



**POLITECHNIKA
BYDGOSKA**


Wydział Telekomunikacji,
Informatyki i Elektrotechniki



HR EXCELLENCE IN RESEARCH

Bydgoszcz, 09.12.2025 r.

dr hab. inż. Tomasz Talaśka, prof. PBS
Zakład Sztucznej Inteligencji i Przetwarzania Sygnałów
Wydział Telekomunikacji, Informatyki i Elektrotechniki
Politechnika Bydgoska im. Jana i Jędrzeja Śniadeckich
ul. Al. Prof. S. Kaliskiego 7, 85-796, Bydgoszcz
e-mail: talaska@pbs.edu.pl



PRZEWODNICZĄCY RADY DYSCYPLINY
Automatyka, Elektronika, Elektrotechnika
i Technologie Kosmiczne

prof. dr hab. inż. Wojciech Szelaąg

RECENZJA ROZPRAWY DOKTORSKIEJ

dla Rady Dyscypliny

Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne

Politechniki Poznańskiej

1. Wprowadzenie

Niniejsza recenzja została przygotowana w wyniku powołania mnie na recenzenta rozprawy doktorskiej pt. „A Multi-Module Object Detection System Based on Deep Neural Networks” przez Radę Dyscypliny: Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne z dnia 16.09.2025 roku.

Autor rozprawy: mgr inż. Aleksandra Kos

Promotor rozprawy: dr hab. inż. Dominik Belter, Prof. PP

Promotor pomocniczy: dr inż. Karol Majek

Praca finansowana była w ramach grantu „Doktorat Wdrożeniowy: numer DWD/5/0203/2021

Niniejsza recenzja (poza wprowadzeniem i wnioskami końcowymi) zawiera odpowiedzi na siedem pytań dotyczących rozprawy doktorskiej.

2. Jaki jest problem naukowy (teza) rozprawy? Czy został on trafnie i jasno sformułowany? Jaki charakter ma rozprawa?

Problemy naukowe rozprawy zostały trafnie sformułowane. Po lekturze pracy (mimo iż nie jest to wprost napisane) można wynieść, że celem rozprawy było opracowanie wydajnego i modułowego systemu detekcji obiektów, opartego na głębokich sieciach neuronowych, który umożliwia wykrywanie bardzo małych (TOD - Tiny Object Detection) i wieloskalowych obiektów w obrazach o wysokiej rozdzielczości. Główny nacisk położono na osiągnięcie wysokiej dokładności detekcji przy jednoczesnym zachowaniu niskiego kosztu obliczeniowego i szybkiego wnioskowania, co jest kluczowe dla zastosowań w czasie rzeczywistym na platformach o ograniczonych zasobach, takich jak drony i roboty mobilne.

Teza główna rozprawy zdefiniowana została w rozdziale 1.2:

Selektywne wnioskowanie w pełnej rozdzielczości na podobszarach obrazu zidentyfikowanych przez Estymator Regionu Zainteresowania i Moduł Śledzenia Obiektów poprawia wydajność detekcji bardzo małych obiektów na obrazach o wysokiej rozdzielczości, mierzoną za pomocą Średniej Precyzji (AP), Średniej Czulości (AR) i prędkości wnioskowania.

Główną hipotezę wspierają trzy hipotezy pomocnicze, z których każda odpowiada jednemu z kluczowych komponentów zaproponowanego w rozprawie przez Autorkę systemu:

Teza 1: **Estymacja ROI:** Estymacja ROI przy użyciu modelu głębokiej sieci neuronowej poprawia zarówno jakość detekcji, jak i prędkość wnioskowania w porównaniu z naiwnym podejściem z oknem przesuwym.

Teza 2: **Predykcja ROI:** Włączenie dodatkowego źródła ROI, takiego jak moduł śledzenia obiektów, do systemu detekcji obiektów opartego na ROI, dodatkowo poprawia jakość detekcji, prędkość wnioskowania i wydajność obliczeniową w porównaniu z metodami detekcji bardzo małych obiektów stanowiącymi stan wiedzy.

Teza 3: **Globalne Filtrowanie:** Fałszywie pozytywne (FP) detekcje cząstkowe w systemach opartych na oknach można zredukować za pomocą technik post-processingu, takich jak Tłumienie nakładających się ramek (Overlapping Box Suppression, OBS) i łączenie (scalanie) nakładających się ramek (Overlapping Box Merging, OBM).

Niniejsza rozprawa ma charakter koncepcyjno-eksperymentalny.

3. Czy w rozprawie przeprowadzono w sposób właściwy analizę źródeł, w tym literatury światowej, stanu wiedzy i zastosowań w przemyśle? Czy wnioski z przeglądu źródeł sformułowano w sposób jasny i przekonujący?

Przegląd i analiza literatury zostały przeprowadzone i przedstawione w sposób właściwy. Autorka jest ekspertem w dziedzinie badań na systemami detekcji obiektów. Autorka rozumie

aktualny stan wiedzy oraz literatury światowej w zakresie rozprawy, co przedstawiła między innymi w rozdziale 2, a także pośrednio w rozdziałach 3-6. W rozdziale drugim w szczegółowy sposób omówione zostały systemy detekcji, ze szczególnym uwzględnieniem bardzo małych obiektów zarówno na obrazach, jak i na video. Poza tym omówiono metryki oceny, zbiory danych potrzebne w procesie detekcji obiektów. Przeanalizowano także dane literaturowe w zakresie śledzenia obiektów i generowania ROI. Autorka w pracy przedstawiając swoje nowe koncepcje, często odnosi się bezpośrednio do danych literaturowych.

Bibliografia zawiera 190 pozycji. Zdecydowana większość cytowanych prac jest wydana po 2015 roku, co świadczy o dobrej znajomości aktualnego stanu wiedzy.

Dorobek publikacyjny doktoranta

W spisie literatury znaleźć można 7 prac Autorki [64-70], które związane są tematycznie z treścią rozprawy. Formalnie w rozdziale 1.6 Autorka wymienia aż swoich 9 artykułów, ale nie do końca rozumiem dlaczego jeden z nich tj. „Deep Learning for Small and Tiny Object Detection: A Survey” [100 pkt, 2023 rok] nie został odpowiednio użyty w pracy?

W czterech przypadkach (na bazie informacji z rozdziału 1.6) są to punktowane czasopisma (odpowiednio 200, 140, 100 i 40 punktów). Pięć pozostałych prac to materiały konferencyjne o zasięgu krajowym i międzynarodowym.

Warto podkreślić jest to, że we wszystkich wymienionych pozycjach Pani Aleksandra Kos wymieniana jest zawsze na pierwszej pozycji. W dwóch przypadkach jest ona jedynym autorem.

4. Czy autorka rozwiązała postawione zagadnienia? Czy użyła do tego właściwych metod dowodząc, że posiadała umiejętności związane z metodyką i metodologią prowadzenia badań naukowych? Czy przyjęte założenia są uzasadnione?

Autorka skutecznie zweryfikowała wszystkie postawione tezy badawcze, udowadniając tym samym, że główny cel pracy tj. modułowy i wydajny system detekcji bardzo małych obiektów w czasie rzeczywistym został zrealizowany. Przyjęte w pracy założenia są uzasadnione i merytorycznie poprawne. Teza (w tym tezy pomocnicze) rozprawy została dowiedziona.

Główna hipoteza zakładała, że selektywne wnioskowanie w pełnej rozdzielczości na podobszarach zidentyfikowanych przez Estymator i Moduł Śledzenia poprawia wydajność detekcji bardzo małych obiektów.

Dowód: Zaproponowany, nowatorski **wielomodułowy Framework** (nazwany w pracy - **SegTrackDetect (STD)**) przewyższył tradycyjne metody oraz szereg najnowocześniejszych modeli (np. InternImage, YOLOv7, QueryDet, DetectoRS) pod względem Średniej Precyzji (AP), Średniej czułości (AR), a przede wszystkim prędkości wnioskowania (FPS).

Hipoteza Pomocnicza 1 (Estymacja ROI), która dotyczyła poprawy jakości detekcji i prędkości wnioskowania w porównaniu z naiwnym podejściem ruchomego okna.

Dowód: Wstępny system TinyROI (oparty tylko na estymacji) osiągnął niemal ośmiokrotne przyspieszenie tj. 7.9 FPS do 1.2 FPS na zbiorze MTSD (Mapillary Traffic Sign Dataset) w stosunku do metody ruchomego okna, zachowując przy tym porównywalną jakość detekcji. Ulepszona wersja zaproponowanego systemu (STD) osiągnęła jeszcze lepsze wyniki (np. 44.5 FPS i AP 52.6% na zbiorze SeaDronesSee). Hipoteza pomocnicza 1 została udowodniona w rozdziale 4.

Hipoteza Pomocnicza 2 (Predykcja ROI ze Śledzeniem), która dotyczyła dodatkowej poprawy jakości, prędkości i wydajności obliczeniowej dzięki włączeniu modułu śledzenia.

Dowód: Włączenie Modułu Predykcji ROI opartego na śledzeniu umożliwiło Estymatorowi ROI działanie w znacznie niższych rozdzielczościach (np. 128x192 px zamiast 448x768 px), co skutkowało prawie czterokrotnym przyspieszeniem procesu selekcji ROI (303 FPS vs 82 FPS), przy jednoczesnym utrzymaniu lub poprawie jakości detekcji (52.4% AP vs 52.9% AP). Śledzenie skutecznie kompensowało pominięcia małych obiektów w zgrubnych maskach segmentacji. Hipoteza pomocnicza 2 została udowodniona w rozdziale 5.

Hipoteza Pomocnicza 3 (Globalne Filtrowanie OBS/OBM), która dotyczyła redukcji fałszywie pozytywnych detekcji cząstkowych za pomocą algorytmów OBS (Overlapping Box Suppression) i OBM (Overlapping Box Merging).

Dowód: Algorytmy OBS i OBM skutecznie rozwiązały problem detekcji fragmentarycznych, który jest typowy dla metod opartych na oknach, przewyższając standardowy algorytm NMS (Non-Maximum Suppression) pod względem wyniku F1-Score (np. poprawa o ponad 10 punktów procentowych w niektórych ustawieniach). OBS konsekwentnie redukował fałszywe pozytywy, a OBM odzyskiwał fałszywe negatywy, łącząc fragmenty w pełne detekcje. Hipoteza pomocnicza 3 została udowodniona w rozdziale 6.

Autorka wykazała się posiadaniem umiejętności związanych z metodyką i metodologią prowadzenia badań naukowych, używając właściwych metod potwierdzających uzyskane wyniki, tj.:

- a) **Studium ablacyjne:** Wykorzystanie dogłębnych badań ablacyjnych (Rozdział 4, 5, 6) było kluczowe i metodycznie poprawne. Pozwoliło to na izolację wpływu każdego modułu (np. rozdzielczości wejściowej Estymatora, włączenia Predykcji ROI, różnych kryteriów filtrowania OBS) i obiektywne uzasadnienie wyborów architektonicznych
- b) **Ewaluacja Porównawcza:** Przeprowadzono szeroko zakrojone porównania z odpowiednimi stanami wiedzy (State-of-the-Art), w tym architekturami ogólnego przeznaczenia (YOLO, InternImage), metodami detekcji małych obiektów (DetectoRS, QueryDet) i metodami detekcji wideo (DiffusionVID, MEGA). Zastosowanie SAHI (Slicing Aided Hyper Inference) jako zewnętrznego, publicznie dostępnego benchmarku dla ruchomego okna dodatkowo uwiarygodniło wyniki.

- c) **Właściwy Dobór Metryk:** Użyto metryk standardowych w detekcji obiektów (AP, AR, FPS) oraz metryk specjalistycznych dla detekcji małych obiektów (APvt, APt, ARvt, ART), a także wprowadzono metryki na poziomie ROI do oceny pośrednich etapów systemu.
- d) **Wdrożenie:** System został wydany jako otwarty, modułowy szkielet (open-source). Praca była częścią programu "Doktorat Wdrożeniowy", co wymusiło praktyczną weryfikację pod kątem wdrożenia w systemach o ograniczonych zasobach, potwierdzając praktyczne umiejętności badawcze i inżynierskie.

Przyjęte założenia są dobrze uzasadnione i oparte na ograniczeniach istniejących metod, które zidentyfikowano w przeglądzie literatury. W pracy poprawnie uzasadniono modułowość i hybrydowe podejścia ROI, polegające na inteligentnym połączeniu (fuzji) dwóch różnych, ale uzupełniających się metod selekcji obszarów obrazu: estymacji ROI opartej na segmentacji (działającej przestrzennie w jednej klatce) i predykcji ROI opartej na śledzeniu (działającej czasowo między klatkami). Poza tym w pracy uzasadniono użycie modułu globalnego filtrowania (gdzie standardowy algorytm NMS był niewystarczający), czy użycie lekkich detektorów (YOLOv7Tiny) i prostego trackera (SORT), co jest uzasadnione dążeniem do wydajności w czasie rzeczywistym i niskiego kosztu obliczeniowego na platformach wbudowanych.

5. Na czym polega oryginalność rozprawy, co stanowi samodzielny i oryginalny dorobek autora, jaka jest pozycja rozprawy w stosunku do stanu wiedzy czy poziomu nauki reprezentowanych przez literaturę światową?

Oryginalność rozprawy polega przede wszystkim na syntezie i optymalizacji istniejących technik w ramach jednej, spójnej i modułowej architektury, co stanowi unikalne podejście hybrydowe do problemu ograniczeń obliczeniowych w detekcji wideo o wysokiej rozdzielczości.

Jako autorskie i oryginalne dokonanie można uznać:

5.1. Opracowanie, implementacja i walidacja wielomodułowego Frameworku (STD).

Jego oryginalność polega na:

- Hybrydowym Podejściu do ROI, czyli połączeniu dwóch fundamentalnie różnych metod selekcji obszarów zainteresowania: Estymacji ROI opartej na segmentacji i Predykcji ROI opartej na śledzeniu. Jest to pierwsze tak efektywne połączenie tych dwóch mechanizmów, umożliwiające Estymatorowi pracę w bardzo niskiej rozdzielczości (dla zwiększenia prędkości), podczas gdy tracker (Predykcja) kompensuje wynikające z tego błędy.
- Selektywne Wnioskowanie w Pełnej Rozdzielczości: System nie przetwarza całego obrazu o wysokiej rozdzielczości, lecz selektywnie kieruje uwagę lekkiego detektora tylko na najbardziej obiecujące regiony. Jest to unikalne rozwiązanie problemu

kompromisu między dokładnością (wymaganą przy małych obiektach) a kosztem obliczeniowym.

5.2. Nowatorskie Algorytmy Post-Processingu - samodzielny i oryginalny wkład stanowią opracowane algorytmy wchodzące w skład Modułu Globalnego Filtrowania. Nowa metoda filtrowania detekcji (OBS), która skuteczniej niż standardowe NMS radzi sobie z fałszywie pozytywnymi detekcjami fragmentarycznymi, powstającymi na granicach nakładających się okien. Dodatkowo innowacyjna metoda konsolidacji częściowych detekcji (OBM) w jedną kompletną, co znacząco zwiększa czułość (Recall) i wynik F1-score, naprawiając błędy, które są nieodłączne w podejściach opartych na podziale obrazu na kawałki.

5.3 Wdrożenie - warto zaznaczyć, że rozprawa ma silny wymiar inżynierski (Program "Doktorat Wdrożeniowy"). Samodzielny dorobek to nie tylko teoria, ale i praktyczne udowodnienie możliwości wdrożenia systemu, co potwierdza jego bardzo wysoką wydajność. Autorka dowiodła, że przedstawiony w pracy Framework (STD) jest w stanie osiągnąć wysoką dokładność AP_{vt} (dla bardzo małych obiektów) przy zachowaniu wysokiej prędkości wnioskowania (FPS) umożliwiającej działanie w czasie rzeczywistym na platformach o ograniczonych zasobach (np. NVIDIA Jetson AGX Orin).

Podsumowując, praca nie tylko identyfikuje lukę badawczą w obszarze szybkiej i zarazem bardzo dokładnej detekcji bardzo małych obiektów, ale także przedstawia nowatorski projekt, implementację i badania unikatowej architektury modułowej oraz nowe algorytmy filtrowania, które skutecznie tę lukę wypełniają, stawiając rozprawę na wysokim poziomie innowacyjności w swojej dziedzinie.

6. Czy autorka wykazała umiejętność poprawnego i przekonującego przedstawienia uzyskanych przez siebie wyników? Jaka jest poprawność redakcyjna rozprawy?

Niniejsza rozprawa, pod kątem redakcyjnym i językowym, została przygotowana poprawnie. Zarówno jej struktura, jak i podział treści są poprawne i odpowiednio wcześniej przemyślane.

Pewne wątpliwości budzić mogą same rysunki, gdzie Autorka często powtarzała, że coś widać podczas, gdy ja tego niestety nie widziałem (np. rys. 4.8, 6.4). Jest to wytłumaczalne w pewnym sensie, bowiem praca dotyczy rozpoznawania bardzo małych obiektów, które są ledwo widoczne. Jedynie co w tym przypadku można by zrobić to mocno powiększyć rysunki (bez zmniejszania ich rozdzielczości) w celu ich lepszej analizy.

7. Jakie są słabe strony rozprawy i jej główne wady?

Pomimo osiągnięcia postawionego celu rozprawy i dowiedzeniu tez w rozprawie można zauważyć pewne aspekty dyskusyjne, wymagające wyjaśnienia i doprecyzowania. Uwagi mające charakter dyskusyjny można sformułować następująco:

- 7.1. We wstępie Autorka jako motywację swojej pracy daje detekcję w czasie rzeczywistym defektów turbin wiatrowych. Praktycznie to jest jedyne zdanie na ten temat i nic więcej nie wiemy np. o wymaganiach stawianych systemom detekcji defektów turbin. Jak np., wygląda rozpoznanie defektów w działających turbinach (gdy „skrzydła” są w ruchu) – co by tłumaczyło potrzebę szybkiego przetwarzania i detekcji.
- 7.2. W podsumowaniu napisano, że głównym celem niniejszej dysertacji było zaprojektowanie modułowego systemu detekcji obiektów opartego na głębokich sieciach neuronowych, dostosowanego do wykrywania bardzo małych i wieloskalowych obiektów w obrazach o wysokiej rozdzielczości. W moim odczuciu, niewiele czasu w rozprawie poświęcono samym głębokim sieciom neuronowym. Nie dano też informacji, czy uczenie polegało tylko na użyciu jednej sieci, czy próbowano ją modyfikować (zmieniać liczbę warstw, funkcje aktywacji, itp.) i uzyskać tym samym inne, być może lepsze rezultaty. W mojej ocenie brakuje szerszej dyskusji na temat samych sieci, ich doboru, ich parametrów i badań z nimi związanymi.
- 7.3. W pracy stwierdzono, że zastosowanie Filtra Kalmana w Module Predykcji ROI ma na celu poprawę efektywności detekcji poprzez selektywne kierowanie detektora. Brakuje jednak głębszego wyjaśnienia merytorycznego, dlaczego akurat Filtr Kalmana został wybrany (a nie inny, np. prostszy model bez adaptacji szumu), oraz jakie są jego konkretne zalety w kontekście proponowanej architektury (niskie zużycie zasobów vs. precyzja predykcji). Ponadto, szczegółowy opis implementacji (Rozdział 5.3.2) jest zbyt skrótowy w odniesieniu do kluczowych elementów. Wymagane jest szersze omówienie formalne.
- 7.4. W sekcji 2.8 Autorka wskazuje, że system TLD jest "podobny" do proponowanego, ale różni się celem realizacji (długoterminowe śledzenie nieznanego obiektu). Stwierdzenie to jest niewystarczające, gdyż nie wykazuje nowości technicznej proponowanego rozwiązania w porównaniu do istniejących metod. W pracy powinno być techniczne porównanie (choćby krótkie) obu rozwiązań tj. TLD z metodą proponowaną przez Autorkę.
- 7.5. Autorka pisze, że efektywne filtrowanie detekcji (realizowane m.in. przez moduły OBS i OBM) ma bezpośredni wpływ na zwiększenie dokładności pracy systemu. Dodatkowo poprzez redukcję liczby redundantnych uruchomień detektora możemy się domyślić, że system tym samym działa szybciej. Warto byłoby dodać taką analizę wpływu filtracji (OBS-OMB) na zmianę nie tylko dokładności detekcji, ale także szybkości (FPS) pracy systemu (wnioskowania).
- 7.6. Autorka słusznie zauważa (Rozdziały 2 i 8), że standardowe metryki oparte na IoU (Intersection over Union) są nieodpowiednie dla ewaluacji bardzo małych obiektów o minimalnej powierzchni pikselowej. Wynika to z bardzo dużej wrażliwości na błąd lokalizacji, gdzie nawet minimalne przesunięcie ramki skutkuje drastycznym zaniżeniem oceny jakości detekcji (IoU).

Mimo tej wiedzy teoretycznej, Estymator ROI (Moduł 1), kluczowy dla wstępnej lokalizacji bardzo małych obiektów, był walidowany z wykorzystaniem miary bazującej na IoU. Może to stanowić ograniczenie metodologiczne, ponieważ Estymator zmusza się

neuronową do optymalizacji miary, która jest niestabilna dla najmniejszych celów, co utrudnia jej efektywną naukę precyzyjnej lokalizacji.

Autorka wskazuje na alternatywne metryki (np. oparte na odległościach, jak NWD) jako kierunek przyszłych prac. Pytanie brzmi: dlaczego ich nie włączono w bieżącą wersję pracy i tym samym nie rozwiązano problemu wrażliwości lokalizacyjnej dla najmniejszych celów?

7.7. Moduł Predykcji ROI, oparty na algorytmie śledzenia SORT wykorzystujący Filtr Kalmana, zakłada liniowy model ruchu między klatkami. W scenach charakteryzujących się nagłymi przyspieszeniami, ostrymi zakrętami lub złożonymi, nieliniowymi trajektoriami (co jest częste w obrazach z dronów i pojazdów autonomicznych, robotów, itp.), to uproszczone założenie może wprowadzać nieścisłości w predykcji przyszłego położenia.

W konsekwencji może to prowadzić do pogorszenia stabilności generowanych obszarów ROI i potencjalnego pominięcia celu w kluczowych klatkach. Wskazane byłoby rozwinięcie tej dyskusji i potencjalne odniesienie się do możliwości wykorzystania bardziej złożonych, nieliniowych modeli ruchu (np. Filtr EKF lub UKF) jako kierunku rozwoju systemu.

7.8. Mam też uwagę do samego tekstu rozprawy. Autorka bardzo często powtarza pewne frazy dotyczące np. celu pracy, itp. Z punktu widzenia czytelnika jest to męczące i przeszkadza w analizie, gdy po raz n -ty czyta się to samo. Dodatkowo znacznie wydłuża to rozmiar rozprawy.

8. Jaka jest przydatność rozprawy dla nauk technicznych i gospodarki?

Tematyka rozprawy, w mojej opinii, mieści się w dyscyplinie naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne, a także z punktu widzenia jej wykorzystania także w Informatyka Techniczna i Telekomunikacja. Można by uznać zatem, że praca jest interdyscyplinarna.

Przydatność rozprawy wynika bezpośrednio z jej nazwy. Systemy rozpoznawania bardzo małych obiektów (Tiny Object Detection, TOD) mają istotne znaczenie zarówno dla rozwoju nowoczesnej gospodarki, jak i dla postępu badań naukowych. W sektorze przemysłowym umożliwiają wczesne wykrywanie mikrouszkodzeń, pęknięć i defektów materiałowych, co bezpośrednio przekłada się na ograniczenie kosztów przestojów, poprawę bezpieczeństwa infrastruktury krytycznej oraz wydłużenie czasu eksploatacji urządzeń. W energetyce odnawialnej, przemyśle lotniczym i automotive systemy TOD pozwalają na automatyzację inspekcji, zwiększając ich częstotliwość i powtarzalność przy jednoczesnym obniżeniu kosztów operacyjnych. Warto podkreślić jeszcze, bardzo popularne ostatnio, wykorzystanie systemów wykrywania małych obiektów w przemyśle wojskowym.

W naukach technicznych detekcja bardzo małych obiektów stanowi kluczowe narzędzie w obszarach przetwarzania sygnałów i obrazów, teledetekcji satelitarnej oraz analizy danych obrazowych pozyskiwanych z platform bezzałogowych (UAV), gdzie obiekty zainteresowania często znajdują się na granicy rozdzielczości systemów pomiarowych. Umożliwia to rozwój zaawansowanych metod estymacji, filtracji i fuzji danych, a także precyzyjną analizę struktur o niskiej sygnaturze wizualnej, detekcję subtelnych zmian w czasie oraz budowę systemów percepcyjnych dla autonomicznych systemów technicznych. Rozwój metod TOD przyczynia się również do postępu w dziedzinie sztucznej inteligencji poprzez wymuszanie nowych architektur sieci i technik przetwarzania obrazu, co ma wpływ na szerokie spektrum innych zastosowań badawczych i technologicznych.

9. Wniosek

Podsumowując, stwierdzam, że przedstawiona do recenzji rozprawa doktorska Pani mgr inż. Aleksandry Kos pt. A Multi-Module Object Detection System Based on Deep Neural Networks stanowi oryginalne rozwiązanie istotnego problemu naukowego i wnosi cenny wkład w rozwój nauk inżynieryjno-technicznych w obrębie dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne.

W świetle powyższej oceny recenzowana dysertacja spełnia wszystkie warunki określone w art. 187 ustawy Prawo o szkolnictwie wyższym i nauce z dnia 20 lipca 2018 r. (Dz.U. z 2024 r., poz. 1571), dlatego wnioskuję o jej dopuszczenie do kolejnych etapów postępowania doktorskiego.

Tomasz Telieka
.....