

Создание синтетического метода распознавания планетарных объектов на основе нейронных сетей

© А.О. Андреев,¹ Ю.А. Нефедьев,² Ю.А. Колосов²

¹Казанский государственный энергетический университет,
420066 Казань, Россия

²Казанский (Приволжский) федеральный университет,
420008 Казань, Россия

E-mail: andreev.alexey93@gmail.com, star1955@mail.ru

Поступило в Редакцию 4 мая 2025 г.

В окончательной редакции 16 июля 2025 г.

Принято к публикации 17 июля 2025 г.

Рассмотрено создание синтетического метода распознавания планетарных объектов на основе объединения двух архитектур Mask R-CNN и (CNN) UNET. Созданный метод верифицирован на лунных кратерах различных категорий, выбранных на снимках современных спутниковых миссий. Распознавание объектов происходит с использованием таких критериев, как соотношение стратиграфических характеристик, морфологических особенностей и оптической структуры.

Ключевые слова: нейронные сети, планетофизические параметры, синтетический метод.

DOI: 10.61011/JTF.2025.12.61785.229-25

Введение

В современных научных работах по исследованию сложных систем, к которым относятся и поверхности небесных тел, активно применяются методы машинного обучения и нейросети (НС) [1]. В настоящей работе проведено создание синтетического метода для обнаружения и исследования объектов на поверхности планет и их спутников. Суть синтетического метода состоит в объединении двух архитектур Mask R-CNN и (CNN) UNET. Синтетический метод позволяет как расширить существующий список исследуемых объектов, так и произвести их категорирование согласно заданным морфологическим и планетофизическим параметрам.

1. Методы исследования

В работах [2,3] машинное обучение строится с использованием сверточной нейронной сети (CNN) UNET. Данный подход продемонстрировал высокую эффективность при идентификации большого количества кратеров. Вместе с тем архитектура (Mask R-CNN) позволяет осуществлять интеллектуальную индикацию объектов с выборкой морфологических признаков. Существуют некоторые различия между вышеописанными методиками:

1) UNET основан на обучении системы на больших объемах данных, где признаки определяются и оптимизируются самостоятельно. В Mask R-CNN производится ввод морфологических параметров экспертами, но при этом объем обучающего материала может быть оптимизирован под конкретную задачу.

2) UNET автоматически адаптируется к разноплановым категориям данных. Например, UNET может быть

применен для других планет, позволяет обнаруживать кратеры разного масштаба, включая объекты со сложной формой, которые не соответствуют классическим морфологическим критериям (например, деградировавшие вследствие эрозии кратеры или кратеры с нарушенной структурой). Mask R-CNN оперирует заранее обозначенными критериями и не выходит за их рамки.

3) Архитектура UNET способна масштабироваться для анализа больших объемов данных, обрабатывать изображения больших размеров и находить новые объекты в течение одной итерации. Архитектура Mask R-CNN обрабатывает каждый объект по отдельности, поэтому осуществляет выборку медленнее.

4) Система UNET автоматически определяет морфологию кратера, учитывая при этом мелкие детали. Mask R-CNN более ориентирована на соответствие заранее заданным морфологическим признакам.

Учитывая все вышесказанное, можно сделать вывод, что архитектура UNET позволяет увеличить анализируемую систему за счет включения новых объектов, в то время как Mask R-CNN может производить выборку тех объектов из всего множества, которые удовлетворяют определенным характеристикам. При этом система UNET формирует идентификационные признаки самостоятельно без надлежащего контроля, так как ориентирована именно на поиск новых кратеров, а не на выборку по определенным параметрам из уже существующего набора объектов. Таким образом, синтетический метод позволяет идентифицировать искомые объекты в два этапа. В первом случае используется архитектура UNET, на основе которой идентифицируются и находятся новые объекты, например, кратеры [4]. При выполнении второго этапа происходит выборка из полученного множества тех объектов, конкретно удовлетворяющих заранее введенным экспертом характеристикам.




Рис. 1. ЦМЛ в диапазоне $\pm 60^\circ$ по широте с разрешением ~ 59 м на пиксель и точностью по высоте $\sim 3\text{--}4$ м, построенный по данным LRO (LOLA) и SELENE Kaguya [7].



Рис. 2. Изображение ЦМЛ после инверсии.

2. Результаты

Данный метод был верифицирован на оптических изображениях лунной поверхности, полученных при выполнении миссий „LRO“ и „Kaguya“. В настоящей работе для верификации используются данные, полученные миссиями „Kaguya“ и „LRO“ [5–7]. Следует отметить, что точность получения пространственных координат из данных космической топографической съемки зависит от масштаба и параметров обрабатываемых снимков, а также методов их фотограмметрической обработки. Можно сказать, что точность топографической съемки напрямую зависит от разрешения снимков, что выражается в метрической мере на пиксель. Разработанный в настоящей работе метод решает задачу классификации изображений. Обучение аналитической системы метода выполнялось на обучающей выборке из снимков, полученных спутниковыми миссиями. Метод тестировался на цифровой модели рельефа Луны (ЦМРЛ) в диапазоне $\pm 60^\circ$ по широте с разрешением ~ 59 м на пиксель и точностью по высоте $\sim 3\text{--}4$ м, построенным по данным LRO (LOLA) и SELENE Kaguya [7] (рис. 1). На рис. 2 представлена инверсия оригинала цифрового рельефа модели Луны для выбранной области цифровой модели.

Точность, обеспечиваемая в рамках данного подхода, оценивалась визуально. При обучении модели НС вручную выбирался фрагмент цифровой карты, и в выбранной области выделена наиболее характерная граница кратера (рис. 3, а). На основе такой обучающей модели программная система училась искать идентичные объекты на космических снимках. Обучающий набор включал изображения, полученные LRO (NASA), разделенные на фрагменты сравнительно небольшого размера (125×125 px) в количестве порядка девяти сот штук. Используя оригинальный снимок LRO размером 1800×950 px, НС способна распознать до 200 кратеров менее, чем за 3 min. В среднем обучение модели длится 40 эпох (итераций), продолжительность каждой — 1 h. В течение одной эпохи изображение разделяется на отдельные плитки (batches), которые анализируются с помощью НС. Далее определяется значение функции активации (AF) НС (основанная на градиентном спуске). При прохождении одной эпохи аппроксимируются веса наблюдений. Если эпох мало, то НС становится недообученной, а если много — переобученной. В последнем случае НС начинает выделять при обучении паттерны, которые в действительности отсутствуют. Оптимальное значение эпох включает функцию „отсечки“ (COF —




Рис. 3. Снимки с ручной выборкой кратеров (а), b — с машинной.

Количественные результаты обработки данных НС

Критерий	Значение (диапазон значений) критерия
pCNNR	53 % < pCNNR < 99 %
P	62 % < P < 98 %
F1s	77 %

„cut-off function“). В данном случае строится диаграмма значений AF, и, если величины не совпадают с последней, процедура обучения прекращается. На практике первоначально принимают предварительно сформированную AF и берут случайное количество эпох, а после COF уже берут сформировавшееся значение AF, соответствующее меньшему количеству эпох. На рис. 3, b представлена машинная выборка кратеров на принятом в обработку фрагменте цифровой модели. Расхождение между вариантом с ручной классификацией и машинной оказалось в районе 4рх. Масштаб и координаты объектов не определялись точно на данном этапе, здесь ключевыми аспектами были само изображение и то, как НС будет фиксировать это изображение.

Основные критерии работы НС — Post-CNN Recall (pCNNR), Precision (P), F1-score (F1s) — для используемого набора данных представлены в таблице.

В дальнейшем планируется исследовать объекты, входящие в построенный нами каталог лунных кратеров с точными селеноцентрическими динамическими координатами, зарегистрированный в Роспатенте RU 2019620426 от 18.03.2019.

Заключение

В настоящее время мы использовали оптические изображения по следующим причинам:

1) для оптических снимков создано гораздо больше карт, каталогов кратеров и обучающих выборок;

2) в оптических снимках нет характерного для радарных данных когерентного „зернистого“ шума;

3) для многих миссий оптические камеры имеют лучшее пространственное разрешение по сравнению с радарами;

4) методы компьютерного зрения (CNN, сегментация, классификация) традиционно лучше развиты для RGB-изображений. Но в дальнейших исследованиях существуют планы по дообучению модели на других типах данных (например, радарных снимках).

Следует отметить, что выборка с помощью НС не всегда идеальна, так как существует проблема недообученности модели. Вместе с тем выделяются структуры, которые отсутствуют при выборке, что свидетельствует о понимании НС того, чему ее пытаются научить. Расхождение между ручной и машинной классификацией в среднем визуально можно определить в 2 рх. При этом существует проблема обнаружения небольших кратеров, которые сложно идентифицировать вследствие пикселизации. Если кратер меньше 3 м в радиусе, его будет сложно различить. С целью получения универсальной НС требуется соблюдение ряда условий: следует использовать снимки с оптимальным разрешением; на снимках необходимо проанализировать максимальное количество объектов, а изображения, участвующие в обучении, должны отличаться по контрастности, углам, под которыми производится съемка лунной поверхности, и количеству объектов на изображении. В дальнейшей работе планируется использовать Цифровой селеноцентрический динамический каталог (ЦСДК) оптических наблюдений миссий „Clementine“, „Kaguya“, „LRO“ и „Apollo“ видимой и обратной сторон Луны как находящийся в свободном доступе, так и полученных в процессе выполнения совместных исследований.

Также следует отметить, что в рамках работы исследовалась поверхность Луны, однако разработанный метод в дальнейшем планируется применять на таких небесных телах, как Марс, Церера и Титан, соответствующие работы уже начаты, у авторов имеются топографиче-

ские данные миссий „Mars Global Surveyor“, „Dawn“ и „Cassini“, а также наборы изображений поверхности перечисленных небесных тел.

Финансирование работы

Авторы выражают благодарность за поддержку выполненных работ Российскому научному фонду, грант 24-22-00260.

Конфликт интересов

Авторы заявляют, что у них нет конфликта интересов.

Список литературы

- [1] A. Esteva, B. Kuprel, R.A. Novoa. *Nature*, **542** (7639), 115 (2017). DOI: 10.1038/nature21056
- [2] A. Silburt, M. Ali-Dib, C. Zhu. *Icarus*, **317**, 27 (2019). DOI: 10.1016/j.icarus.2018.06.022
- [3] C.I. Fassett, J.W. Head, S.J. Kadish. *J. Geophys. Research: Planets*, **117**, E12 (2012). DOI: 10.1029/2011JE003951
- [4] J.W. Head, C.I. Fassett, S.J. Kadish, D.E. Smith, M.T. Zuber, G.A. Neumann, E. Mazarico. *Science*, **329** (5998), 1504 (2010). DOI: 10.1126/science.1195050
- [5] F. Scholten, J. Oberst, K.-D. Matz, T. Roatsch, M. Wählisch, E.J. Speyerer, M.S. Robinson. *J. Geophys. Research: Planets*, **117** (2012). DOI: 10.1029/2011JE003926
- [6] Электронный ресурс. Режим доступа: <http://gisstar.gsi.go.jp/selene/index-E.html>
- [7] Электронный ресурс. Режим доступа: https://astrogeology.usgs.gov/search/map/moon_lro_lola_selene_kaguya_tc_dem_merge_60n60s_59m.