Построение модели распределения кратеров, образованных медленными ударниками, с использованием методов создания нейронных сетей

© А.О. Андреев, Ю.А. Колосов, Ю.А. Нефедьев

Казанский (Приволжский) федеральный университет,
420008 Казань, Россия
e-mail: andreev.alexey93@gmail.com, star1955@mail.ru

Поступило в Редакцию 4 мая 2026 г.
В окончательной редакции 25 августа 2026 г.
Принято к публикации 23 октября 2026 г.

Рассмотрено создание методики распознавания планетарных объектов на основе архитектур Mask R-CNN и U-Net. Проверка достоверности предложенного метода осуществлялась с использованием набора лунных кратеров, представляющих различные морфологические типы и отобранных по материалам орбитального дистанционного зондирования. Идентификация объектов осуществляется на основе совокупного анализа стратиграфических характеристик, морфологических признаков и особенностей их оптической структуры.

Ключевые слова: нейронные сети, ударные кратеры, медленные астероиды.

DOI: 10.61011/JTF.2026.12.64045.305-26

Введение

В современных научных работах по исследованию сложных систем, к которым относятся и поверхности небесных тел, в связи с огромным объемом обрабатываемых данных активно применяются методы машинного обучения и нейросети (НС) [1]. Изучение динамических процессов и планетофизических особенностей Луны в настоящее время предполагает использованием современных средств цифрового моделирования. Одним из возможных инструментов является формирование комплексной селенографической модели, предназначенной для воссоздания условий формирования ударных кратеров. Ее использование позволяет исследовать последствия столкновений с поверхностью Луны крупных космических тел, а также выявлять те участки, в которых вследствие подобных процессов могли сформироваться скопления полезных ресурсов. Перспективы освоения космического пространства тесно связаны с поиском альтернативных источников полезных ресурсов. В этой связи ведутся исследования и разрабатываются проекты, направленные на добычу и практическое использование вещества астероидов, сближающихся с Землей. Альтернативный подход, рассмотренный в работе [2], состоит в использовании астероидного вещества, сохранившегося в пределах лунной поверхности. Авторы отмечают, что такой вариант способен снизить технологическую сложность работ и при этом повысить их экономическую целесообразность. С применением современных методов компьютерного моделирования [3] было установлено, что сравнительно низкие скорости столкновения астероидов (менее 12 km/s) способствуют сохранению существенной доли их вещества. В таких сценариях до 40 % массы ударного объекта остается локализованным в приповерхностной зоне в виде раздробленного материала. Результаты долговременных наблюдений, выполненных миссией Lunar Reconnaissance Orbiter (LRO), демонстрируют, что существенная доля современных ударных событий на Луне обусловлена столкновениями с относительно медленно движущимися небесными телами. Так, из более чем 200 кратеров, выявленных за семь лет наблюдений, приблизительно 25 % связаны с падением тел, средняя скорость которых составляла порядка 10 km/s [4,5]. Современный облик поверхности Луны во многом определяется множественными ударными кратерами, возникшими вследствие интенсивных столкновений с космическими телами [6]. Эти структуры относятся к различным этапам геологической эволюции спутника, которые в совокупности охватывают период продолжительностью около четырех миллиардов лет. Эволюция ударных структур Луны отражает основные этапы развития внутренней части Солнечной системы и поэтому представляет значительный научный интерес [7]. Многолетние исследования естественного спутника Земли, проводившиеся в рамках отечественных и зарубежных космических программ, позволили сформировать обширный массив данных. В результате выполнения миссий „Луна“, Apollo, LRO, Kaguya, Smart-1 и ряда других были получены цифровые изображения поверхности, высокоточные модели лунного рельефа, а также образцы лунного вещества, используемые для решения широкого круга научных и прикладных задач. Современные методы обработки вышеупомянутых данных позволили существенно расширить список известных ударных кратеров Луны [8]. Тем не менее оценки их планетофизических характеристик остаются неоднозначными. Это обусловлено влиянием человеческого фактора при визуальной идентификации, а также ограниченной эффективностью автоматизированных методов при работе с разнородными источни-

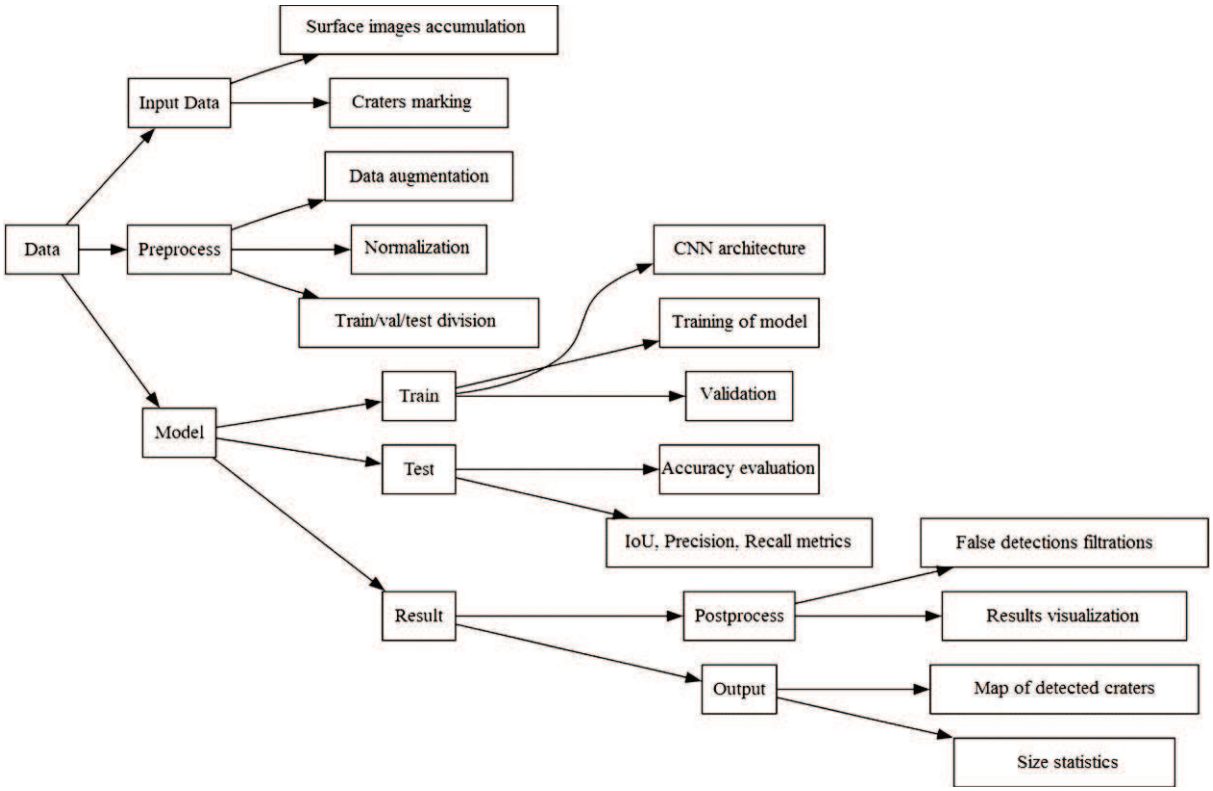


Рис. 1. Блок-схема Программного комплекса для идентификации ударных кратеров с использованием системы нейросетей.

ками данных [9]. Ручная обработка данных имеет ряд ограничений, вследствие чего объектами исследования, как правило, становятся кратеры с хорошо выраженной и простой геометрией. Ударные структуры неправильной формы или в значительной степени разрушенные зачастую исключаются из анализа, хотя именно они могут содержать ценную информацию о ранних этапах формирования лунной поверхности и наличии вещества астероидного происхождения [10]. Широкий диапазон размеров ударных кратеров, а также разнообразие их морфологических признаков существенно усложняют задачу автоматизированного выявления. Дополнительные трудности обусловлены перекрытием кратеров структурами, сформировавшихся позднее, заполнением их внутренней области породным материалом и процессами деградации, приводящими к искажению первоначальной формы. В связи с этим разработаны алгоритм и программный комплекс автоматического обнаружения ударных объектов, использующие методы распознавания образов и машинного обучения (ML).

В рамках нашего исследования сформулированы принципы, обеспечивающие автоматическое выявление и анализ объектов на поверхности планет и естественных спутников. Суть метода — использование архитектуры (CNN) Mask R-CNN, которая зарекомендовала себя как стабильный и высокоточный инструмент сегментации снимков, в частности, для распознавания слабоконтрастных элементов рельефа. Предлагаемый подход обеспечивает возможность включения в анализ более широкого спектра объектов и при этом создает основу для их систематизации по совокупности заранее заданных морфологических и планетофизических характеристик.

1. Методы исследования

Метод, используемый в настоящей работе, основан на архитектуре (CNN) Mask R-CNN. В настоящей работе анализировались снимки, полученные в ходе миссии „Lunar Reconnaissance Orbiter (LRO)“. Для решения задачи сегментации кратеров используется авторский алгоритм, в котором подробно проработан каждый этап создания модели искусственной нейронной сети (ИНС) — от подготовки данных и обучения модели до ее применения и оценки точности. Следует сказать, что изначально для нашей задачи анализировались две популярные архитектуры Mask R-CNN и U-Net. В ходе исследования мы определили, что Mask R-CNN подходит для наших задач лучше благодаря экземплярной сегментации, лучшей работоспособности с объектами разных масштабов и форм, разделению соприкасающихся кратеров на отдельные объекты.

В результате на основе архитектуры Mask R-CNN был разработан „Программный комплекс для идентификации ударных кратеров с использованием системы нейросетей“ (Свидетельство о государственной регистрации

программы для ЭВМ № 2025694272 от 04 декабря 2025 г.). Далее в настоящей работе этот комплекс будем сокращенно называть ПКИУД. На рис. 1 приведена блок-схема данного программного комплекса.

Обучение модели проводилось на основе снимка NAC_ROI_KOROLEV_LOA_E081S2025.PYR. Из изображения было выбрано три участка размером 2000×1500 px, масштаб 2 m/px, которые были размечены вручную. Размечая кратеры, мы ориентировались на следующие характеристики, свойственные кратерам, образованным медленными ударниками:

1) относительно пологая структура;

2) наличие выраженного центрального подъема внутри кратера;

3) сглаженные края и вал кратера;

4) в случае, если ударник падает под тупым углом, форма элемента поверхности может быть овальной или в отдельных сценариях иметь диффузные компоненты.

Далее были выполнены следующие этапы редукции:

1. В качестве исходных данных был выбран произвольный фрагмент изображения лунной поверхности из набора астрономических снимков миссии LRO QuickMap с пространственным разрешением 250 m/px.

2. С использованием ПКИУД был сформирован проект в системе координат Moon_2000. Следует отметить, что данные LRO QuickMap также представлены в той же системе координат.

3. Затем было выполнено проецирование изображения в выбранной системе координат.

4. После применения модели ИНС в течение 2–3 min было автоматически выявлено около 2000 объектов. По результатам последующей ручной проверки и удаления артефактов итоговое число выделенных объектов составило 1764.

Процесс обучения был воспроизведен с помощью ПКИУД в среде программирования Python, время обучения порядка 15 h.

2. Результаты

В работе процесс обучения выполнялся четыре раза для изучения наиболее подходящей комбинации входных данных и модели ИНС. На рис. 2 приведен итог работы первично-обученной модели ИНС на базе архитектуры U-Net; модель плохо распознает кратеры.

На рис. 3 приведен итог работы первично-обученной модели ИНС на базе архитектуры Mask R-CNN; модель успешно справляется с детекцией кратеров.

На рис. 4 показано, как итоговая модель обучалась на полигональной (слева) и векторной (справа) разметках входных данных; как итог модель, которая обучалась на полигональных данных, показала наилучший результат. После создания модели ИНС последовали ее тестирование и оценка точности, которые приведены в табл. 1.

Для расчета метрик был использован участок тестовой выборки. Первая метрика, которую мы определили, — это IoU (Intersection over Union) модели ИНС — площадь пересечения объекта ручной детекции и машинной; получаем оценку mAP IoU $(0.5 : 0.95) = 0.412715$ (примерно 41.3 %). Для расчета следующих метрик примем порог IoU = 0.5 и 0.75. TP — количество верно

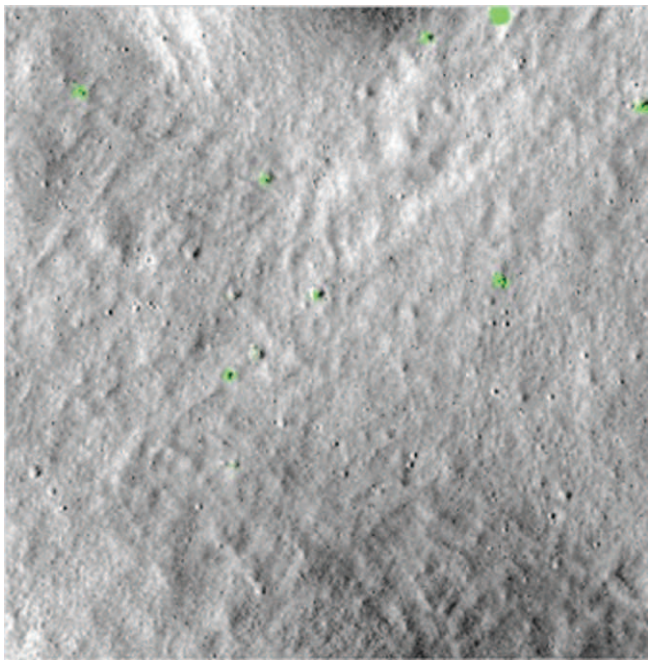


Рис. 2. Работа модели U-Net на независимом участке изображения.

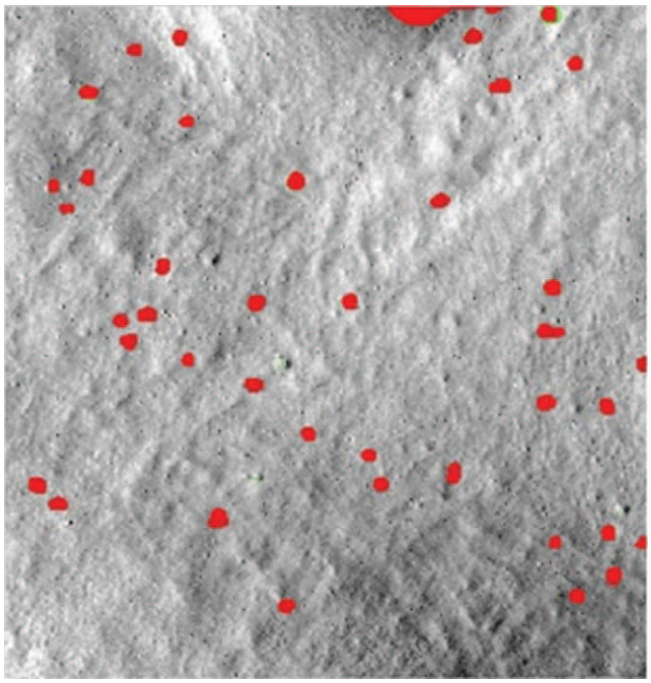


Рис. 3. Работа модели Mask R-CNN на независимом участке изображения.

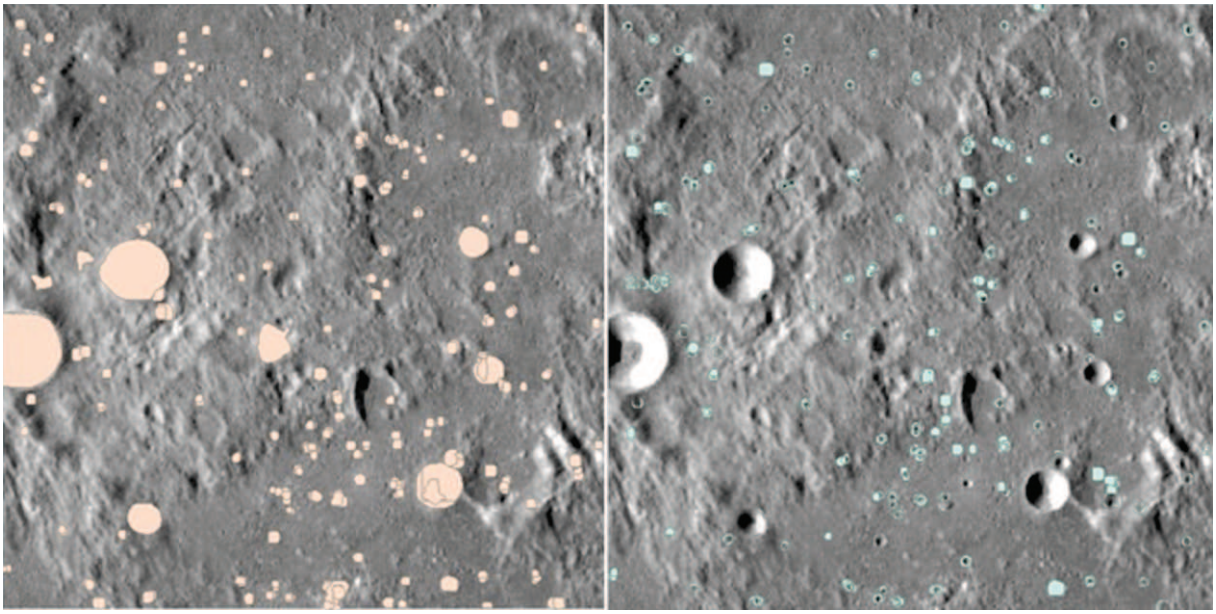


Рис. 4. Работа обученной на разных данных модели на основе архитектуры Mask R-CNN.

Таблица 1. Значения метрик для оценки точности работы ИНС

Метрика	IoU ≥ 0.5	IoU ≥ 0.75
Precision	0.4713	0.2216
Recall	0.7628	0.3586
F1 Score	0.5826	0.2739
AP	0.6913	0.2342
TP	402	189
FP	451	664
FN	125	338

определенных объектов, FP — количество объектов, которые отмечены ИНС и не отмечены вручную; FN — количество объектов, которые отмечены вручную и не отмечены ИНС. Далее мы можем рассчитать Precision — доля объектов, отмеченных ИНС на изображении, которые были размечены вручную, Recall — доля кратеров, присутствующих на изображении, обнаруженных ИНС, F1 Score — параметр, определяющий то, насколько хорошо модель ИНС одновременно не пропускает кратеры и не путает их с фоном, AP — общая оценка, среднее арифметическое всех правильных положительных результатов модели ИНС.

Полученное значение IoU можно считать хорошим результатом для модели ИНС в сфере дистанционного зондирования и ГИС. Модель уверенно находит сами объекты, но форма их полигонов слегка отличается от ручной разметки (границы сдвинуты на несколько пикселей, углы сглажены или рамка чуть шире/уже оригинала). При базовом пороге перекрытия (IoU ≥ 0.5) модель успешно обнаруживает большинство объектов, об этом говорит метрика Recall $= 76.28\,\%$.

Далее для выделенных кратеров были вычислены координаты как в метрической форме, так и в десятичных градусах, после чего полученные данные были экспортированы в табличный формат. В табл. 2 приведены координаты, площади выделенных объектов и их порядковые номера. Столбцы таблицы содержат следующие сведения:

1) OID (Object ID) — порядковый номер обнаруженного объекта;

2) Class — категория объекта; в рассматриваемом случае использовался один класс, поскольку модель решает задачу простой классификации „кратер / не кратер“;

3) X, Y — координаты выявленных кратеров в среде ArcGIS в системе координат Moon_2000_Equidistant_Cylindrical;

4) Long, Lat — селенографические координаты, полученные в результате преобразования координат X, Y.

Необходимость такого преобразования обусловлена тем, что в LRO QuickMap координатное представление не является строго прямоугольным и зависит от области отображения. В экваториальных и средних широтах применяется равнопромежуточная цилиндрическая проекция (Equirectangular), в которой меридианы и параллели формируют регулярную сетку. Для полярных областей используется полярная стереографическая проекция (Polar Stereographic), позволяющая уменьшить искажения формы кратеров. Кроме того, в интерфейсе QuickMap предусмотрен ортографический

Таблица 2. Каталог координат кратеров, выбранных на основе работы ИНС

OID	Class	*X*	*Y*	Long	Latt	*S*	Confidence	Shape_Length	Shape_Area
1	1	90714.36	−67234.07	2.991567	−2.21723	685000	99.9479830	31056.34919	68500000
51	1	88476.96	−64356.516	2.9177833	−2.122341	378125	0.52646691	9596.194078	3781250
126	1	130046.1	−66928.162	4.288646	−2.207149	113750	91.1290466	12449.74747	11375000
127	1	145819.1	−77528.349	4.8088066	−2.556721	582500	79.9799263	28813.7085	58250000
141	1	153247.5	−57072.213	5.0537808	−1.882120	250312	9.12125110	19253.04833	25031250
173	1	182327.3	−50096.714	6.0127696	−1.652083	244063	10.1751580	21545.99375	24406383
182	1	143188.7	−96484.328	4.7220611	−3.181849	825000	86.4551842	10828.42712	8250000
186	1	143283.0	−99357.119	4.72517361	−3.276587	2750000	10.52502245	6121.320344	2750000

режим (Orthographic), обеспечивающий визуализацию Луны в виде шара.

Для последующей идентификации выделенных кратеров в интерфейсе QuickMap было выполнено преобразование координатных данных. В таблицу также были включены дополнительные характеристики объектов: *S* (Shape_Area) — площадь объекта, выраженная в метрах; Confidence — оценка достоверности распознавания, отражающая степень уверенности нейросетевой модели в корректности выделения объекта; Shape_Length — периметр объекта, выраженный в метрах. Следует отметить, что при практическом использовании модели предпочтительно учитывать объекты со значением Confidence выше 70 %. Вместе с тем визуальный анализ показал, что и для части объектов с существенно меньшими значениями данного показателя (вплоть до 10 %) выделение на снимке может оставаться корректным.

В заключительной части работы проводилось сопоставление полученных результатов с данными LRO QuickMap. С этой целью для кратеров, выделенных ИНС, использовались рассчитанные координаты, по которым выполнялся их поиск на карте. Установлено, что обнаруженные объекты в целом соответствуют положениям кратеров в LRO QuickMap.

В дальнейшем предполагается проведение исследований лунных кратеров, локализованных в околополярных областях, с использованием ПКИУД.

Заключение

Полученные результаты заключаются в следующем: создан каталог кратеров, образованных медленными лунными ударниками и, таким образом, потенциально содержащих полезные ресурсы. На данном этапе работы предпочтение отдавалось оптическим изображениям как основному типу обрабатываемых данных. Это связано с наличием большого объема разнородных карт, каталогов ударных событий и обучающих выборок. Существенным преимуществом является также и то, что в рамках многих космических миссий оптические камеры обеспечивали более высокое пространственное разрешение по сравнению с радиолокационными системами. Следует отметить и достаточный высокий уровень методов компьютерного зрения для анализа изображений. В последующих исследованиях планируется расширить рассматриваемый подход за счет включения возможности использовать иные типы данных, в том числе радиолокационные, благодаря дополнительному обучению модели.

Необходимо отметить, что автоматизированное выделение объектов на основе нейросетевых методов не обеспечивает абсолютной точности результатов, например, вследствие недостаточной полноты обучения модели. Однако выявление структур, отсутствующих в исходной выборке, указывает на способность модели выделять ключевые признаки исследуемых объектов. Прямое сопоставление результатов ручной и автоматической классификаций показывает, что оцениваемое визуально расхождение составляет в среднем ~ 2 px.

Существенным ограничением остается обнаружение кратеров сравнительно небольших диаметров, распознавание которых усложняется из-за пикселизации изображения. Данная проблема особенно отчетливо проявляется для объектов радиусом менее 3 m. Для повышения точности требуются использование изображений с оптимальным пространственным разрешением, а также формирование обучающей выборки, покрывающей разнообразные объекты и условия их наблюдения. В идеальном случае набор данных должен содержать изображения, существенно отличающиеся по контрасту, особенностям проведения съемки и плотности присутствующих на снимках объектов.

В дальнейшей нашей работе планируется комплексное использование различных способов разметки обучающей выборки, что позволит повысить качество обнаружения как крупных, так и малых кратеров.

В заключение отметим, что разработанный алгоритм не ограничивается анализом лунной поверхности, и в дальнейшем может быть применен к другим небесным телам Солнечной системы с обучением модели на ак-

туальных для изучаемого объекта снимках. Здесь необходимо добавить, что различные планеты и спутники существенно отличаются как условиями освещения, так и морфологией поверхности и характером ударных образований. Соответствующие исследования уже начаты авторами настоящей работы. Таким образом, предложенный метод может служить основой для изучения особенностей автоматического выделения кратеров на различных объектах Солнечной системы, особенно на безатмосферных телах.

Финансирование работы

Выполненные работы поддержаны Российским научным фондом, грант 25-22-00930, а также грантом, предоставленным Академией наук Республики Татарстан образовательным организациям высшего образования, научным и иным организациям на поддержку планов развития кадрового потенциала в части стимулирования их научных и научно-педагогических работников к защите докторских диссертаций и выполнению научно-исследовательских работ (Соглашение от 22.12.2025 № 12/2025-ПД-КФУ).

Конфликт интересов

Авторы заявляют, что у них нет конфликта интересов.

Список литературы

[1] J. Deng, W. Cheng, Y. Jiao. Remote Sensing, **14** (24), 6335 (2022). DOI: 10.3390/rs14246335
[2] В.В. Шевченко. Космическая техника и технологии, **1** (20), 5 (2018).
[3] P.A. Bland, N.A. Artemieva, G.S. Collins, W.F. Bottke, D.B.J. Bussey, K.H. Joy. Lunar and Planetary Sci., **XXXIX**, 2045-1 (2008).
[4] E.J. Speyerer, R.Z. Povilaitis, V.S. Robinson, P.C. Thomas, R.V. Wagner. Nature, **538** (7624), 215 (2016). DOI: 10.1038/nature19829
[5] Z. Yue, B.C. Johnson, D.A. Minton, H.J. Melosh, K. Di, W. Hu, Y. Liu. Nature Geosci., **6**, 435 (2013). DOI: 10.1038/ngeo1828
[6] D. Nesvorný, F.V. Roig, D. Vokrouhlický, W.F. Bottke, S. Marchi, A. Morbidelli, R. Deienno. Icarus, **399**, 115545 (2023). DOI: 10.1016/j.icarus.2023.115545
[7] M.-H. Zhu, N. Artemieva, A. Morbidelli, Q.-Z. Yin, H. Becker, K. Wünnemann. Nature, **571**, 226 (2019). DOI: 10.1038/s41586-019-1359-0
[8] O. Sun, W. Fa, M.-H. Zhu, J. Du. Icarus, **404**, 115688 (2023). DOI: 10.1016/j.icarus.2023.115688
[9] M.-H. Zhu, A. Morbidelli, W. Neumann, Q.-Z. Yin, J.M.D. Day, D.C. Rubie, G.J. Archer, N. Artemieva, H. Becker, K. Wünnemann. Nature Astronomy, **5**, 1286 (2021). DOI: 10.1038/s41550-021-01475-0
[10] Q.-L. Li, Q. Zhou, Y. Liu, Z. Xiao, Y. Lin, J.-H. Li, H.-X. Ma, G.-Q. Tang, S. Guo, X. Tang, J.-Y. Yuan, J. Li, F.-Y. Wu, Z. Ouyang, C. Li, X.-H. Li. Nature, **600**, 54 (2021). DOI: 10.1038/s41586-021-04100-2