

Prof. dr hab. Bogusław Cyganek
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie
Wydział Informatyki, Elektroniki i Telekomunikacji
Instytut Elektroniki
cyganek@agh.edu.pl

Kraków, 20.01.2026

Recenzja rozprawy doktorskiej
Pana magistra Jana Ludziejewskiego
z tytułu:
Improving Performance of
Mixture of Experts Large Language Models

Wstęp

Recenzja rozprawy doktorskiej Pana magistra Jana Ludziejewskiego z tytułu „*Improving Performance of Mixture of Experts Large Language Models*”, która powstała w roku 2025 na Uniwersytecie Warszawskim. Promotorem pracy jest Pan dr hab. Marek Cygan. Przygotowanie recenzji zostało wykonane na zlecenie Przewodniczącego Rady Dyscypliny Naukowej Informatyka, Pana prof. dra hab. Andrzeja Tarleckiego. Rozprawa doktorska została napisana w języku angielskim. Recenzja ma formę odpowiedzi na pytania dotyczące rozprawy doktorskiej Pana mgra Jana Ludziejewskiego.

1. Problem badawczy i jego znaczenie

Jaki jest najważniejszy problem rozwiązany w rozprawie?

Współczesne czasy przynoszą nam kolejną rewolucję technologiczną związaną z rozwojem tzw. sztucznej inteligencji (ang. *Artificial Intelligence* – AI). Systemy AI powstały dzięki synergii w rozwoju sprzętu obliczeniowego – głównie wielo-rdzeniowych procesorów z milionami tranzystorów oraz kart graficznych obejmujących wielotysięczne matryce rdzeni obliczeniowych – jak również oprogramowania w postaci głębokich sieci neuronowych oraz tzw. transformerów. Systemy te, bazujące na sieciach neuronowych i początkowo zoptymalizowane na detekcję oraz klasyfikację obiektów widocznych w obrazach, wykazały się skutecznością znacząco przekraczającą dotychczasowe metody oparte głównie na modelach eksperckich, wkrótce – bazując już na strukturach transformerów – umożliwiły przetwarzanie języka naturalnego i to nie tylko do tłumaczenia z jednego języka na kolejny, ale również skutecznie zaczęły sobie radzić z odpowiedziami na pytania, z którymi wcześniej się nie spotkały. Ta niesamowita zdolność tych nowatorskich systemów nazwanych wielkimi modelami językowymi (ang. *large language models* – LLM) doprowadziła do prawdziwego przełomu praktycznie we wszystkich dziedzinach wiedzy w jakikolwiek sposób związanych z przetwarzaniem danych i treści cyfrowych, a swoim zasięgiem objęła cały świat bez wyjątków. Wkrótce sztuczna inteligencja stała się polem rywalizacji między głównymi potęgami światowymi, a opracowywaniem nowych modeli i systemów AI zajęły się firmy i uczelnie z całego świata. W przeciągu kilkunastu miesięcy powstały liczne platformy bazujące na LLM, z których najbardziej znane to różne wersje ChatGPT, Llama,

Claude, Grok, Gemini oraz np. DeepSeek, którego pojawienie się na chwilę zachwiało nawet notowaniami na giełdach światowych. Jednakże opracowywanie oraz trenowanie tego typu modeli nie należy do łatwych ani tanich – wymagają one bowiem olbrzymich repozytoriów danych, olbrzymich mocy obliczeniowych i, w końcu, olbrzymich nakładów finansowych na które stać tylko dominujących „graczy” w tej dziedzinie. Niemniej istotne są nakłady intelektualne związane ze śledzeniem dotychczasowych rozwiązań i zdobywaniem nowej wiedzy w tej dziedzinie, które są kluczowe do wyciągania właściwych wniosków badawczych i, w rezultacie, do opracowywania własnych rozwiązań. Ze względu na ciągły wyścig w opracowywaniu systemów coraz bardziej „inteligentnych”, a jednocześnie gigantycznie rosnących zapotrzebowań na energię i moce obliczeniowe konieczne przy trenowaniu systemów AI, bardzo istotne są badania nad opracowaniem nowych skalowalnych rozwiązań. W kontekst ten wpisują się osiągnięcia naukowe Pana magistra Jana Ludziejewskiego zaprezentowane w jego rozprawie doktorskiej.

W swoich badaniach Doktorant skoncentrował się na problemie zwiększania efektywności oraz skalowalności wielkich modeli językowych LLM głównie poprzez zastosowanie tzw. kompozycji klasyfikatorów eksperckich (ang. *Mixture of Experts* – MoE). Sama idea MoE jest szerzej znana i rozwijana w kontekście systemów klasyfikacji danych już od lat dziewięćdziesiątych. W swojej istocie polega ona na odpowiednim podziale przestrzeni rozwiązań problemu klasyfikacyjnego na specyficzne pod-przestrzenie, które są następnie eksplorowane przez niezależne klasyfikatory składowe, wchodzące w skład zespołu współpracujących klasyfikatorów. Kolejną cechą charakterystyczną takiego układu jest moduł rozdzielający (ang. *gating network*). Z wykorzystaniem tego zespołowego paradygmatu, głównym celem prac badawczych Pana magistra Jana Ludziejewskiego było więc opracowanie nowych zależności teoretycznych, jak również nowych architektur i implementacji, które umożliwiają tworzenie pionierskich wersji wielkich modeli językowych o dużej skali, a jednocześnie bardziej wydajnych obliczeniowo oraz pamięciowo. Jest to więc praca również z szeroko pojętej dziedziny optymalizacji systemów informatycznych.

Opracowania teoretyczne, jak również metody zaprezentowane w rozprawie doktorskiej Pana magistra Jana Ludziejewskiego wpisują się w wyżej opisane obszary badawcze związane z tworzeniem nowoczesnych systemów wielkich modeli językowych. Dzięki tym metodom nie tylko można zoptymalizować wymagania pamięciowo-obliczeniowe, ale również można otrzymać nowe i lepsze systemy przy założonym budżecie obliczeniowym.

Czy praca ma charakter naukowy?

Nie ulega wątpliwości, że podjęte w dysertacji doktorskiej Pana magistra Jana Ludziejewskiego zagadnienia mają charakter naukowy. W tym kontekście Doktorant nie tylko potrafił śledzić i analizować najnowsze osiągnięcia naukowe w niezwykle dynamicznej dziedzinie AI, ale co więcej, potrafił zaobserwować pewne ograniczenia istniejących systemów LLM i do ich przewyższenia zaproponował nowatorskie metody redukujące istniejące niedogodności. Główne osiągnięcia zostały opublikowane.

Czy praca ma znaczenie praktyczne?

Praca Doktoranta ma również niebagatelne znaczenie praktyczne. Jest to zarówno możliwość znaczącej redukcji wymagań pamięciowych i obliczeniowych systemów LLM, jak również możliwość uzyskania systemów LLM o zwiększonej jakości odpowiedzi przy założonym budżecie obliczeniowym.

2. Wkład Autora

Jaki jest najważniejszy wkład Autora rozprawy?

Główne osiągnięcia naukowe Autora rozprawy, Pana magistra Jana Ludziejewskiego przedstawione zostały w poniższym zestawieniu.

1. *Zaproponowanie nowej metody skalowania architektur wielkich modeli językowych z wykorzystaniem struktury MoE:*

Bazując na istniejących rozwiązaniach zarówno w dziedzinie LLM, jak również MoE, Pan magister Jan Ludziejewski zaproponował zastosowanie nowego tzw. hiper-parametru określającego ziarnistość (ang. *granularity*), który służy do kontroli rozmiaru poszczególnych modułów eksperckich w zespole MoE. Doktorant wyprowadził odpowiednie zależności teoretyczne i wykazał, że użycie tego parametru w prawach skalowania prowadzi do odpowiedniej ziarnistości ekspertów, co z kolei prowadzi do znaczącej poprawy efektywności całego systemu w szerokim zakresie przyjętych tzw. budżetów obliczeniowych. Doktorant wykazał przez to, że zaproponowane przez Niego modele MoE przewyższają nie tylko systemy bazujące na tzw. gęstych transformerach, ale również ich przewaga zwiększa się wraz ze skalą.

Ponadto Doktorant wyprowadził i zweryfikował prawa skalowania, porównując zarówno modele gęste oraz MoE z uwzględnieniem bieżącej liczby aktywnych parametrów – które mają bezpośredni wpływ na zajętość pamięci – jak również rozmiaru zbioru danych oraz samej liczby ekspertów w systemie MoE. Najciekawszym odkryciem Doktoranta jest wykazanie, że architektury MoE mogą być bardziej oszczędne w użyciu pamięci niż modele gęste, co wprost wpływa na projektowanie rzeczywistych systemów LLM.

Badania te doprowadziły Pana magistra Jana Ludziejewskiego do sformułowania nowego prawa skalowania, które uwzględnia zarówno ziarnistość, jak i długość trenowania. Co więcej, wyniki otrzymane przez Pana magistra Jana Ludziejewskiego stoją w opozycji do dotychczasowego stanu wiedzy i publikacji Clarka *et al.* z roku 2022. Mianowicie, doktorant wykazał że MoE może być zawsze bardziej efektywna niż gęsty transformer i to bez względu na wielkość modelu.

2. *Opracowanie optymalizacji dynamiki uczenia LLM w dużej skali:*

Pan magister Jan Ludziejewski zaproponował zastosowanie tzw. względnych harmonogramów uczenia (ang. *Relative Learning Rate Schedules* – RLRS). W tym kontekście Doktorant zaproponował przypisywanie różnego tempa uczenia właśnie poszczególnym klasyfikatorom z zespołu. Jak wykazał, takie podejście prowadzi do nawet 23% przyspieszenia treningu całego systemu, jak również wykazuje się dużą skalowalnością, gdyż hiperparametry dostrojone na mniejszych modelach mogą być skutecznie przenoszone na modele do 27 razy większych. Zaproponowane podejście RLRS stanowi z jednej strony prostą metodę przyspieszania treningu, ale jednocześnie i przenośną i efektywną obliczeniowo metodę, i to zarówno w przypadku tzw. modeli gęstych, jak i eksperckich.

3. *Zaproponowanie architektury mieszanin tokenów (ang. Mixture of Tokens – MoT):*

Ciekawym podejściem zaproponowanym przez Doktoranta Pana magistra Jana Ludziejewskiego jest zaproponowana nowatorska architektura mikstur tokenów MoT, która stanowi alternatywną drogę do wcześniej badanych i opracowanych systemów bazujących na koncepcji MoE. Cechą charakterystyczną tego podejścia, które różni się od tradycyjnych modeli rzadkich oraz innych modeli nieciągłych, jest zapewnienie przez MoT ciągłego mechanizmu przypisywania właśnie mieszanin tokenów do modułów eksperckich wchodzących w skład całego zespołu. Architektura tego typu umożliwi autoregresyjną metodykę uczenia przy jednoczesnym znaczącym przyspieszeniu samego procesu trenowania w porównaniu do gęstych transformerów, a jednocześnie prowadząc do wyników porównywalnych jedynie do optymalnych modeli bazujących na koncepcji MoE.

Istotną i nowatorską propozycją Doktoranta jest skierowanie nie wszystkich, ale odpowiednio dobranych grup tokenów, do wszystkich ekspertów należących do grupy. Podejście takie umożliwi ekspertowi dynamiczne tworzenie ciągłej reprezentacji całej grupy tokenów, która jest łatwiejsza w przetwarzaniu niż przetwarzanie każdego tokenu z osobna.

4. *Zaproponowanie rozszerzenia koncepcji MoE na architektury inne niż transformery:*

W środowisku naukowym trwają ciągłe prace prowadzące do stworzenia nowszych i bardziej skutecznych architektur głębokiego uczenia, które umożliwiłyby przetwarzanie większych zbiorów danych w krótszym czasie, czy też przy założeniu ograniczeń technologicznych dostępnych systemów komputerowych. W tym kontekście obserwowaliśmy dynamiczny rozwój głębokich sieci neuronowych, po których hegemonię przejęły transformery, również do przetwarzania danych wizyjnych oraz wielo-modalnych. Jednakże ze względu na złożoność ich architektury, która również i wielokrotnie była modyfikowana, oczy badaczy skupiły się na nowym typie architektur, tym razem bazujących na modelach przestrzeni stanów (ang. *State Space Models* – SSM). W tej grupie wyróżniająca jest tzw. architektura *Mamba*. Z jej użyciem, Doktorant Pan magister Jan Ludziejewski zaproponował oryginalną fuzję w postaci hybrydowego modelu MoE-Mamba, która połączyła zalety systemów SSM z efektywnością systemów MoE. Dzięki temu podejściu Doktorant otrzymał systemy o wydajności porównywalnej z oryginalnym systemem Mamba, a jednocześnie o ponad dwukrotnie mniejszej liczbie kroków treningowych, a jednocześnie przy zachowaniu korzystnych właściwości wnioskowania opartego o SSM. Jest to oryginalna i nowatorska architektura zaproponowana przez Pana magistra Jana Ludziejewskiego i wykazująca przewagę podejścia MoE, które jednocześnie wykraczają poza szlaki utarte przez klasyczne już w tym kontekście transformery.

Metody zaproponowane przez Pana magister Jan Ludziejewski w Jego rozprawie doktorskiej nie tylko są oryginalne oraz nowatorskie, ale wręcz wyznaczają nowe kierunki rozwoju kolejnych generacji systemów wielkich modeli językowych. Centralnym osiągnięciem jest opracowanie nowych praw skalowania oraz strategii optymalizacji z wykorzystaniem koncepcji zespołu współpracujących klasyfikatorów typu MoE. Zaproponowane przez Pana magistra Jana Ludziejewskiego metody mają nie tylko istotne znaczenie dla samej teorii informatyki, ale również posiadają wprost przełożenie na realizacje praktyczne bardziej efektywnych obliczeniowo systemów wielkich modeli językowych.

Wszystkie wymienione zagadnienia badawcze, jak i ich oryginalne rozwiązania naukowe zaproponowane przez Pana mgra Jana Ludziejewskiego świadczą o Jego kompletnej i dogłębnej

B. G. S

wiedzy, jak również o dojrzałości naukowej. Świadczą one również o znajomości najnowszych osiągnięć i technologii światowych.

3. Poprawność naukowa

Czy stwierdzenia zawarte w rozprawie są godne zaufania? Czy uzasadnienia są poprawne? Wskaż zauważone słabości i błędy. Wskaż także te aspekty dotyczące poprawności, które są najbardziej wartościowe.

Pan mgr Jan Ludziejewski podjął uzasadnioną naukowo metodykę prowadzenia badań bazującą na wnikliwej analizie rozwiązań już istniejących i opublikowanych przez inne zespoły badawcze. Bazując na tej wiedzy zauważył możliwości zaproponowania rozwiązań nowszych i konkurencyjnych do rozwiązań istniejących. Podejście takie oceniam jako jak najbardziej poprawne z naukowego punktu widzenia.

Poprawność zaproponowanych rozwiązań jest też potwierdzona poprzez publikacje naukowe z udziałem Pana mgra Jana Ludziejewskiego. Jest to 5 publikacji, z których 3 na czołowych konferencjach AI – *International Conference on Machine Learning (ICML)* oraz *Conference on Neural Information Processing Systems (NeurIPS)*. Tym niemniej, są to publikacje wielo-autorskie, w których w 3 przypadkach Doktorant jest jednak pierwszym z autorów.

Należy tutaj dodać, że Doktorant jest członkiem bardzo prężnie działającego zespołu naukowego o istotnych osiągnięciach w skali światowej. Niewątpliwie jest to czynnik sprzyjający szybkiemu rozwojowi naukowemu Kandydata.

Rozprawa doktorska Pana magistra Jana Ludziejewskiego prezentuje pewne aspekty, które wymagają jednak dodatkowego doprecyzowania, czy też rozszerzenia i dyskusji:

1. Jak wskazuje sam Autor w rozdziale 1, rozprawa doktorska bazuje na 5 publikacjach wielo-autorskich, w których Doktorant jest jednym z autorów; w 3 z nich Pan magister Jan Ludziejewski jest pierwszym z autorów. Tym niemniej, niektóre publikacje to praca aż 10 autorów. Mimo więc podania udziału procentowego Doktoranta, istotne byłoby też choćby krótkie przedstawienie kluczowego wkładu merytorycznego Pana magistra Jana Ludziejewskiego do każdego z istotnych zagadnień naukowych zaprezentowanych w rozprawie doktorskiej.
2. Bardzo cenne byłoby przedstawienie choćby podstawowego przeglądu istniejących architektur głębokich modeli językowych LLM¹, choćby wspomniany już model DeepSeek, w kontekście architektur zaproponowanych oraz przetestowanych przez Doktoranta.
3. Str. 25 – wnioski dotyczące trenowania modelu na dużym zbiorze danych są wyprowadzone z użyciem jednego specyficznego zbioru danych (dataset), nasuwa się więc pytanie na ile te stwierdzenia można generalizować na inne zbiory danych?
4. Str. 26 – nie jest jasne w jaki sposób zostały otrzymane wartości zaprezentowane w Tabeli 2.1.
5. Str. 28 – nie jest do końca jasne na ile odkrycie dotyczące przewagi MoE nad gęstymi transformerami ma charakter heurystyczny czy też formalny.
6. Str. 47 – Czy istnieją jakieś wskazówki, jaka architektura sprzętowa (nowa lub zmieniona) byłaby optymalna dla MoE? Czy może więcej mniejszych procesorów graficznych? A co z komunikacją? Innymi słowy, czy istnieją jakieś optymalne architektury sprzętowe?

¹ https://en.wikipedia.org/wiki/List_of_large_language_models

7. Wiadomo również, że różnorodność ekspertów jest korzystna dla różnorodności ekspertów – czy Autor uzyskał podobne wyniki?
8. Str. 58 – Jak zaproponowane „uczenie się w transferze” tzn. od ekstrapolacja parametrów z modeli małych do modeli większych, jest optymalne w rzeczywistych realizacjach (to raczej jest założenie).
9. Drobne usterki edycyjne, np. str. 63, 64 itd.
10. Str. 64 – jakie jest uzasadnienie dla wartości przyjętych w kroku nr 2 w Algorithm 2? Czy mogą być użyte inne podziały?
11. Str. 72 – Przy analizie wpływu tokenów może należałoby przeanalizować ich zależności statystyczne? Innym podejściem byłoby rozważenie entropii między tokenami.
12. Str. 83 – Czy w metodzie MoT przy wyborze właściwego klasyfikatora eksperckiego dla każdego tokena („suitable experts for each token”) nie możemy zastosować tego samego pomysłu łączenia tokenów, co w poprzednim rozdziale dotyczącym mieszanki tokenów?
13. Wyniki otrzymane w rozdziale 6 są bardzo „świeże” i wskazują na raczej wstępne osiągnięcia – jak można rozwinąć to podejście? W kontekście badań prowadzonych przez Doktoranta, jakie są przewagi każdej z technologii: transformer vs. Mamba?
14. Na ile pokrewna do badań Doktoranta jest dziedzina *Neural architecture search* (NAS)?

Powyższa lista pytań dotyczy dodatkowych zagadnień naukowych, czy też sugeruje głębsze potraktowanie pewnych tematów poruszonych w rozprawie doktorskiej Pana mgra Jana Ludziejewskiego - mają one jednak wyłącznie charakter dyskusyjny i w żadnym stopniu nie umniejszają istotnego wkładu merytorycznego przedstawionego w rozprawie.

4. Wiedza Kandydata

Które z rozdziałów (lub sekcji w rozdziałach) rozprawy omawiają istniejący stan wiedzy i dzięki temu potwierdzają ogólny stan wiedzy kandydata w zakresie informatyki? Jakie obszary tych dyscyplin zostały omówione w tych rozdziałach/sekcjach? Jaka jest opinia recenzenta o jakości tych rozdziałów sekcji? Jaka jest opinia recenzenta o bibliografii? Na ile bibliografia jest kompletna? Prosimy o podanie innych argumentów za lub przeciw stwierdzeniu, że kandydat posiada ogólną wiedzę w dyscyplinie informatyka.

Rozprawa Pana magistra Jana Ludziejewskiego plasuje się w samym centrum zainteresowania współczesnej informatyki – czyli w dziedzinie sztucznej inteligencji. Jest to dziedzina, która jest rodzajem ukoronowania postępów informatyki w ciągu ostatnich kilkudziesięciu lat. Ale ze względu na swój przełomowy charakter oraz wszechobecny wpływ na praktycznie wszystkie istotne aspekty rozwoju współczesnych społeczeństw, jest to dziedzina niezwykle dynamicznie rozwijana, na którą przeznaczane są niebagatelne fundusze. W tym kontekście Pan magister Jan Ludziejewski, bazując na najnowszych osiągnięciach innych badaczy, potrafił zaproponować oryginalne metody i rozwiązania. Jest to niezwykle cenne osiągnięcie naukowe zasługujące na podkreślenie.

Przedłożona rozprawa doktorska Pana mgra Jana Ludziejewskiego jest dość obszerna, liczy 122 strony. Została napisana po angielsku i składa się z 7 rozdziałów oraz bibliografii:

- *Introduction* – Autor przedstawia główną tezę oraz strukturę pracy;
- *Scaling Laws for Fine-Grained Mixture of Experts* (Prawa skalowania dla drobnoziarnistej mieszanki ekspertów) – rozdział prezentuje osiągnięcia p. mgra Jana Ludziejewskiego

B. 97⁵

dotyczące opracowanych przez niego praw skalowania wielkich modeli językowych dla tzw. drobno-ziarnistej mieszanki ekspertów LLM.

- *Joint MoE Scaling Laws* (ogólne prawa skalowania mikstur modeli eksperckich) – jest to rozdział, w którym Doktorant m.in. wykazał że modele typu MoE mogą być bardziej efektywnie pamięciowo niż modele gęste. Sformułował tu też prawa skalowania MoE.
- *Decoupled Relative Learning Rate Schedules* (Rozdzielnik względnego tempa uczenia) – rozdział ten dotyczy analizy doboru tempa uczenia do różnych wag co Pan magister Jan Ludziejewski zaproponował w postaci odsprężonego modułu sterowania tempem uczenia.
- *Mixture of Tokens* (Mieszanka tokenów) – w rozdziale tym zaprezentowana jest oryginalna metoda połączonych tokenów w architekturze transformera przypominającej MoE, w której jednakże każdy klasyfikator ekspercki przetwarza nie indywidualny token, ale odpowiednio skomponowaną kombinację tokenów.
- *MoE-Mamba* – rozdział opisujący oryginalną architekturę łączącą metody MoE z architekturą modelu przestrzeni stanów (SSM) Mamba.
- *Conclusions* (Konkluzje) – podsumowanie osiągnięć naukowych zaprezentowanych w rozprawie Pana magistra Jana Ludziejewskiego.

Bardzo imponująca jest bibliografia, która liczy kilkaset pozycji, głównie artykułów z ostatnich kilku lat, a dotyczących dynamicznie rozwijającej się dziedziny sztucznej inteligencji związanej z przetwarzaniem języka naturalnego za pomocą wielkich modeli językowych LLM.

Na kolejne podkreślenie oraz wyróżnienie zasługuje też liczba oraz wysoka jakość przeprowadzonych eksperymentów. Również i zgodnie z najnowszymi trendami we współczesnej nauce, Doktorant dostarcza kod umieszczony na platformie GitHub w celu umożliwienia weryfikacji eksperymentów przez innych naukowców. Jest to podejście zasługujące na wyróżnienie.

Dokonania Pana mgra Jana Ludziejewskiego zostały odnotowane w serwisie *scholar.google.com*. Strona ta przytacza 294 cytowania oraz tzw. H-index w wartości 6. Jest to wartość normalna dla młodego naukowca w dyscyplinie informatyka. Z kolei na stronie *Web of Science* nie znalazłem odnotowanych żadnych publikacji Kandydata. Stan ten może być spowodowany wolniejszym tempem serwisu *WoS* w porównaniu z *Google Scholar*, jak również faktem publikacji głównie w serwisie *arxiv*.

Wszystko to świadczy o ponadprzeciętnej wiedzy Doktoranta Pana magistra Jana Ludziejewskiego w dyscyplinie informatyka, a w szczególności w dziedzinie metod uczenia maszynowego i sztucznej inteligencji.

5. Podsumowanie

Rozprawa doktorska Pana magistra Jana Ludziejewskiego prezentuje ogólną i głęboką wiedzę Kandydata w dyscyplinie informatyka oraz umiejętność samodzielnego prowadzenia pracy naukowej. Przedmiotem rozprawy doktorskiej Pana magistra Jana Ludziejewskiego są oryginalne rozwiązania istotnych problemów naukowych dotyczących sztucznej inteligencji. Opracowane przez Niego metody i algorytmy są nowatorskie i na bardzo wysokim poziomie naukowym. Stanowią one oryginalny własny wkład Doktoranta Pana magistra Jana Ludziejewskiego w rozwój dyscypliny naukowej informatyka.

Przy ich realizacji Pan magister inżynier Jan Ludziejewski wykazał się dogłębną znajomością najnowszych metod i algorytmów uczenia maszynowego oraz sztucznej inteligencji, jak również dobrym opanowaniem warsztatu badawczego, a w rezultacie również wysoką dojrzałością naukową.

Recenzowaną pracę oceniam jako z spełniającą ze znacznym nadmiarem formalne oraz zwyczajowe wymagania stawiane rozprawom doktorskim. Wnioskuje o jej przyjęcie oraz o dopuszczenie Pana magistra Jana Ludziejewskiego do publicznej obrony.

Zważywszy również na bardzo wysoki poziom naukowy opracowanych nowatorskich metod, jak i ich wpływ na rozwój współczesnej informatyki, **wnioskuje o wyróżnienie rozprawy.**

