

Д.М. Жексебай* , С.А. Хохлов , Е.Т. Кожагулов 

Казахский национальный университет им. аль-Фараби, Казахстан, г. Алматы
*e-mail: zhexebay92@gmail.com

ПРОГНОЗИРОВАНИЕ ПАРАМЕТРОВ И КЛАССИФИКАЦИЯ МОЛЕКУЛЯРНЫХ ОТТОКОВ С ПОМОЩЬЮ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

В современной астрофизике машинное обучение приобретает все большую популярность благодаря своей невероятно мощной способности делать прогнозы или рассчитывать предположения для больших объемов данных. Мы описываем применение машинного обучения к регрессии параметров молекулярного оттока (масса, импульс, кинетическая энергия и динамическое время) и классификации биполярного оттока с использованием сверточных нейронных сетей. Размер нашей обучающей выборки составляет ~ 125 источников молекулярного оттока для классификации, то есть 80% от общего количества данных, где 67 источников является биполярным оттоком и ~ 75 источников биполярного оттока для регрессии. Полученные результаты показывают, что использование CNN повышает точность классификации изображения до 97%. Модель регрессии позволяет предсказывать параметры молекулярного оттока со средней абсолютной процентной ошибкой 37.7% для обучающих данных и со средней абсолютной ошибкой 88.0 (масса), 1237.7 (импульс), 193.3 (кинетическая энергия) и 3.0 (динамическое время) для тестовых данных. Алгоритм машинного обучения уменьшает время обработки данных для прогнозов и классификации, и эта методология имеет широкую перспективу применения в будущих исследованиях задач астрофизики.

Ключевые слова: радиоастрономия, звездообразование, биполярные оттоки, машинное обучение, сверточные нейронные сети.

D.M. Zhexebay*, S.A. Khokhlov, Y.T. Kozhalgulov

Al-Farabi Kazakh National University, Kazakhstan, Almaty
*e-mail: zhexebay92@gmail.com

Prediction of parameters and classification of molecular outflows using convolutional neural networks

Machine learning is gaining popularity in modern astrophysics for its incredibly powerful ability to make predictions or make assumptions over large amounts of data. We describe the application of machine learning to regression of molecular outflow parameters (mass, momentum, kinetic energy, and dynamic time) and classification of bipolar outflow using convolutional neural networks. The size of our training sample is ~ 125 sources of molecular outflow for classification, that is, 80% of the total amount of data, where 67 sources are bipolar outflow and ~ 75 sources of bipolar outflow for regression. The results show that the use of CNN improves the image classification accuracy up to 97%. The regression model predicts molecular outflow parameters with an average absolute percentage error of 37.7% for the training data and with an average absolute error of 88.0 (mass), 1237.7 (momentum), 193.3 (kinetic energy), and 3.0 (dynamic time) for test data. The machine learning algorithm reduces data processing time for predictions and classification, and this methodology has a broad prospect for future studies of astrophysics problems.

Key words: radio astronomy, star formation, bipolar outflows, machine learning, convolutional neural networks.

Д.М. Жексебай*, С.А. Хохлов, Е.Т. Кожағұлов

Әл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан, Алматы қ.
*e-mail: zhexebay92@gmail.com

Үйірткілі нейрондық желілерді қолданып молекулалық сырт ағындардың параметрлерін болжау және жіктеу

Заманауи астрофизикада машиналық оқыту үлкен көлемдегі мәліметтер үшін болжам жасауда немесе жорамалдарды есептеуде керемет қуаттылығының арқасында танымалдығы артып келеді. Біз машиналық оқытуды молекулалық сырт ағын параметрлеріне (масса, импульс, кинетикалық

энергия және динамикалық уақыт) болжам жасауда және үйірткілі нейрондық желілерді қолдана отырып, биполярлы сырт ағындардың жіктелуіне қолдануды сипаттаймыз. Біздің оқу үлгісінің мөлшері – жіктеу үшін ~ 125 молекулалық сырт ағын дереккөзін құрайды, яғни мәліметтердің жалпы көлемінің 80% құрайды, мұндағы 67 дереккөздер биполярлық ағындар болып табылады және ~ 75 биполярлық ағын дереккөзі регрессия үшін қолданылды. Нәтижелер көрсеткендей, CNN-ді пайдалану кескінді жіктеу дәлдігін 97% дейін жақсартады. Регрессия моделі жаттығу деректері үшін орташа абсолюттік пайыздық қателігі 37,7% құрады және абсолюттік қателігі 88,0 (масса үшін), 1237,7 (импульс үшін), 193,3 (кинетикалық энергия үшін) және 3,0 (динамикалық оқыту үшін) шамасында молекулалық сырт ағынның параметрлерін болжай алады. Машиналық оқыту алгоритмі болжау мен жіктеу үшін мәліметтерді өңдеу уақытын қысқартады және бұл әдістеме болашақ астрофизика мәселелерін зерттеу үшін үлкен үміт береді.

Түйін сөздер: радиоастрономия, жұлдыздардың пайда болуы, биполярлық сырт ағындар, машиналық оқыту, үйірткілі нейрондық желілер.

Введение

Применение методов машинного обучения (ML) для анализа наборов астрофизических данных стало чрезвычайно популярным, особенно по мере того, как вычислительные мощности и сложные алгоритмы становятся более мощными и доступными. Крупные наблюдательные обзоры предоставили массивные наборы данных для разработки инструментов машинного обучения для решения прикладных задач астрофизики, что сделало машинное обучение еще более привлекательным [1]. Методы машинного обучения были применены для классификации звезд/галактик и определения физических параметров [2-11]. Еще одним успехом ML в астрофизике стало использование архитектуры глубокой нейронной сети для анализа звездных спектров [12]. В работе [12] показали, что параметры звезд (температура, сила тяжести и металличность) из всей спектральной базы данных SDSS-III APOGEE могут быть определены с такой же точностью и точностью, что и конвейер APOGEE, всего за несколько секунд с помощью машинного обучения. А также, машинное обучение позволяет быстро и точно определять особенности молекулярного оттока. Несколько алгоритмов машинного обучения были использованы для определения характеристик молекулярных оттоков [13-19]. Метод опорных векторов (SVM) использовались, чтобы отличить остаток сверхновой звезды от окружающего газа [13] и идентифицировать молекулярные оттоки в комплексе темных облаков [18]. В работе [18] приняли SVM для определения характеристик оттока в выбросах ^{12}CO и ^{13}CO в Cygnus. SVM хорошо справляется с задачами классификации, но для создания обучающего набора требуется ручное извлечение признаков. Алгоритмы Random Forest, которые классифицируют векторы признаков, изучая серию пра-

вил принятия решений, надежно работают при обнаружении звездных пузырей в выбросе пыли [14,19]. Подобно SVM, Random Forest требуют ручного извлечения функций в качестве входных данных. Сверточные нейронные сети (CNN) – это новый мощный подход машинного обучения, применяемый для идентификации структур или объектов. CNN не чувствительны к положению объектов в данных, поэтому их несложно применить к крупным обзорам. Что наиболее важно, CNN не требует ручного извлечения признаков в качестве входных данных. Вместо этого CNN автоматически извлекает признаки из данных, применяя различные фильтры на разных уровнях во время обучения [20-25]. Алгоритмы, основанные на CNN, были разработаны и успешно применены для идентификации пузырей (область разреженного горячего газа неправильной формы в межзвездной среде) [15-16], а также для идентификации и прогнозирования физических параметров протозвездных оттоков [17].

Модель сверточной нейронной сети

Нейронные сети имеют множество параметров. Эти параметры определяют саму сеть (например, размер и нелинейность каждого уровня) и определяют обучение сети (например, размер мини-пакета или скорость обучения). Кроме того, архитектура нейронной сети может существенно повлиять на ее производительность. В этом разделе мы даем краткое описание ключевых параметров и архитектуру нашей модели.

Общая архитектура рассмотренной модели для классификации изображения показана на рисунке 1. Сеть состоит из 5 обучаемых слоев, где 3 из них сверточные слои и 2 полностью связанные слои. Первый сверточный слой фильтрует входное изображение $150 \times 150 \times 3$ с 32 фильтрами размером 5×5 . Во всех слоях, кро-

ме выходного слоя, была применена функция активации ReLU. Максимальное объединение с фильтрами размера 2×2 следует за сверточным слоем. Второй и третий сверточный слой имеет 64 и 128 фильтров с размером 3×3 и 2×2 соответственно. Первый полностью связанный слой имеет 256 каналов, а второй выпол-

няет двоичную классификацию. Выходные значения последнего полностью связанного слоя обрабатывается через функцию softmax. Для обучения наших моделей мы используем алгоритм RMSprop со скоростью обучения 0.0004 и мини-пакетный градиентный спуск с размером пакета 16.




Рисунок 1 – Архитектура сверточной нейронной сети для классификации данных

Архитектура нашей модели для регрессии показана на рисунке 2. Размеры слоев, количества фильтров и функции активации сверточных слоев соответствует выше упомянутой модели классификации, но отличается количеством нейронов и функцией активаций вы-

ходного слоя, а также отличается алгоритмом обучения. На выход последнего полностью связанного слоя подается линейная функция. Модель для прогнозирования параметров обучен с помощью алгоритма Adam со скоростью обучения 0.001.





Рисунок 2 – Архитектура сверточной нейронной сети для прогнозирования данных

Для реализации нашей модели мы используем программный пакет Python и библиотеку Keras работающий поверх платформы машинного обучения TensorFlow. Библиотека TensorFlow упрощает использование графического процессора для вычислений, а использование графиче-


ского процессора позволяет примерно на порядок более быстрое обучение, чем использование только центрального процессора.

Набор данных для классификации составляет 157 источников, которые 84 является биполярными оттоками. Данные были взяты из работы

[26]. Первая модель классификации имеет 110 источников для обучения и 47 источников для тестирования, то есть процентная соотношения выборок 70/30 процентов от общего количества данных. Вторая модель классификации имеет процентное соотношение 80/20 для обучающих и тестовых данных. На рисунке 3 показана зависимость точности и потери модели нейронной сети от эпохи обучения двух модели классификации для тестовых данных. Результаты показывают высокую точность второй модели, а также минимальную потерю модели нейронной сети, чем первая модель.



(a)




(б)


Рисунок 3 – Зависимость точности и потери модели нейронной сети от эпохи обучения для тестовых данных при соотношении обучающих и тестовых данных 70/30 (а) и 80/20 (б)

Набор данных для прогнозирования параметров составляет 84 источников. Обучающая выборка – 75, тестовая 9. В качестве метрики мы использовали MAE (Средняя абсолютная ошибка) и MAPE (Средняя абсолютная процентная ошибка) для решения проблем регрессии. Поэтому по были созданы две модели прогнозирования. Зависимость потери двух моделей от эпохи обучения приведена на рисунке 4. Результаты об-

учения показывают, что обучающие данные второй модели точнее прогнозирует, чем тестовые данные.



(a)



(б)

Рисунок 4 – Зависимость потери двух модели (1-модель (а), 2-модель (б)) нейронной сети от эпохи обучения для обучающих (синяя линия) и тестовых данных (красная линия) при выборе метрики качества обучения MAE (а) и MAPE (б)

Результаты и обсуждения

В этом разделе мы сначала описываем показатели производительности, которые использовались для оценки моделей. Затем мы представляем эффективность классификации и прогнозирования нашей модели.

Точность модели определяется по следующей формуле:

$$ACC = \frac{TP + TN}{P + N} \quad (1)$$

где, TP – количества истинных биполярных оттоков, классифицированных как биполярные оттоки (истинно положительный результат), TN – истинно отрицательный результат, P – общее количество биполярных оттоков, N – общее ко-

личество оттоков, которые не являются биполярным оттоком.


Точность модели классификации приведена в таблице 1 для разных количеств обучающего набора данных. Результаты показывают то, что чем больше обучающих данных, тем более высокая точность. Модель классификации имеет 100 процентную точность для двух моделей, однако вторая модель имеет точность $\sim 97\%$ при соотношении обучающих и тестовых данных 80/20 для тестовых данных.

Таблица 1 – Результат тестирования для разных наборов данных


№	Количества обучающих и тестовых данных	Точность обучающих и тестовых данных (%)
1	110 и 47	100 и 85.1
2	125 и 32	100 и 96.9

Мы используем тестовые данные, чтобы оценить, насколько точно можно определить физические свойства по биполярным оттокам. Мы применяем обе модели регрессии к тестовой выборке. На рисунке 5 показаны физические параметры оттока (масса, импульс, кинетическая энергия и динамическое время), оцененная для двух моделей, model 1 и model 2. Мы также наносим на график истинную массу, импульса, энергию и динамической времени оттока, которые были взяты из работы [26]. Мы обнаружили, что model 2 переоценивает массу молекулярного оттока в 2,7 или более раз, в то время как model 1 правильно предсказывает массу молекулярного оттока с разбросом в два раза (Рисунок 5, а). На рисунке 5 (б) показано, что импульс, предсказанный моделью 2, в 1,87 раза выше, чем импульс, предсказанный моделью 1. Результаты показывают эффективность модели прогнозирования model 1, где результаты сопоставимы с результатами работы [16-17].


Оценка ошибки прогнозирования приведены в таблицах 2 и 3. В таблице 2 показано значение средней абсолютной ошибки первой модели регрессии и средней абсолютной процентной ошибки второй модели. По этим данным трудно сказать эффективности модели, но по результатам тестирования можно определить эффективность моделей (Рисунок 5). Результаты эффективной модели прогнозирования физических параметров молекулярного оттока показаны в таблице 3.




(а)



(б)



(в)



(г)

Рисунок 5 – Зависимость параметров оттока (масса (а), импульс (б), кинетическая энергия (в) и динамическое время (г)) от прогнозируемых характеристик двух модели для обучающих (○, □) и тестовых (●, ■) данных.

Таблица 2 – Результаты моделей прогнозирования данных

№ модели	MAE для обучающих и тестовых данных	MAPE для обучающих и тестовых данных
1	0.0246 и 0.0831	-
2	-	34.6571 и 909.7830

Таблица 3 – Результаты прогнозирования первой модели обучающих и тестовых данных

	масса	импульс	кинетическая энергия	динамическое время
MAE	16.8 / 88.0	190.6 / 1237.7	25.8 / 193.3	0.7 / 3.0
MAPE	45.9 % / 198.1 %	44.5 % / 271.4 %	44.3 % / 370.5 %	16.0 % / 58.4 %

Выводы

Мы применяем метод глубокого обучения для определения параметров молекулярных оттоков и классификации биполярных оттоков. Создавая разные обучающие выборки, мы разрабатываем две модели глубокого машинного обучения. Модель классификации может определить биполярные оттоки. Модель прогнозирования предсказывает долю массы, импульса, энергии и динамическое время связанную с оттоком. Наши основные выводы заключаются в следующем:

1. Мы применяем модель классификации и успешно идентифицируем ранее визуально

идентифицируемых биполярных оттоков с точностью 97%.

2. Модель регрессии успешно предсказывает физические параметры, например, долю массы, импульса, энергии и времени, полученные результате оттока.

3. Масса оттока, предсказанная моделью 1, сравнима с массой оттока, рассчитанной [26].

Импульс $1179.71 M_{\odot} km s^{-1}$, и кинетическая энергия $124.052 \times 10^{45} erg$ от оттока в источнике G010.284-00.114 того же порядка, что и расчеты в работе [26], которые составляют $945.2 M_{\odot} km s^{-1}$ и $137.24 \times 10^{45} erg$ соответственно.

Литература

- 1 Venn K., Fabbro S., Liu A., Hezaveh Y., Levasseur L., Eadie G., Ellison S., Woo J., Kavelaars J., Moo Yi K., Hlozek R., Bovy J., Teimoorinia H., Ravanbakhsh S., Spencer L. Machine Learning Advantages in Canadian Astrophysics //CLRP. – 2019. – Vol. 2020. – P. 5.
- 2 Bai Y., Liu J., Wang S., Yang F. Machine Learning Applied to Star–Galaxy–QSO Classification and Stellar Effective Temperature Regression //The Astronomical Journal. – 2018. – Vol. 157. – P. 9.
- 3 Martin G., Kaviraj S., Hocking A., Read S.C., Geach J.E. Galaxy morphological classification in deep-wide surveys via unsupervised machine learning //Monthly Notices of the Royal Astronomical Society. – 2020. – Vol. 491. – P. 1408-1426.
- 4 Bai Y., Liu J.F., Wang S. Machine learning classification of gaia data release 2 //Research in Astronomy and Astrophysics. – 2018. – Vol. 18. – P. 118.
- 5 Ghosh A., Urry C.M., Wang Z., Schawinski K., Turp D., Powell M.C. Galaxy Morphology Network: A Convolutional Neural Network Used to Study Morphology and Quenching in \square 100,000 SDSS and \square 20,000 CANDELS Galaxies //The Astrophysical Journal. – 2020. – Vol. 895. – P. 112.
- 6 Kim E.J., Brunner R.J. Star-galaxy classification using deep convolutional neural networks //Monthly Notices of the Royal Astronomical Society. – 2017. – Vol. 464. – P. 4463-4475.
- 7 Akras S., Leal-Ferreira M.L., Guzman-Ramirez L., Ramos-Larios G. A machine learning approach for identification and classification of symbiotic stars using 2MASS and WISE //Monthly Notices of the Royal Astronomical Society. – 2019. – Vol. 483. – P. 5077-5104.
- 8 Sharma K., Kembhavi A., Kembhavi A., Sivarani T., Abraham S., Vaghmare K. Application of convolutional neural networks for stellar spectral classification //Monthly Notices of the Royal Astronomical Society. – 2020. – Vol. 491. – P. 2280-2300.
- 9 Lukic V., Brüggem M., Mingo B., Croston J.H., Kasieczka G., Best P.N. Morphological classification of radio galaxies: capsule networks versus convolutional neural networks //Monthly Notices of the Royal Astronomical Society. – 2019. – Vol. 487. – P. 1729-1744.

- 10 Zhu X.P., Dai J.M., Bian C.J., Chen Y., Chen S., Hu C. Galaxy morphology classification with deep convolutional neural networks // *Astrophysics and Space Science*. – 2019. – Vol. 364. – P. 55.
- 11 Liu W., Zhu M., Dai C., He D.Y., Yao J., Tian H.F., Wang B.Y., Wu K., Zhan Y., Chen B.Q., Luo A.L., Wang R., Cao Y., Yu X.C. Classification of large-scale stellar spectra based on deep convolutional neural network // *Monthly Notices of the Royal Astronomical Society*. – 2019. – Vol. 483. – P. 4774-4783.
- 12 Fabbro S., Venn K.A., O’Brian T., Bialek S., Kielty C.L., Jahandar F., Monty S. An application of deep learning in the analysis of stellar spectra // *Monthly Notices of the Royal Astronomical Society*. – 2018. – Vol. 475. – P. 2978-2993.
- 13 Beaumont C.N., Williams J.P., Goodman A.A. Classifying Structures in the Interstellar Medium with Support Vector Machines: The G16. 05-0.57 Supernova Remnant // *The Astrophysical Journal*. – 2011. – Vol. 741. – P. 14.
- 14 Beaumont C.N., Goodman A.A., Kendrew S., Williams J.P., Simpson R. The Milky Way Project: leveraging citizen science and machine learning to detect interstellar bubbles // *The Astrophysical Journal Supplement Series*. – 2014. – Vol. 214. – P. 3.
- 15 Van Oort C.M., Xu D., Offner S.S., Gutermuth R.A. Casi: A convolutional neural network approach for shell identification // *The Astrophysical Journal*. – 2019. – Vol. 880. – P. 83.
- 16 Xu D., Offner S.S., Gutermuth R., Van Oort C. Application of Convolutional Neural Networks to Identify Stellar Feedback Bubbles in CO Emission // *The Astrophysical Journal*. – 2020. – Vol. 890. – P. 64.
- 17 Xu D., Offner S.S., Gutermuth R., Van Oort C. Application of Convolutional Neural Networks to Identify Protostellar Outflows in CO Emission // *arXiv preprint arXiv:2010.12525*. – 2020.
- 18 Zhang S., Yang J., Xu Y., Chen X., Su Y., Sun Y., Zhou X., Li Y., Lu D. Searching for Molecular Outflows with Support Vector Machines: The Dark Cloud Complex in Cygnus // *The Astrophysical Journal Supplement Series*. – 2020. – Vol. 248. – P. 15.
- 19 Xu D., Offner S.S.R. Assessing the performance of a machine learning algorithm in identifying bubbles in dust emission // *The Astrophysical Journal*. – 2017. – Vol. 851. – P. 149.
- 20 Krizhevsky A., Sutskever I., Hinton G.E. Imagenet classification with deep convolutional neural networks // *Communications of the ACM*. – 2017. – Vol. 60. – P. 84-90.
- 21 Girshick R. Fast r-cnn // *Proceedings of the IEEE international conference on computer vision*. – 2015. – P. 1440-1448.
- 22 Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks // *IEEE transactions on pattern analysis and machine intelligence*. – 2017. – Vol. 39. – P. 1137.
- 23 Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection // *Proceedings of the IEEE conference on computer vision and pattern recognition*. – 2016. – P. 779-788.
- 24 Zhao L., Li S. Object Detection Algorithm Based on Improved YOLOv3 // *Electronics*. – 2020. – Vol. 9. – P. 537.
- 25 Yao G., Lei T., Zhong J. A review of Convolutional-Neural-Network-based action recognition // *Pattern Recognition Letters*. – 2019. – Vol. 118. – P. 14-22.
- 26 Li Q., Zhou J., Esimbek J., He Y., Baan W.A., Li D., Wu G., Tang X., Ji W., Zhexebay D. High-mass Outflows Identified from COHRS CO (3–2) Survey // *The Astrophysical Journal*. – 2018. – Vol. 867. – P. 167.

References

- 1 K. Venn, S. Fabbro, A. Liu et al, CLRP, 2020, 5 (2019).
- 2 Y. Bai, J. Liu, S. Wang, and F. Yang, *The Astronomical Journal*, 157, 9 (2018).
- 3 G. Martin, S. Kaviraj, A. Hocking, S.C. Read, and J.E. Geach, *Monthly Notices of the Royal Astronomical Society*, 491, 1408-1426 (2020).
- 4 Y. Bai, J.F. Liu, and S. Wang, *Research in Astronomy and Astrophysics*, 18, 118 (2018).
- 5 A. Ghosh, C.M. Urry, Z. Wang, K. Schawinski, D. Turp, and M.C. Powell, *The Astrophysical Journal*, 895, 112 (2020).
- 6 E.J. Kim, and R.J. Brunner, *Monthly Notices of the Royal Astronomical Society*, 464, 4463-4475 (2017).
- 7 S. Akras, M.L. Leal-Ferreira, L. Guzman-Ramirez, and G. Ramos-Larios, *Monthly Notices of the Royal Astronomical Society*, 483, 5077-5104 (2019).
- 8 K. Sharma, A. Kembhavi, A. Kembhavi, T. Sivarani, S. Abraham, and K. Vaghmare *Monthly Notices of the Royal Astronomical Society*, 491, 2280-2300 (2020).
- 9 V. Lukic, M. Brüggen, B. Mingo, J.H. Croston, G. Kasieczka, and P.N. Best, *Monthly Notices of the Royal Astronomical Society*, 487, 1729-1744 (2019).
- 10 X.P. Zhu, J.M. Dai, C.J. Bian, Y. Chen, S. Chen, and C. Hu, *Astrophysics and Space Science*, 364, 55 (2019).
- 11 W. Liu, M. Zhu, C. Dai, D.Y. He, J. Yao, H.F. Tian, B.Y. Wang, K. Wu, Y. Zhan, B.Q. Chen, A.L. Luo, R. Wang, Y. Cao, and X.C. Yu, *Monthly Notices of the Royal Astronomical Society*, 483, 4774-4783 (2019).
- 12 S. Fabbro, K.A. Venn, T. O’Brian, S. Bialek, C.L. Kielty, F. Jahandar, S. Monty, *Monthly Notices of the Royal Astronomical Society*, 475, 2978-2993 (2018).
- 13 C.N. Beaumont, J.P. Williams, and A.A. Goodman, *The Astrophysical Journal*, 741, 14 (2011).

- 14 C.N. Beaumont, A.A. Goodman, S. Kendrew, J.P. Williams, and R. Simpson, *The Astrophysical Journal Supplement Series*, 214, 3 (2014).
- 15 C.M. Van Oort, D. Xu, S.S. Offner, and R.A. Gutermuth, *The Astrophysical Journal*. 880, 83 (2019).
- 16 D. Xu, S.S. Offner, and R.A. Gutermuth, and C. Van Oort, *The Astrophysical Journal*. 890, 64 (2020).
- 17 D. Xu, S.S. Offner, and R.A. Gutermuth, and C. Van Oort, arXiv preprint arXiv:2010.12525, (2020).
- 18 S. Zhang, J. Yang, Y. Xu, X. Chen, Y. Su, Y. Sun, X. Zhou, Y. Li, and D. Lu, *The Astrophysical Journal Supplement Series*, 248, 15 (2020).
- 19 D. Xu, and S.S.R. Offner, *The Astrophysical Journal*, 851,149 (2017).
- 20 A. Krizhevsky, I. Sutskever, G.E. Hinton, *Communications of the ACM*, 60, 84-90 (2017).
- 21 R. Girshick, *Proceedings of the IEEE international conference on computer vision (Santiago, 7-15 December, 2015)*, p.1440-1448.
- 22 S. Ren, K. He, R. Girshick, and J. Sun, *IEEE transactions on pattern analysis and machine intelligence*, 39, 1137 (2017).
- 23 J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, *Proceedings of the IEEE conference on computer vision and pattern recognition (Las Vegas, 27-30 June, 2016)*, p.779-788.
- 24 L. Zhao, and S.Li, *Electronics*. 9, 537 (2020).
- 25 G. Yao, T. Lei, and J. Zhong, *Pattern Recognition Letters*, 118, 14-22 (2019).
- 26 Q. Li, J. Zhou, J. Esimbek, Y. He, W.A. Baan, D. Li, G. Wu, X. Tang, W. Ji, D. Zhexebay, *The Astrophysical Journal*. 867, 167 (2018).