

RECENZJA ROZPRAWY DOKTORSKIEJ
DLA RADY DYSCYPLINY INFORMATYKI TECHNICZNEJ
I TELEKOMUNIKACJI POLITECHNIKI ŚLĄSKIEJ
(UCHWAŁA NR 98/2023
Z DNIA 29 września 2023 r.)

Tytuł rozprawy: „Wieloobrazowa rekonstrukcja nadrozdzielcza z wykorzystaniem głębokich sieci neuronowych”

Autor rozprawy: mgr inż. Tomasz Tarasiewicz

I. Problem naukowy (teza) rozprawy

Nieustanny wzrost wymagań w stosunku do systemów przetwarzania obrazów, systemów transmisji i wizualizacji obrazu jest motorem postępu w zakresie powstawania systemów obrazowych o coraz lepszych parametrach jakościowych, w tym między innymi, systemów o wysokich rozdzielczościach. Niesie to w konsekwencji potrzebę powstawania systemów dysponujących coraz większymi mocami obliczeniowymi.

Od początku tego dziesięciolecia obserwujemy niewiarygodny postęp, jaki dokonuje się w obszarze przetwarzania obrazów. Wzrost taniej mocy obliczeniowej oferowanej przez ogólnodostępne komputery oraz wzrost ilości dostępnych danych obrazowych umożliwiły szybsze eksperymentowanie i testowanie algorytmów. Spektakularnym przykładem sukcesu w tej dziedzinie są konwolucyjne sieci neuronowe, dla których pierwowzorem był neocognitron przedstawiony przez Kunihiko Fukushimę w 1980 roku.

Niekwestionowanym liderem w dziedzinie przetwarzania obrazów jest ta właśnie koncepcja konwolucyjnych sieci neuronowych (ang. *convolutional neural networks*), czasami też tłumaczona na język polski jako *splotowe sieci neuronowe*. Ich ogromna zaleta to zdolność redukcji obrazu do formy, która jest o wiele prostsza do przetwarzania, ale zachowuje wszystkie cechy istotne do poprawnego wnioskowania.

Warstwy spłotowe można interpretować jako zbiór neuronów połączonych z niewielką ilością neuronów w warstwie poprzedzającej, w przeciwieństwie do warstw klasycznych, gdzie neuron połączony jest ze wszystkimi neuronami w poprzedniej warstwie. Ponadto, neurony posiadają grupowo współdzielone wagi (w ramach jednego filtra spłotowego). Wymienione właściwości umożliwiają znaczną redukcję ilości parametrów, co umożliwia skuteczne uczenie takich struktur.

Istnieje jednak wiele innych koncepcji związanych z sieciami neuronowymi, które również dają bardzo dobre rezultaty w obszarze przetwarzania obrazów. GNN (ang. *Graph Neural Network*) – grafowe sieci neuronowe to rodzaj sieci neuronowych, które działają na danych zapisanych za pomocą grafu. Sprawdzają się chociażby przy analizie danych chemicznych, badaniu struktur molekularnych czy przewidywaniu cen aktywów finansowych.

W tezie rozprawy Autor stwierdza, że:

„Przy użyciu grafowej reprezentacji zbioru obrazów z subpikselowymi przesunięciami, możliwe jest przeprowadzenie rekonstrukcji nadrozdzielczej za pośrednictwem odpowiednio zaprojektowanej grafowej sieci neuronowej. Pozwala to na uzyskanie obrazu o wysokiej rozdzielczości, którego jakość jest porównywalna lub nawet wyższa niż w przypadku czołowych architektur wieloobrazowej rekonstrukcji nadrozdzielczej bazujących na sieciach konwolucyjnych”.

Uważam, że teza rozprawy została jasno sformułowana, choć zabrakło informacji o pomiarze wspomnianej jakości.

Podstawowym celem rozprawy było wybranie rozwiązań architektonicznych zastosowanych w wiodących architekturach konwolucyjnych, czyli spłotowych sieci neuronowych do wieloobrazowej rekonstrukcji nadrozdzielczej, co mogłoby znaleźć zastosowanie w modelach grafowych, efektywnie podnosząc jakość ich rekonstrukcji. Techniki te obejmowały: indywidualne wydobywanie cech dla każdego obrazu wejściowego, wykorzystanie mechanizmów uwagi (uwagi), czy też użycie dynamicznych i możliwych do wytrenowania algorytmów rejestracji obrazów. Wykorzystanie grafowych sieci neuronowych umożliwiło rekonstrukcję stanu sceny w wyznaczonym punkcie czasowym, kierując się momentem akwizycji jednego z obrazów wejściowych. W takim ujęciu, jeden obraz z puli dostępnych obrazów wejściowych był uznany jako wiodący, podczas gdy reszta obrazów służyła jako uzupełniające źródła informacji, zwiększając tym samym dokładność rekonstrukcji. Prezentowane podejście skutecznie może zredukować niespójności wizualne w obszarach o wysokiej zmienności czasowej, gwarantując uzyskanie obrazu o wyższej rozdzielczości, który jest spójny czasowo.

Te wymienione wyżej podcele znalazły się w tezie 2 i 3 recenzowanej pracy doktorskiej i są ważnym odniesieniem się do tematyki prototypów w wyjaśnialnej sztucznej inteligencji, XAI. Nie jestem pewna, czy ważność tych 3 tez jest taka sama, czy jednak powinny one zawierać pewną hierarchię.

I. Aktualność i ważność tematyki rozprawy

Przetwarzanie obrazów, czasami nazywane też *widzeniem maszynowym* (ang. *computer vision*) to pojemna dziedzina podzielona na wiele odrębnych obszarów. Obszary te jasno pokazują, że ma ona zastosowanie w wielu praktycznych aspektach. Najczęściej używane techniki to segmentacja/detekcja oraz klasyfikacja. Istotnym zagadnieniem jest również łączenie technik przetwarzania obrazów z technikami przetwarzania języka naturalnego w takich obszarach, jak odpowiadanie na pytania, tagowanie obrazów czy rozumienie sceny. Coraz bardziej popularne są również techniki związane z tworzeniem nowych oraz modyfikacją istniejących obrazów, takie jak generowanie obrazów czy też transfer stylu. Warto również zwrócić uwagę na to, że dziedzina przetwarzania obrazów nie ogranicza się jedynie do obrazów dwuwymiarowych, ale porusza również zagadnienia związane z nagraniami wideo oraz obrazami trójwymiarowymi.

Akwizycja wiedzy z obrazów o wysokiej rozdzielczości bywa jednak często utrudniona z powodu ograniczeń wszelakiego rodzaju. Jednym ze sposobów obejścia tych ograniczeń są metody rekonstrukcji nadrozdzielczej (ang. *super-resolution reconstruction*, SRR), które mają na celu zwiększenie rozdzielczości przestrzennej obrazów o niskiej rozdzielczości.

W ostatnich latach zaznaczył się znaczący rozwój w tym zakresie, podyktowany rosnącym zapotrzebowaniem na obrazy wysokiej rozdzielczości w wielu dziedzinach. W tym okresie przedstawiono szereg metod mających na celu sprostanie wyzwaniom, które niesie za sobą rekonstrukcja nadrozdzielcza. W świecie uczenia maszynowego, sieci neuronowe stały się kluczowym narzędziem rozwoju w wielu zastosowaniach, takich jak rozpoznawanie gestów i mowy czy przetwarzanie języka naturalnego. Metody, które istotnie przyczyniły się do rozwoju SRR, zostały dogłębnie przeanalizowane, obejmując zarówno rekonstrukcję nadrozdzielczą jedno- jak i wieloobrazową. Ponadto, w recenzowanej pracy poruszono temat ściśle powiązany z SISR, jakim jest rekonstrukcja nadrozdzielcza obrazów wielospektralnych.

Nieskrępowany niczym rozwój technik przetwarzania obrazów związanych z sieciami neuronowymi to z pewnością dziś jedno z najważniejszych zagadnień stawianych we wszystkich pracach związanych ze sztuczną inteligencją i uczeniem maszynowym. Dodatkowo proces ten można porównać do stworzenia struktury prototypów, co jest zadaniem czasami trudnym do zinterpretowania i wizualizacji oraz nie zapewnia ono dobrej intuicji, co do natury rozwiązania. Ponadto, przy braku rygorystycznych ram, trudno jest porównać i zestawić je ze sobą w celu jednoznacznej odpowiedzi, co jest najlepsze w danej sytuacji. W podsumowaniu tego punktu należy podkreślić ważność i aktualność tematyki recenzowanej pracy doktorskiej.

II. Oryginalny dorobek Autora, jego znaczenie poznawcze oraz przydatność praktyczna dla nauki i techniki

Oryginalny dorobek rozprawy jest zawarty w rozdziałach 3–7 rozprawy. Do dorobku tego należy zaliczyć dwa ważne procesy:

1. Konstruowanie grafu dla GNN z wielu obrazów przedstawionych w formie macierzy 3D. Zaprezentowane podejście zapewniło bezstratną konwersję, zachowując wszystkie informacje macierzy wejściowej. Co ważne, przekształcenie to okazało się nie tylko bezstratne, ale także zwiększyło ilość przechowywanej informacji, określając relacje przestrzenne między każdą połączoną parą węzłów. Ten proces, przedstawiony na rys. 1 omawianej dysertacji, składał się z trzech głównych etapów:
 - pozycjonowanie węzłów: to proces przeniesienia pikseli z macierzy na węzły umieszczone na wspólnej płaszczyźnie dwuwymiarowej, przy czym pozycja każdego węzła odzwierciedlała oryginalną pozycję piksela w macierzy przed konwersją. Cechy każdego węzła odpowiadały dokładnym wartościom pikseli, nawet tym wielokanałowym.
 - Obliczanie przemieszczenia: wyliczono wektory przemieszczenia każdego obrazu względem obrazu referencyjnego. Następnie każdy węzeł został odpowiednio przesunięty na podstawie przypisanego mu wektora przesunięć.
 - Konstrukcja grafu: utworzono połączenia między węzłami na podstawie ich odległości, przy użyciu określonego promienia. Dodatkowo każda krawędź (połączenie) pomiędzy dwoma węzłami posiadała swój wektor cech, przechowujący wektor przesunięcia konkretnego węzła względem węzła sąsiadującego.
2. Opracowano różnorodne modele w celu uzasadnienia wszystkich tez niniejszej rozprawy i są one wymienione poniżej:
 - **MagNet** – wstępny dowód koncepcji: analizując graf wejściowy składający się z wielu obrazów o niskiej rozdzielczości, MagNet stanowił pierwszą próbę w obszarze MISR bazującą na sieciach grafowych. Model ten posiadał pewne ograniczenia, jak np. redukcja liczby węzłów grafu na pewnym etapie procesu, co potencjalnie mogło prowadzić do zmniejszenia ilości informacji wykorzystywanych na etapie zwiększania rozdzielczości.
 - **MagNet++**: uwzględnienie próbkowania grafowego pozwoliło na lepsze modelowanie zależności przestrzennych, co było jednym z kluczowych zagadnień omawianych w drugiej tezie niniejszej rozprawy.
 - **MagNet_{enc}**: zawierał on ulepszoną procedurę ekstrakcji cech dla każdego obrazu wejściowego indywidualnie, co przyczyniło się do lepszego uchwycenia szczegółów obiektów z każdego obrazu wejściowego.
 - **MagNAt**: główny model spośród zaproponowanych. Charakteryzował się dynamiczną rejestracją poprzez trenowalny moduł rejestrujący, dla każdej krawędzi grafu wyliczana była wartość współczynnika uwagi (uwagi), określająca znaczenie węzła w kontekście węzła sąsiedniego.
 - **MagNAt_{no_reg}**: ta wersja modelu MagNAt była pozbawiona komponentu

dynamicznej rejestracji, umożliwiając ocenę wpływu tego składnika na jakość rekonstrukcji.

- **MagNAt_{lead}**: modyfikacja modelu MagNAt zrealizowana była w celu potwierdzenia trzeciej tezy, skoncentrowana na rekonstrukcji sceny w określonym punkcie czasowym zdeterminowa przez wiodący obraz wejściowy.
3. Przedstawiono metodykę zastosowaną do treningu poszczególnych modeli oraz opisano metryki użyte w części eksperymentalnej dysertacji w celu ewaluacji każdej z metod. Zaprezentowano parametry treningowe. Dla każdego z wiodących modeli state-of-the-art (HighRes-Net, RAMS, PIUNET i TR-MISR) zachowano wartości parametrów przedstawionych w ich oryginalnych publikacjach, co gwarantowało możliwość odtworzenia środowiska treningowego dla każdego modelu. Opisano procedurę treningu przyjętą dla wszystkich modeli, podkreślając znaczenie dostrajania wydajności opierającej się na walidacji, aby zapobiec nadmiernemu dopasowaniu.
 4. Omówiono konkretne metryki, takie jak: cPSNR (ang. *corrected peak signal-to-noise ratio*), SSIM (ang. *structural similarity index measure*), LPIPS (ang. *learned perceptual image patch similarity*), MGE (ang. *mean gradient error*) i TBE (ang. *the blur effect*), które zapewniły kompleksowe narzędzia do oceny i porównania jakości rekonstrukcji nadrozdzielczej między poszczególnymi modelami. Zdefiniowano również proces ich dostosowania do wymagań stawianych przez dane rzeczywiste, proponując ich zmodyfikowane wersje. Omówienie to stanowiło bazę dla walidacji eksperymentalnej przeprowadzonej w kolejnym etapie przeprowadzonych eksperymentów, zapewniając dogłębne zrozumienie metodyki, na której opierają się badania.

Oceniając poszczególne składowe dorobku rozprawy stwierdzam, co następuje:

- Przeprowadzono ewaluację modeli na dwóch zestawach danych symulowanych za pomocą analizy ilościowej (tab. 1 omawianej pracy), potwierdzonej testami statystycznymi, oraz analizy jakościowej (rys. 3 omawianej pracy). Zwrócono szczególną uwagę na wydajność modelu MagNAt, pokazując jego zdolność do generowania wysokiej jakości obrazów zrekonstruowanych w określonych warunkach. Wyniki liczbowe oraz wizualne wskazały na przewagę MagNAt w porównaniu z innymi modelami, tym samym częściowo potwierdzając pierwszą tezę niniejszej rozprawy.
- Porównano skuteczność modelu MagNAt z wiodącymi metodami, z wykorzystaniem danych z zestawu Próba-V do ewaluacji. Eksperyment obejmował zarówno analizę ilościową, jak i jakościową, potwierdzoną testami statystycznymi. Analiza wyników wskazała na znaczącą wydajność modelu MagNAt w porównaniu z innymi modelami, gdzie skutecznie radzono sobie z wyzwaniami związanymi z danymi rzeczywistymi, co w pełni potwierdziło pierwszą postawioną tezę. Została również omówiona dynamika wydajności przy różnej liczbie obrazów wejściowych dla poszczególnych modeli.
- Zwrócono uwagę na wyzwanie związane ze zmiennością czasową danych

wejściowych, wyróżniając sposób, w jaki model MagNat radził sobie z tym wyzwaniem, kierując proces rekonstrukcji opierającej się na określonych ramach czasowych wiodącego obrazu wejściowego. Skuteczność tego podejścia w tworzeniu spójnych czasowo obrazów nadrozdzielczych zilustrowano na rys. 5 recenzowanej pracy, oraz przedstawiono jego wyniki ilościowe. Eksperyment ten potwierdził trzecią tezę dysertacji.

Oceniając całościowy dorobek rozprawy stwierdzam, że Autor pokazał, jak wielkie znaczenie ma rekonstrukcja wieloobrazowa - MISR, omówiono wpływ wykorzystania grafowych sieci neuronowych w MISR oraz sformułowano trzy tezy badawcze. Doktorant dokonał kompleksowego przeglądu literatury, co pozwoliło uwypuklić luki i wyzwania stawiane przed istniejącymi technikami MISR, głównie opartymi na splotowych sieciach neuronowych. Stanowiło to asumpt dla proponowanego podejścia bazującego na grafowych sieciach neuronowych. Omówiono proces tworzenia grafu z obrazów o niskiej rozdzielczości oraz przedstawiono zaprojektowane modele zdolne do przetwarzania grafu wejściowego w celu rekonstrukcji nadrozdzielczej. Wybrano zestawy danych symulowanych oraz rzeczywistych do oceny proponowanych podejść, a także opisano szczegóły treningu modeli. Dodatkowo, zaproponowano metryki użyte do ewaluacji modeli w fazie eksperymentalnej. Szczegółowa analiza wymagań czasowych i pamięciowych uwypukliła wydajność obliczeniową oraz skalowalność, wraz z identyfikacją możliwości optymalizacji zaproponowanych rozwiązań.

Autor w sposób systematyczny zrealizował zaplanowane badania oraz ocenił ich wyniki. Wyniki badań są dobrze udokumentowane. Autor wykazał się dużą starannością oraz pracowitością przygotowując rozprawę.

III. Wiedza Autora oraz znajomość współczesnej literatury z dyscypliny naukowej, której dotyczy rozprawa

Autor rozprawy wykazuje bardzo dobrą znajomość dorobku literaturowego dotyczącego zagadnień, którym poświęcona jest rozprawa.

W pierwszym rozdziale Doktorant przedstawił różnicę między rekonstrukcją nadrozdzielczą opartą na pojedynczym obrazie (ang. *single-image super-resolution*, SISR) a wieloobrazową (ang. *multiimage super-resolution*, MISR). Jak wyjaśniono, metody SISR koncentrują się na zwiększeniu rozdzielczości opierając się na jednym obrazie podczas gdy metody MISR wykorzystują wiele obserwacji tej samej sceny w celu stworzenia bardziej szczegółowego obrazu o wyższej rozdzielczości. Dodatkowo w rozprawie opisane zostały dwa główne etapy MISR: rejestracja obrazów i fuzja informacji, wraz z wyzwaniami im towarzyszącymi, takimi jak: różnice czasowe, okluzje oraz zmienne warunki oświetlenia.

W tej części pracy omówione były ograniczenia tradycyjnych sieci neuronowych konwolucyjnych (ang. *convolutional neural networks*, CNN) w kontekście MISR,

skupiając się na problemach takich jak trudności w radzeniu sobie z różnicami czasowymi między obrazami wejściowymi oraz ograniczone możliwości przekazywania informacji wejściowej, co wiąże się z wymogiem przedstawienia danych wyłącznie w formacie macierzy. Ta pogłębiona dyskusja stanowiła punkt wyjścia do przedstawienia motywacji dotyczącej zastosowania grafowych sieci neuronowych (ang. graph neural networks, GNN), które oferują alternatywne podejście do wyzwań spotykanych w modelach CNN w kontekście MISR.

Autor rozprawy w rozdziale drugim dokonał kompleksowego przeglądu literatury na temat technik rekonstrukcji nadrozdzielczej, ze szczególnym uwzględnieniem podejść opartych na uczeniu głębokim. Przedstawiono w nim istniejące luki badawcze i wyzwania związane z obecnymi technikami MISR, kładąc tym samym fundament pod zaproponowaną metodę wykorzystującą głębokie sieci grafowe.

Autor rozprawy wykazuje się biegłością w tematyce rozprawy. Jego znajomość dorobku literaturowego dotyczącego zagadnień, którym poświęcona jest rozprawa jest warta podkreślenia. Przegląd tych zagadnień został zrealizowany w rozdziale 1 i 2 rozprawy. Został on dokonany wyczerpująco i napisany zrozumiałym językiem.

IV. Wady i słabe strony rozprawy, uwagi dyskusyjne

Rozprawa jako całość nie ma istotnych wad. Wśród słabszych stron bądź uchybień można wskazać na unikanie generalizacji i nie szukanie pewnego rodzaju uzasadnień, wyjaśnień czy motywacji dotyczących zaproponowanych rozwiązań. Zabrakło mi również definicji problemu rekonstrukcji obrazu jako problemu optymalizacyjnego. Poniżej kilka cytatów z innych prac, wyjaśniających o co mi chodzi:

- „Modele rekonstrukcji obrazu bazują na dostępności zbiorów uczących S , zawierających oryginalne i uszkodzone wzorce. Alternatywnie, ogólny model rekonstrukcji obrazu może być zapisany równaniem:

$$Ax = \tilde{y}$$

gdzie:

A – znany operator liniowy np. operator macierzowy,

x – oryginalny obraz;

\tilde{y} – obserwowany zdegenerowany obraz.

Zgodnie z równaniem rekonstrukcja obrazu prowadzi do rozwiązania problemu odwrotnego”.

- „Problemy związane z przetwarzaniem i klasyfikacją obrazów polegają na odzyskaniu nieznanego wektora x (interpretowanego jako obraz lub sygnał) na podstawie zaszumionych lub niekompletnych danych y . Jest to klasyczny problem odwrotny, Problem ten modelowany jest za pomocą problemów optymalizacyjnych polegających na minimalizacji zregulowanej funkcji kosztu/energii. Typowo,

funkcja kosztu/energii jest sumą pewnej skończonej liczby funkcji, takich jak: składnik dopasowania do danych, składnik regularyzacyjny i inne składniki odpowiadające pewnym szczególnym pożądanym cechom odzyskiwanego obrazu”.

W związku z powyższym mam tylko kilka pytań wynikających być może z niezrozumienia pewnych treści.

Pierwsze pytanie dotyczy modelu MagNet_{enc} i związków do wyuczenia, czyli „Learnable Relationships”.

1. Weryfikacja ważnych węzłów sąsiednich w GNN i ich uporządkowanie oraz nadanie wag powoduje uwypuklenie najważniejszych cech obrazów. Czy jest to odpowiednik ekstrakcji cech w data mining?

Następne pytania dotyczą modelu MagNAt.

2. Czy w związku z tym, że w obliczeniach na a_{ij} (ang. *attention based convolution* czy *computation*?) jest on zależny od a^T – parametru wagi uczenia (ang. *learnable weight*) można to zinterpretować jako element adaptacyjności występujący w tym modelu? (równanie 3.5, str. 53, rozdz. 3.5.1.)
3. Czy w efekcie poszukiwania współczynnika uwagi (uwagi), Autor miał na uwadze zbudowanie odpowiednich prototypów, czyli obiektów będących reprezentantami danej grupy obserwacji, czy obrazów. (to odpowiednik centroidu w algorytmie k -średnich lub mody w k -modes)?
4. Czy obraz wiodący w tezie III jest prototypem do odtworzenia lub rekonstrukcji obrazów o dużej niespójności w czasie?
5. Czy w dostępnym tłumaczeniu streszczenia pracy właściwie zostało przetłumaczone określenie związane z „attention-guided computation”? czy nie lepiej obliczenia sterowane uwagą bez słowa „atencja”?
6. W 2017 Geoffrey Hinton (i inni), zapożyczyli pomysły z neurobiologii, które sugerują, że mózg jest zorganizowany w moduły zwane kapsułkami (ang. *CapsNets*). Kapsułki te są szczególnie dobre w rozpoznawaniu cech takich, jak ułożenie (położenie, rozmiar, orientacja), deformacja, prędkość, odcień, tekstura itp. W kontekście sieci neuronowych kapsułki reprezentowane są przez grupy neuronów.

Rezultaty zaprezentowane w pracach Hintona pokazały, że *sieci neuronowe kapsułkowe* mają najwyższą wydajność w standardowych zestawach danych, Jednak aplikacje i wydajność tych sieci na rzeczywistych i bardziej złożonych danych nie zostały w pełni zweryfikowane. Bardzo ważną korzyścią, jaką zapewniają sieci kapsułkowe, jest przejście od sieci neuronowych typu *black-box* do tych, które reprezentują bardziej konkretne cechy, mogące pomóc nam przeanalizować i zrozumieć, w jaki sposób sieć neuronowa działa od środka.

Czy Pana zdaniem, ta nowa propozycja sieci neuronowych daje większą szansę na wyjaśnialność obserwowanych relacji, czy związków między obrazami i czy spodziewać się należy jeszcze skuteczniejszej metody do rekonstrukcji obrazów? Jakiego podobieństwa Pan dostrzeże w porównaniu z tą propozycją i swoją?

I ostatnia uwaga:

7. Czy *nauczanie transferowe* (ang. *Transfer learning*) , które ostatnio stało się popularną techniką w widzeniu maszynowym (ang. *Computer Vision*), umożliwiając trenowanie głębokich sieci neuronowych przy ograniczonej ilości danych poprzez wykorzystanie wstępnie wytrenowanych modeli poprawiłoby i przyspieszyłoby rekonstrukcję nadrozdzielczą obrazów? Na czym polegałoby to zadanie w przypadku GNN?

V. Wniosek końcowy

W podsumowaniu stwierdzam, że mimo drobnych uchybień przedstawionych powyżej rozprawa doktorska Pana mgr inż. Tomasza Tarasiewicza spełnia z nadmiarem wymagania obowiązujących przepisów dotyczących zawartości i formy rozpraw doktorskich. Wnoszę zatem o dopuszczenie Pana mgra inż. Tomasza Tarasiewicza do następnej fazy przewodu doktorskiego.

Ponadto, z uwagi na oryginalność uzyskanych rozwiązań, dużą staranność oraz wnikliwość jaką Autor wykazał prowadząc prace badawcze wnoszę o wyróżnienie rozprawy.

Urszula Bomystra