

Prof. dr hab. inż. Jacek Kluska
Katedra Informatyki i Automatyki
Wydział Elektrotechniki i Informatyki
Politechnika Rzeszowska im. Ignacego Łukasiewicza
al. Powstańców Warszawy 12
35-029 Rzeszów
e-mail:jacklu@prz.edu.pl

Rzeszów, 2.03.2016 r.

Recenzja rozprawy doktorskiej mgr. inż. Piotra Józwicka-Wabika
pt. „*Wykorzystanie metod uczenia maszynowego w
przetwarzaniu oraz analizie obrazów astronomicznych*”

Niniejsza recenzja została przygotowana w związku z wyznaczeniem mnie na recenzenta rozprawy doktorskiej Pana mgr. inż. Piotra Józwicka-Wabika przez Radę Dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne Politechniki Śląskiej. Postaram się w niej zawrzeć ocenę dotyczącą spełnienia wymagań stawianym rozprawom doktorskim, określonym w art. 187 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz.U.2024.1571 t.j., Art. 187).

1 Informacja o rozprawie doktorskiej

a) Tematyka rozprawy

Podstawę ubiegania się o nadanie stopnia doktora przez Pana mgr. inż. Piotra Józwicka-Wabika stanowi rozprawa doktorska pt. „*Wykorzystanie metod uczenia maszynowego w przetwarzaniu oraz analizie obrazów astronomicznych*”, wydana w październiku 2015 roku i zrealizowana pod promotorską opieką Pana dr. hab. inż. Adama Popowicza, prof. Politechniki Śląskiej i promotora pomocniczego - Pana dr. inż. Krzysztofa Bernackiego.

Rozprawa dotyczy wykorzystania sieci neuronowych do poprawy jakości obrazów astronomicznych, rozumianej jako lepsza „jakość pomiarowa” (w tym detekcja obiektów oraz wyznaczanie ich położenia i jasności), w porównaniu z dotychczasowymi algorytmami deterministycznymi, jak również do uzyskania mniejszych wymagań sprzętowych lub większej szybkości przetwarzania.

Motywacja jest osadzona w realiach małych, zdalnych obserwatoriów. Autor wskazuje ograniczenia energetyczne, tj. zasilanie akumulatorowe, koszt energetyczny centrów danych, jako tło dla potrzeby efektywności obliczeniowej przetwarzania obrazów.

Zakres rozprawy wiąże się z rozwinięciem takich tematów, jak:

- podstawy obserwacji astronomicznych (rozdz. 2),
- podstawy sieci neuronowych z punktu widzenia przetwarzania obrazów (rozdz. 3), a potem trzy kolejne studia przypadków na danych o rosnącej złożoności,

- redukcja szumu na danych ze zbioru empirycznych obrazów odręcznie pisanych cyfr MNIST (Modified National Institute of Standards and Technology; rozdz. 4),
- redukcja szumu na obrazach nocnego nieba wraz z oceną wpływu na detekcję gwiazd (rozdz. 5),
- redukcja zakłóceń atmosferycznych w obrazach słonecznych i porównanie z algorytmem MFBD („wieloklatkowej ślepej rekonstrukcji w modelu splotowym”; rozdz. 6),
- kompresja (przycinanie) sieci neuronowych pod kątem zasobów sprzętowych (rozdz. 7).

Podsumowanie zawarto w rozdziale 8.

b) Ocena układu rozprawy, metodologii badawczej i uzyskanych wyników

W rozdziale 1 Autor wskazuje, że sieci neuronowe są coraz szerzej stosowane w astronomii, np. do detekcji/klasyfikacji obiektów oraz redukcji szumu i zwraca uwagę na problem niedopasowania rozwiązań projektowanych pod dane z dużych instrumentów do danych z małych teleskopów. Stwierdza potrzebę empirycznej weryfikacji wyników dla danych pochodzących z małych obserwatoriów i zwróca uwagę na ograniczenia sprzętowo-energetyczne małych, zdalnych instrumentów.

Rozdział 2 podkreśla rolę astronomicznych obserwatoriów naziemnych i sieci małych teleskopów. Omawia zakresy promieniowania, miejsce prowadzenia obserwacji, podkreśla czynniki obniżające jakość danych, wskazując na turbulencje atmosfery i ich szybkie zmiany, zanieczyszczenie światłem oraz szumy aparatury. Ponadto, Autor porównuje „duże” i „małe” instrumenty na przykładzie obserwatorium astronomicznego na kanaryjskiej wyspie La Palma oraz teleskopów grupy SUTO Politechniki Śląskiej. Konkluzja Autora jest taka, że dla małych teleskopów większy potencjał poprawy leży w rozwiązaniach algorytmicznych niż sprzętowych.

Rozdział 3 omawia sieci neuronowe w przetwarzaniu obrazów, sygnalizuje ryzyko „czarnej skrzynki” oraz potrzebę rozumienia mechanizmów projektowania/diagnozy modeli. Omawia m.in. mechanizm uczenia sieci, dobór ich architektur oraz hiperparametry wpływające na jakość modelu neuronowego. Omówione są: elementy architektury istotne w przetwarzaniu obrazów, mechanizmy stabilizacji i uogólniania, funkcje aktywacji, normalizacja, podział danych, augmentacja, inicjalizacja wag itd. Autor wskazuje też stosowane środowisko implementacyjne (Python jako dominujące narzędzie w ML użyte w pracy).

W rozdziale 4 Autor przedstawia schemat architektury i deklaruje, że model jest symetryczny, z warstwami redukującymi i zwiększającymi wymiar oraz z wektorem kodowań, a jego złożoność kontroluje przez liczbę map cech i długość kodowań. Dodatkowo, podaje szczegóły uczenia (np. 300 epok, podział na mini-grupy) oraz definiuje funkcję straty (jako sumę składników L_1 , L_2 i zmodyfikowanej metryki Wassersteina).

Rozdział 5 rozszerza metodykę o kryteria stricte astronomiczne. Opisuje detekcję gwiazd za pomocą 'algorytmu do automatycznej detekcji źródeł punktowych na obrazie astronomicznym' o nazwie DAOSStarFinder, w tym interpretację progu detekcji i zalecenie progu 5σ jako typowego kompromisu, a także sygnalizuje analizę odchylenia położenia i jasności wykrytych źródeł. W rozdziale zdiagnozowano nieprzydatność *wskaźnika podobieństwa strukturalnego* (SSIM) do oceny jakości obrazów z rzadko rozmieszczonymi źródłami punktowymi. Wykazano, że dominacja jednorodnego tła prowadzi do saturacji wskaźnika SSIM

(wartości większe od 0.999), co uniemożliwia rzetelną ocenę zmian lokalnych w obrębie gwiazd. Jako rozwiązanie wprowadzono metrykę *podobieństwa cech* FSIM (Feature Similarity Index), która dzięki analizie cech strukturalnych (ważnych dla percepcji detali) pozwala na precyzyjne różnicowanie jakości odwzorowania obiektów istotnych, pomijając wpływ nieistotnego informacyjnie tła. Ogranicza to ryzyko wyciągania wniosków na podstawie miary o małej rozdzielczości diagnostycznej w danym reżimie danych.

W rozdziale 6 Autor zestawia podejście sieciowe z „wieloklatkową ślepą rekonstrukcją w modelu splotowym” - MFBD, uznanym punktem odniesienia w obrazowaniu słonecznym. Wskazuje, że metoda MFBD bywa kosztowna obliczeniowo i często wymaga czasu przetwarzania wielokrotnie przekraczającego czas akwizycji, oraz że w pracy używa istniejącej implementacji MFBD, konsultując dobór parametrów z autorem prac dotyczących algorytmów MFBD. Opis danych SUTO-Solar pochodzący z Obserwatorium Politechniki Śląskiej obejmuje uzasadnienie adekwatności do małych teleskopów (monitoring pełnej tarczy i wycinki 100×100 lub 200×200 pikseli) oraz jawny podział na zbiory uczący (treningowy), walidacyjny i testowy (tabela 6.1), co umożliwia weryfikację rzetelności procedury oceny. Architektury są raportowane wraz z liczbą parametrów (ok. 12 tys., 150 tys. i 3.2 mln), a Autor doprecyzowuje, że architektura „koder-dekoder” z publikacji bazowej jest w praktyce siecią U-Net (architekturą splotowej sieci neuronowej, zaprojektowaną pierwotnie do segmentacji obrazów), ze względu na połączenia pomijające (skrótowe, *skip connections*), co stanowi weryfikowalne uściślenie pojęciowe. W zakresie wyników i ich interpretacji rozdział 6 zawiera elementy istotne dla oceny. Autor wskazuje, że wybrane metryki (FSIM, VIF - metryka wierności informacji wizualnej) mogą sugerować niższą jakość wyników MFBD i wyjaśnia tę pozorną sprzeczność efektem przesunięcia obrazu i przycięcia krawędzi wprowadzanym przez MFBD, przechodząc następnie do analizy wizualnej. W konsekwencji Autor uznaje, że w tej konfiguracji dane liczbowe nie są wystarczające do rozstrzygnięcia i wymaga to interpretacji w oparciu o mechanizm powstawania różnic, co ogranicza ryzyko błędnej inferencji z nieadekwatnej metryki. Jednocześnie Autor dostarcza danych w tabelach 6.3-6.4 raportując czasy przetwarzania, gdzie MFBD osiąga rząd 27 000 - 38 000 ms (zależnie od liczby klatek), podczas gdy sieci osiągają rząd 2 - 9 ms (GPU) lub 2 - 31 ms (CPU), i sam stwierdza przewagę „3 rzędy wielkości” na korzyść sieci. Autor jednocześnie zaznacza, że czas MFBD dotyczy całego oprogramowania na specjalistycznym sprzęcie, a nie samego algorytmu, przez co jest obarczony niepewnością, podczas gdy czasy sieci obejmują wczytanie i przetworzenie danych i są raportowane bardziej bezpośrednio.

W rozdziale 7 Autor analizuje kompresję (przycinanie) sieci neuronowej i raportuje skutki tej operacji w tabelach (np. tab. 7.2 dla sieci „średniej”), obejmując równolegle liczbę parametrów, pamięć i czas dla rozmiarów 176×176 oraz 2304×2304 przy różnych poziomach przycięcia. Autor formułuje wniosek, że dla dużego rozmiaru przestrzennego czas przetwarzania zależy głównie od liczby klatek wejściowych, a nie od stopnia przycięcia, a dla mniejszych danych czasy pozostają poniżej 10 ms; w tym sensie, tj. w zakresie szybkości, wskazuje sieci jako alternatywę dla MFBD w kontekście przetwarzania danych szybciej niż ich akwizycja.

c) Ocena zastosowanego piśmiennictwa

Bibliografia liczy 173 pozycje i wykazuje cechy interdyscyplinarności rozprawy, obejmując zarówno klasyczne pozycje fundamentalne dla sztucznej inteligencji (AI) i uczenia

głębokiego (np. Turing 1950, AlexNet 2012, GAN 2014, ResNet 2016), jak i prace oraz narzędzia używane w astronomii obserwacyjnej (np. DAOPHOT/DAOFIND i Photutils). Są też cytowania prac nt. oceny jakości obrazu, jak SSIM, FSIM, krytycznego porównania *szczytowego stosunku sygnału do szumu* - PSNR oraz SSIM. Dobór źródeł nie budzi zastrzeżeń - jeżeli Autor używa określonej metryki lub narzędzia, wskazuje standardowe źródło bibliograficzne. Są odwołania do literatury i implementacji dotyczących MFBD oraz prac o sieciach typu koder-dekoder jako alternatywie dla MFBD. Dodatkowo Autor zapewnia ślad replikacyjny poprzez podanie repozytorium implementacji w przypisie. Część materiału w rozdziale 2 jest zaczerpnięta z zasobów internetowych z podanym adresem i datą dostępu.

Generalnie, dobór źródeł wspiera argumentację zawartą w częściach badawczych rozprawy.

d) Wskazanie i ocena tezy oraz celu pracy

Teza pracy mówi, że przetwarzanie obrazów astronomicznych sieciami neuronowymi może poprawiać jakość pomiarową w porównaniu z algorytmami deterministycznymi, a równoległe prowadzi do niższych wymagań sprzętowych lub większej szybkości przetwarzania. Teza jest więc dwuczłonowa, gdyż zawiera komponent jakościowy (detekcja / położenie / jasność), jak również zasobowo-czasowy.

Autor deklaruje, że prace badawcze dzieli na cztery części; pierwsza dotyczy autoenkoderów, a następnie rozdziały 4-7 są skonstruowane tak, aby dostarczyć empirycznych sprawdzeń obu członów tezy, tzn. jakości (metryki, detekcja gwiazd, analiza wizualna) oraz zasobów (czasy, pamięć, przycinanie). Autor podał mierzalne wskaźniki i porównania z punktami odniesienia, które dotyczą *nielokalnego uśredniania* (NLM) i *dopasowywania podobnych bloków oraz filtrowania w 3D* (BM3D) w rozdz. 4 oraz MFBD w rozdz. 6).

e) Ocena części dotyczącej omówienia wyników badań

W rozdziale 5 Autor stwierdza, że SSIM jest niewrażliwy dla danych nocnych (saturacja większa od 0.999) i uzasadnia przejście na FSIM na str. 90. Tym samym dyskusja nie polega jedynie na raportowaniu liczb, lecz na wykazaniu, że miara musi być adekwatna do struktury danych (dominujące tło a lokalne źródła punktowe - gwiazdy).

W rozdziale 6 omówienie wyników obejmuje krytykę własnych danych porównawczych, gdzie Autor pokazuje sytuację, w której FSIM i VIF sugerują gorszy wynik MFBD, a następnie wyjaśnia to przesunięciem obrazu i przycięciem krawędzi wprowadzanym przez MFBD, co wpływa na porównania względem obrazu referencyjnego (por. rys. 6.8-6.9). W konsekwencji Autor uzasadnia potrzebę analizy wizualnej i mechanistycznej interpretacji, zamiast bezrefleksyjnie opierać wnioski na jednej metryce.

W rozdziale 8 Autor formułuje syntezę wyników i stwierdza, że niewielkie sieci mogą osiągać wysoką skuteczność i mogą przewyższać zarówno algorytmy deterministyczne, jak i większe modele, oraz że rozwiązania nie były w pełni optymalizowane, co jest wskazane jako ograniczenie na tym etapie prac.

f) Perspektywa praktycznego zastosowania wyników badań

Praktyczna perspektywa zastosowań jest zadeklarowana wprost w motywacji, tzn. zdalne teleskopy o ograniczonym zasilaniu wymagają rozwiązań efektywnych obliczeniowo i energetycznie. W części „słonecznej” Autor dostarcza argumentu wdrożeniowego w posta-

ci różnicy rzędu trzech rzędów wielkości czasu przetwarzania na korzyść sieci neuronowych względem MFBD, co bezpośrednio wspiera scenariusz przetwarzania serii w czasie krótszym niż akwizycja.

W rozdziale 7 Autor analizuje wpływ przycinania na pamięć i czas także dla bardzo dużych rozmiarów przestrzennych (2304×2304), co odpowiada obrazowaniu pełnego dysku Słońca i jest istotne dla implementacji na sprzęcie o ograniczonych zasobach. Ponadto, Autor wskazuje kontynuację prac poprzez rozszerzenie eksperymentów nocnych na dane o różnym czasie ekspozycji oraz zamiar zgłoszenia artykułu do czasopisma *Astronomy & Astrophysics*, co świadczy o planie dalszego rozwijania wyników w stronę zastosowań i walidacji w szerszym kontekście.

g) Ocena oryginalności rozwiązania problemu naukowego

Pracę można uznać za oryginalną, ze względu na dwa aspekty:

- (1) sformułowanie problemu w sposób łączący jakość pomiarową z ograniczeniami zasobowymi małych obserwatoriów oraz
- (2) sposób walidacji obejmującego kryteria astronomiczne, a nie wyłącznie poleganiu na metrykach obrazowych.

Pierwszy aspekt wiąże się z tezą pracy i motywacją odnoszącą się do zdalnych teleskopów oraz w późniejszym włączeniu benchmarków czasu i pamięci oraz rozdziału o przycinanie.

Drugi aspekt jest widoczny w rozdziale 5, gdzie ocena obejmuje detekcję gwiazd oraz odchyłki położenia i jasności, czyli wielkości odpowiadające wprost jakości pomiarowej z tezy.

Dodatkowym wskaźnikiem oryginalnego wkładu Autora (w sensie nowości praktycznej i naukowej), jest informacja o publikacjach wybranych wyników, ponieważ Autor wymienia współautorskie artykuły: jeden w czasopiśmie *Sensors* (2023) o strategiach uczenia autoenkoderów [170] i drugi - w *Scientific Reports* (2025) [172] odpowiadający rozdziałowi 6.

h) Ocena ogólnej wiedzy teoretycznej Kandydata do stopnia doktora w dyscyplinie i umiejętności samodzielnego prowadzenia pracy naukowej

W części o podstawach astronomii Autor omawia praktyczne aspekty redukcji szumu za pomocą techniki łączenia klatek (stacking) i podaje równania opisujące spadek wariancji szumu wraz z liczbą klatek, wskazując jednocześnie ograniczenia uśredniania dla składowych długozmiennych atmosfery oraz związek z rozmyciem obrazu. W rozdziale przedstawia elementy teorii uczenia sieci na poziomie umożliwiającym weryfikację matematyczną. Opisuje algorytm gradientu prostego i podaje równanie aktualizacji parametrów, a także wiąże propagację wsteczną z odwrotnym różniczkowaniem automatycznym pochodzącym od Linnainmaa. Ponadto, omawia stabilność uczenia w kontekście problemów znikającego i eksplodującego gradientu oraz uzasadnia rolę funkcji aktywacji ReLU w praktyce uczenia głębokiego, odwołując się do historii badań (Glorot & Bengio 2010) i do przykładu AlexNet.

Opis warstw splotowych jest powiązany z klasycznym przetwarzaniem sygnałów i zawiera komentarz dotyczący liczby parametrów niezależnej od rozmiaru przestrzennego obrazu, co stanowi poprawne uzasadnienie dominacji splotowej sieci neuronowej (CNN) w zadaniach przetwarzania obrazów.

Konkludując, Kandydat posiada ugruntowaną wiedzę teoretyczną, która pozwala mu na swobodne poruszanie się między zagadnieniami fizyki sensorów, elektroniki cyfrowej a zaawansowanymi algorytmami AI. Wykazana zdolność do formułowania problemów badawczych, projektowania eksperymentów oraz ich rzetelnej dokumentacji w pełni potwierdza Jego przygotowanie do samodzielnej pracy naukowej i uzyskania stopnia doktora w dyscyplinie „automatyka, elektronika, elektrotechnika i technologie kosmiczne”.

2 Uwagi i kwestie do dyskusji

Poniżej podaję kilka uwag, drobnych niedopatrzeń i kwestii do dyskusji.

1. W literaturze dotyczącej porównań algorytmów uczenia maszynowego zaleca się stosowanie formalnych testów (np. test Wilcoxon dla porównań parowanych, a przy wielu algorytmach test Friedmana z analizą post-hoc) jako bezpiecznych, nieparametrycznych procedur weryfikacji różnic. Skoro Autor ma dane naturalnie parowane (te same klatki/te same obrazy przetworzone różnymi metodami) i sam pokazuje, że wyniki mają rozrzut (np. pasma $\pm\sigma$), to dla obrony tez typu „udowodniono wyższość” właściwym, oczekiwanym uzupełnieniem byłyby testy istotności (lub równoważnie: przedziały ufności i wielkości efektu) dla kluczowych metryk. W opisie „statystycznego podejścia” ograniczono się do wykresów pudełkowych jako podstawy opisu statystycznego i wizualizacji $\pm\sigma$.
2. Rysunek 3.12 pochodzący z pracy [Wu, Y., & He, K. (2018). Group normalization, Proc. Eur. Conf. Comp. Vision (ECCV), pp. 3-19] nie wyjaśnia, że w rzeczywistości każda z pokazanych warstw posiada dwa trenowalne parametry: γ - skalowanie i β - przesunięcie, które pozwalają sieci „odwrócić” normalizację, jeśli jest to potrzebne dla wydajności. W p. 3.4.8 preferowałbym podanie wzorów matematycznych dla normalizacji 'Batch Norm (BN)' - wsadowej, 'Layer Norm (LN)' - warstwowej, 'Instance Norm (IN)' - instancji (tj. pojedynczego przykładu) oraz 'Group Norm (GN)' - normalizacji grupowej.
3. W rozprawie Autor błędnie nazwał zbiór MNIST „danymi syntetycznymi” (str. 12, 62). MNIST nie jest zbiorem wygenerowanym algorytmicznie od zera, tylko zbiorem empirycznych obrazów odręcznie pisanych cyfr (poddanych standaryzującemu przetwarzaniu). LeCun i in. napisali, że aby uzyskać odpowiedni protokół uczenia/testu, zbudowano nową bazę przez wymieszanie zbiorów NIST (SD-1 oraz SD-3), które zawierają obrazy cyfr napisanych przez wielu różnych autorów (cyt. „digit images written by 500 different writers”).
4. Str. 70. Zamiast „elementów praca naukowych”, powinno być „elementów prac naukowych”.
5. Str. 55. Zamiast „... z biegiem czasu okazało się, że znajdowane minima lokalne sprawowały się na tyle dobrze, że ...”, lepiej napisać „z biegiem czasu okazało się,

że rozwiązania osiągnane w praktyce, choć nie są globalnie optymalne, często mają wystarczające właściwości uogólniania ...”.

6. W kontekście aktualnego stanu wiedzy (2023–2025) Autor mógł wspomnieć, że w astronomicznym przetwarzaniu obrazów stosuje się już takie podejścia z AI, jak architektury transformerowe, np. ViT (Vision Transformer, czyli transformer do analizy obrazów), Swin (Swin Transformer, czyli transformer z mechanizmem „przesuwanej okna uwagi”) oraz Restormer (Restoration Transformer, czyli transformer do rekonstrukcji i poprawy jakości obrazów). Stosowane są też modele dyfuzyjne, jak DDPM (Denoising Diffusion Probabilistic Models, probabilistyczne modele dyfuzyjne do odsumiania) i DDIM (Denoising Diffusion Implicit Models, implicitne modele dyfuzyjne do odsumiania).
7. Dla czytelników interesujących się ML warto byłoby dodać, że użycie popularnej krzywej ROC nie jest zasadne. Autor ma detektor, który zwraca listę detekcji obiektów punktowych, a nie klasyfikację każdego piksela/każdej pozycji jako „gwiazda / nie-gwiazda”. Wtedy „negatywy” to praktycznie całe tło obrazu (ogromna liczba potencjalnych miejsc), więc TN jest nie tylko trudne do policzenia, ale też wprowadza metryki zdominowane przez olbrzymią liczbę negatywów. W tak niezrównoważonych zadaniach krzywe Precision-Recall (precyzja-czułość) są standardowo bardziej informatywne niż ROC, bo bezpośrednio śledzą kompromis „czystość vs kompletność” detekcji.

Pytania do dyskusji

1. Porównanie szybkości sieci neuronowych z MFBD nie ma charakteru porównania *algorytm1* kontra *algorytm2*, ponieważ wyniki uzyskano na różnych platformach sprzętowych i w różnym reżimie pomiarowym, tzn. sieci trenowano/testowano na procesorze AMD Ryzen 9 5950X z kartą GeForce RTX 3090 Ti, natomiast MFBD uruchamiano jako „specjalnie skonfigurowane oprogramowanie” na Intel Xeon E5-2680 (s. 126). Dla MFBD nie zmierzono czasu samego algorytmu, lecz czas całego oprogramowania, a wynik jest „obciążony pewną niepewnością” (str. 132). Pytanie dotyka drugiego członu tezy: „niższe wymagania sprzętowe / większa szybkość”. *Jakie dodatkowe eksperymenty lub normalizacje czasu należałoby wykonać, aby wniosek o przewadze zasobowej był porównywalny i odporny na zarzut „nieporównywalnych platform” (str. 132)?*
2. W danych nocnych „ref” (obraz referencyjny) jest uśrednioną klatką serii testowej i pełni rolę punktu odniesienia dla detekcji oraz dla oceny ilościowej (str. 91). Wskazano, że uśrednianie może powodować rozmycie przez pozorne przesunięcia. Formalnie prowadzi to do zastąpienia „funkcji rozrzutu punktu PSF” przez „rozszerzoną funkcję rozrzutu PSF”, co może wpływać na strumienie (fotometria) i centroidy (astrometria), a w konsekwencji zaburzać interpretację błędów liczonych względem „ref”. W pracy nie ma dowodu neutralności „ref” jako dodatkowego dowodu poza analizą wizualną. *Czy nie ma ryzyka, że „ref” nie jest neutralnym wzorcem fotometryczno-astrometrycznym?*
3. Część tezy mówi o „poprawie jakości pomiarowej” względem metod deterministycznych. Odniesienie dla słonecznych danych jest jawnie oznaczone jako MFBD200 (str.

- 126), a jednocześnie pokazano, że MFBD może powodować przesunięcie i przycięcie krawędzi, które zaburzają porównania metryczne (str. 128-129). *Jak zatem uzasadnić traktowanie MFBD jako „prawdy” do uczenia/oceny oraz jak rozdzielić poprawę jakości struktur od uczenia się artefaktów MFBD (str. 126; str. 128-129)?*
4. Teza jest ogólna i mówi się o „przetwarzaniu obrazów astronomicznych”. Degradację obrazu modeluje się jako addytywny szum Gaussa o trzech poziomach dobranych na podstawie analizy wizualnej, a „Clean” uzyskuje się przez uśrednianie 100 obrazów (str. 64). *Jak uzasadnić, że taki model degradacji jest reprezentatywny dla realnych sensorów, skoro wcześniej, w części teoretycznej wskazano istotne źródła zakłóceń typowe dla sensorów takie jak „szum Poissona / fotonowy” oraz artefakty matrycy typu „gorące piksele” (str. 23)?*
 5. Autor trenował modele głównie na danych z Obserwatorium SUTO. Ponieważ PSF i statystyka szumu zależą od instrumentu, sieć trenowana głównie na danych z małych teleskopów SUTO może nie przenosić się na dane z teleskopów dużej klasy (np. 1 m, często z optyką adaptacyjną). *Czy praca deklaruje uogólnienie międzyinstrumentowe; jeśli tak, proszę uzasadnić, jeśli nie - trzeba ograniczyć zakres stosowalności do klasy instrumentów/danych rozważanych w pracy (a może stoimy przed koniecznością tworzenia osobnej sieci dla każdego instrumentu na świecie?)*.
 6. Chodzi o doprecyzowanie wniosku z rozdz. 7: „lepiej projektować małe sieci od zera niż stosować pruning dużych modeli”. *Czy to dotyczy wyłącznie badanego wariantu przycinania strukturalnego z ograniczonym dalszym dostrajaniem, czy ma mieć charakter ogólny? Czy rozważane były eksperymenty kontrolne w duchu hipotezy „zwykłego losu” (Lottery Ticket Hypothesis), tj. (i) - trening przyciętej architektury „od zera”, (ii) - cofnięcie wag do wcześniejszej inicjalizacji (tzw. „rewinding”), (iii) - sprawdzenie wrażliwości wyniku na sposób inicjalizacji i losowe ziarno? (dlaczego takie testy nie były możliwe lub nie były potrzebne w przypadku danych astronomicznych?)*
 7. Autor pokazuje czasy przetwarzania sieci na Raspberry Pi 5 (tabele 7.4-7.5), ale nie raportuje pomiaru latencji end-to-end w trybie online: od odczytu klatki z kamery, przez transfer i ewentualne kopie buforów, po prezentację wyniku. *Co dokładnie obejmował pomiar i jak wygląda oszacowanie, czy przy wysokiej kadencji (np. 100 klatek/sek) i większych rozmiarach danych (2304×2304) system spełni warunek nadążania?*

Wskazane w recenzji uwagi nie mają większego znaczenia dla całościowej pozytywnej oceny, ale ich charakter jest stymulujący do dyskusji.

3 Konkluzja

Rozprawa doktorska Pana mgr. inż. Piotra Józwicka-Wabika wnosi pewien wkład w rozwój dyscypliny automatyka, elektronika, elektrotechnika i technologie kosmiczne. Najbardziej wartościowe osiągnięcia pracy to wykazanie skutecznej redukcji szumu na obrazach nocnego nieba wraz z oceną jakości rekonstrukcji miarami opartymi o błąd i podobieństwo cech oraz sprawdzeniem wpływu na automatyczną detekcję gwiazd. Wartościowe jest również

pokazanie na danych słonecznych, że sieci neuronowe mogą dostarczać rezultaty porównywalne z klasyczną wieloklatkową rekonstrukcją obrazu przy wielokrotnie krótszym czasie obliczeń, dalej analiza przycinania i „odchudzania” sieci z raportem konsekwencji dla liczby parametrów, pamięci i czasu także dla obrazów o bardzo dużej rozdzielczości, oraz potwierdzenie dojrzałości części wyników przez ich publikację w recenzowanym czasopiśmie naukowym.

Z moich dotychczasowych uwag wynika, że:

- 1 - przedmiotem rozprawy doktorskiej Pana mgr. inż. Piotra Józwicka-Wabika jest oryginalne rozwiązanie problemu naukowego,
- 2 - rozprawa doktorska prezentuje ogólną wiedzę teoretyczną doktoranta w dyscyplinie automatyka, elektronika, elektrotechnika i technologie kosmiczne,
- 3 - rozprawa i współautorskie publikacje naukowe doktoranta wskazują na umiejętność samodzielnego prowadzenia pracy naukowej.

Stwierdzam, że, rozprawa doktorska spełnia wszystkie wymagania określone w art. 187 ustawy z dnia 20 lipca 2018r. Prawo o szkolnictwie wyższym i nauce ((Dz.U.2024.1571 t.j., Art. 187)). Jednocześnie zwracam się do Wysokiej Rady Dyscypliny Naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne Politechniki Śląskiej o dopuszczenie Pana mgr. inż. Piotra Józwicka-Wabika do dalszego postępowania w sprawie nadania Mu stopnia doktora w dyscyplinie automatyka, elektronika, elektrotechnika i technologie kosmiczne.