymi radarami 24 GHz. Głównym celem radaru 77 GHz jest wykrywanie i identyfikacja obiektów, np. pieszych i rowerzystów na mniejszych odległościach niż jest to możliwe w radarze 24 GHz i dlatego ta technologia radaru jest intensywnie badana w ośrodkach naukowych przemysłu motoryzacyjnego, np. na potrzeby radaru samochodowego. Większa precyzja pomiarów prędkości obiektów pomaga w bardziej precyzyjnym monitorowaniu ruchu obiektów, co jest ważne w przypadku ruchu drogowego. Analiza odpowiedzi radaru w paśmie 77 GHz nie jest trywialna i często niedokładna ze względu na ekstremalnie krótkie długości fal, co sprawia, że odpowiedź radaru jest bardzo wrażliwa na położenie obiektu, a więc również na zakłócenia.

Sygnatury mikro-Dopplerowskie interpretowane w spektrogramie do celów klasyfikacji nie są pomysłem Doktoranta, ale w raportach naukowych z tej tematyki dane częściej pozyskiwane były z wcześniej przygotowanych publicznych baz danych, np. MAFAT, RadEch. Surowe dane radarowe zebrane na konkretne potrzeby konkretnej klasyfikacji różnią się od tych zestawów z publicznych baz danych, ponieważ w bardziej naturalny sposób w chwili pomiaru odwzorowują środowisko.

W rozprawie doktorskiej Doktorant przygotował autorskie bazy danych z symulowanymi sygnałami radarowymi na potrzeby klasyfikacji wyszczególnionych wyżej 10 klas z wieloma obiektami jednocześnie dla radaru 77 GHz i 6 klas dla radaru 24 GHz. Jest to rozszerzenie badań prezentowanych w literaturze światowej, gdzie połączenie tak wielu obiektów jednocześnie w klasyfikacji jest jeszcze mało rozpoznane. Doktorant poprzez zaproponowanie architektury sieci CNN, wykorzystaniu sygnatur MD obiektów reprezentowanych przez spektrogramy, przeprowadzeniu szeregu eksperymentów numerycznych i środowiskowych starał się udowodnić tezę rozprawy doktorskiej:

Możliwe jest stworzenie zautomatyzowanej metody pozwalającej na detekcję i jednoznaczne rozpoznanie wybranych obiektów ruchu drogowego za pomocą radaru FMCW stosując krótkoczasową transformację Fouriera echa odebranego sygnału oraz dedykowaną strukturę konwolucyjnej sieci neuronowej jako klasyfikatora obiektów.

W ocenie recenzenta, powyższa teza została sformułowana poprawnie, a próba jej udowodnienia jest niewątpliwie ambitnym zadaniem Autora, pokazującym potrzebę wykorzystania sztucznej inteligencji na potrzeby radiolokacji. Realizacja celu pracy stanowi pewien wkład do rozwoju technik głębokiego uczenia w radiolokacji.

Dane wejściowe do sieci CNN zostały wygenerowane z sygnału radarowego odbitego od obiektu i przekształcone do formy obrazowej w postaci spektrogramów. Dzięki temu spektrogramy mogą być analizowane przez sieć CNN w sposób podobny do klasycznych obrazów wizualnych. Klasyfikator neuronowy wykorzystuje zawarte w spektrogramie charakterystyczne czasowo-częstotliwościowe zachowania obiektów indukowane ruchem obiektu i dokonuje automatycznie ekstrakcji specyficznych cech obiektu poprzez warstwy konwolucyjne sieci. Warstwy konwolucyjne zawierają wyuczone filtry (kernele), które wyodrębniają cechy odróżniające od siebie różne spektrogramy obiektów. Pozwala to na klasyfikację obiektów z dużą precyzją, niespotykaną w innych metodach klasyfikacji.

Podjęta przez Doktoranta tematyka badań jest jak najbardziej aktualna, a sformułowane przez Doktoranta problemy badawcze nie zostały jak dotąd efektywnie i jednoznacznie rozwiązane,

pomimo stosunkowo dużej liczby publikacji na temat klasyfikacji przez sieć CNN w innych aplikacjach.

2. Analiza wartości merytorycznej oraz zestawienie kluczowych osiągnięć Autora

Za oryginalny dorobek Doktoranta recenzent uznaje:

- Opracowanie metody generowania bazy danych zawierającej modele symulowanych obiektów takich jak piesi, rowerzyści oraz samochody i ich kombinacji.
- Przygotowanie rozszerzonej bazy danych (transformacje geometryczne, skalowanie) w postaci symulacyjnych obrazów spektrogramowych do celów uczenia i testowania sieci CNN dla radaru 77 GHz i 24 GHz.
- Opracowanie bazy danych pozyskanej z rzeczywistych pomiarów wykonanych radarem uRAD v1.2 pracującym na częstotliwości 24 GHz.
- Zaprojektowanie architektury dedykowanej sieci konwolucyjnej do klasyfikacji 10 klas i do klasyfikacji 6 klas, zawierających kombinację wielu obiektów.
- Wykonanie unikalnych symulacji klasyfikacji z dedykowaną siecią CNN dla radaru FMCW 77GHz i radaru FMCW 24 GHz.
- Wykonanie klasyfikacji środowiskowej z dedykowaną siecią i radarem uRAD v1.2.
- Ocena jakości klasyfikacji.

W recenzowanej rozprawie Autor zrozumiale prezentuje opracowane przez siebie metody klasyfikacji obiektów z wykorzystaniem klasyfikatora opartego całkowicie na sieciach konwolucyjnych, zarówno w środowisku symulacyjnym jak i naturalnym środowisku terenowym z radarem uRAD v1.2. Wybór głębokich sieci neuronowych jako klasyfikatora ma cenną zaletę, ponieważ ekstrakcja cech do klasyfikacji odbywa się automatycznie wewnątrz sieci i nie wymaga udziału człowieka. Dobór architektury sieci oraz właściwe przeprowadzenie procesu jej uczenia stanowią kluczowe elementy determinujące skuteczność klasyfikacji.

Doktorant zaproponował architekturę składającą się z 4 warstw konwolucyjnych z liczbą 270240 parametrów do ustawienia w procesie uczenia dla 10-klasowej klasyfikacji i praktycznie taką samą strukturę w klasyfikacji 6-klasowej. Pierwsza warstwa konwolucyjna składała się z 16 neuronów, druga warstwa konwolucyjna składała się z 32 neuronów, trzecia warstwa konwolucyjna składała się z 64, czwarta warstwa konwolucyjna składała się ze 128 neuronów i ostatnia warstwa zawierała 10 lub 6 neuronów klasyfikacyjnych, w zależności od wariantu klasyfikacji. W każdej warstwie konwolucyjnej dla każdego neuronu zaproponowano filtr konwolucyjny (jądro splotu) o wymiarach 5x5. Po każdej warstwie splotu następuje warstwa uśredniająca 2x2 (Max Pooling), zmniejszająca wymiarowość map cech ze współczynnikiem 2. Przeprowadzono też odpowiednie skalowanie danych w warstwie normalizującej. Każda warstwa wykorzystuje funkcje aktywacji (ReLU). Ostateczna klasyfikacja jest przeprowadzona przez warstwę softmax. Pełna struktura sieci została przedstawiona na stronach 70-71 rozprawy na Rys. 4.8 i Rys. 4.9.

Jest to więc sieć splotowa niezbyt dużych rozmiarów, która dobrze dawała sobie radę w klasyfikacji większej liczby zróżnicowanych klas. Zaprojektowana sieć ma znacznie mniej warstw uczących, a więc mniej parametrów do nauczenia niż typowe architektury VGG-16 z 13 warstwami splotowymi czy VGG-19 z 16 warstwami splotowymi wykorzystywane do klasyfikacji obrazowej. Modyfikacje sieci typu VGG użyte co celów klasyfikacji były

Ewa Smieva

analizowane w kilku pozycjach w Bibliografii.

Wyniki klasyfikacji przedstawiono za pomocą tradycyjnych ocen, tzn. macierzy pomyłek i dodatkowych metryk dla najlepszego przypadku klasyfikacji (osobno dla radaru FMCW 77 GHz, radaru FMCW 24 GHz w eksperymentach symulacyjnych oraz radaru uRAD v1.2 w eksperymentach terenowych). Metryki klasyfikacji wieloklasowej pokazują dużą precyzję klasyfikacji klas jedno-obiektowych i zdecydowanie mniejszą precyzję klasyfikacji klasy złożonej z wielu obiektów, co nie budzi zaskoczenia. Szczególnym obiektem jest pieszy, którego sygnatura MD może być bardzo skomplikowana i mocno uzależniona od zamierzonych i niezamierzonych ruchów głowy, rąk nóg, tułowia. Rozpoznawanie tak wielu aktywności człowieka jest trudne, a ekstrakcja charakterystycznych parametrów ze spektrogramu jest wyzwaniem. Człowiek w kombinacji z innym obiektem jeszcze bardziej komplikuje spektrogram, który może pokazywać wzajemnie pokrywające się cechy obu obiektów wpływające na obniżenie precyzji klasyfikacji, co pokazała klasyfikacja zaproponowana przez Doktoranta. Równie skomplikowanym obiektem jest rowerzysta. Zaproponowane przez Doktoranta modele symulacyjne pieszego i rowerzysty sprawdziły się w przeprowadzonych symulacjach, osiągając dużą precyzję klasyfikacji w zaproponowanej strukturze sieci CNN.

Recenzent uznaje, że teza rozprawy doktorskiej została obroniona przy założeniach ograniczonych warunków ruchu obiektów, jak np. określona prędkość poruszania się pieszego, ograniczona prędkość jazdy roweru, czy też prędkość jazdy samochodu. Ograniczenia zostały przedstawione w Tabeli 4.1.

Zaprezentowane w rozprawie podejście do klasyfikacji wieloklasowej, jest wynikiem oryginalnych koncepcji Autora i ma znaczenie poznawcze i potencjalne znaczenie praktyczne w przyszłości.

Doktorant publikował częściowe wyniki swoich badań w czasopismach krajowych oraz czasopismach o zasięgu międzynarodowym. Spośród 77 cytowanych w Bibliografii pozycji literatury, 8 pozycji stanowią wysoko punktowane, zamieszczone w Wykazach czasopism naukowych i recenzowanych materiałów z konferencji międzynarodowych publikowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego, współautorskie prace Doktoranta. Przedstawione pozycje literaturowe w Bibliografii wskazują na duże rozeznanie Autora co do aktualnego stanu badań w dziedzinie, w której jest ulokowana rozprawa doktorska. Przedstawiona Bibliografia jest reprezentatywna w odniesieniu do zagadnień realizowanych w ramach rozprawy doktorskiej i nie wymaga uzupełnień.

3. Spostrzeżenia krytyczne oraz komentarze dotyczące rozprawy

Po dokładnej analizie treści rozprawy zauważono pewne nieprecyzyjne sformułowania oraz pewne błędy redakcyjne, które mogą budzić wątpliwości i wymagają doprecyzowania. Jednakże uwagi te nie mają wpływu na merytoryczną wartość pracy.

Str.17 Autor formułuje frazę: *Ponadto, za cel autor postawił sobie również stworzenie kompleksowego i uniwersalnego kompendium wiedzy dotyczącego zastosowania sztucznej inteligencji w radiolokacji.* Recenzent nie uważa, że przedstawione w rozprawie krótkie i raczej powierzchowne opisy wybranych z literatury metod, bez dogłębnej analizy teoretycznej i bez waloru dydaktycznego mogłyby stanowić kompendium wiedzy

o zastosowaniu sztucznej inteligencji w radiolokacji. Znane wykorzystania sztucznej inteligencji w radiolokacji Autor wymienił na str.40.

Str.30 Autor bardzo skrótowo odniósł się do teoretycznego aspektu uczenia sieci głębokich. Po zaproponowaniu modelu CNN (podaniu specyfikacji architektury sieci, typu neuronów ukrytych) istotna jest postać funkcji kosztu podlegająca minimalizacji w celu wyznaczenia wartości wszystkich wag sieci. Zazwyczaj jako funkcja kosztu w procesie uczenia sieci wykorzystywany jest błąd średniokwadratowy (MSE) lub cross-entropy (CE). Nie bardzo wiadomo, jakiej postaci funkcji kosztu użył Doktorant do uczenia dedykowanej sieci CNN, która stanowi kluczowe osiągnięcie w rozprawie. Proszę o doprecyzowanie tego aspektu uczenia sieci.

Str. 34 Źle oznaczona została Tabela 1.2

Str. 56 Pomyłony został numer przywołanej pozycji z Bibliografii. Jest [66], a powinno być [67].

Str. 62 W Tabeli 4.1 pomyłono rozdzielczość w odległości radaru 24 GHz i 77 GHz

Częstotliwość pracy	24 GHz	77 GHz
Maksymalny wykrywalny zasięg	100 m	100 m
Rozdzielczość w odległości	0,04? m	0,5? m

W Tabeli również zamieszczono prędkości ruchu rowerzysty i samochodu. Czy rowerzysta i samochód poruszają się w tym samym zakresie prędkości 1-10 m/s, tj. od 3.6 km/godz. do 36 km/godz.? Dla samochodu to zapewne stanowczo za mało.

Str. 67 Dotyczy frazy: *W związku z powyższym, sięgnięto po sprawdzone wcześniej rozwiązanie będące metodą doboru struktury i jej hiperparametrów w sposób ręczny czyli ewolucji jej struktury na podstawie kolejnych eksperymentów.*

Próba określenia architektury sieci została potraktowana dość pobieżnie. Czy do budowy architektury dedykowanej sieci CNN w zadaniach klasyfikacji obrazów były wykorzystywane inne wzorce i biblioteki wspomagające tworzenie samej struktury? Czy były to tylko doświadczenia wspomagane intuicją w poszukiwaniu struktury sieci CNN, finalnie przedstawionej na Rys. 4.8 i Rys. 4.9?

Brak jest uzasadnienia, dlaczego tylko ta architektura jest skuteczna w przeprowadzonej klasyfikacji.

Str. 68 Autor krótko informuje, że optymalizacja w celu wyznaczenia wartości wag w sieci była prowadzona metodą stochastycznego spadku wzdłuż gradientu z momentum (SGDM).

Natomiast inne hiperparametry jak wartości wag są dostosowywane w procesie uczenia przy użyciu algorytmu SGDM (ang. Stochastic Gradient Descent with Momentum).

Jest to dość ogólne stwierdzenie. Algorytm SGDM jest chętnie wykorzystywany w głębokim uczeniu ze względu na rolę momentum w lepszym oszacowaniu wag. Brak choćby krótkiego wyjaśnienia tej metody recenzent uważa za poważne niedopatrzenie w redakcji rozprawy.

Ewa Świruta

Str. 72 proces uczenia sieci byłby bardziej przekonujący, jeżeli pokazane byłyby przykładowe mapy cech po każdej warstwie spłotowej.

Str. 76 Na tej stronie przedstawiono 10 spektrogramów odpowiadającym 10 klasom rozpatrywanych obiektów. Wygenerowana baza danych obrazów zawierała po 1000 obrazów na każdą z 10 klas. Te spektrogramy powinny być opisane dokładniej, ze wskazaniem, jakie cechy ruchu obiektów widoczne w spektrogramie są dyskryminujące dla każdej z klas. O ile spektrogramy 1-3 pokazują lekko zauważalne różnice w ruchu pierwszego pieszego i ruchu dwóch innych pieszych, o tyle wizualnie nie różnią się spektrogramy roweru i samochodu. Z pewnością Autor w symulacjach zróżnicował ruch samochodu i roweru, a te różnice ze względu być może na ograniczoną rozdzielczość barw nie zostały pokazane w zamieszczonych spektrogramach, natomiast istnieją w numerycznym zapisie pikseli histogramu. To są tylko domysły i wymagają bardziej precyzyjnego wyjaśnienia.

Str. 79 W Tabeli 5.1 zdaniem recenzenta macierz pomyłek dla klasyfikacji radarem 77 GHz ma niewłaściwy opis wierszy i kolumn. Zamiast nazwy w poziomie **klasa predykowana** powinna być nazwa **klasa rzeczywista**, a zamiast nazwy **klasa rzeczywista** w pionie powinna być nazwa **klasa predykowana**. Analizując drugą kolumnę po zamianie nazw: klasa 2 (rzeczywista) w 150 próbach została poprawnie przewidziana w 131 próbach i niepoprawnie przewidziana jako klasa 9 w 19 próbach i stąd miara np. $precyzja=131/150=0.873$.

Str. 80 W Tabeli 5.3, podobnie jak w Tabeli 5.1, powinna nastąpić zamiana nazw w poziomie i w pionie. Recenzentowi brakuje przedstawienia spektrogramów 6 klas dla radaru 24 GHz w symulacjach. Można byłoby porównać różnice w dokładności spektrogramów dla radarów 77 GHz i 24 GHz, uzyskane w symulacjach.

Str. 81 W Tabeli 5.4 jest chyba pomyłkowy zapis ‘Symulacja 2 (10 klas obiektów po 1000 obrazów)’ dla radaru 24 GHz.

Str. 81 Dotyczy frazy: *Obiekty poruszały się z różnymi prędkościami prostopadle do zbudowanego stanowiska pomiarowego w obu kierunkach.*

Można byłoby podać wartości tych różnych prędkości i jakieś bliższe szczegóły ruchu w doświadczeniu środowiskowym. Przedstawione histogramy 6 klas na Rys. 5.4 ze str. 84 w opinii recenzenta są zdecydowanie bardziej wyraziste i łatwiej pozwalają na odszukanie cech dyskryminacyjnych generowanych przez odmienne sygnatury MD obiektów przypisanych do klas.

Str. 84 Do Tabeli 5.5 odnoszą się te same uwagi jak do Tabeli 5.1 i Tabeli 5.3.

4. Ocena i podsumowanie wyników analizy rozprawy doktorskiej

Postawione przez Doktoranta zagadnienia naukowe zostały w rozprawie rozwiązane z wynikiem pozytywnym.

Sformułowana na str. 17 teza rozprawy została udowodniona, zakładając określone ograniczenia na obiekty poddane klasyfikacji i określone parametry radaru. Obiekty do klasyfikacji rozważane w rozprawie miały przypisany ograniczony zestaw możliwych sygnatur MD, więc trudno mówić o uogólnieniach działania klasyfikacyjnego zaprojektowanej sieci CNN w nowych warunkach. Aby osiągnąć pożądane rezultaty, konieczne byłoby trenowanie sieci na znacznie bardziej zróżnicowanym zbiorze danych,

a być może także wprowadzenie zmian w jej strukturze. Nie można jednoznacznie stwierdzić, że propozycje Doktoranta wykazują właściwości uniwersalnej metody. Nie sposób mówić tu o pełnym uniwersalizmie, gdyż różnorodność obiektów w ruchu drogowym oraz złożona dynamika ich przemieszczania, odzwierciedlona w spektrogramach, sprawiają, że jedynie określone ograniczenia narzucone na obiekty umożliwiają opracowanie skutecznej metody klasyfikacji. Taka klasyfikacja z ograniczeniami została zaprezentowana w przedstawionej do recenzji rozprawie doktorskiej.

Uzyskane wyniki klasyfikacji w scenariuszu opisanym w rozprawie są obiecujące. Natomiast trudno je porównać dokładnie do wyników innych badaczy przedstawianych w literaturze, ponieważ eksperymenty w literaturze bazowały na innych założeniach. Można jedynie przypuszczać, że uproszczona architektura sieci CNN, zaproponowana przez Doktoranta, może zapewniać równie dobre, a być może nawet lepsze wyniki klasyfikacji, jednak wymagałoby to zachowania identycznych warunków eksperymentalnych.

Badania wykonane przez Doktoranta pokazały, że właściwe modyfikacje architektury mogą przyczynić się do lepszej jakości klasyfikacji. Jednym z niedociągnięć rozprawy jest brak uzasadnienia, że wyłącznie omawiana w niej architektura sieci CNN potwierdza postawioną tezę.

Stacjonarny radar, pełniący funkcję sensora zbierającego dane dla sieci CNN, nie jest powszechnie stosowany, a rozprawa doktorska wpisuje się w nurt badań nad taką klasyfikacją. Cenną zaletą rozprawy jest budowa realistycznego środowiska pomiarowego wykorzystującego radar uRAD v1.2 i właściwie zorganizowanego środowiska obliczeniowego.

Metoda klasyfikacji oparta całkowicie na sieci CNN analizująca obrazy radarowe jest bardzo perspektywiczna i wymagająca intensywnych badań. Dalsze prace mogłyby polegać na uwzględnieniu bardziej realistycznych obiektów i bardziej realistycznych warunków otoczenia z różnymi zakłóceniami.

W związku z Art. 186 ust. 1 oraz Art. 187 ust. 1 i 2 Ustawy z dnia 3 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (tj. Dz. U. z 2024 r., poz. 1571 z późn. zm.) stawiam wniosek o dopuszczenie rozprawy doktorskiej mgr inż. Błażeja Ślesickiego do publicznej obrony przed Radą Dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne w Wojskowej Akademii Technicznej w Warszawie.

Ewa Ślesicka

