

Łódź, 9 września 2025 roku

prof. dr hab. inż. Piotr M. Szczypiński  
Instytut Elektroniki Politechniki Łódzkiej  
Al. Politechniki 8, 93-590 Łódź

## **Recenzja rozprawy doktorskiej Metody uczenia maszynowego w głębokiej analizie obrazu preparatów histologicznych**

**Rozprawa autorstwa mgr. Alhassana Alego Hassana Ahmeda**

**przygotowana pod opieką prof. dr hab. Elżbiety Kaczmarek oraz prof. dr hab. Martina Witta**

Recenzja przygotowana na prośbę prof. dr hab. Przemysława Mitkowskiego,  
zgodnie z uchwałą nr 96/2025 z dnia 24.06.2025 roku  
Kapituły Nauk Medycznych UM w Poznaniu.

### **Kompetencje recenzenta**

Jako recenzent informuję, że moje kompetencje mieszczą się w dziedzinie nauk inżynieryjno-technicznych. Prowadzę prace badawcze w ramach dyscyplin informatyka techniczna i telekomunikacja oraz inżynieria biomedyczna. Moja wiedza w zakresie nauk medycznych i nauk o zdrowiu nie jest dogłębna. Zwracam uwagę, że moja ocena będzie więc odnosić się głównie do aspektów technicznych doktoratu oraz do osiągnięć i poprawności prowadzonych badań w tym właśnie zakresie. Ponieważ dysertacja wskazuje, że główne osiągnięcia dotyczą obszaru nauk medycznych, należy mieć na uwadze, że moja ocena tych elementów pracy może być niepełna.

### **Zawartość pracy**

Rozprawę doktorską napisano w języku angielskim. Obejmuje ona cykl trzech publikacji oraz autoreferat, w którym autor wyjaśnia problem naukowy, przedstawia cel badań oraz streszcza treść tych publikacji. Dostarczona dokumentacja zawiera ponadto krótką biografię autora, streszczenia w językach polskim i angielskim, oświadczenia współautorów publikacji dotyczące zakresu ich udziału w przeprowadzonych pracach, a także zaświadczenie przewodniczącego komisji bioetycznej potwierdzające, że badania prowadzone przez doktoranta nie miały charakteru eksperymentu medycznego.

### **Problem badawczy, cel i tezy rozprawy**

Autor definiuje problemy badawcze w autoreferacie (str. 13) w pięciu punktach:

(I) Interpretacja preparatów histologicznych może być subiektywna, co prowadzi do zmienności diagnoz pomiędzy różnymi patomorfologami, a nawet u tego samego specjalisty w różnym czasie.

(II) Analiza preparatów histologicznych jest pracochłonna i czasochłonna, zwłaszcza w kontekście dużej liczby przypadków, które muszą być badane w dużych instytucjach medycznych. Może to powodować opóźnienia w diagnostyce, wpływając negatywnie na terminowe decyzje terapeutyczne.

(III) Obrazy histologiczne są złożone i zawierają ogromne ilości informacji w różnych skalach. Identyfikacja subtelnych różnic między komórkami łagodnymi a złośliwymi wymaga dużej spostrzegawczości i rozległego przeszkolenia.

(IV) Dostęp do doświadczonych patomorfologów jest ograniczony. Może to prowadzić do opóźnionych lub błędnych diagnoz, negatywnie wpływając na wyniki leczenia pacjentów.

(V) Ogromna liczba cyfrowych obrazów histologicznych stwarza poważne wyzwania w zakresie zarządzania danymi, w tym ich przechowywania, wyszukiwania i przetwarzania.

**Problemy badawcze podjęte w pracy obejmują zagadnienia związane z obrazową diagnostyką preparatów histologicznych, możliwymi błędami i opóźnieniami w procesie diagnostycznym oraz zarządzaniem danymi. W mojej ocenie tak sformułowane zagadnienia mieszczą się w zakresie dyscypliny nauk medycznych, mają istotne znaczenie społeczne i pozostają aktualne.**

W dalszej części doktorant definiuje cel swojej pracy. Niniejsza rozprawa doktorska ma na celu wprowadzenie metod uczenia maszynowego (ML) w celu usprawnienia głębokiej analizy obrazów histologicznych, ze szczególnym uwzględnieniem diagnostyki raka płuc.

**Aktualnie problem wiarygodnej, powtarzalnej i zautomatyzowanej analizy obrazów histologicznych tkanek płucnych pozostaje otwarty. Istniejące metody są niewystarczająco dokładne aby stosować je w praktyce klinicznej. Autor trafnie wskazuje nowoczesne sieci neuronowe głębokiego uczenia jako potencjalną metodę rozwiązania problemu.**

Na stronie 13 autor definiuje cele szczegółowe jako: po pierwsze, zbadanie wiedzy i poglądów patologów na temat wykorzystania modeli sztucznej inteligencji w diagnostyce nowotworów, a po drugie, stworzenie modelu uczenia maszynowego, który pomoże patologom w diagnozowaniu komórek nowotworowych z większą dokładnością i skróceniem czasu diagnostyki. Ponadto na stronie 14 autor pisze, że celem jest opracowanie i walidacja modelu głębokiego uczenia do wykrywania guzów płuc.

**Tak sformułowane cele wyraźnie wskazują na interdyscyplinarność doktoratu. Badania poglądów patologów można częściowo umiejscowić w dziedzinie nauk społecznych, dyscyplinie nauk socjologicznych, natomiast zastosowania i rozwój metod uczenia maszynowego w naukach inżynierjno-technicznych i dyscyplinie informatyka techniczna.**

Na stronie 14 autor przedstawia tezy dysertacji (choć błędnie określa je jako założenia – assumptions):

*Integracja narzędzi wspomaganych przez sztuczną inteligencję w wykrywaniu nowotworów może zwiększyć skuteczność i poprawić dokładność diagnozy medycznej. Wykorzystanie narzędzi AI w środowisku medycznym może oszczędzać czas i zasoby, wpływać na przebieg leczenia pacjenta oraz usprawniać funkcjonowanie systemu opieki zdrowotnej.*

**Tak sformułowane tezy pozostawiają pewien niedosyt. Są one ogólne i pozbawione oryginalności, powielają opinie, które pojawiły się niejednokrotnie w innych publikacjach dotyczących zastosowania metod uczenia maszynowego we wspomaganiu diagnostyki medycznej. Wyrażenia z użyciem słowa może (ang. could), takie jak może zwiększyć oraz może oszczędzać, sprawiają, że tezy są niejednoznaczne i wyrażają jedynie potencjalną zdolność lub przypuszczenie.**

## Przegląd aktualnego stanu wiedzy

Odpowiednie przeglądy literatury zostały przeprowadzone we wszystkich trzech publikacjach wchodzących w skład cyklu. Artykuł *Deep Learning Approaches in Histopathology...* poświęcony jest szczegółowemu przeglądowi metod sztucznej inteligencji stosowanych w analizie obrazów medycznych. Głównym celem tego przeglądu było kompleksowe omówienie aktualnych i potencjalnych zastosowań uczenia maszynowego (ML) oraz głębokiego uczenia (DL) w analizie obrazów histologicznych, w szczególności skanów całopreparatowych tkanek płucnych. Przegląd prezentuje różnorodne algorytmy wykorzystywane do detekcji nowotworów, w tym klasyczne metody inżynierii cech i klasyfikatory maszyn wektorów nośnych, sztuczne sieci neuronowe, a także konwolucyjne sieci neuronowe oparte na głębokim uczeniu.

W tabeli 1 autor zebrał 48 doniesień literaturowych ilustrujących zastosowania metod sztucznej inteligencji w analizie obrazów medycznych. Zestawienia te zostały uporządkowane według rodzaju analizowanych nowotworów: raka szyjki macicy, jelita grubego, żołądka, glejaka, raka płuc, prostaty, tarczycy oraz innych. Dodatkowo autor wskazał liczbę analizowanych przypadków, cele analiz oraz uzyskiwane miary ilościowe. W tekście dokonano krótkiej charakterystyki stosowanych algorytmów i skomentowano wyniki zawarte w publikacjach poddanych przeglądowi. Należy uznać, że przegląd ma szeroki zakres, obejmuje nowoczesne metody analizy obrazów medycznych i został ukierunkowany na zastosowania bliskie planowanej przez doktoranta analizie skanów całopreparatowych tkanek płucnych.

Przegląd przedstawiony w tym artykule pozostawia jednak pewien niedosyt. Brakuje w nim pogłębionego wyjaśnienia zasad działania omawianych algorytmów oraz wskazania różnic w sposobie ich funkcjonowania. Na rysunku 2 przedstawiono schematy trzech sieci neuronowych, jednak w treści artykułu zabrakło ich omówienia i interpretacji. Niewystarczająca jest również krytyczna ocena przeprowadzonego porównania – autor nie zwraca uwagi na fakt, że porównywane są odmienne miary ilościowe, a uzyskane wyniki dotyczą zbiorów obrazów znacznie różniących się między sobą. Ponadto w częściach 3.3–3.5 autor formułuje własne opinie na temat problemów związanych z transmisją dużych zbiorów danych oraz odpowiedzialnością patologów i klinicystów, nie odwołując się jednak do odpowiednich źródeł literaturowych.

Artykuł *Perception of Pathologists in Poland...* przedstawia wyniki oryginalnego badania ankietowego. Przegląd literatury ma w tym przypadku charakter wspierający – służy wyjaśnieniu, czym są metody sztucznej inteligencji, jak wykorzystywane są we wspomaganiu diagnostyki medycznej, jaki wpływ wywierają na pracę patologów oraz jakie ograniczenia wiążą się z ich stosowaniem. Uporządkowano go tak, aby nakreślić aktualny stan wiedzy oraz zidentyfikować problemy pojawiające się na styku pracy eksperta i metod automatycznej analizy danych.

W artykule *Development and Validation of a Deep Learning Model...* doktorant przedstawił oryginalne wyniki swoich badań dotyczących zastosowania głębokiej sieci neuronowej do analizy obrazów histopatologicznych nowotworów płuc. Przegląd w tym przypadku obejmuje stan techniki oraz przykłady zastosowań sztucznej inteligencji w podobnych zadaniach. W obu artykułach prezentujących oryginalne wyniki badań doktoranta przeglądy literatury zostały oparte na aktualnych źródłach i właściwie dostosowane do treści publikacji.

## Zastosowana metodyka badawcza

Metodyka badawcza zastosowana w doktoracie opiera się na trzyetapowym podejściu, którego celem było opracowanie i walidacja modelu głębokiego uczenia do wykrywania raka płuc na podstawie obrazów histopatologicznych, z równoczesnym uwzględnieniem percepcji patologów.

W pierwszej fazie przeprowadzono obszerny przegląd literatury dotyczący metod uczenia maszynowego i głębokiego w diagnostyce nowotworów. Zgromadzone informacje posłużyły do stworzenia ram koncepcyjnych dalszych badań. Dodatkowo zebrano i przeanalizowano 200 (170?) preparatów histologicznych, aby wyodrębnić kluczowe cechy komórek zdrowych i nowotworowych, co stanowiło podstawę do szkolenia modeli.

Druga faza badań obejmowała wybór odpowiednich algorytmów głębokiego uczenia maszynowego oraz analizę percepcji lekarzy praktyków. Spośród wielu testowanych rozwiązań największy potencjał wykazały splotowe sieci neuronowe (CNN), ze względu na zdolność do automatycznego wyodrębniania złożonych cech obrazowych. Ponadto przeprowadzono badanie ankietowe wśród 68 patologów z Polski, którego celem była ocena wiedzy, postaw i gotowości środowiska medycznego do wdrożenia narzędzi sztucznej inteligencji w diagnostyce medycznej. Wyniki poddano analizie statystycznej z wykorzystaniem odpowiedniego aparatu matematycznego obejmującego uznane testy statystyczne.

Trzecia faza badań dotyczyła opracowania i walidacji modelu głębokiego uczenia. Zaprojektowany model CNN wzbogacono o konwolucje rozdzielne i bloki rezydualne, co zwiększyło efektywność ekstrakcji cech i zmniejszyło złożoność obliczeniową. Model trenowano na samodzielnie przygotowanym zestawie obrazów histopatologicznych uzyskanych z biopsji płuc. Zastosowano techniki optymalizacji takich jak augmentacja danych, dropout i regularyzacja. Uzyskano też dużą dokładność 98% na danych testowych oraz 100% na niezależnym zbiorze walidacyjnym. Porównanie z ocenami patologów potwierdziło, że w rozpoznawaniu nowotworów model dorównuje skutecznością ekspertom.

**Podsumowując, metodyka badawcza obejmowała przegląd stanu wiedzy w zakresie zastosowań sztucznej inteligencji w diagnostyce obrazowej materiałów histopatologicznych, zebranie i opracowanie materiału badawczego w postaci zbioru obrazów, przeprowadzenie badań ankietowych wśród patologów wraz z analizami statystycznymi ich opinii, zaplanowanie i realizację eksperymentu badawczego z użyciem sieci głębokiego uczenia. Całość została uzupełniona o krytyczną ocenę i dyskusję uzyskanych wyników, co pozwoliło na zweryfikowanie postawionych celów naukowych. Obrane podejście dobrze odpowiada więc charakterowi i zakresowi pracy naukowej.**

## **Oryginalność i wkład do dyscypliny**

Znaczący wkład doktoranta przejawia się przede wszystkim w ustanowieniu solidnych ram koncepcyjnych poprzez kompleksowy przegląd literatury, który jasno przedstawia funkcje, mocne strony i najnowsze osiągnięcia metod sztucznej inteligencji w diagnostyce onkologicznej. Przegląd ten stworzył merytoryczne podstawy dla kolejnych etapów badań i uzasadnił wybór stosowanych technik.

Istotnym wkładem jest także zgromadzenie i opracowanie zbioru obrazów preparatów histologicznych, co umożliwiło precyzyjne wyodrębnienie kluczowych cech morfologicznych wykorzystywanych do trenowania sieci neuronowych. Przygotowanie rzetelnych, reprezentatywnych danych uczących jest dziś równie ważnym i wymagającym elementem badań, jak projektowanie samych algorytmów; warto jednak wyjaśnić, czy i w jakim zakresie zbiory te zostały udostępnione innym badaczom, co miałoby duże znaczenie dla reprodukowalności i dalszego rozwoju badań.

Za kolejne oryginalne osiągnięcie należy uznać przeprowadzenie pierwszego w Polsce badania przekrojowego wśród 68 patologów, mającego na celu ocenę ich percepcji i gotowości do integracji technologii AI w diagnostyce. Badanie to dostarczyło cennych informacji o stopniu wiedzy, akceptacji i barierach wdrożeniowych w polskim środowisku diagnostów, wskazując jednocześnie na potrzebę działań edukacyjnych oraz transparentności algorytmów.

Najważniejszym osiągnięciem jest opracowanie i walidacja modelu głębokiego uczenia do wykrywania raka płuc w obrazach histopatologicznych. Zaproponowana architektura stosuje rozdzielone warstwy splotowe

oraz bloki rezydualne, co poprawia efektywność ekstrakcji cech przy zachowaniu rozsądnej złożoności obliczeniowej.

Uważam jednak, że doktorant powinien sprecyzować zakres oryginalności architektury: połączenie konwolucji separowalnych z blokami rezydualnymi nie jest koncepcją nową (przykładowo rozwiązania tego typu istnieją w literaturze, np. architektura Xception), dlatego autentyczną ocenę nowatorstwa ułatwiłoby udostępnienie szczegółowego opisu implementacji oraz kodu modelu. Taka transparentność umożliwiłaby rzetelną weryfikację oraz reprodukcję wyników przez innych badaczy.

**Podsumowując, całościowe podejście łączące aspekty techniczne w zastosowaniach medycznych z analizą czynników ludzkich czyni pracę interdyscyplinarną i tym bardziej wartościową. Aby jednak jednoznacznie zaklasyfikować najważniejsze osiągnięcia do dyscypliny nauk medycznych, autor powinien precyzyjnie uzasadnić to przypisanie, przedstawiając kryteria ocen i dowody wskazujące, które z wyników stanowią nowatorski i istotny wkład merytoryczny w tę właśnie dyscyplinę.**

## **Formalna i prezentacyjna strona rozprawy**

Praca doktorska obejmuje cykl trzech publikacji w języku angielskim, które tworzą spójne i całościowe podejście do problemu badawczego, łączące aspekty techniczne zastosowań medycznych z analizą czynników ludzkich. Publikacje mają formę i strukturę typową dla prac naukowych, a autor konsekwentnie stosuje i objaśnia specjalistyczną terminologię, której zestawienie zamieścił także we wstępie autoreferatu.

Artykuły wzbogacają liczne ilustracje materiału badawczego, diagramy architektur sieci neuronowych oraz wizualizacje koncepcji analizy, przebiegu eksperymentów i uzyskanych wyników. W pracy umieszczono także wykresy prezentujące metryki wydajności modelu i proces uczenia, a dane ilościowe przedstawiono w tabelach. Autor wskazał również zastosowane narzędzia obliczeniowe i oprogramowanie, co podkreśla praktyczny wymiar badań.

Wyniki zaprezentowano z użyciem standardowych miar statystycznych, takich jak średnia i odchylenie standardowe, mediana z zakresem międzykwartylowym oraz testy: Shapiro–Wilka, U Manna–Whitneya i chi-kwadrat. W każdym przypadku podano wartości  $p$  umożliwiające ocenę istotności wyników. Do oceny działania klasyfikatora wykorzystano metrykę dokładności i pole pod krzywą (AUC).

Zgromadzony zbiór 200 obrazów całopreparatowych tkanek płucnych nie został jednak udostępniony ani szczegółowo scharakteryzowany. Brak informacji o jego reprezentatywności, zróżnicowaniu czy zbalansowaniu klas utrudnia ocenę jakości danych. Autor zastosował różne testy statystyczne i miary klasyfikacji, lecz nie podał ich precyzyjnych definicji ani formalnych zapisów matematycznych. W pracy zabrakło również macierzy pomyłek, stanowiących standard w prezentacji jakości klasyfikacji.

Autor opracował sieć neuronową, wykorzystując – jak deklaruje – język Python oraz bibliotekę TensorFlow, jednak nie zamieścił kodu źródłowego programu. Brak dostępu do implementacji utrudnia ocenę innowacyjności rozwiązania oraz weryfikację jego oryginalności w odniesieniu do istniejących modeli.

Język i styl autoreferatu są nierówne. W części tekst jest precyzyjny i trafnie podsumowuje wyniki badań, jednak pojawiają się także fragmenty ogólnikowe, niejasne i nadmiernie emfatyczne. Sformułowania takie jak *massive potential*, *remarkable efficiency* czy *paving the way for future innovations* mają charakter przesadnie promocyjny i nie odwołują się do konkretnych wyników. Streszczenie publikacji (sekcja 3.3) jest fragmentaryczne, krąży wokół istoty sprawy i powiela te same informacje, co obniża przejrzystość wyводу. Ewidentnym przykładem jest sekcja 3.3.1 składająca się z zaledwie dwóch akapitów, przy czym ten drugi jedynie powiela informacje przedstawione w pierwszym. W sekcji 3.3.2 brakuje jednoznacznego wskazania celu, motywacji i wniosków z badania. Fragmenty te sprawiają wrażenie, że zostały wygenerowane

automatycznie, przy czym narzędzia sztucznej inteligencji nie zostały użyte jedynie do korekty czy poprawy stylu, lecz do tworzenia treści.

## Uwagi krytyczne i zagadnienia do dyskusji

W drugiej publikacji doktorant nie przedstawił formularza ankiety. Nie jest jasne czy w zadawanych pytaniach zastosowano dodatkowe objaśnienia ile punktów przypisać w określonej sytuacji. Taki zabieg pozwoliłby zminimalizować subiektywność oceny ankietowanych. Brak takich wyjaśnień przy skali 0–10 obniża rzetelność wyników, ponieważ respondenci różnie interpretują znaczenie poszczególnych wartości.

Na stronie 15 autoreferatu oraz na stronie 2 trzeciego artykułu doktorant opisuje proces przygotowania zbioru uczącego: *A substantial dataset of 200 histological slides was meticulously acquired and analyzed using VENTANA Image Viewer v3.2 software. (...) All the slides were collected from adenocarcinoma patients, and were of a mixed type (micropapillary, solid, and acinar) but with different percentages of each. We obtained 170 WSIs stained with Hematoxylin and Eosin dye (H&E). Each slide was used to randomly extract an average of six images by zooming in and out in different slide regions and rotating the slide. This process resulted in a total of 934 images: 557 cancerous images and 377 healthy images. The images were further split into training and test datasets. We followed the known approach of a 70% training dataset versus 30% testing dataset.*

Podane informacje wydają się częściowo sprzeczne a opis jest nieprecyzyjny. Nie jest jasne:

- Czy pozyskano obrazy referencyjne od osób zdrowych i jakie były proporcje między liczbą obrazów tkanek zdrowych i z nowotworami?
- Ile w rzeczywistości pozyskano obrazów do badania 170 czy 200?
- Na czym polegał proces ekstrakcji, jakie były rozmiary ekstrahowanych fragmentów?
- Dlaczego ekstrahując po 6 obrazów ze 170 skanów uzyskano liczbę 934 a nie  $170 \times 6 = 1020$ ?
- Kto i w jaki sposób etykietował dane (przypisywał je do klas)?
- Dlaczego zastosowano obracanie obrazów i czemu miało ono służyć?
- Proces podziału na zbiory uczący i testowy przeprowadzono po ekstrakcji i augmentacji danych co może być błędem. W obu zbiorach mogły pojawić się obrazy tych samych próbek. Czy na podstawie walidacji i testowania można więc mieć pewność, że nie wystąpiło zjawisko nadmiernego dopasowania modelu do danych uczących (ang. *overfitting*)?
- Pozyskane obrazy przypisano do czterech klas (micropapillary, solid, acinar, healthy). Dlaczego opracowano klasyfikator binarny rozróżniający jedynie tkankę zdrową od chorej a nie predyktor dla wszystkich czterech klas?

Do testowania wykorzystano również obrazy ze zbioru DHCM uzyskując dokładność 100%. Czy zbiór ten zawierał jedynie obrazy ze zmianami nowotworowymi czy obejmował również obrazy tkanek zdrowych? Zgodnie z opisem w cytowanej publikacji [10] *evaluated our model on an independent set of 143 whole-slide images patients with a diagnosis of lung adenocarcinoma since 2016*. Według tego opisu zbiór DHCM obejmuje jedynie przypadki klasy gruczolakoraka i nie obejmuje obrazów klasy referencyjnej z tkankami zdrowymi. Czy w tej sytuacji zbiór ten można uznać za odpowiedni do testowania opracowanego klasyfikatora odróżniającego tkanki z nowotworami od zdrowych?

W publikacji nr 3 w tabeli 2 podano wyniki wskazujące, że patolodzy P1 i P2 dokonali różnych ocen obrazu 13.

- Czy identyczna wartość dokładności podana dla tych patologów jest obliczona poprawnie?
- Co w tym badaniu przyjęto za prawdziwą przynależność do klasy (ground-truth), ocenę innego „nieomylnego” patologa czy wynik klasyfikacji za pomocą opracowanej sieci neuronowej?

W trzeciej z publikacji str. 5: *We evaluated the model using accuracy and Area Under the Curve (AUC) metrics on the training, validation, and test datasets (Figure 2)*. Przy czym rysunek 2 przedstawia wykres dokładności zmieniającej się podczas uczenia. Miara AUC pola pod krzywą powinna być obliczona na podstawie krzywej charakterystyki odbiornika (ROC). Na podstawie przedstawionego opisu należy uznać, że miara AUC została obliczona błędnie.

Podano, że czas detekcji przez opracowaną sieć neuronową wyniósł 10 sekund. Jakich danych dotyczy ten pomiar (ilu obrazów i jakiej wielkości) i dla jakiej konfiguracji komputera uzyskano ten wynik?

Czy baza danych obrazów opracowanych przez doktoranta oraz kody programu definiującego opracowaną sieć neuronową zostały udostępnione?

## **Wniosek końcowy**

Podsumowując stwierdzam, że rozprawa doktorska Alhassana Ali Hassana Ahmeda zatytułowana *Metody uczenia maszynowego w głębokiej analizie obrazu preparatów histologicznych* (ang. *Machine Learning Methods in Deep Image Analysis of Histological Slides*) prezentuje oryginalne rozwiązanie problemu naukowego polegające na opracowaniu metody uczenia głębokiego do analizy obrazów histologicznych płuc. Pan Alhassan Ali Hassan Ahmed wykazał się umiejętnością samodzielnej pracy badawczej, wiedzą w dyscyplinie nauk medycznych wystarczającą do rozwiązania postawionego problemu naukowego i znajomością literatury światowej. Rozprawę doktorską stanowi zbiór trzech opublikowanych i powiązanych tematycznie artykułów naukowych uzupełnionych o autoreferat oraz streszczenia w języku polskim i angielskim.

W mojej opinii przedstawiona do recenzji rozprawa spełnia wymagania stawianych rozprawom doktorskim w Art. 187 Ustawy Prawo o szkolnictwie wyższym i nauce z dnia 20 lipca 2018 roku. Wnoszę o jej przyjęcie i dopuszczenie do dalszych etapów postępowania doktorskiego.

*Piotr M. Szaryn*

