

Streszczenie

Identification and characterization of strong gravitational lenses and low surface brightness galaxies using deep learning

Hareesh THURUTHIPILLY

Pomimo sukcesu modelu Λ CDM w ciągu ostatnich dwóch dekad, model ten napotkał kilka nierozwiązanych napięć z obserwacjami. Obejmują one naturę ciemnej energii i ciemnej materii, problem brakujących barionów oraz niezgodności w skali galaktyk, zwane łącznie problemami małych skal. Aby rozwiązać te napięcia, musimy przetestować przewidywania modelu Λ CDM na układach galaktyk, co może stanowić wyzwanie i udoskonalić nasze rozumienie Wszechświata. Silne soczewki grawitacyjne (SGL) i galaktyki o niskiej jasności powierzchniowej (LSBG) to dwa takie źródła, które możemy wykorzystać do rozwiązania napięć w modelu Λ CDM za pomocą obserwacji. SGL to systemy powstające, gdy pole grawitacyjne masywnej galaktyki pierwszego planu zniekształca obraz galaktyki tła lub kwazara, tworząc wiele obrazów, łuków lub pierścieni źródła. LSBG są ogólnie definiowane jako galaktyki, które są bledsze niż nocne niebo, co czyni je trudnymi do wykrycia. Oczekuje się, że przyszłe wielkoskalowe przeglądy, takie jak Legacy Survey of Space and Time (LSST) i Euclid, w nadchodzących latach zidentyfikują około 10^5 SGL i ponad 10^5 LSBG, torując drogę do ery dużych zbiorów danych w astronomii. Jednak identyfikacja tych systemów stanowi wyzwanie ze względu na rzadkość systemów SGL i trudność w odróżnieniu LSBG od artefaktów. W niniejszej rozprawie, zainspirowany sukcesem modeli głębokiego uczenia się w analizie zwyczajnych obrazów, wprowadzam modele transformatorowe do identyfikacji SGL i LSBG z przeglądów na dużą skalę i z powodzeniem wdrażam te modele do tego celu.

Aby porównać wydajność transformatorów z CNN do identyfikacji SGL, skonstruowałem i wytrenowałem 21 modeli transformatorów i pięć CNN do identyfikacji soczewek grawitacyjnych z Bologna Lens Challenge. Do oceny wykorzystałem cztery różne wskaźniki: dokładność klasyfikacji, obszar pod krzywą charakterystyki operacyjnej odbiornika (AUROC) oraz wyniki TPR0 i TPR10 (dwa wskaźniki oceny dla wyzwania bolońskiego). Porównałem wydajność modeli transformatorowych oraz najlepszych modeli z wyzwania bolońskiego i stwierdziłem, że modele transformatorowe wypadły lepiej niż wszystkie modele, które wzięły udział w wyzwaniu, w tym również CNN, które wygrały to wyzwanie. Modele transformatorowe mogą identyfikować kandydatów na SGL z wysokim poziomem ufności i będą w stanie odfiltrować potencjalnych kandydatów z rzeczywistych danych. Przetestowałem modele transformatorowe na kandydatach na SGL znalezionych przez wyszukiwanie SGL w Kilo Degree Survey (KiDS) i pomimo tego, że nie zostały one przeszkolone na danych KiDS, modele transformatorowe były w stanie zidentyfikować 65% kandydatów na SGL.

W mojej kolejnej pracy badam wykorzystanie modeli transformatorowych do oddzielenia LSBG od artefaktów w danych z Dark Energy Survey (DES) Data Release 1. Stworzyłem osiem różnych modeli transformatorowych, które osiągnęły dokładność $\sim 94\%$ i wykorzystałem dwa zespoły tych ośmiu modeli do identyfikacji LSBG z DES. Korzystając z modeli transformatorowych, wyszukałem nowe LSBG z DES, które mogły zostać pominięte w poprzednich wyszukiwaniach i znalazłem 4083 nowe LSBG w gromadach galaktyk,

które nie zostały zgłoszone w poprzednich poszukiwaniach. Następnie zbadano właściwości nowo znalezionych LSBG w gromadach, wraz z analizą całej próbki LSBG w gromadach w DES. Dodając 4083 nowe LSBG w gromadach, zwiększyłem rozmiar próbki znanych LSBG w gromadach w DES o $\sim 17\%$ i zwiększyłem gęstość liczbowa LSBG w gromadach w DES do $5,5 \text{ deg}^{-2}$. Nowa próbka LSBG składa się głównie z niebieskich i zwartych galaktyk. Przeprowadziłem analizę skupień galaktyk LSBG w DES przy użyciu funkcji autokorelacji kątowej dwupunktowej i odkryłem, że galaktyki LSBG grupują się silniej niż ich odpowiedniki o dużej jasności powierzchniowej. Efekt ten jest spowodowany głównie przez czerwone LSBG w gromadach. Powiązałem 1310 LSBG z gromadami galaktyk i zidentyfikowałem wśród nich 317 kandydatów na galaktyki ultra-rozproszone. Analizując właściwości gromad, odkryłem, że te LSBG w gromadach w DES stają się coraz bardziej niebieskie i większe w kierunku krawędzi gromad w porównaniu z LSBG w centrum.

W mojej następnej pracy badałem zakres uczenia transferowego do identyfikacji LSBG. Wyszkoliłem dwa zespoły modeli transformatorów z danymi z DES, które osiągnęły dokładność $\sim 95\%$. Następnie modele te zostały przetestowane na danych gromady Abell 194 uzyskanych z ukierunkowanych obserwacji za pomocą Hyper Suprime-Cam (HSC), które są o dwa rzędy wielkości głębsze niż dane DES. Zidentyfikowałem próbkę 171 galaktyk LSBG, z których 87 jest zupełnie nowych na podstawie danych HSC, a następnie sklasyfikowałem 28 galaktyk LSBG jako galaktyki ultra-rozproszone (UDG). Liczba UDG w gromadzie Abell 194 jest zgodna z obserwacjami w literaturze, zgodnie z którymi liczba UDG skaluje się proporcjonalnie do masy gromady. Analizując właściwości próbki w centrum gromady, stwierdziłem, że gromady LSBG i UDG w pobliżu centrum gromady są jaśniejsze i mają wyższe wartości indeksu Sérsic'a w porównaniu do LSBG w regionach zewnętrznych. Dodatkowo, LSBG w pobliżu centrum gromady mają tendencję do bycia bardziej czerwonymi niż te w zewnętrznych częściach gromady Abell 194, przy czym trend ten jest bardziej wyraźny w kolorach $FUV - NUV$ i $NUV - r$ w porównaniu do koloru $g - r$. Analizując przestrzeń barwno-magnitudową ($NUV - r$ vs M_r) LSBG stwierdzono, że większość LSBG emitujących NUV jest w kolorze niebieskim, a tylko dwie LSBG są w kolorze czerwonym, przy czym obie są masywnymi galaktykami.

Wykazałem, że modele transformatorowe mają potencjał, aby dorównać CNN jako najnowocześniejsze algorytmy w identyfikacji SGL i LSBG. Ponadto wykazałem, że uczenie transferowe z płytkiego przeglądu do głębszego przeglądu przy użyciu modeli transformatorowych może być z powodzeniem osiągnięte. Metodologia, którą opracowałem w ramach tej pracy, może okazać się cenna przy identyfikacji i analizie danych astronomicznych w nadchodzących przeglądach, takich jak LSST i Euclid.