

dr hab. inż. Maciej Jaworski, prof. PK
Katedra Informatyki
Wydział Informatyki i Telekomunikacji
Politechnika Krakowska
Warszawska 24, 31-155 Kraków

Kraków, 14.02.2025

Recenzja rozprawy doktorskiej mgr inż. Łukasza Karbowiaka pt. „System wykrywania sytuacji nietypowych w obrębie pojazdów z wykorzystaniem obrazów oraz map głębi, bazujący na uczeniu głębokim”

Niniejsza recenzja została przygotowana na prośbę wystosowaną w piśmie dra hab. inż. Adama Kulawika, prof. PCz, Prodziekana ds. Nauki Wydziału Informatyki i Sztucznej Inteligencji Politechniki Częstochowskiej, z dnia 12.12.2024, nr pisma R-WIMil-BOD-510-9/21.

Ocena układu pracy i zastosowanego piśmiennictwa

Recenzowana rozprawa doktorska liczy 128 stron i składa się z siedmiu rozdziałów, co stanowi dobrze przemyślaną strukturę umożliwiającą czytelnikowi płynne zapoznanie się zarówno z podstawami teoretycznymi, jak i z praktycznym aspektem badań.

Rozdział pierwszy pełni funkcję wprowadzenia, w którym Autor prezentuje tematykę pracy oraz jej cele. W szczególności omawia sześć poziomów autonomii pojazdów, co pozwala umiejscowić zakres badań w kontekście aktualnego stanu wiedzy w tej dziedzinie. Teza pracy jest jasno sformułowana, a cele zostały sprecyzowane w sposób umożliwiający ich późniejszą weryfikację.

Kolejne cztery rozdziały stanowią teoretyczną podstawę pracy. W rozdziale drugim Autor koncentruje się na metodach przekształcania obrazów, które są kluczowe dla przetwarzania danych wejściowych. Zostały tu omówione różne sposoby reprezentacji kolorów, techniki binaryzacji oraz metody poprawy jakości obrazu, w tym zaawansowana metoda CLAHE.

Rozdział trzeci poświęcono analizie danych pochodzących z urządzeń LIDAR. Autor szczegółowo opisuje sposoby komunikacji z tymi urządzeniami oraz formaty przechowywania danych (pcap, pcd, pliki binarne). Przedstawiona została również specyfikacja dwóch używanych w pracy urządzeń: Velodyne Puck Hi-Res oraz Hesai Pandar64.

Rozdział czwarty omawia zagadnienie synchronizacji danych z różnych sensorów, co jest istotnym aspektem pracy. Autor skupił się głównie na synchronizacji obrazu z kamery i danych z LIDAR-a, przedstawiając autorski System Synchronizowanej Akwizycji Danych (SDAS) oraz algorytm czasowego wyrównywania próbek. Mimo że temat synchronizacji jest rozległy, Autor umiejętnie zawęża go do aspektów kluczowych dla realizowanego projektu.

Rozdział piąty to przegląd dostępnych sieci neuronowych do detekcji obiektów. Autor analizuje trzy scenariusze: 1) Detekcję obiektów na obrazach 2D (np. Faster RCNN, YOLO), 2) Detekcję obiektów w chmurach punktów LIDAR-a (np. ModelNet40, ShapeNet, PointNet, PointRCNN), 3) Detekcję obiektów na danych będących fuzją obrazu i chmury punktów (Frustum PointNet).

Rozdział szósty stanowi najważniejszą część pracy pod kątem badań własnych. Autor prezentuje wyniki działania systemu synchronizacji oraz opisuje proces akwizycji danych dla sieci neuronowych. Szczegółowo omówiono również wyniki testów dla wszystkich trzech scenariuszy detekcji obiektów.

Rozdział siódmy podsumowuje uzyskane wyniki i wskazuje możliwe kierunki dalszych badań. Autor sugeruje rozszerzenie zestawu sensorów, np. o kamery termowizyjne, oraz implementację systemu na platformie NVidia Drive AGX Orin. Bibliografia jest obszerna i zawiera 151 pozycji, co świadczy o szerokiej analizie literatury przez Autora. Wśród nich znajduje się osiem publikacji własnych Autora rozprawy, przy czym w czterech z nich pełni on rolę pierwszego autora, a w jednej jest jedynym autorem. Choć prace te nie pochodzą z czasopism o wysokim współczynniku IF, ich liczba oraz rola Autora w publikacjach świadczą o jego aktywności naukowej.

Wskazanie oraz ocena celu pracy

Głównym celem rozprawy było opracowanie metod detekcji obiektów i sytuacji nietypowych, które mogą znaleźć zastosowanie w systemach wspomagania

kierowcy oraz autonomicznego przemieszczania się pojazdów. Kluczowym aspektem badań było wykorzystanie algorytmów sztucznej inteligencji, uczonych na danych pochodzących zarówno z obrazów kamer, jak i map głębi uzyskiwanych z LIDAR-a.

Aby zrealizować ten cel, Autor określił sześć celów szczegółowych, które obejmują wszystkie kluczowe aspekty niezbędne do skutecznej implementacji systemu:

- Opracowanie metody synchronizacji danych wielowymiarowych z różnych czujników – synchronizacja danych z kamer i LIDAR-ów jest fundamentalnym wyzwaniem, wpływającym na jakość analizy i skuteczność działania algorytmów AI.
- Opracowanie zbioru danych złożonych z synchronizowanych obrazów i map głębi – stworzenie takiego zbioru jest niezbędne do trenowania i testowania modeli sztucznej inteligencji.
- Analiza i dostosowanie istniejących architektur sieci neuronowych do detekcji sytuacji nietypowych – w tym celu Autor rozważył różne modele konwolucyjne i ich zastosowanie do danych różnych typów.
- Przeprowadzenie badań eksperymentalnych nad detekcją sytuacji nietypowych – eksperymenty obejmowały uczenie i testowanie sieci neuronowych na przygotowanych danych.
- Analiza wpływu rodzaju i wielkości danych uczących na skuteczność modeli – ocena, jak różne konfiguracje danych wpływają na efektywność systemu.
- Porównanie skuteczności modeli fuzji danych z modelami działającymi na pojedynczych modalnościach (tylko obrazy lub tylko mapy głębi) – to istotny aspekt badań, pozwalający określić wartość dodaną wynikającą z integracji różnych źródeł informacji.

Dodatkowym wyzwaniem była konieczność zapewnienia wydajności systemu, tak aby detekcja mogła odbywać się w czasie rzeczywistym na urządzeniach brzegowych. Aspekt ten ma kluczowe znaczenie dla potencjalnego zastosowania rozwiązania w rzeczywistych warunkach.

Ocena celów pracy wskazuje, że zostały one dobrze określone i obejmują wszystkie istotne aspekty związane z analizowaną tematyką. Są ambitne i wymagające, zwłaszcza biorąc pod uwagę konieczność synchronizacji danych, dostosowania architektur sieci neuronowych oraz zapewnienia wydajności systemu. Wyniki

przedstawione w rozdziale 6 wskazują jednak, że Autorowi udało się je osiągnąć, a przeprowadzone badania dostarczyły odpowiedzi na pytania wynikające z poszczególnych celów szczegółowych.

Podsumowując, cele rozprawy są jasno sformułowane, kompleksowe i dobrze dostosowane do założeń pracy. Ich realizacja wymagała szerokiej wiedzy z zakresu przetwarzania obrazów, sensorów LIDAR, metod fuzji danych oraz głębokiego uczenia, co potwierdza wysoki poziom merytoryczny rozprawy.

Wskazanie oraz ocena zastosowanych metod badawczych

Metody badawcze zastosowane w rozprawie zostały starannie dobrane i charakteryzują się wysokim poziomem profesjonalizmu oraz praktycznym podejściem do problemu detekcji obiektów i sytuacji nietypowych. Autor przeprowadził zarówno testy laboratoryjne, jak i eksperymenty terenowe, co pozwoliło na kompleksową ocenę proponowanego systemu.

Na początkowym etapie badań system synchronizacji danych został poddany testom w warunkach laboratoryjnych. Pozwoliło to na weryfikację jego działania przed rozpoczęciem właściwego procesu akwizycji danych w warunkach rzeczywistych. Taki etap badań wskazuje na dobrze przemyślane podejście do problemu, eliminujące potencjalne błędy jeszcze przed rozpoczęciem pracy na dużych zbiorach danych.

Następnie Autor przeprowadził eksperymenty terenowe, korzystając ze specjalnie przygotowanego pojazdu wyposażonego w kamerę i LIDAR zamontowane na dachu. Przeprowadzono jazdy testowe w rzeczywistych warunkach miejskich, co pozwoliło na zebranie dużego i realistycznego zbioru danych do uczenia sieci neuronowych. Takie podejście gwarantuje, że modele AI były trenowane na danych odpowiadających realnym sytuacjom, a nie na syntetycznych czy ograniczonych zbiorach dostępnych w literaturze.

Kluczowym elementem eksperymentów było uczenie i testowanie różnych sieci neuronowych na trzech typach danych: obrazy z kamery (2D), chmury punktów z LIDAR-a, a także połączenie obu modalności. Każda z testowanych architektur była oceniana przy użyciu precyzyjnych metryk, takich jak precision, recall czy mAP@50, co świadczy o rzetelnym podejściu do ewaluacji wyników.

Ważnym aspektem było również elastyczne podejście do doboru sprzętu. W trakcie badań zauważono, że LIDAR Velodyne Puck Hi-Res z 16 wiązkami lasera nie zapewniał wystarczającej jakości danych, co negatywnie wpływało na skuteczność modeli. W związku z tym, jak opisano w pracy, podjęto decyzję o wymianie go na bardziej zaawansowany sensor Hesai Pandar64, który oferuje 64 wiązki lasera i dostarcza znacznie dokładniejsze informacje o otoczeniu. Ta zmiana pozwoliła na uzyskanie lepszych wyników, co pokazuje, że Autor potrafił dynamicznie reagować na napotkane wyzwania i dostosowywać konfigurację systemu do uzyskanych wyników.

Ocena części rozprawy doktorskiej, dotyczącej omówienia wyników badań

Wyniki przeprowadzonych eksperymentów zostały szczegółowo przedstawione w rozdziale 6 rozprawy. Autor wykonał szereg analiz, których celem było zweryfikowanie skuteczności zarówno systemu synchronizacji, jak i sieci neuronowych odpowiedzialnych za detekcję obiektów. Całość została omówiona w sposób rzetelny, a uzyskane wyniki poparte są konkretnymi danymi liczbowymi, co pozwala na obiektywną ocenę skuteczności zastosowanych metod.

W ramach testów synchronizacji przeprowadzono dwa eksperymenty: 1) synchronizację obrazu z dwóch kamer – pozwoliło to na ocenę skuteczności algorytmu w przypadku pracy na identycznych modalnościach, 2) synchronizację obrazu z kamery i danych z LIDAR-a – kluczowe dla dalszej pracy, ponieważ dane z obu sensorów są używane w fuzji modalności.

W obu przypadkach wykazano redukcję czasów opóźnień pomiędzy korespondującymi ramkami danych, co dowodzi skuteczności opracowanego przez Autora algorytmu synchronizacji. Zapewnienie precyzyjnego wyrównania czasowego jest niezwykle istotne dla dalszego procesu przetwarzania, w szczególności w przypadku analizy dynamicznych scen.

Do detekcji obiektów w obrazach 2D wykorzystano sieć YOLOv7, której skuteczność oceniono za pomocą metryk precision, recall oraz mAP@0.5. Wyniki były bardzo dobre dla większości obiektów, jednak wykazano, że dla niektórych klas, takich jak przejazd kolejowy z zaporami czy znak ostrzegawczy przed przejazdem,

skuteczność była niższa. Mimo to osiągnięte wartości, mieszczące się w przedziale 66% – 80%, wciąż świadczą o dobrej zdolności detekcyjnej modelu.

W przypadku chmur punktów testowano dwie architektury sieci neuronowych: 1) PointRCNN i 2) PillarPoints. Pierwotnie dane pochodziły z LIDAR-a Velodyne Puck Hi-Res (16 wiązek), jednak uzyskane wyniki były niezadowalające, co skłoniło Autora do wymiany sensora na Hesai Pandar64 (64 wiązki). Dzięki temu znacząco poprawiono jakość danych wejściowych i efektywność detekcji. Ze względu na ograniczoną rozdzielczość danych z LIDAR-a, detekcja została ograniczona do czterech klas obiektów: samochód, pieszy, rowerzysta oraz przejście dla pieszych. Analiza wyników wykazała, że sieć PointRCNN osiągnęła wyraźnie lepsze rezultaty niż PillarPoints, co potwierdza jej skuteczność w przetwarzaniu danych 3D.

Do analizy danych z obu modalności zastosowano sieć Frustum PointNet, której działanie opiera się na dwuetapowym procesie: 1) Detekcja obiektów na obrazach – pierwotnie wykorzystywano Faster RCNN, jednak Autor podjął decyzję o zastąpieniu go siecią YOLOv7, którą miał już dobrze wytrenowaną na wcześniejszym etapie badań, 2) Detekcja na mapach głębi – przeprowadzana na obszarach odpowiadających wcześniej wykrytym obiektom, co pozwala na zwiększenie precyzji. Taki wybór był trafną i praktyczną decyzją, ponieważ pozwolił na ograniczenie liczby dodatkowych operacji obliczeniowych i wykorzystanie już wcześniej nauczonego modelu. Uzyskane wyniki okazały się najlepsze spośród wszystkich testowanych podejść, chociaż ponownie ograniczono się do wykrywania czterech głównych klas obiektów.

Autor zaprojektował także system decyzyjny, który generuje ostrzeżenia dotyczące możliwych zagrożeń. Ograniczono się tutaj do detekcji pieszych, rowerzystów oraz zwierząt, jako obiektów o największym znaczeniu dla bezpieczeństwa ruchu drogowego.

Ważnym spostrzeżeniem było to, że w systemie bazującym na danych z map głębi łatwiej jest szacować ruch obiektów i przewidywać, czy może dojść do kolizji.

Wariant wykorzystujący fuzję danych (kamera + LIDAR) osiągnął najwyższą skuteczność, ale miał też istotną wadę – niższą szybkość działania. W porównaniu do rozwiązania operującego wyłącznie na obrazach (60 FPS), system łączący obie modalności działał z prędkością 15 FPS, co może stanowić problem w zastosowaniach wymagających bardzo niskich opóźnień.

Podsumowując, rozdział 6 przedstawia wyniki badań w sposób kompleksowy i dobrze ustrukturyzowany. Każdy z etapów badań – od testów synchronizacji, przez detekcję w różnych modalnościach, po fuzję danych i system decyzyjny – został dokładnie przeanalizowany i oceniony przy użyciu odpowiednich metryk. Pod względem metodologicznym i analitycznym jest to bardzo dobrze opracowany fragment rozprawy, który wskazuje na wysoki poziom samodzielności i zaawansowania badań prowadzonych przez Autora. Jedynym potencjalnym ograniczeniem jest spadek wydajności w rozwiązaniu łączącym dane z kamer i LIDAR-a, co może stanowić wyzwanie przy implementacji w czasie rzeczywistym. Mimo tego uzyskane wyniki są spójne z założeniami pracy i dostarczają odpowiedzi na pytania badawcze, co świadczy o rzetelnie przeprowadzonych eksperymentach i wysokiej jakości analizie uzyskanych rezultatów.

Informacje dotyczące praktycznego zastosowania uzyskanych wyników badań

Uzyskane wyniki badań mają istotny potencjał praktyczny w systemach autonomicznych pojazdów. Opracowany System Synchronizowanej Akwizycji Danych (SDAS) poprawia synchronizację sensorów, co może zwiększyć niezawodność systemów percepcyjnych w rzeczywistych warunkach drogowych. Zastosowanie Frustum PointNet z ulepszoną architekturą detekcji pozwala na skuteczniejsze wykrywanie obiektów na podstawie fuzji danych, a opracowany system decyzyjny może wspierać ostrzeganie kierowcy o zagrożeniach. Przed wdrożeniem w systemach rzeczywistych konieczne może być jednak dalsze podniesienie skuteczności, zwłaszcza w zakresie detekcji trudniejszych obiektów czy poprawy działania w zmiennych warunkach pogodowych. Możliwe jest także rozszerzenie systemu o dodatkowe sensory, np. kamery termowizyjne, co mogłoby zwiększyć jego niezawodność. Implementacja na platformach obliczeniowych typu Nvidia Drive AGX Orin mogłaby umożliwić optymalizację pod kątem pracy w czasie rzeczywistym. Podsumowując, zaproponowane rozwiązania mają duży potencjał aplikacyjny, jednak ich pełne wdrożenie wymaga dalszych badań i optymalizacji, aby zapewnić maksymalną skuteczność w warunkach rzeczywistych.:

Uwagi krytyczne i zagadnienia do dyskusji

Uwagi krytyczne:

- W kilku miejscach w pracy można zauważyć pewne nieścisłości matematyczne. Przykładowo, we wzorze (2.5) indeksy pikseli obrazu i, j występują po lewej stronie równania, lecz brakuje ich po prawej, co może wprowadzać czytelnika w błąd. Z kolei wzór (4.2) definiuje skrzywienie jako C_i , jednak przy tak podanej definicji wynik powinien wynosić $C_i - 1$. Chyba że definicja opiera się na ilorazie, a nie różnicy dwóch wielkości.
- W pracy zabrakło formalnego wprowadzenia do niektórych stosowanych miar, takich jak $mAP@0.5$. Choć można założyć, że czytelnik zna podstawowe wskaźniki oceny jakości detekcji, to w rozprawie zdefiniowano bardziej oczywiste miary, takie jak precision i recall, a pominięto te bardziej specyficzne. Wyjaśnienie tych wskaźników zwiększyłoby czytelność i wartość dydaktyczną rozprawy.
- Praca zawiera opisy wykorzystania sieci YOLOv7, ale brak jest szczegółowego omówienia jej architektury. W szczególności nie wyjaśniono, czym jest głowica połączona i odłączona, co mogłoby być istotne dla zrozumienia funkcjonowania tej architektury w kontekście rozwiązywanego problemu.
- W rozdziale 6.3 pojawia się stwierdzenie: „zbiór testowy wykorzystany w procesie uczenia”. Jest to sformułowanie nieprecyzyjne, ponieważ zbiór testowy służy do oceny modelu po zakończeniu treningu, a nie do samego procesu uczenia. Jeśli Autor miał na myśli wykorzystanie zbioru testowego do monitorowania postępów uczenia, to należałoby doprecyzować, że chodzi o zbiór walidacyjny, który w pracy został osobno wyszczególniony.
- W pracy podano jedynie ogólne informacje na temat działania systemu ostrzegania i powiadamiania. Zabrakło bardziej technicznego opisu jego funkcjonowania, np. schematów blokowych, które pomogłyby lepiej zobrazować przepływ danych i sposób podejmowania decyzji o generowaniu ostrzeżeń dla kierowcy.
- W kilku miejscach w pracy występują błędy stylistyczne i literówki, np.:
Rozdział 1, str. 5: „zdarzenia te mogą być skutkiem obrażeń” zamiast „zdarzenia te mogą być przyczyną obrażeń”,
Rozdział 4.3: „W równaniu 2”

zamiast „W równaniu (4.6)”, Rozdział 5.3, str. 63: „sieć lekkiego regresji”,
Rozdział 6, str. 65: „eóżnice”, Rozdział 6.4, str. 83: „pozwoliło to do walidacji”.

Zagadnienia do dyskusji:

- W pracy pojawia się stwierdzenie, że modele, np. YOLO, zostały „zaadoptowane”. Nie jest jednak jasne, na czym dokładnie polegał ten proces: Czy modele były trenowane od podstaw na nowych danych? Czy zastosowano podejście transfer learningu, czyli wykorzystania modeli wstępnie wytrenowanych na innych zbiorach danych i ich dalszego dostosowania do konkretnego problemu? Jeśli transfer learning nie był stosowany, to czy Autor uważa, że jego wykorzystanie mogłoby jeszcze poprawić skuteczność modeli?
- Czy osiągnięte wyniki skuteczności są wystarczające dla praktycznego zastosowania? W rozprawie uzyskano wartości skuteczności detekcji na poziomie np. 95% dla pieszych. Czy taka wartość rzeczywiście jest wystarczająca w praktycznym zastosowaniu w systemach wspomagania jazdy? Czy przeprowadzono eksperymenty symulacyjne lub analizy wpływu tych błędów na rzeczywiste warunki jazdy?
- W rozdziale 6.6, str. 97 pojawia się stwierdzenie, że skuteczność modelu opartego na obrazach zależy od warunków pogodowych. Czy da się to zmierzyć ilościowo? Możliwe podejście mogłoby obejmować: 1) podział zbioru testowego na różne warunki pogodowe (np. pogoda słoneczna, deszcz, śnieg, mgła), 2) porównanie skuteczności modelu dla tych grup i analiza, w jakim stopniu warunki pogodowe wpływają na jakość detekcji. W pracy podano jedynie ocenę jakościową (intuicyjne stwierdzenie, że pogoda ma wpływ), ale nie przedstawiono żadnych dowodów ilościowych. Czy Autor przeprowadzał próby takiej analizy lub planuje to w przyszłości?
- W pracy uwzględniono detekcję zwierząt jako część systemu ostrzegania, jednak nie podano szczegółowych informacji o tym, jakie zwierzęta były obecne w zbiorze danych. Czy w próbie uczącej dominowały głównie psy prowadzone przez właścicieli? Jest to scenariusz często spotykany w miastach, ale jednocześnie nie jest to największe zagrożenie dla kierowców. Większe ryzyko wypadków wiąże się z dzikimi zwierzętami, takimi jak sarny, jelenie czy dziki, które mogą nagle wtargnąć na jezdnię. W pracy na Rys. 6.26

zaprezentowano zarejestrowaną sarnę, ale czy w trakcie zbierania danych udało się zebrać reprezentatywną próbę danych z tego typu obiektami?

Ocena, czy rozprawa doktorska stanowi oryginalne rozwiązanie problemu naukowego

Recenzowana rozprawa doktorska zdecydowanie stanowi oryginalne rozwiązanie problemu naukowego, łącząc nowatorskie podejście do synchronizacji danych multimodalnych z efektywną detekcją obiektów w systemach wspomagania jazdy. Jej oryginalność przejawia się przede wszystkim w opracowaniu autorskiego Systemu Synchronizowanej Akwizycji Danych (SDAS), który zapewnia skuteczne wyrównanie czasowe danych z kamer i LIDAR-a, co jest kluczowe dla poprawnej analizy dynamicznych scen drogowych. Kolejnym elementem świadczącym o oryginalności pracy jest modyfikacja istniejących metod AI, w tym zastosowanie sieci Frustum PointNet w zmienionej formie – poprzez zastąpienie klasycznego Faster RCNN nowocześniejszą architekturą YOLOv7. Takie podejście nie było dotychczas szeroko analizowane w literaturze i stanowi istotny wkład w rozwój metod fuzji danych w zadaniach detekcji obiektów. Praca wnosi również wartość poprzez kompleksowe porównanie różnych metod detekcji – zarówno tych bazujących na obrazach 2D, jak i chmurach punktów 3D, oraz analizę ich skuteczności w kontekście systemów autonomicznych. Zawiera także oryginalne rozwiązanie w postaci systemu decyzyjnego, który ostrzega kierowcę o potencjalnych zagrożeniach, co nadaje jej praktyczny wymiar.

Podsumowując, rozprawa nie tylko podejmuje istotny problem naukowy, ale także proponuje własne, autorskie rozwiązania, które wzbogacają aktualny stan wiedzy w dziedzinie percepcji maszynowej i integracji danych z sensorów w pojazdach autonomicznych. Tym samym można uznać ją za oryginalny wkład w rozwój technologii sztucznej inteligencji w systemach transportowych.

Ocena, czy rozprawa doktorska prezentuje ogólną wiedzę teoretyczną kandydata w dyscyplinie informatyka techniczna i telekomunikacja oraz umiejętność samodzielnego prowadzenia pracy naukowej

Rozprawa zdecydowanie potwierdza szeroką wiedzę Autora w dyscyplinie informatyka techniczna i telekomunikacja oraz jego zdolność do samodzielnego prowadzenia badań naukowych. Autor wykazuje dogłębne zrozumienie przetwarzania obrazów, analizy danych LIDAR oraz metod fuzji multimodalnej, a także zaawansowanych architektur sieci neuronowych stosowanych w detekcji obiektów. Samodzielność badawcza przejawia się w kompleksowym podejściu do problemu – od opracowania systemu synchronizacji, przez zbieranie i przetwarzanie danych, po optymalizację modeli AI. Autor nie tylko poprawnie dobiera metody badawcze, ale także modyfikuje istniejące rozwiązania dla swoich potrzeb. Praca jest dobrze ustrukturyzowana, wyniki przedstawione w sposób rzetelny, a metody ocenione krytycznie. Świadczy to o wysokich kompetencjach kandydata zarówno w zakresie teorii, jak i praktycznej realizacji badań, co w pełni potwierdza jego przygotowanie do samodzielnej działalności naukowej.

Konkluzja recenzji

Podsumowując wszystkie powyższe uwagi stwierdzam, że rozprawa doktorska mgra inż. Łukasza Karbowiaka spełnia we wszystkich możliwych aspektach wymagania nakładane przez Ustawę „Prawo szkolnictwie wyższym i nauce” z dn. 20.07.2018 z późn. zm. i wnoszę o dopuszczenie rozprawy do publicznej obrony.