



UNIwersytet
Warszawski



OBSERWATORIUM
ASTRONOMICZNE
UNIwersytetu
Warszawskiego

POLITECHNIKA ŚLĄSKA
Biuro Rady Dyscypliny
Automatyka, Elektronika, Elektrotechnika
i Technologie Kosmiczne

wpłynęło dnia 14.04.2026

nr zał.

Prof. dr. hab. Łukasz Wyrzykowski
Obserwatorium Astronomiczne
Uniwersytet Warszawski
Al. Ujazdowskie 4
00-478 Warszawa

Warszawa, 8 kwietnia 2026r.

Recenzja pracy doktorskiej

mgr inż. Piotr Józwik-Wabik
Politechnika Śląska

p.t.:

Wykorzystanie metod uczenia maszynowego w przetwarzaniu oraz analizie obrazów astronomicznych

Promotorzy:

Dr hab. Adam Popowicz, prof. Politechniki Śląskiej

Dr inż. Krzysztof Bernacki

Praca doktorska Piotra Józwika-Wabika dotyczy zbadania, w jakim stopniu metody uczenia maszynowego mogą usprawnić i poprawić analizę obrazów astronomicznych, zarówno gwiazd, jak i danych słonecznych. Temat podjęty w pracy jest bardzo aktualny ze względu na coraz szersze zastosowania uczenia maszynowego, ale zastosowanie go do danych astronomicznych w celu ich poprawienia jest nowatorskie i potencjalnie przełomowe. Wnioski pracy wskazują, że podejście to może skutecznie zredukować szum i poprawiać jakość pomiarów, często dorównując lub przewyższając tradycyjne metody deterministyczne.

Praca liczy 182 stron i zawiera osiem głównych rozdziałów, w tym pierwsze trzy są wprowadzeniem, rozdziały 4-7 zawierają część badawczą, a rozdział 8 jest podsumowaniem całej pracy. Materiał zawarty w pracy jest oryginalny, jego części zostały wcześniej zaprezentowane na krajowych i międzynarodowych konferencjach naukowych oraz w formie artykułów czy wystąpieniach konferencyjnych. Według Autora, materiał rozdziału 5 jest przygotowywany do publikacji w wysoko-cytowanym czasopiśmie astronomicznym *Astronomy and Astrophysics*.

Prezentacja i układ pracy są poprawne i przejrzyste, z licznymi rysunkami i tabelami. Tekst pracy jest zrozumiały i jest napisany bez błędów edytorskich i językowych. Rysunki i tabele zawierają opisy, które moim zdaniem mogłyby być bardziej rozbudowane i obszerniejsze.

Pierwsze trzy rozdziały tworzą spójne i logiczne wprowadzenie do tematyki pracy, obejmujące zarówno kontekst dziedziny, jak i podstawy metodologiczne. Ich zakres jest szeroki i dobrze przygotowuje grunt pod część eksperymentalną, choć momentami ma charakter przeglądowny.

Rozdział 1 (Wprowadzenie) przedstawia kontekst wykorzystania metod uczenia maszynowego w analizie danych, ze szczególnym uwzględnieniem astronomii obserwacyjnej. Autor uzasadnia potrzebę badań, wskazując na rosnącą rolę małych teleskopów oraz ograniczenia tradycyjnych metod przetwarzania danych. Sformułowana zostaje teza pracy, zakładająca, że zastosowanie sieci neuronowych może poprawić jakość pomiarów astronomicznych oraz efektywność przetwarzania danych.

Rozdział 2 (Obserwacje astronomiczne w praktyce) wprowadza podstawowe zagadnienia związane ze zbieraniem obserwacyjnych danych astronomicznych. Omawia rodzaje obserwacji, czynniki wpływające na jakość danych (takie jak szum instrumentalny, drgania atmosfery, zanieczyszczenie światłem oraz ograniczenia aparatury) oraz kluczowe pojęcia, m.in. czas ekspozycji, rozdzielczość, fotometrię i astrometrię. Szczególny nacisk położono na specyfikę danych pochodzących z małych teleskopów naziemnych, które stanowią główny przedmiot badań w pracy. Pewne elementy dotyczące szczegółów wykonywania pomiarów fotometrycznych w formie wprowadzenia pojawiają się również w rozdziale 5, a moim zdaniem lepiej pasowałyby do rozdziału 2.

Rozdział 3 (Sieci neuronowe w przetwarzaniu obrazów) przedstawia podstawy teoretyczne uczenia maszynowego ze szczególnym uwzględnieniem sieci neuronowych. Autor omawia ich rozwój, zasadę działania, strukturę (warstwy i architektury), proces treningu oraz kluczowe parametry. Rozdział ten uzasadnia wybór sieci neuronowych jako głównego narzędzia badawczego i przygotowuje czytelnika do analizy eksperymentów przedstawionych w kolejnych częściach pracy. Ponownie, pewne elementy związane z trenowaniem i interpretowaniem wyników działania sieci, które znalazły się w rozdziałach 5, 6 i 7 (np. opis krzywej AUC w 5.2.2), moim zdaniem bardziej pasowałyby do rozdziału 3.

Rozdział 4 ma charakter metodologiczno-eksperymentalny i poświęcony jest opracowaniu oraz wstępnej walidacji metod redukcji szumu z wykorzystaniem sieci neuronowych. Autor koncentruje się na porównaniu różnych strategii uczenia modeli, w szczególności w sytuacji braku idealnych danych referencyjnych, co stanowi istotny problem w zastosowaniach astronomicznych.

Zaproponowane podejścia obejmują szereg wariantów trenowania sieci neuronowych do zadania redukcji szumu, różniących się dostępnością i wykorzystaniem danych referencyjnych. Autor przygotowuje syntetyczny zestaw danych oparty na powszechnie stosowanym w uczeniu maszynowym zbiorze MNIST, do którego wprowadza kontrolowany szum o zadanych parametrach, co umożliwia jednoznaczną i ilościową ocenę jakości rekonstrukcji. Następnie implementuje i porównuje różne schematy uczenia, w tym klasyczne podejście z danymi referencyjnymi (Noise2Clean), metody wykorzystujące jedynie pary zaszumionych obrazów (Noise2Noise), jak również podejścia samo-nadzorowane, niewymagające czystych danych odniesienia (np. Noise2Self, Clean2Self).

Dla każdego z podejść autor przeprowadza proces trenowania wybranych architektur sieci neuronowych, analizując wpływ parametrów uczenia oraz konfiguracji modelu na końcowy wynik. Uzyskane rezultaty są następnie porównywane przy użyciu ilościowych miar jakości obrazu, takich jak PSNR i SSIM, a także oceniane wizualnie. Autor bada również stabilność i zdolność generalizacji modeli, wskazując różnice w skuteczności poszczególnych metod w zależności od charakteru szumu i dostępności danych treningowych. Przeprowadzona w rozdziale analiza doprowadziła do identyfikacji takiej strategii uczenia, która oferuje najlepszy kompromis pomiędzy jakością rekonstrukcji a wymaganiami dotyczącymi danych wejściowych, stanowiąc podstawę do dalszych eksperymentów przeprowadzonych na rzeczywistych danych astronomicznych.

Rozdział 5 stanowi bezpośrednią kontynuację rozważań przedstawionych w poprzedniej części pracy i poświęcony jest zastosowaniu opracowanych metod redukcji szumu do rzeczywistych danych astronomicznych, w szczególności obserwacji gwiazd. Autor aplikuje zbadane i zweryfikowane wcześniej strategie uczenia sieci neuronowych z kontrolowanego środowiska danych syntetycznych do bardziej złożonego i realistycznego problemu, jakim są astronomiczne obserwacje gwiazd obciążone szumem instrumentalnym. Celem rozdziału jest ocena skuteczności tych metod w praktycznych warunkach obserwacyjnych oraz ich wpływu na poprawę jakości pomiarów astronomicznych.

Autor opisuje proces przygotowania danych wejściowych na rzeczywistych obrazach, obejmujący standardowe etapy redukcji danych astronomicznych (kalibracja *bias*, *dark*, *flatfield*), a następnie ich normalizacja i standaryzacja do postaci odpowiedniej dla sieci neuronowych. Szczególną uwagę poświęca konstrukcji zbiorów treningowych, które w przypadku danych obserwacyjnych nie posiadają „czystej” referencji, wykorzystuje tu różne rozwiązania tworzenia par treningowych, np. zestawianie obrazów tego samego pola wykonanych w różnych momentach lub przy różnych warunkach obserwacyjnych. Dane wykorzystane w analizie opierają się na bardzo krótkich ekspozycjach pojedynczych klatek o czasie naświetlania 500 ms, które następnie są łączone poprzez uśrednianie w zestawy kilkudziesięciu obrazów. Nawet przy złożeniu 50 ramek daje to efektywny czas naświetlania 25 s, co wciąż pozostaje stosunkowo krótką ekspozycją jak na potrzeby precyzyjnej fotometrii i detekcji słabszych obiektów.

W tym kontekście brakuje bardziej szczegółowego opisu zestawu danych obserwacyjnych, który byłby istotny dla pełnej oceny wyników. Nie jest jednoznacznie określone, czy dane pochodzą z jednej nocy obserwacyjnej, czy z dłuższego okresu, ani jakie były warunki obserwacyjne, takie jak faza Księżyca, masa powietrza (*airmass*) obserwowanego pola (oraz jej zmiana), zachmurzenie czy poziom zanieczyszczenia światłem. Informacje te mają bezpośredni wpływ na charakterystykę szumu i jakość danych, a tym samym na skuteczność testowanych metod. Warto byłoby również wyraźniej przypomnieć lokalizację teleskopu, aby lepiej osadzić analizę w kontekście warunków obserwacyjnych.

Dodatkowo pewne wątpliwości budzi wybór sposobu łączenia klatek. Autor stosuje uśrednianie, podczas gdy w praktyce astronomicznej często wykorzystuje się sumowanie (*stackowanie*) obrazów w celu maksymalizacji stosunku sygnału do szumu. Wybór uśredniania może być uzasadniony z punktu widzenia stabilności numerycznej lub przygotowania danych do sieci neuronowych, jednak wymagałoby krótkiego uzasadnienia, zwłaszcza w kontekście porównania z klasycznymi metodami redukcji szumu.

Podrozdział 5.5 stanowi kluczową część analizy wyników uzyskanych dla danych obserwacyjnych i koncentruje się na szczegółowej ocenie skuteczności oraz złożoności zastosowanych metod redukcji szumu. Autor prezentuje tam zarówno wyniki ilościowe, jak i jakościowe dla różnych wariantów trenowania sieci, zestawiając je między sobą oraz z metodami klasycznymi. Poszczególne pod-podrozdziały odpowiadają różnym konfiguracjom eksperymentalnym lub analizowanym aspektom (np. różnym strategiom uczenia, parametrom treningu lub sposobom przygotowania danych), co pozwala na systematyczne porównanie ich wpływu na końcową jakość obrazu.

Szczególny nacisk położony jest na ocenę wpływu redukcji szumu na zachowanie sygnału astronomicznego, w tym stabilność pomiarów fotometrycznych oraz astrometrycznych poprzez porównanie z wartościami referencyjnymi (rys. 5.14–5.16). Przedstawione zależności wskazują na wyraźną poprawę jakości fotometrii w stosunku do danych surowych, gdyż rozrzut względem wartości referencyjnych ulega zmniejszeniu. Poprawa ta jest widoczna dla większości analizowanych metod, z wyjątkiem w przypadku prostszej architektury U-Net trenowanej w schemacie Noise2Clean, gdzie efekty są mniej jednoznaczne.

Jednocześnie interpretacja wyników, w szczególności na rys. 5.14, nie jest w pełni klarowna. Wykres sugeruje możliwe różnice w liczbie wykrytych obiektów pomiędzy poszczególnymi metodami, co rodzi pytanie, czy zastosowane algorytmy wpływają nie tylko na jakość pomiarów, ale również na sam proces detekcji źródeł. Nie jest jednoznacznie wyjaśnione, czy analizowana jest ta sama próbka gwiazd dla wszystkich metod, czy też każda z nich prowadzi do innej liczby detekcji, np. poprzez ujawnienie słabszych obiektów po redukcji szumu lub generowanie artefaktów. Kwestia ta ma istotne znaczenie dla interpretacji wyników fotometrycznych w kontekście porównania z wartościami referencyjnymi. W przypadku wyników astrometrycznych (rys. 5.17), poprawa wyników nie jest obserwowana, a wręcz widoczne jest niewielkie pogorszenie wyników w porównaniu z klatką referencyjną oraz brak znaczących zmian w porównaniu z klatką surową.

Rozdział 6 poświęcony jest zastosowaniu metod uczenia maszynowego do redukcji szumu atmosferycznego w seriach obrazów Słońca. W odróżnieniu od poprzedniego rozdziału, autor analizuje tu dane z obrazami rozciągniętych struktur z powierzchni Słońca, gdzie dominującym źródłem degradacji jakości jest wpływ atmosfery (*seeing*). W rozdziale tym badane są możliwości wykorzystania sieci neuronowych do poprawy jakości sekwencji obrazów, zarówno w kontekście rekonstrukcji szczegółów struktur, jak i stabilizacji obrazu w czasie. Autor przenosi wcześniej opracowane podejścia do problemu dynamicznych danych obrazowych, oceniając ich skuteczność w porównaniu ze sprawdzonymi rozwiązaniami klasycznymi (algorytm MFBD oraz najlepsza klatka).

Autor szczegółowo opisuje proces projektowania i implementacji różnych architektur sieci neuronowych dostosowanych do analizy sekwencji obrazów słonecznych. Przedstawia wybór struktur modeli, ich parametryzację, sposób przygotowania danych wejściowych oraz strategie uczenia, uwzględniając specyfikę danych czasowych i przestrzennych. Omawia m.in. różnice pomiędzy wariantami sieci (mała, średnia, duża), dobór funkcji kosztu, procedury optymalizacji oraz wpływ parametrów na stabilność i jakość wyników. Wprowadza i definiuje również metryki niezbędne do oceny efektywności rozwiązań. Opis jest technicznie szczegółowy i spójny, co świadczy o dobrej znajomości zagadnień związanych z uczeniem maszynowym i ich praktycznym zastosowaniem w analizie danych obrazowych.

Analiza wyników polegała na porównaniu osiągnięć zaprojektowanych systemów z sieciami neuronowymi z algorytmem MFBD. Jako referencyjne wybrano jedynie MFBD₂₀₀ (oparte o 200 klatek), jednak nie przedstawiono porównania z innymi wynikami dla mniejszej liczby klatek. Wyniki wskazują, że zastosowanie sieci neuronowych pozwala na istotną poprawę jakości obrazów, w szczególności pod względem kontrastu i odwzorowania drobnych struktur powierzchni Słońca. W wielu przypadkach uzyskane rezultaty są porównywalne z wynikami MFBD, przy znacznie mniejszym koszcie obliczeniowym i krótszym czasie przetwarzania. Jednocześnie Autor zwraca uwagę na różnice jakościowe pomiędzy metodami, gdyż MFBD pozostaje podejściem opartym o fizykę i w pewnych sytuacjach może lepiej zachowywać rzeczywiste struktury obrazu, podczas gdy metody oparte na uczeniu maszynowym mogą prowadzić do ich częściowego wygładzenia lub wprowadzenia artefaktów.

Wyniki przedstawione w rozdziale 6 wskazują, że metody oparte na sieciach neuronowych mogą skutecznie poprawiać jakość obrazów słonecznych i stanowić szybszą alternatywę dla MFBD, jednak wymagają ostrożnej interpretacji ze względu na możliwe zniekształcenia struktur fizycznych.

Rozdział 7 poświęcony jest zagadnieniu kompresji sieci neuronowych w kontekście przetwarzania danych słonecznych, ze szczególnym uwzględnieniem redukcji złożoności modeli przy zachowaniu ich wydajności i poprawności. Autor analizuje różne techniki upraszczania sieci, takie jak redukcja liczby parametrów, modyfikacje architektury czy optymalizacja procesu wnioskowania, a następnie bada ich wpływ na jakość rekonstrukcji obrazów słonecznych. Przeprowadzone eksperymenty pozwalają ocenić kompromis pomiędzy wydajnością obliczeniową a dokładnością wyników, wskazując, że możliwe jest znaczące

przyspieszenie działania modeli przy relatywnie niewielkiej utracie jakości, co ma istotne znaczenie dla praktycznych zastosowań, w szczególności w systemach wymagających szybkiego przetwarzania danych.

Autor przedstawia analizę wyników uzyskanych dla różnych wariantów skompresowanych modeli, koncentrując się na ocenie kompromisu pomiędzy redukcją złożoności sieci a jakością rekonstrukcji obrazów. Porównywane są modele o różnej liczbie parametrów i stopniu uproszczenia, a ich działanie oceniane jest zarówno ilościowo, jak i jakościowo. Wyniki wskazują, że istotne zmniejszenie rozmiaru modeli oraz przyspieszenie ich działania jest możliwe przy relatywnie niewielkiej degradacji jakości obrazu, choć w bardziej agresywnych wariantach kompresji pojawiają się zauważalne straty szczegółów oraz zwiększone ryzyko artefaktów. Autor identyfikuje zatem zakres parametrów, w którym uzyskiwany jest korzystny kompromis pomiędzy efektywnością obliczeniową a dokładnością, co ma znaczenie dla praktycznych zastosowań wymagających szybkiego przetwarzania danych. Jako przykład zastosowania skompresowanej sieci, Autor opisuje również próbę uruchomienia algorytmu na mikroskopijnym urządzeniu Raspberry Pi 5, wykazując że taka możliwość może być brana pod uwagę, co z kolei może pozwolić projektować systemy analizy danych astronomicznych bezpośrednio tuż przy samym teleskopie.

Rozdział 8 stanowi podsumowanie całej pracy, jednak jego forma pozostaje stosunkowo zwięzła i w mojej ocenie niewystarczająco rozwinięta w stosunku do zakresu pracy. Autor wskazuje jedynie główne kierunki badań oraz ogólne wnioski dotyczące zastosowania metod uczenia maszynowego w redukcji szumu, jednak brakuje bardziej szczegółowego odniesienia do wyników uzyskanych w poszczególnych rozdziałach. W szczególności pożądanym byłoby wyraźniejsze powiązanie rezultatów z rozdziałów 4-7, obejmujących zarówno testy na danych syntetycznych, jak i analizę rzeczywistych danych astronomicznych oraz obrazów słonecznych, a także eksperymenty związane z kompresją modeli. Rozdział ten mógłby również w bardziej syntetyczny sposób podkreślić wspólne wnioski wynikające z całej pracy, takie jak zależność skuteczności metod od jakości danych wejściowych, kompromis pomiędzy redukcją szumu a zachowaniem sygnału fizycznego czy praktyczne ograniczenia zastosowań sieci neuronowych. W obecnej formie podsumowanie spełnia swoją rolę formalną, jednak jego rozszerzenie i pogłębienie znacząco zwiększyłoby klarowność oraz siłę przekazu końcowych wniosków pracy.

PODSUMOWANIE

Rozprawa stanowi spójne i kompleksowe studium zastosowania metod uczenia maszynowego, w szczególności sieci neuronowych, do problemu redukcji szumu w danych obserwacyjnych w astronomii. Autor prowadzi czytelnika od kontrolowanych eksperymentów na danych syntetycznych, poprzez analizę rzeczywistych obserwacji nocnego nieba, aż po bardziej złożone przypadki obrazów słonecznych oraz zagadnienia optymalizacji i kompresji modeli. Praca pokazuje, że podejścia oparte na uczeniu maszynowym mogą skutecznie poprawiać jakość danych i wspierać analizę astronomiczną, w tym detekcję i fotometrię obiektów, często oferując wyniki porównywalne z metodami klasycznymi przy niższym koszcie obliczeniowym. Jednocześnie Autor trafnie identyfikuje ograniczenia tych metod, związane m.in. z zależnością od jakości danych wejściowych oraz ryzykiem zniekształcenia sygnału fizycznego. Całość pracy jest dobrze ustrukturyzowana, a przedstawione wyniki mają zarówno wartość poznawczą, jak i potencjał praktycznych dalszych zastosowań w analizie danych obserwacyjnych.

Podsumowując, uważam, że doktorant wykonał bardzo obszerną i wartościową pracę badawczą, realizując ją w sposób staranny i konsekwentny. Rozprawa zawiera szczegółową prezentację całego procesu analizy problemu badawczego oraz proponuje nowatorskie rozwiązania oparte na metodach uczenia maszynowego. Autor wykazał się wysokimi kompetencjami badawczymi, podejmując się złożonych zadań związanych z przetwarzaniem i analizą danych, a także ich interpretacją, co potwierdza jego dojrzałość naukową.

W mojej ocenie praca mgr. inż. Piotra Józwika-Wabika spełnia wszystkie formalne i zwyczajowe wymagania stawiane rozprawom doktorskim w Polsce i dlatego rekomenduję ją do dalszego rozpatrywania.

Warszawa, 8 kwietnia 2026r.

prof. dr. hab. Łukasz Wyrzykowski