

dr hab. inż. Krzysztof Rojek, prof. PCz

Częstochowa, 29.05.2023r.

Katedra Informatyki

Wydział Inżynierii Mechanicznej i Informatyki

Politechnika Częstochowa

ul. Dąbrowskiego 69, 42-210 Częstochowa

Recenzja rozprawy doktorskiej

Tytuł rozprawy: Neural Simulation Pipeline for Liquid State Machines

Autor: mgr Karol Chlasta

Promotor: dr hab. Grzegorz M. Wójcik, prof. PJAiT

Promotor pomocniczy: dr hab. Izabela Krejtz, prof. USWPS

Dziedzina problemowa oraz cel (teza rozprawy), zakres i charakter rozprawy (teoretyczny, doświadczalny, inny)

Pan mgr Karol Chlasta w ramach opracowanej rozprawy doktorskiej poruszył zagadnienie rekurencyjnych sieci neuronowych Liquid State Machines (LSM), które wykorzystywane są do rozpoznawania wzorców i klasyfikacji. Autor porusza problem wysokiej złożoności obliczeniowej tych sieci, i co za tym idzie, dużym czasem ich przetwarzania. Autor formułuje następującą tezę, że symulacje numeryczne wymagają metodyki rozwoju modeli, odpowiednich testów i procedur sterowania symulacją, aby zwiększyć wydajność i efektywnie wykorzystać infrastrukturę obliczeniową.

W celu rozwiązania powyższego problemu autor proponuje zastosowanie narzędzia Neural Simulation Pipeline (NSP), który redukuje koszty obliczeniowe symulacji LSM, jednocześnie automatyzując zarządzanie eksperymentami i ich uruchamianie w różnych środowiskach wykonawczych. Zaletą proponowanego narzędzia NSP jest jego uniwersalność, co daje możliwość używania go na różnych platformach sprzętowych i architekturach mikroprocesorów, umożliwiając badaczom wybór najbardziej odpowiedniego sprzętu i oprogramowania. Zaproponowane narzędzie NSP składa się z trzech głównych modułów: modułu przetwarzania danych wstępnych, modułu symulacji oraz modułu przetwarzania wyników.

Pierwszym celem badania było stworzenie modelu cybernetycznego układu przy użyciu sieci neuronalnej impulsowej, który byłby wystarczająco prosty do wykonania na komputerach jednopłytkowych, pozwalał na łatwe zrozumienie jego działania i jednocześnie mógłby ilustrować najważniejsze funkcje kory wzrokowej. W pracy doktorskiej przeprowadzono analizę wiedzy związanej z modelowaniem sieci neuronów impulsowych oraz układu wzrokowego. Omówiono fundamentalne struktury, a także mechanizmy związane z interakcją różnych elementów układu wzrokowego i kory wzrokowej w mózgu, omówiono modele obliczeniowe neuronów stosowane w procesie i platformy symulacyjne, przedstawiono możliwą implementację za pomocą LSM oraz przeprowadzono symulacje modeli neuronalnych ilustrujące pewne aspekty układu wzrokowego modelowanego jako LSM.

Skuteczność NSP jest demonstrowana na przykładzie zadania rozpoznawania wzorców z użyciem programu GENESIS oraz dwóch niestandardowych systemów wizualnych opartych na LSM. W tym celu wykorzystano dwanaście różnych algorytmów odczytu LSM, które oceniono przy użyciu pięciu standardowych metryk klasyfikacji i procesu walidacji krzyżowej 10-krotnej, osiągając powtarzalną dokładność oraz wynik F1 na poziomie 81% dla odczytu opartego na Light Gradient Boosting Machine. Dodatkowo przeprowadzono 54 eksperymenty w środowisku AWS Public Cloud, które weryfikują skuteczność narzędzia NSP. Autor zbudował również autorski klaster jedнопłytkowy (Neural Simulation Cluster).

Jako główny wkład, autor prezentuje NSP. Ten eksperymentalny system umożliwia przeprowadzanie symulacji neuronalnych zarówno w chmurze, jak i lokalnie. W ramach pracy doktorskiej autor eksperymentował z niskoprądowym klastrem obliczeniowym o nazwie Neural Simulations Cluster (NSC), zbudowanym z płytek Raspberry Pi i ROCKPro64, aby wspomagać symulacje w środowisku domowym. NSC umożliwia rozwijanie i uruchamianie równoległych symulacji neuronalnych na dedykowanym superkomputerze lub nawet na wysokiej klasy komputerze stacjonarnym.

NSP to prosty system zarządzania pracą naukową, oparty na 18 skryptach Bash, zarządzający eksperymentami i ułatwiający ich definiowanie, i wykonywanie w różnych silnikach symulacyjnych w sposób ujednoczony. Autorzy zdołali zweryfikować NSP, uruchamiając go w trzech różnych środowiskach uruchomieniowych: (1) przy użyciu kontenerów w chmurze AWS i na miejscu (2) na infrastrukturze HPI oraz (3) bezpośrednio na systemie operacyjnym bez konteneryzacji. Ten prosty system zarządzania pracą naukową skutecznie zarządza kolejką eksperymentów, ujednocza kluczowe zmienne eksperymentalne, zbiera dane i statystyki eksperymentalne, a także zapewnia podstawową weryfikację parametrów eksperymentu, monitoruje wykonywanie eksperymentów, wspiera testowanie kodu symulacyjnego i sprawdza kompletność wyników eksperymentu.

W celu oceny NSP autor przeprowadził kilka pełnych cykli eksperymentalnych pokazując, że modele LSM reagują różnie na 3 różne wzorce wejściowe: liczby ("0", "1") i literę ("A"). NSP został użyty do pomiaru czasu wykonania modelu (czasu CPU), zużycia pamięci oraz liczby spike'ów w każdym przebiegu symulacji dla łącznie 54 eksperymentów na modelach RetNet.

Cele, założenia i postawione hipotezy przez autora są sformułowane w sposób zrozumiały. Czytelnik ma jasny obraz tego, co autor zamierza osiągnąć i jakie badania zostaną wykonane. Założenia oraz hipotezy są również sformułowane w sposób precyzyjny, co zapewnia ich wysoką wartość dla dalszych badań, a także analiz. Sformułowane cele są ambitne i zgodne ze współczesnymi wyzwaniami nauk technicznych w dyscyplinie Informatyka Techniczna i Telekomunikacja. Autor wyraźnie wytyczył kierunek swojego badania.

Ocena analizy i doboru źródeł uwzględniając literaturę światową

Literatura cytowana przez autora świadczy o jego dużej wiedzy, jak i dobrym rozeznaniu tematu. Obejmuje ona badania z zakresu dyscypliny Informatyka począwszy od historycznych materiałów oraz metod proponowanych w latach 70-tych ubiegłego wieku, aż do najnowszych publikacji z 2023 roku. Autor solidnie opiera swoje prace na istniejących badaniach, odnosząc się do kluczowych artykułów naukowych, monografii, konferencji i innych źródeł literaturowych, istotnych dla dziedziny Informatyka. Dzięki tak szerokiemu zakresowi cytowanej literatury, autor wykazuje dogłębną znajomość dotychczasowych osiągnięć naukowych oraz technologicznych w swojej dziedzinie. Ponadto, odwoływanie się do najnowszych publikacji pozwala autorowi na uwzględnianie najświeższych osiągnięć i trendów, co wzbogaca i aktualizuje jego wkład w rozwój Dyscypliny Informatyka Techniczna i Telekomunikacja.

Aktualność i znaczenie tematyki rozprawy, dobór właściwej metody i ocena przyjętych założeń

Tematyka rozprawy jest aktualna i ważna. Propozycje rozwiązań zaproponowane przez autora są bardzo istotne, ponieważ obejmują one szereg kwestii, które mają duże znaczenie dla rozwoju dziedziny. Wskazane przez autora rozwiązania mają szansę przyczynić się do rozwiązania istotnych problemów technicznych i inżynierskich, stanowiących wyzwanie dla dzisiejszych specjalistów. Należy tutaj rozpatrzyć kilka aspektów.

Pierwszym z nich jest zapewnienie wysokiej wydajności i wykorzystania infrastruktury obliczeniowej. Integracja metodyki rozwoju modeli, odpowiednich testów, jak i procedur sterowania symulacją - pozwala poprawić wyniki pracy naukowej oraz efektywnie wykorzystać dostępne zasoby obliczeniowe. Kolejny aspekt to standaryzacja i automatyzacja procesu wykonywania eksperymentów obliczeniowych. Przekształcenie obecnego niestandardowego oraz manualnego procesu w standardowy i częściowo zautomatyzowany ma wiele korzyści. Poprawia ono reprodukowalność, redukuje błędy ludzkie, ułatwia współpracę, a także umożliwia skalowanie eksperymentów. Standaryzacja sprzyja również tworzeniu najlepszych praktyk i pozwala naukowcom skupić się bardziej na aspektach naukowych swojej pracy. Inny aspekt obejmuje analizę kosztów obliczeniowych symulacji (LSM). Posiadają one niewątpliwie ogromne możliwości, ale symulowanie ich może być kosztowne obliczeniowo ze względu na ich dużą liczbę i złożoność. Opracowanie technik i narzędzi umożliwiających redukcję kosztów obliczeniowych przy zachowaniu dokładności jest kluczowe dla szerokiego stosowania LSM i ich praktyczności w aplikacjach rzeczywistych.

Ważnym aspektem jest również opracowana uniwersalna platforma symulacyjna niezależna od dostawcy, dająca możliwość uruchamiania symulacji na różnych platformach sprzętowych i architekturach mikroprocesorów, zapewniająca elastyczność oraz wybór dla naukowców i inżynierów.

Ocena skuteczności różnych algorytmów odczytu LSM przy użyciu standaryzowanych miar klasyfikacji dostarcza cennych informacji na temat ich możliwości i ograniczeń. Ta ocena pomaga badaczom zrozumieć mocne i słabe strony różnych podejść. Pomaga również w doborze odpowiednich algorytmów do konkretnych zadań. Ocena NSP pod kątem kosztów i praktyczności, włączając porównania między wykonaniem lokalnym a w chmurze, podkreśla potencjalne korzyści z przyjęcia takich narzędzi. Poprzez obniżenie barier wejścia i dostarczenie opłacalnych opcji symulacyjnych, naukowcy mogą prowadzić eksperymenty na większą skalę, a także eksplorować bardziej złożone symulacje.

Praktyczne wskazówki dotyczące prototypowania z wykorzystaniem autorskiego klastra jednopłytkowego NSC stanowią źródło wiedzy dla badaczy zainteresowanych budowaniem własnych konfiguracji symulacyjnych. Ponadto, wytyczone kierunki dalszych badań wskazują na potencjalne obszary poprawy i rozwoju NSP, przyczyniając się do ciągłego rozwoju metod symulacji w neuroinformatyce obliczeniowej.

Podsumowując, rozwiązanie tych problemów zwiększa efektywność, dostępność i praktyczność symulacji numerycznych, otwierając nowe możliwości dla odkryć naukowych oraz zastosowań praktycznych w neuroinformatyce obliczeniowej, jak i w pokrewnych dziedzinach. Autor wykorzystał właściwe metody badawcze przy opracowaniu proponowanych rozwiązań, a przyjęte w pracy założenia są uzasadnione.

Oryginalność rozprawy, samodzielny dorobek autora, pozycja rozprawy w stosunku do stanu wiedzy prezentowanej w literaturze światowej

Autor swoimi rozwiązaniami poszerza obecny stan wiedzy, przyczyniając się do rozwinięcia i rozwoju dziedziny nauki, której poświęcona jest rozprawa doktorska. Poprzez swoje badania oraz eksperymenty, autor wnosi nowe spostrzeżenia, teorie i metody, odnoszących się do szeregu problemów. Pierwszym z nich jest poprawa dużych symulacji modeli płynnych. Autor skupia się na badaniu modelowania różnych sieci neuronów impulsowych, tworzących tzw. Liquid State Machines. Celem jest zrozumienie, jak można poprawić duże symulacje modeli płynnych w modelowaniu mózgu, co przyczynia się do rozwoju nauki z zakresu neuroinformatyki.

Główne osiągnięcie autora w tym tekście polega na zmniejszeniu barier wejścia do modelowania numerycznego i symulacji na dużą skalę dzięki zastosowaniu NSP. NSP ma zastosowanie zarówno w sieciach mózgowych (GENESIS), jak i w symulacjach bio-mechaniki mózgu (Kinetikit). NSP ukrywa skomplikowane techniczne aspekty instalacji silnika symulacji na różnych platformach, umożliwiając łatwe uruchamianie tego samego modelu na różnych rodzajach procesorów i w chmurze obliczeniowej. Autor ma nadzieję, że NSP przedstawiony w tej pracy doktorskiej spopularyzuje stosowanie symulatorów neuronalnych i pozwoli na rozwój naukowych metod pracy w badaniach mózgu.

Kolejnym poruszonym problemem jest badanie wpływu zasobów obliczeniowych na wydajność modelu. Autor bada wpływ różnych zasobów obliczeniowych na wydajność modelu oraz generację danych dla coraz bardziej złożonych modeli sieci neuronalnych. Analiza ta pomaga zidentyfikować najbardziej odpowiednie zasoby obliczeniowe do efektywnych symulacji.

Automatyzacja w rozwoju, testowaniu i wdrażaniu modeli. Autor wprowadza automatyzację do procesu rozwoju, testowania i wdrażania modeli. Poprzez prototypowanie potoku symulacji neuronalnych wzorując się na neurobiologicznych symulacjach układu wzrokowego. Autor ma na celu usprawnienie i automatyzację tych istotnych aspektów pracy z symulacjami.

Transformacja procesu eksperymentów obliczeniowych. Autor proponuje konieczność przekształcenia ręcznego i niestandardowego procesu eksperymentów obliczeniowych w proces zautomatyzowany i standaryzowany. Ta transformacja ma na celu poprawę wydajności oraz zapewnienie możliwości powtarzalności symulacji.

Integracja metodyki rozwoju modeli. Autor twierdzi, że symulacje numeryczne powinny obejmować metodykę rozwoju modeli, włączając testowanie i proces sterowania symulacją. Ta integracja ma na celu zwiększenie wydajności badań, a także poprawę wykorzystania infrastruktury obliczeniowej zarówno w lokalnym środowisku, jak i w chmurze.

Ponadto, autor podejmuje kilka pytań badawczych dotyczących rozwoju i optymalizacji modeli LSM, automatyzacji testowania i wdrażania, włączania uczenia maszynowego do przewidywania wzorców wejściowych, technik prototypowania, optymalizacji kosztów symulacji oraz redukcji barier wejścia do tworzenia dużych symulacji neuronalnych. Poprzez badanie tych pytań, autor wnosi wkład w rozwój dziedziny i dostarcza praktycznych wskazówek dla badaczy zajmujących się modelowaniem mózgu i neuroinformatyką.

Podsumowując, wkład autora koncentruje się na integracji metod rozwoju modeli, automatyzacji procesu symulacji, poprawie dużych symulacji, analizie wpływu zasobów obliczeniowych oraz badaniu różnych zagadnień badawczych w celu doskonalenia rozwoju oraz wydajności symulacji neuronalnych. Wymienione osiągnięcia stanowią oryginalny wkład w rozwój Dyscypliny Informatyka Techniczna i Telekomunikacja. Autor, poprzez swoje innowacyjne rozwiązania i badania, przyczynia się do

rozszerzenia granic tej dziedziny, a także przyspiesza postęp w obszarze technologii komputerowych, systemów telekomunikacyjnych i inżynierii oprogramowania. Wpływ tych osiągnięć kierowany jest zarówno do społeczności akademickiej, gdzie wprowadzane są nowe teorie i metody. Może znaleźć również zastosowanie w praktyce, przyczyniając się do realnego wpływu na rozwój technologiczny i społeczny.

Umiejętność autora poprawnego i przekonującego przedstawienia uzyskanych przez siebie wyników

Autor posiada umiejętność prawidłowego i przekonującego przedstawiania uzyskanych wyników. Opinia ta wynika z kilku czynników. Po pierwsze, autor prezentuje dokładne opisy metodyki badawczej, co wskazuje na solidne zrozumienie procesu badawczego. Autor wyjaśnia kroki podejmowane w celu opracowania modelu, przeprowadzenia symulacji oraz analizy wyników. Ta spójność i jasność w opisie procesu badań wskazuje na kompetencje autora w dziedzinie neuroinformatyki obliczeniowej.

Po drugie, autor prezentuje wyniki w sposób przystępny i zrozumiały. Opisuje metryki wykorzystywane do oceny algorytmów odczytu oraz prezentuje liczby i statystyki, które wspierają uzyskane rezultaty. Autor również podaje szczegóły dotyczące eksperymentów, takie jak konfiguracje systemów, co umożliwi innym badaczom dokładne zrozumienie i replikację eksperymentów.

Po trzecie, autor dostarcza dowody na poparcie swoich wyników. Przedstawia wyniki porównań między różnymi algorytmami odczytu oraz oceny dokładności i wyników F1. Ponadto, autor przeprowadza dodatkowe eksperymenty, porównuje wykonanie lokalne oraz w chmurze obliczeniowej, podaje koszty wykonania w środowisku AWS. To zwięzłe i konkretnie przedstawienie faktów przekonuje o zdolności autora do prezentowania wyników w sposób rzetelny, jak i przekonujący.

Podsumowując, autor posiada zdolność do poprawnego oraz przekonującego przedstawiania uzyskanych wyników. Dzięki klarownemu opisowi metodologii, przystępnemu przedstawieniu wyników, a także dostarczeniu dowodów na poparcie swoich twierdzeń, autor buduje zaufanie do swojej pracy i wniosków.

Uwagi wymagające dyskusji

Istnieje kilka kwestii, które warto poddać dyskusji w celu lepszego zrozumienia i oceny przedstawionych badań. Kwestie te wymagają odniesienia się do nich w trakcie obrony rozprawy doktorskiej.

Konfiguracja RetNet. Chciałbym zapytać, dlaczego autor przyjął właśnie taką konfigurację RetNet(28x28,4) z 784 komórkami dla Retiny i 1024 komórkami dla każdej z czterech kolumn LSM. Jakie czynniki i dowody skłoniły autora do wyboru tych konkretnych parametrów? Również chciałbym aby zostało wyjaśnione, czy wybrana konfiguracja jest jednocześnie najlepsza dla badanego zagadnienia. Czy były przeprowadzone porównania z innymi konfiguracjami? Czy istnieją badania lub dowody potwierdzające, że ta konkretna konfiguracja osiąga najlepsze wyniki? Dobór konfiguracji powinien być poparty eksperymentami lub innymi odpowiednimi metodami. W dziedzinie machine learning i tworzenia modeli sieci neuronowych istnieje wiele podejść do optymalizacji konfiguracji, ale kluczowym aspektem jest przetestowanie i weryfikacja tych konfiguracji. Inne metody, takie jak badania porównawcze, analiza danych, benchmarking czy ocena metryk wydajności, również mogą być stosowane w celu potwierdzenia skuteczności wybranej konfiguracji. Ważne jest, aby mieć solidne podstawy naukowe i dowody popierające wybór danej konfiguracji.

Czasy wykonania symulacji oraz złożoność problemu. Wyniki zamieszczone w tabeli 4.2 sugerują, że symulacje RetNet(8x5,1) i RetNet(28x28,4) nie są tak czasochłonne, jak autor sugeruje (w pracy znajdujemy informacje, że symulacje wykonują się kilka dni lub tygodni). Oczywiście, warto

poddać to kwestii dyskusji i rozważyć czy dobrane eksperymenty odzwierciedlają rzeczywiste zapotrzebowanie tych modeli na moc obliczeniową. Różne czynniki, takie jak konkretny zestaw danych, architektura sprzętowa, zastosowane optymalizacje czy inne zmienne, mogą mieć wpływ na czas wykonania symulacji. W zależności od tych czynników, wyniki mogą się różnić. W każdym przypadku, ważne jest, aby przeprowadzić szczegółową dyskusję na temat wyników i metodologii, aby zrozumieć, dlaczego istnieje rozbieżność między opisanymi czasami wykonania w odniesieniu do podjętego problemu a rzeczywistością przedstawioną w części eksperymentalnej. Ten etap obejmuje wyniki, których wykonanie zajmuje od 70s do 474s.

Tabela 4.3 sugeruje, że jedynie faza "the data acquisition and pre-processing" jest czasochłonna. Można założyć, że sama akwizycja i przetwarzanie danych może być bardziej wymagające obliczeniowo niż reszta procesu. Warto zauważyć, że faza akwizycji i przetwarzania danych jest często nieodłącznym elementem procesu uczenia maszynowego i może wymagać znacznych zasobów obliczeniowych, zwłaszcza w przypadku dużych zbiorów danych lub skomplikowanych operacji przetwarzania. Dodatkowo, wyniki w tabeli 4.4 wskazują, że koszt symulacji wynosi od 0,02 do 4 USD. To sugeruje, że te symulacje nie są szczególnie kosztowne, nawet jeśli niektóre z nich są czasochłonne. Podsumowując, jeśli wyniki wydajnościowe pokazują, że symulacje są niedrogie, nawet jeśli są czasochłonne, to jest to informacja która wskazuje, że prace nad poprawą wydajności nie są aż tak istotne.

Seria przetestowanych algorytmów machine learning wylistowanych w sekcji 4.5.2. Chciałbym podjąć dyskusję na temat procesu selekcji konfiguracji algorytmów przedstawionych w pracy. Nie znajdujemy w pracy szczegółowego opisu tego procesu i nie jest jasne, dlaczego właśnie te konkretne konfiguracje zostały wybrane. Jaki był proces selekcji konfiguracji? Jakie czynniki zostały wzięte pod uwagę podczas tego procesu? Czy przeprowadzono badania porównawcze lub eksperymenty, aby ocenić skuteczność różnych konfiguracji? Czy były jakieś kryteria wyboru? Dodatkowo, czy istnieją jakieś badania lub dowody potwierdzające, że ta konkretna konfiguracja pozwala osiągnąć najlepsze rezultaty? Czy rozważano alternatywne konfiguracje i porównano je z wybraną konfiguracją? Kwestia ta jest o tyle istotna, że tylko jeden z algorytmów osiąga wynik „bardzo dobry” o wartości parametru $accuracy=0,8096$, mieszczący się w przedziale 0,8 - 0,9.

Energooszczędność i jednoczesne wykonanie do dwóch potoków. Chciałbym skierować uwagę na opisane przez autora korzyści wynikające z zastosowania pipeline'u w kontekście przyspieszenia analizy danych eksperymentalnych oraz energooszczędności. Autor zaznacza, że pipeline ten przyczynia się do poprawy efektywności energetycznej i umożliwia szybszą analizę danych eksperymentalnych. Energooszczędność to również jedna z kluczowych cech, jaką autor wymienia w odniesieniu do zbudowanego klastra. Mam kilka pytań, które chciałbym zadać, aby lepiej zrozumieć te korzyści:

1. Jak dokładnie pipeline przyczynia się do efektywności energetycznej? Czy zostały przeprowadzone konkretne pomiary lub analizy, aby potwierdzić tę korzyść? Czy mierzone były zużycie energii lub oszacowano zużycie energii na podstawie określonych parametrów?
2. W odniesieniu do przyspieszenia analizy danych eksperymentalnych, czy można podać bardziej szczegółowe informacje na temat tego, jak pipeline umożliwia tę przyspieszoną analizę? Czy zidentyfikowano konkretną część procesu analizy danych, która została przyspieszona? Czy zostały przeprowadzone porównania czasowe między pipeline'em a innymi podejściami?
3. W odniesieniu do informacji autora o możliwości tworzenia dwóch niezależnych potoków, jak wpływa to na wyniki wydajnościowe? Czy przyspieszenie obliczeń zostało zmierzone lub oszacowane? Czy różne konfiguracje potoków miały różny wpływ na wydajność?

Brak powtarzalności w relacji wydajności pomiędzy trzema prezentowanymi modelami. Chciałbym zwrócić uwagę na Rys. 5.11, który prezentuje różnice w trendach wydajności pomiędzy modelami RetNet. Mamy tutaj wyszczególnione trzy modele: bare-bone HPI, containerised HPI i containerised AWS. Zauważyć można, że różnice w ich wydajności są dość zmienne, czasami jeden model osiąga lepsze wyniki, a innym razem drugi model jest lepszy. To skłania do refleksji na temat przyczyn tych zależności oraz trudności w ich oszacowaniu i nieprzewidywalności. Czy autor mógłby przedstawić więcej informacji na temat tych różnic w trendach? Czy przeprowadzono analizę, aby zidentyfikować czynniki, które wpływają na te różnice? Czy istnieją konkretne cechy lub parametry, które mogą mieć decydujący wpływ na wyniki?

Opinia końcowa o rozprawie

Wg. mojej opinii stwierdzam, że recenzowana rozprawa doktorska pod tytułem "Neural Simulation Pipeline for Liquid State Machines", przedłożona do oceny przez mgr Karola Chlastę, stanowi unikalne rozwiązanie znaczącego problemu naukowo-badawczego. Ponadto, wykazuje głęboką teoretyczną wiedzę w dziedzinie Informatyki Technicznej i Telekomunikacji, łączącą się z bardzo dobrymi umiejętnościami zastosowania metod przetwarzania oraz realizacji obliczeń. Ocena pracy jest jednoznacznie pozytywna. Recenzowana rozprawa spełnia wszystkie ustawowe wymagania. Wnoszę zatem o dopuszczenie rozprawy doktorskiej do publicznej obrony.


Krzysztof Rojek