



ul. Bartycka 18, 00-716 Warszawa  
tel: (22) 841 00 41, (22) 3296 100  
email: camk@camk.edu.pl  
<http://www.camk.edu.pl>

CENTRUM ASTRONOMICZNE IM. MIKOŁAJA KOPERNIKA PAN

30 sierpnia 2024

Dr hab. Michał Bejger  
Profesor instytutu, CAMK

## **Recenzja rozprawy doktorskiej Hareesha Thuruthipilly'ego pt. "Identification and characterization of strong gravitational lenses and low surface brightness galaxies using deep learning"**

Rozprawa doktorska pana Hareesha Thuruthipilly'ego omawia zastosowania metod uczenia maszynowego (machine learning, ML) do analizy symulowanych i rzeczywistych danych w domenie elektromagnetycznej dwóch klas zjawisk astrofizycznych: soczewek grawitacyjnych i galaktyk. W szczególności rozprawa koncentruje się na szkoleniu i walidacji głębokich sieci neuronowych w przypadku wykrywania i charakteryzowania (szacowania parametrów) stosowanych w astrofizyce silnych soczewek grawitacyjnych (strong gravitational lenses, SGL), galaktyk o niskiej jasności powierzchniowej (low surface brightness galaxies, LSBG) i ultra-rozproszonych galaktyk (ultra-diffuse galaxies, UDG), wykorzystując najnowocześniejsze rozwiązania ML dla danych wejściowych składających się z obrazów, takich jak splotowe sieci neuronowe (convolutional neural networks, CNN) i architektury sieci neuronowych opartych o mechanizm uwagi (attention), zwane również transformatorami.

Temat jest interesujący z czysto astrofizycznego punktu widzenia, ale też bardzo aktualny, ponieważ planowana infrastruktura obserwacyjna, taka jak misja Euclid czy Legacy Survey of Space and Time with the Large Synoptic Survey Telescope (LSST, Vera Rubin Observatory), zapewnią ogromny wzrost ilości wysokiej jakości danych astrofizycznych, co z kolei wymaga zoptymalizowanych i zautomatyzowanych metod analizy danych w celu ich właściwego przetwarzania; obliczeniowo wydajne metody, będące alternatywą dla tradycyjnych, dobrze znanych narzędzi, mogą, oprócz zwiększonej dokładności, szybkości itp., umożliwić również prowadzenie badań przy niższych kosztach dla środowiska (efektywność energetyczna).

Główna część pracy (rozdziały 3, 4 i 5) opiera się o trzy manuskrypty (dwa z nich już opublikowane), z kandydatem jako pierwszym autorem. Artykuły opublikowano w *Astronomy and Astrophysics* i, według NASA ADS, były cytowane łącznie 17 razy w

momencie pisania tego raportu, co pokazuje, że wyniki zostały zauważone przez społeczność. Ponadto kandydat udostępnia internetowe repozytorium z udokumentowanymi implementacjami oprogramowania i oraz wykazuje się aktywnością publikacyjną w formie różnych materiałów konferencyjnych.

Praca jest napisana poprawnym angielskim i przyjemnie się ją czyta, a rysunki są przejrzyste i dobrze wykonane. Tekst składa się z następujących części: streszczenie, podziękowania, spis rysunków i tabel oraz 6 rozdziałów: rozdział 1 - wprowadzenie do kosmologii, astrofizyki galaktyk i soczewkowania grawitacyjnego, które służy również jako motywacja do późniejszych rozdziałów; rozdział 2 - wprowadzenie do metod uczenia maszynowego, w szczególności transformatorów i metryk oceny jakości wytrenowania modeli; rozdział 3 - metody oparte o CNN i transformatory do znajdowania SGL w symulowanych danych (Bologna Strong Gravitational Lens Finding Challenge), opublikowane jako Thuruthipilly, H., Zadrozny, A., Pollo, A. i Biesiada, M. 2022, A&A, 664, A4; rozdział 4 - CNN i metody oparte o transformatory do znajdowania LSBG i UDG w katalogach Dark Energy Survey (DES) i Hyper Suprime Cam (HSC), opublikowanych jako Thuruthipilly, H., Junais, Pollo, A., et al. 2024b, A&A, 682, A4; rozdział 5 - znajdowanie LSBG i UDG w gromadzie Abell 194 przy użyciu uczenia transferowego i metod opracowanych w rozdziale 4. Rozdział 6 zawiera podsumowanie: wnioski i perspektywy na przyszłość. Rozprawę uzupełnia bibliografia zawierająca 389 pozycji.

Dwa rozdziały wprowadzające zajmują mniej więcej jedną trzecią całkowitej długości tekstu głównego (132 strony), pozostawiając około 90 stron na główne wyniki i wnioski. Każdy rozdział oparty na publikacjach zawiera nieco zbędny wstęp, co jest nieuniknione w przypadku rozprawy doktorskiej opartej na publikacjach. Ten sam komentarz dotyczy rozdziału 5, powtarzającego informacje już zawarte w rozdziale 4, więc zawiera pewne części tekstu istotne dla przygotowania danych, które są dość podobne. Wprowadzenia w rozdziałach 1 i 2 są dość standardowe, ale zawierają wszystkie informacje niezbędne do zrozumienia późniejszych rozdziałów z oryginalnymi badaniami i motywacją, która stoi za wyborami. Moim zdaniem byłoby korzystne dla ogólnej prezentacji, gdyby techniczne wprowadzenie do ML było nieco bardziej szczegółowe, ponieważ chociaż w całym rozdziale podano wiele odniesień do literatury, nie czyta się go jako całkowicie samodzielnego, ale raczej jako dość krótki, schematyczny wstęp.

Badania w szybko zmieniającej się dziedzinie, takiej jak współczesna kosmologia, często stanowią krok w rozwoju. Chciałbym pochwalić udane zastosowanie opracowanych metod na rzeczywistych danych, w szczególności identyfikację i analizę następczą nowych kandydatów SGL, LSBG i UDG, co jest najlepszym dowodem na użyteczność wdrożonych metod.

Podczas czytania rozprawy znalazłem kilka kwestii, które chciałbym omówić lub wyjaśnić bardziej szczegółowo:

- Rozdział 2.2.2: "Generally, the validation loss will be less than or similar to the training loss at each epoch" wymaga więcej wyjaśnień,

- Równanie 2.5 i równania 2.7-2.8 wymagają więcej wyjaśnień, aby były bardziej przydatne jako wprowadzenie,
- Rozdział 2.5.3: stwierdzeniu “transformers are permutation invariant” należy się dodatkowe wyjaśnienie, głównie dlatego, że jest to interesująca cecha tego narzędzia,
- Rozdział 2.6: “One fact that should be considered when applying transfer learning from one survey to another is the difference in the instruments used in these surveys” - czy oznacza to, że dane muszą być odpowiednio znormalizowane, czy też zwykle nie jest to wystarczające?
- Rysunek 3.2: czy to dobry przykład typowego obrazu, tj. czy większość przypadków jest idealnie lub prawie idealnie symetryczna?
- Jak wybrano najlepsze modele w Tabeli 3.1? Czy dany model architektury został wytrenowany raz, czy kilka razy, a następnie wybrano najlepiej działającą instancję? Innymi słowy, jak niezawodna (stabilna w klasyfikacji) jest dana wytrenowana instancja modelu w porównaniu z inną instancją o tej samej architekturze, ale wytrenowaną na (nieco) innych danych treningowych,
  - Powiązane pytanie: jaki był czas szkolenia, całkowity rozmiar danych szkoleniowych i urządzenia (hardware), na którym trenowano modele?
- Rozdział 3: Czy porównanie modeli o różnych rozmiarach jest „uczciwe”, np. między modelami Lens Detector 15 a Lens Detector 16, który jest dwa razy większy od Lens Detector 15? Innymi słowy, czy należy wprowadzić dodatkowe metryki związane z rozmiarem modelu?
- Rozdział 3: bardziej szczegółowy opis (tabela?) wartości przestrzeni hiper-parametrów branych pod uwagę przy znajdowaniu najlepszych modeli byłby przydatny; nie jest jasne, czy te informacje można uzyskać z repozytorium github,
- Pytanie z ciekawości: jaka jest różnica między „false positives” na rys. 3.14 a „false negatives” na rys. 3.15? Dla niewprawnego oka wyglądają one dość podobnie. Innymi słowy: jak dobrze zdefiniowane jest to, czego szukamy?
- Rozdział 4.3.3: wspomniano, że “hyperparameters for the all the LSBG DETR models were customized based on the results from Thuruthipilly et al. (2022), which extensively investigated the hyperparameter configurations of DETR models”, ale szczegóły tych konfiguracji nie są jasno podane w rozdziale 4,
- Rozdział 4.5.1: czy rozważano dodatkowe wstępne przetwarzanie danych w celu poprawy wydajności klasyfikacji? To pytanie jest związane z komentarzami na stronie 75 dotyczącymi wykrywalności niektórych cech.

Drobne uwagi (poprawki redakcyjne, błędy drukarskie itp.):

- W całym tekście tytuły rozdziałów są drukowane w taki sposób, że czasami zakrywają numery stron,
- Rozdział 1: niektóre nazwiska są wprowadzane jako Imię Nazwisko (np. Alexander Friedmann), inne jako tylko Nazwisko (np. Zwicky),
- Rozdział 1.1.3: “turned a new leaf” → “turned over a new leaf”,

- Rozdział 1.1.3: "Following the decoupling of baryons from radiation, they rapidly fall into these dark matter potential wells. Thereby starting the formation (...)" - przecinek zamiast kropki,
- Przecinek zamiast kropki po równaniu 1.3,
- Rozdział 1.2.3:  $\Lambda_{\text{emitted}} \rightarrow \lambda_{\text{emitted}}$ ,
- Rozdział 1.2.3 i później: Symbole pasm (filtry g, r, i, itd.) są wspomniane, ale nie jest wytłumaczone, jakich długości fal dotyczą,
- Rozdział 1.3, w części dotyczącej brakujących barionów: "It is speculated that some fraction of the missing baryons must be reading in the very faint galaxies (...)" - powinno być "residing in"?
- Rozdział 1.4.2, in części dotyczących UDG: podwójna kropka po Kadowaki et al. 2021; Hyper Supriem Cam  $\rightarrow$  Hyper Suprime Cam
- Rozdział 2.2.1: operator "." w  $f(x) = \theta(\vec{w} \cdot \vec{x} + b)$  nie jest opisany,
- W rozdziale 3.1, wspomniano, że ta implementacja jest pierwszym zastosowaniem modeli opartych na transformatorach w astrofizyce, co moim zdaniem nie jest prawdą (np. arXiv:2110.01024 "Galaxy Morphological Classification with Efficient Vision Transformer")
- Organizacja rozdziału 3 jest zgodna ze strukturą publikacji, ale na końcu rozdziału 3.1 numery rozdziałów nie są zgodne z tekstem pracy doktorskiej, ale z oryginalnym artykułem,
- Rozdział 5: SourceExtractor i Sextractor to nazwy tego samego narzędzia, jak przypuszczam, ale Sextractor pojawia się bez ostrzeżenia tylko w tym rozdziale,
- Strona 125: S'ersic  $\rightarrow$  Sérsic.

Powyższe komentarze i pytania nie mają zauważalnego wpływu na moją ogólną pozytywną ocenę rozprawy. Ponieważ rozprawa doktorska pana Thuruthipilly'ego spełnia wymagania dotyczące rozpraw doktorskich określone przez prawo i zwyczaj, a ja jestem przekonany, że kandydat kwalifikuje się do uzyskania stopnia doktora, wnoszę o dopuszczenie pracy do publicznej obrony.

Z poważaniem,

 Michał Bejger