



Politechnika Łódzka

Instytut Informatyki

Rada Naukowa Dyscypliny
**INFORMATYKA TECHNICZNA
I TELEKOMUNIKACJA**

Sekretariat

Data wpływu... **7.04.25r.**

Numer.....

Łódź, 28 marca 2025 roku

prof. dr hab. inż. Adam Wojciechowski

Instytut Informatyki

Wydział Fizyki Technicznej, Informatyki i Matematyki Stosowanej

Politechnika Łódzka

Al. Politechniki 8, 93-590 Łódź

RECENZJA ROZPRAWY DOKTORSKIEJ

Tytuł rozprawy: **Analiza obrazów wielospektralnych i RGB z zastosowaniem głębokich sieci neuronowych dla potrzeb automatycznej oceny parametrów kondycji kukurydzy przez robota polowego**

Autor rozprawy: **mgr inż. Justyna Stypułkowksa**

Promotor rozprawy: **prof. dr hab. inż. Przemysław Rokita**

Jakie zagadnienie naukowe jest rozpatrywane w pracy (teza rozprawy) i czy zostało ono dostatecznie jasno sformułowane przez Autorkę? Czy tematyka rozprawy jest aktualna lub dostatecznie ważna? Jaki charakter ma rozprawa (teoretyczny, doświadczalny, inny)?

Pani mgr inż. Justyna Stypułkowksa podjęła w swojej pracy doktorskiej, realizowanej w ramach doktoratu wdrożeniowego, zagadnienie wizyjnej oceny upraw kukurydzy. Tematyka rozprawy dotyczyła zastosowania technik i metod uczenia maszynowego w klasyfikacji obrazów RGB i obrazów wielospektralnych. W ramach zagadnienia badawczego sformułowano cele pracy. Obejmują one zarówno opracowanie dedykowanych zbiorów danych jak i przeprowadzenie badań z wykorzystaniem wielozadaniowych głębokich sieci neuronowych w celu analizy obrazów wielospektralnych i obrazów RGB na potrzeby automatycznej klasyfikacji faz rozwoju kukurydzy w skali BBCH, poziomów nawodnienia kukurydzy oraz porażenia kukurydzy wybranymi patogenami. Rozwiązanie jest dedykowane do systemu robota polowego, którego funkcjonalność wynika z rozwoju tzw. rolnictwa precyzyjnego, któremu poświęcony był doktorat wdrożeniowy i towarzyszący jemu projekt naukowo-badawczy, finansowany z NCBR, w którym Doktorantka brała udział. Zagadnienie badawcze zostało zatem precyzyjnie sformułowane i wyjaśnione.

Tematyka rozprawy jest aktualna i ważna w kontekście automatyzacji rolnictwa oraz precyzyjnego wizyjnego nadzoru upraw. W literaturze można spotkać zastosowanie sieci neuronowych w procesie monitorowania upraw, ale konkretnie dla upraw kukurydzy prac jest bardzo niewiele. Tym samym podjęcie tematyki dla upraw kukurydzy jest istotne i wymaga opracowania autorskich rozwiązań informatycznych.

Rozprawa ma charakter eksperymentalny i nosi w sobie istotny potencjał praktyczny. Doktorantka przeprowadziła szereg prób uczenia głębokich modeli sieci neuronowych, autorsko przygotowanym zbiorem danych oraz ocenę ich przydatności w zadaniu klasyfikacji cech roślin kukurydzy, w trzech przedmiotowych kontekstach. Przedstawione analizy są ciekawe i rzeczowe. Praca z racji podjętej problematyki, zakresu oraz metodologii badawczej jest pełnoprawnym osiągnięciem o charakterze naukowo-badawczym w dziedzinie nauk inżyneryjno-technicznych, w dyscyplinie Informatyka Techniczna i Telekomunikacja.

Czy w rozprawie przeprowadzono w sposób właściwy analizę źródeł (w tym literatury światowej i stanu zagadnień w przemyśle) świadczącą o dostatecznej wiedzy Autorki? Czy wnioski z przeglądu źródeł sformułowano w sposób jasny i przekonujący?

W przedstawionej do oceny rozprawie doktorskiej, przegląd literatury rozpoczyna się w rozdziale drugim i podzielony jest na trzy logiczne części. Pierwsza poświęcona jest przybliżeniu wybranych architektur sieci neuronowych w zadaniu klasyfikacji. Trudno określić jaki związek z podjętym problemem ma przedstawienie formalnego modelu perceptronu, procesu uczenia oraz propagacji wstecznej błędu, czy sieci splotowej, szczególnie tak synergicznego z pracą [Rashka 2018], jeśli formalny opis i oznaczenia nie występują w dalszej części pracy. Po wprowadzeniu formalnym, Doktorantka przywołała uznane głębokie architektury wielozadaniowych sieci neuronowych: *ResNet50*, *ResNet101*, *ResNeXt101*, *Mask2Former*, *ConvNeXt*, *EfficientNet*, *Vision Transformer*, *Swin Transformer*, in., ale ich dyskusja była już znacznie bardziej ogólna. Niemniej lektura tej części rozdziału była przyjemna i przydatna dla zbudowania kontekstu badawczego. Jednocześnie uzasadnienie wyboru dyskutowanych architektur, szczególnie w zakresie predyspozycji do klasyfikowania zadanych cech roślin kukurydzy, na pewno ubogaciłoby rozprawę. Druga część rozdziału drugiego została poświęcona analizie charakterystyk obrazów wielospektralnych i RGB oraz ocenie jakości modeli i technik walidacyjnych. Szkoda, że pomimo deklaracji podjęcia problemów detekcji i klasyfikacji, Autorka skoncentrowała się na miarach klasyfikacji, a nie omówiła szerzej miar detekcji, do której odnosi się w rozprawie. Ostatnia część przeglądu dotyczy dziedzinowej analizy faz wzrostu kukurydzy, nawodnienia roślin, identyfikacji patogenów oraz analizy nielicznych rozwiązań referencyjnych. Ciekawe dlaczego spośród rozwiązań literaturowych żadne nie zostało uznane za referencyjne i zestawione z rozwiązaniami Autorki, szczególnie, że ponoć „opracowane modele pokazały dużą skuteczność” w podobnym zadaniu - str. 69 [Zhao i in., 2020][Bera i in., 2024]?

Rozdział trzeci to analiza materiałów i metod badawczych. Rozdział jest o tyle ważny, że stanowi przegląd narzędzi do akwizycji danych, w tym m.in. opisano specjalistyczne kamery wielospektralne *MicaSense RedEdge MX Dual* i *MapIR Survey3 Red+Green+NIR*. Opis jest umiarkowanie kompletny. Szkoda, że na wzór kamery *MicaSense* nie przeanalizowano pasm spektralnych kamery *MapIR* i kamery RGB, gdyż wtedy można by przedyskutować praktyczne różnice pomiędzy poszczególnymi urządzeniami – wszystkie bowiem urządzenia rejestrują, w pewnym sensie, spektrum z okolic światła czerwonego i zielonego. Bardzo przydatna byłaby też dyskusja poszczególnych klas obrazów (cech kukurydzy) w świetle poszczególnych kanałów spektralnych. Czy istnieją dziedzinowe przesłanki sugerujące, że w którymkolwiek spektrum fal świetlnych którakolwiek klasa (np. porażenia patogenami, czy nawodnienia) jest lepiej widoczna? Czy poczyniono w tym zakresie jakiekolwiek spostrzeżenia?

W zakresie metodologii badawczej opisy są bardzo obszerne, ale miejscami nieklarowne. Przykładowa wątpliwość dotyczy deklarowanego zadania jednoczesnej/sekwencyjnej detekcji i klasyfikacji. Jeśli dla klasyfikacji faz rozwojowych oznaczano rośliny na obrazach wielokątami to jaką formalnie rolę odgrywała detekcja w procesie klasyfikacji i na ile obciążająca, dla finalnej klasyfikacji, była ewentualna niedokładna detekcja? Czy monitorowano dokładność detekcji roślin na obrazach? Jak wyglądała detekcja w przypadku nawodnienia? Czy do analizy nawodnienia brano pod uwagę tylko największą roślinę kukurydzy na obrazie? Szkoda, że przy okazji sygnalizowania wskaźnika *bbox_mAP_50* nie podano dokładnej jego definicji i nie przedyskutowano wpływu detekcji na klasyfikację obrazów.

Wartościowa jest analiza zbiorów danych, szczególnie liczności i zbalansowania klas, która uzasadnia poprawność wyboru miar klasyfikacji. Trudno natomiast domyśleć się jaka była intencja rejestrowania osobnych zbiorów danych RGB we wczesnych fazach rozwoju roślin i w późniejszych fazach. Czy Doktorantce zależało jedynie na rozdzieleniu zbiorów RGB odpowiadających kamerze *MicaSense*

i *MapIR*? Czy skoro wiadomo, że wielkość zbioru danych uczących zwykle pozytywnie wpływa na jakość uczonego nim modelu, nie warto rozważyć połączenia zbiorów? Chociaż Doktorantka wspomina o podziale zbiorów danych na podzbiór treningowy, walidacyjny i testowy to czy przy, jakby nie patrzeć, ograniczonym i unikalnym zbiorze obrazów nie warto było rozważyć kilku różnych podziałów danych i krzyżowej walidacji algorytmów?

Przegląd należy uznać za rzeczowy i umiarkowanie aktualny – większość prac jest sprzed 3 lat lub starsza. Bibliografia jest dość obszerna i liczy 98 pozycji, w tym 2 prace z udziałem Doktorantki oraz zgłoszenie patentowe. W dorobku Autorki znajduje się praca w czasopiśmie *Machine Graphics and Vision* oraz publikacja na międzynarodowej konferencji *FedCSIS*. Całokształt dokonań publikacyjnych Doktorantki jest wystarczający w świetle obowiązujących wymagań.

Czy Autorka rozwiązała postawione zagadnienie, czy użyła właściwej do tego metody i czy przyjęte założenia są uzasadnione?

W obszarze podjętej problematyki, Doktorantka rzetelnie przeprowadziła analizę problemu, określiła kluczowe etapy prac badawczych, przygotowała zbiory danych, zaproponowała głębokie architektury sieci neuronowych, po czym przeprowadziła eksperymenty weryfikujące ich przydatność w klasyfikacji charakterystyk roślin kukurydzy, co systematycznie wspierało kontrybucje Doktorantki.

Dobór architektur głębokich sieci neuronowych do przedmiotowego problemu był odpowiedni, chociaż prawdopodobnie intuicyjny. Doktorantka wybrała popularne modele architektur sieci głębokich, które dostosowała do postawionych celów badawczych. Zbiór obrazów rejestrujących fazy rozwoju roślin przetwarzany był przy użyciu zaadaptowanych architektur *HTC_x101*, *HTC_r101*, *HTC_r50*, *Mask2Former*, zaś zbiór obrazów dokumentujących różne poziomy nawodnienia i zbiór dokumentujący porażenie patogenami był przetwarzany przy użyciu modeli *ConvNeXt Small*, *ResNet50*, *EfficientNet-B3*, *Vision Transformer*, *Swin Transformer*. Doktorantka nie doprecyzowała jednak kryteriów doboru modeli do zagadnień klasyfikacyjnych. Prawdopodobnie przeprowadzenie eksperymentów z udziałem wszystkich modeli dla wszystkich danych dałoby szerszy obraz możliwości wykorzystania sztucznej inteligencji w ocenie upraw kukurydzy?

Rozdział 4 poświęcony jest nominalnie detekcji i klasyfikacji faz rozwoju kukurydzy w skali BBCH na obrazach RGB i obrazach wielospektralnych z kamery *MicaSense*. Eksperymenty prowadzone były zgodnie ze schematem zademonstrowanym na rysunku 4.1, który nie uwypukla fazy detekcji, ale określa warianty badań. Zakres prowadzonych badań miał na celu porównanie klasyfikacji obrazów RGB, klasyfikacji poszczególnych (dziesięciu) kanałów spektralnych oraz klasyfikacji agregującej wynik z poszczególnych kanałów z użyciem klasyfikatora głosującego. Doktorantka przeprowadziła wiele wariantów eksperymentów i opracowała wyniki w formie tabel oraz wykresów reprezentujących krzywe uczenia poszczególnych modeli. Wartościowym uzupełnieniem byłoby przeanalizowanie nie tylko wyników, ale macierzy pomyłek i dyskusja ewentualnych przyczyn niedoskonałości. Ciekawy jest wniosek z badań wskazujący, że największą skuteczność można uzyskać z użyciem klasyfikatora głosującego oraz, że najlepszymi kanałami okazały się kanał 5 i 7 kamery wielospektralnej. Ze względu na fakt, że kanał 5 jest podpasmem spektrum światła czerwonego zaś kanał 7 jest podpasmem spektrum światła zielonego to nasuwa się spostrzeżenie, że warto być może sprawdzić skuteczność klasyfikacji obrazu RGB w schemacie głosowania klasyfikatorów trzech kanałów R, G, i B lub tylko dwóch R i G. Czy skoro pozostałe kanały wielospektralne obciążają wynik głosowania (są gorsze) może warto ograniczyć głosowanie tylko do kanału 5 i 7 jako najbardziej reprezentatywnych? Ciekawa byłaby też dyskusja porównująca obrazy z kanałów słabszych i lepszych, aby odpowiedzieć na pytanie dlaczego obrazy rejestrowane w konkretnych pasmach światła (kanał 5 i 7) lepiej demonstrują fazy wzrostu roślin?

Rozdział 5 poświęcony był również detekcji i klasyfikacji faz rozwoju kukurydzy w skali BBCH z kamery RGB i z kamery wielospektralnej *MapIR Survey3 Red+Green+NIR*. Kamera wielospektralna *MapIR* ma przewagę względem kamery *MicaSense* polegającą na rejestrowaniu obrazów z jednego obiektywu, przez co obrazy dla różnych pasm spektrum światła mają takie samo ujęcie i różna perspektywa rejestracji nie obciąża klasyfikacji. Wyniki są nieco gorsze niż dla poprzedniej kamery wielospektralnej, ale czy rzeczywiście jest tak jak pisze Doktorantka, że „obraz RGB dostarcza pełniejszego spektrum informacji”? Być może należało klasyfikację przeprowadzić nie na najlepszym modelu ale w schemacie głosowania klasyfikatorów poszczególnych kanałów kamery *MapIR*, który wykazał swoją przewagę na poprzednim etapie eksperymentów? Na str. 152 Doktorantka, podsumowując cechy modelu *HTC_r50*, wspomina o zdolności modelu do generalizacji. Nasuwa się pytanie, które etapy eksperymentu pozwalają na takie stwierdzenie?

Rozdział 6 poświęcony jest detekcji i klasyfikacji poziomów nawodnienia na obrazach RGB i wielospektralnych z kamery *MapIR*. Do klasyfikacji trzyklasowej Autorka wybrała zupełnie inny garnitur modeli sieci głębokich. Przeprowadzone eksperymenty wykazały istotną zmianę jakościową wyników klasyfikacji. Nawet pojedyncze modele pozwalały uzyskać skuteczność klasyfikacji bliską 90%. Na pewno wpływ na to miało samo zadanie, mniejsza liczba klas, ale być może też same architektury sieci. Czy nie warto byłoby zastosować najlepszych modeli z danego eksperymentu (tj. *Vision Transformer*, *Swin Transformer*) do klasyfikacji faz rozwoju rośliny? Niemniej analiza wyników jest pogłębiona. Wartościowa jest analiza skuteczności modelu w czasie uczenia i odpowiadająca im analiza wartości funkcji straty. W rozdziale związanym z przygotowaniem danych Autorka deklaruje podział na zbiór treningowy, walidacyjny i testowy, podczas gdy w rozdziale szóstym prawdopodobnie zbiór walidacyjny był jednocześnie zbiorem testowym, co prawdopodobnie warto było wyraźniej zakomunikować. Można też odnieść wrażenie, że wartości liczbowe zakomunikowane w tabeli 6.2 nie odpowiadają konkluzji w sekcji 6.5.

Rozdział 7 poświęcony jest zagadnieniu detekcji i klasyfikacji porażenia kukurydzy patogenami. W tym scenariuszu badań Doktorantka posłużyła się zewnętrznym zbiorem obrazów z platformy *Kaggle*, które dostępne były tylko w formacie RGB. Do testów wykorzystano analogiczny zbiór modeli sieci głębokich co w zadaniu dotyczącym klasyfikacji nawodnienia. Wyniki okazały się rewelacyjne dla niektórych modeli (np. *Swin/Vision Transformer*) gdyż sięgały blisko 100%. Zastanawiające jest to, że bazowano wyłącznie na obrazach RGB i przy aż 5 klasach (dla nawodnienia były 3) uzyskano tak wysmienite rezultaty. Ciekawe czy zauważalna była jakościowa różnica pomiędzy obrazami RGB zaczerpniętymi z platformy *Kaggle* i zarejestrowanymi przez Doktorantkę? Czy może bardzo wysoka skuteczność klasyfikacji wynika z ewidentności samych klas?

Dysertację wieńczą sekcje podsumowujące kontrybucje Doktorantki, wkład w dyscyplinę naukową oraz perspektywa dalszych badań. Doktorantka, ze względu na reporterski styl narracji, koncentruje się mocniej na sprawozdawczym referowaniu wyników z poszczególnych eksperymentów niż na jakościowej analizie porównawczej uzyskanych wyników. Zabrakło chyba pogłębionej refleksji nad wiarygodnością uzyskanych wyników, czy generalizacją samych modeli sieci, co można było zawrzeć w sekcji poświęconej ograniczeniom/założeniom przeprowadzonych badań. Niemniej cele badawcze, które sformułowano na początku pracy należy uznać za osiągnięte.

Podsumowując, przedstawione rozwiązania, eksperymenty oraz wyniki są ciekawe i nowatorskie. Szczególnie wartościowy jest zbiór danych obrazów wielospektralnych oraz seria przeprowadzonych na nich eksperymentów, stosująca bardzo nowoczesne modele głębokich sieci neuronowych do zadania klasyfikacji charakterystyk upraw kukurydzy.

Na czym polega oryginalność rozprawy, co stanowi samodzielny i oryginalny dorobek Autorki, jaka jest pozycja rozprawy w stosunku do stanu wiedzy, czy poziomowi techniki reprezentowanych przez literaturę światową?

Oryginalność rozprawy doktorskiej leży przede wszystkim w szeroko pojętym zakresie eksperymentów przeprowadzonych z użyciem nowoczesnych architektur głębokich sieci spłotowych, których zadaniem była klasyfikacja faz rozwoju kukurydzy, określenie poziomu nawodnienia roślin, czy faktu porażenia roślin patogenami. W szczególności najważniejszymi, moim zdaniem, osiągnięciami są:

- opracowanie autorskiego zbioru danych obrazów z kamer RGB i kamer wielospektralnych, która stanowi bazę dla dalszych badań nad monitorowaniem upraw kukurydzy lub nawet badań generalizowalnych na inne uprawy;
- przeprowadzenie usystematyzowanej serii eksperymentów na wielu architekturach sieci neuronowych, w różnych strategiach klasyfikacji (indywidualnie, poprzez głosowanie), które zwróciły uwagę na możliwość wykorzystania obrazów wielospektralnych w monitorowaniu upraw kukurydzy;
- wdrożenie opracowanych rozwiązań do rzeczywistego robota polowego, co wiązało się z realizacją projektu naukowo-badawczego, finansowanego przez NCBR, i zakończyło się, między innymi, zgłoszeniem patentowym;

Wymienione osiągnięcia stanowią bezsprzecznie oryginalny wkład Doktorantki w rozwój dyscypliny Informatyka Techniczna i Telekomunikacja.

Czy Autorka wykazała umiejętność poprawnego i przekonującego przedstawienia uzyskanych przez siebie wyników (zwięzłość, jasność, poprawność redakcyjna rozprawy)?

Praca stanowi bardzo szerokie studium analizy obrazów wielospektralnych przy użyciu wielozadaniowych architektur sieci neuronowych. Oprócz przedmiotowego zagadnienia monitorowania charakterystyk upraw kukurydzy, którym Doktorantka poświęciła, w sposób naturalny, wiele miejsca, same badania dotyczące skuteczności klasyfikacji, były opisane dokładnie, czasami nawet w kilku miejscach można było dostrzec powtarzające się treści.

Miejscami Doktorantka rozluźniała podejście do terminologii badań i szczegółów eksperymentów, ale można to usprawiedliwić zakresem prowadzonych eksperymentów oraz wysoce praktycznym ujęciem badań, które narzucało konkretne wdrożenie. Niewielka, choć wystarczająca liczba publikacji z udziałem Doktorantki wynika prawdopodobnie ze zgłoszenia patentowego poczynionego w 2023 roku, co formalnie blokuje możliwość publikowania rezultatów przed samym złożeniem wniosku patentowego. Docenienia wymaga spójny i przyjemny w lekturze układ pracy, który konsekwentnie i logicznie ujmuje przedmiotowy obszar badań. Pracę czyta się bardzo dobrze.

Pod względem edycyjnym praca została zredagowana starannie. Praca zawiera wszystkie niezbędne spisy oraz bibliografię. Autorce nie udało się uniknąć drobnych błędów. Przykładowo: na str. 32 i 34 pisząc o funkcji sinusoidalnej Doktorantka miała na myśli prawdopodobnie funkcję sigmoidalną; na str. 33 pojawiają się nieprecyzyjności oznaczeń wymiarów macierzy W (np. m zamiast m_1). Nie udało się uniknąć drobnych błędów tekstowych, np.: „za zbiorze” str. 61, 63; „po późniejszego” str. 73. W tekście pracy można też napotkać wiele powtarzających się stwierdzeń – przykładowo zawartość sekcji 3.4.3 i 3.5.1 jest mocno redundantna.

Osobną kwestią są rysunki zamieszczone w pracy, które z racji swojej szczegółowości są trudne w analizie w formie wydrukowanej – niestety na niektórych napisy są prawie nieczytelne, np. rys. 3.18,

6.3, 6.4, 8.1. Dodatkowo chyba na rysunku 6.10 kolory są niewłaściwie opisane (np. model *ConvNeXt Small* i *EfficientNet-B3*)?

Jakie są słabe strony rozprawy i jej główne wady?

Rozprawa doktorska nie zawiera istotnych uchybień, a poniższe uwagi mają przede wszystkim charakter dyskusyjny. Przykładowe kwestie, które mogłyby zostać omówione, lecz nie ujmują pozytywnej oceny rozprawy, dotyczą:

W deklaracji opracowania zbiorów danych (str. 17) Autorka wspomina o przygotowaniu danych treningowych, walidacyjnych i testowych, podczas gdy w dalszej części pracy dane walidacyjne są mieszane z danymi testowymi. Skłania to czytelnika do refleksji jak optymalnie operować podobnymi zbiorami danych, o wystarczającej, chociaż niezbyt dużej liczności, aby uzyskać najbardziej wiarygodne wyniki eksperymentów? Czy nie warto było stosować walidacji krzyżowej i dynamicznego podziału zbioru danych dla podniesienia wiarygodności uzyskanych wyników?

Chociaż w celach pracy i w opisach zagadnień pojawia się deklaracja zarówno detekcji i klasyfikacji to jednak samej detekcji nie omówiono zbyt szczegółowo w pracy. Główne schematy w rozdziałach 4,5,6 nawet nie zaznaczają etapu detekcji, który pojawia się w temacie rozdziałów i jest immanentnym etapem wielozadaniowych modeli użytych w pracy. Proszę o przybliżenie roli detekcji w analizie obrazów oraz wpływu detekcji na finalną skuteczność klasyfikacji.

Podsumowanie rozdziału 4 nie do końca jest spójne z wynikami eksperymentów opisanych w tym rozdziale. Przykładowo na str. 142 Doktorantka pisze, że algorytm *HTC_r101* osiągnął najlepsze wyniki m.in. dla kanału 10, czego nie potwierdza rys. 4.9. Dodatkowo Autorka pisze, że algorytm *HTC_x101* osiągnął najgorsze wyniki m.in. dla kanału 5, czego nie potwierdzają wyniki zaprezentowane na rys. 4.10. Te prawdopodobne omyłki i koncentracja na suchych wynikach, w innym miejscach rozprawy, skłoniły mnie do pytań odnośnie ogólnej przydatności/przewagi obrazów wielospektralnych w analizie faz rozwoju kukurydzy, ocenie nawodnienia czy porażenia patogenami. Które pasma spektralne i dlaczego mają szansę zapewnić dokładniejszą analizę upraw? Które modele sieci głębokich neuronowych i dlaczego wydają się najwłaściwsze do analizy obrazów w wąskim spektrum fal? Co możemy zyskać dzieląc pasmo rejestracji na pasma spektralne skoro w dużej części eksperymentów obraz RGB uzyskiwał najlepsze wyniki i uzasadniano to szerszym spektrum dostarczanych informacji?

Konkluzja

Uważam, że cele rozprawy doktorskiej zostały w pełni zrealizowane. Doktorantka przedstawiła w rozprawie nowe badania z zakresu wizyjnej klasyfikacji obrazów wielospektralnych przy ocenie upraw kukurydzy. Uzyskane przez Doktorantkę wyniki uważam za oryginalne, wartościowe i ciekawe poznawczo. Zakres prowadzonych badań był szeroki, analiza opracowanych rozwiązań wszechstronna, a warsztat badawczy Doktorantki był właściwy. Doktorantka może poszczycić się również aktywnością projektową i zgłoszeniem patentowym, które stanowią ważne uzupełnienie jej dorobku i dają szansę na owocne kontynuowanie ambitnych badań.

Tym samym rozprawa prezentuje wartościowe osiągnięcia naukowe w obszarze dyscypliny Informatyka Techniczna i Telekomunikacja oraz potwierdza umiejętność samodzielnego prowadzenia przez Doktorantkę pracy naukowej.

Bez najmniejszej wątpliwości stwierdzam, że recenzowana rozprawa doktorska Pani mgr inż. Justyny Stypułkowskiej spełnia wymagania stawiane rozprawom doktorskim, przez obowiązującą ustawę. Wnoszę o jej przyjęcie i dopuszczenie rozprawy do publicznej obrony.

