

Обзор современных подходов к обработке изображений в задачах исследования космоса

Б. А. Юматов, Е. В. Белинская, Р. В. Бессонов, А. Н. Василейская

Институт космических исследований РАН, Москва, 117997, Россия

E-mail: bumatov@gmail.com

В последнее десятилетие произошли существенные изменения в подходах к решению задач технического зрения. Практически во всех существующих задачах классические подходы были вытеснены алгоритмами искусственного интеллекта, и в частности нейронными сетями, показывающими заметно более высокую точность, а в некоторых случаях открывшими возможность получать практически применимые результаты в тех задачах, для которых ранее не существовало рабочих решений. Дополнительным стимулом к вышеуказанным изменениям стала повсеместная доступность мощных вычислительных устройств, в частности графических процессоров, которые на текущий момент имеют габариты, позволяющие использовать их во встраиваемых системах и, таким образом, решать прикладные задачи в реальном времени. Космос в данном случае не считается исключением и с некоторым отставанием встает на рельсы общих тенденций. В статье рассматриваются существующие прецеденты использования алгоритмов искусственного интеллекта в задачах освоения космоса, а также исследования и работы, которые ведутся в этом направлении. Затрагивается вопрос бортового исполнения подобных алгоритмов, проводится краткий обзор существующих и будущих разработок в области вычислительных устройств космического назначения, характеристики которых предполагают возможным выполнения на них ресурсозатратных и параллельных алгоритмов.

Ключевые слова: машинное зрение, обработка изображений, искусственный интеллект, нейронные сети, сверточные нейронные сети, ДЗЗ, некооперируемое взаимодействие, планетоход, вычислительные устройства

Одобрена к печати: 02.08.2022

DOI: 10.21046/2070-7401-2022-19-4-9-22

Обработка изображений со спутников дистанционного зондирования Земли

Одной из наиболее остро стоящих проблем для космических аппаратов, генерирующих большие объёмы информации, представляется обеспечение временного хранения, а также своевременной и быстрой передачи данных на Землю. Зачастую линия связи с Землёй обладает низкой пропускной способностью, а в некоторых случаях, в зависимости от орбиты аппарата, может быть доступна лишь в крайне ограниченные интервалы времени. Для спутников дистанционного зондирования Земли (ДЗЗ), регулярно генерирующих многоканальные изображения в высоком разрешении, эта проблема становится наиболее актуальной. Одним из способов снизить нагрузку на линию связи выступает отбраковка некачественных изображений.

В 2017 г. в рамках миссии Space Test Program — Houston 5 (STP-H5) министерства обороны США на орбиту был выведен малый искусственный спутник с оптико-электронной системой на борту, осуществлявшей съёмку земной поверхности и последующую передачу изображений на Землю в течение нескольких лет (Manning et al., 2018).

На *рис. 1* (см. с. 10) представлены примеры изображений из полученной выборки.

Как можно видеть, часть изображений оказалась непригодной к использованию, и её передача впустую занимала линию связи. Для того чтобы снизить поток невалидной информации в последующих экспериментах, была обучена нейронная сеть, классифицирующая изображения по 5 классам: с недостаточной степенью освещённости сцены, с наличием засветки на снимке, полностью белые изображения, изображения с наличием воды и облаков, изображения с наличием поверхности суши. Точность классификации представлена на *рис. 2* (см. с.10).




Рис. 1. Выборка из изображений, полученных в ходе эксперимента STP-H5: *a* — изображение с недостаточной степенью освещённости стены; *б* — с наличием воды и облаков; *в* — с наличием засветки на снимке; *г* — с наличием поверхности суши; *д* — полностью белые изображения

Точность классификации в среднем находится на уровне 85 %, что уже даёт возможность отбраковки значительной части непригодной информации.

К концу 2021 г. архитектура нейронной сети была реализована в бортовом исполнении и вместе с другими нейросетевыми алгоритмами апробируется на новом космическом аппарате (КА), выведенном в рамках STP-H7 (Perryman et al., 2021; Roffe et al., 2020).

Ещё одним способом снизить поток непригодной информации со спутников ДЗЗ и облегчить последующую обработку на Земле становится определение совокупной площади областей изображения, покрытых облаками, а также координат этих областей в плоскости снимка. Для решения этой задачи авторами работы (Jeppesen et al., 2019) была обучена свёрточная

нейронная сеть, базирующаяся на архитектуре U-Net и решающая задачу сегментации. Полученная сеть продемонстрировала высокие показатели точности по сравнению с классическими подходами (например, алгоритмом FMask), используя в качестве входных данных лишь RGB-каналы (R — *англ.* red, красный; G — *англ.* green, зелёный; B — *англ.* blue, синий) изображения. На рис. 3, 4 (см. с. 11) представлены результаты сегментации и их сравнение с классическими алгоритмами.

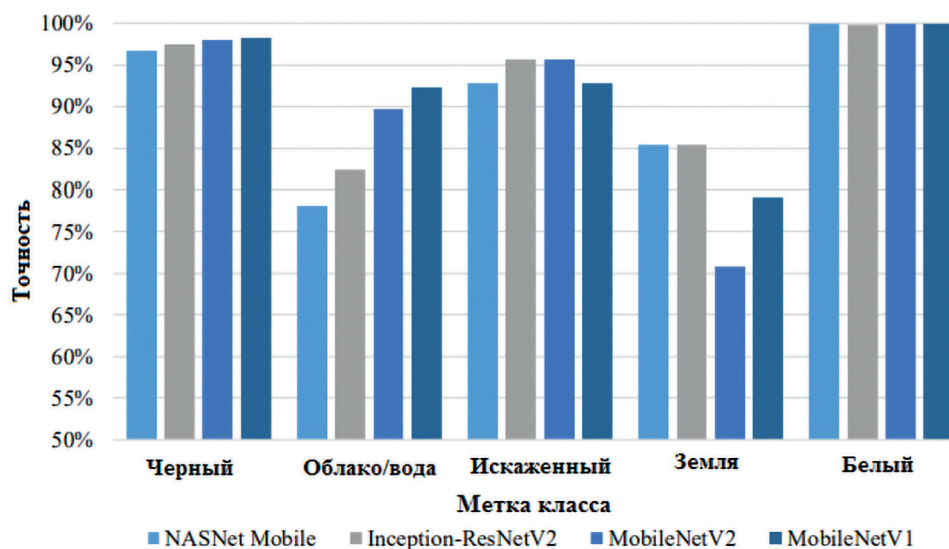




Рис. 2. Точность обученной модели классификации в зависимости от архитектуры нейронной сети



a


б



в


г

Рис. 3. Сравнение результатов сегментации облаков на снимках с наличием заснеженной поверхности: *a* — исходное изображение; *б* — эталонная разметка; *в* — результат сегментации с использованием алгоритма FMask; *г* — результат сегментации с использованием сверточной нейронной сети



a

б



в

г

Рис. 4. Сравнение результатов сегментации облаков на снимках с наличием водной поверхности: *a* — исходное изображение; *б* — эталонная разметка; *в* — результат сегментации с использованием алгоритма FMask; *г* — результат сегментации с использованием сверточной нейронной сети

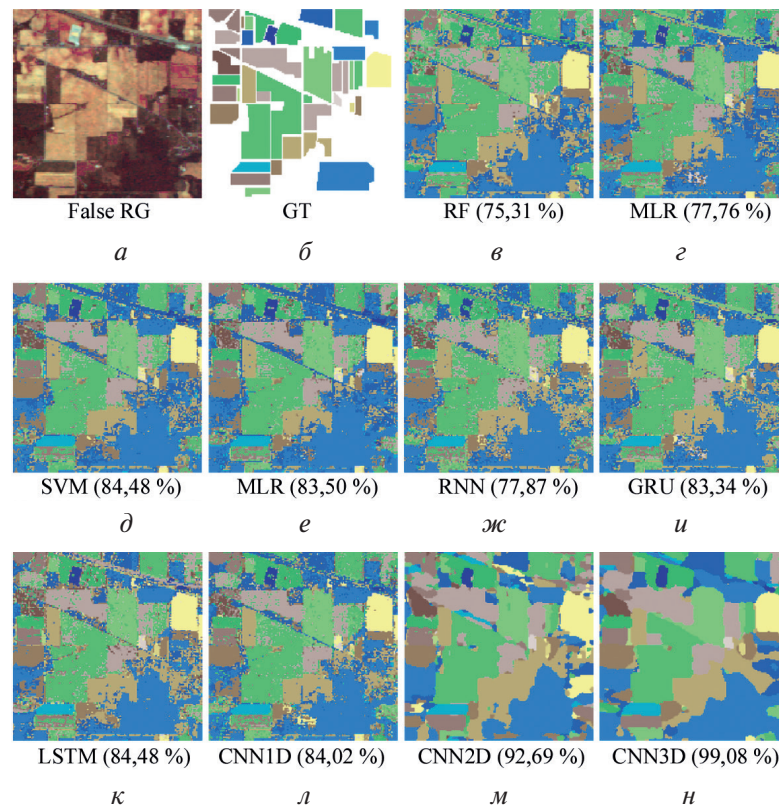


Рис. 5. Результаты сегментации гиперспектральных изображений различными алгоритмами: *a* — исходное псевдо-RGB-изображение; *б* — эталонная сегментация; *в–д* — классические алгоритмы; *к–н* — нейросетевые алгоритмы

Из сравнения видно, что при наличии на снимке заснеженной или водной поверхности классические подходы решают задачу сегментации с достаточно низкой точностью, в то время как нейросетевой алгоритм демонстрирует заметно большую стабильность работы в подобных условиях.

Ещё одной областью, где использование нейросетевых подходов становится всё более предпочтительным, выступает сегментация гиперспектральных изображений. Говорить о бортовом исполнении подобных алгоритмов преждевременно, так как наилучшие результаты показывают свёрточные трёхмерные сети, которые слабо оптимизированы даже для наземных вычислительных комплексов, однако их точность близка к эталонной (Paoletti et al., 2019) и поэтому уже сейчас может использоваться в наземной обработке. На рис. 5 (см. с. 11) представлены результаты сравнения точностей сегментации для различных алгоритмов.

Как видно из результатов сравнения, наибольшей точностью, близкой к эталонной, обладает трёхмерная свёрточная нейронная сеть, в то время как лучший результат среди классических алгоритмов — 84,48 % для метода опорных векторов. Трёхмерная свёрточная нейронная сеть демонстрирует столь высокую точность за счёт использования объёмных свёрточных фильтров, анализирующих все спектральные зоны снимка одновременно.

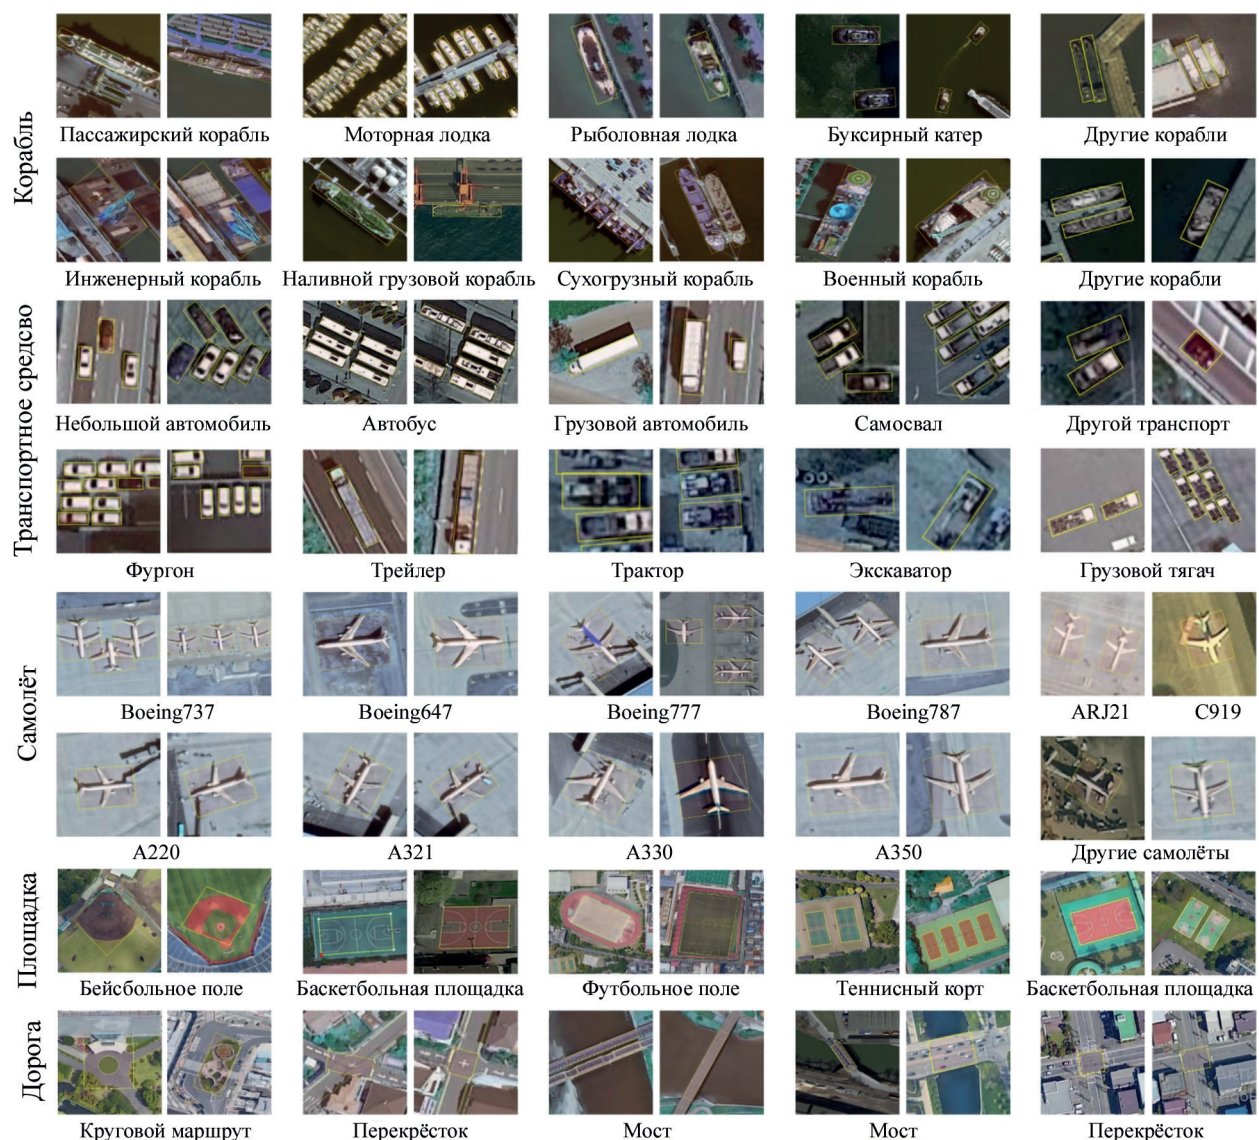


Рис. 6. Выборка из датасета FAIR1M

Помимо сегментации ландшафта на снимках со спутников ДЗЗ, ещё одной актуальной на текущий момент задачей считается распознавание объектов на аэрофотоснимках.

В последние несколько лет в этом направлении активно ведутся исследования и формируются наборы данных с множеством размеченных классов и содержащих их областей, среди которых представлены как строения и элементы инфраструктуры, так и всевозможные виды транспортных средств. Один из наиболее крупных наборов данных на текущий момент — датасет (англ. dataset) FAIR1M (Sun et al., 2022). На рис. 6 (см. с. 12) и 7 представлены выборки из вышеуказанного набора.




Рис. 7. Изображения из датасета FAIR1M: *а* — аэропорт; *б* — грузовой порт; *в* — логистический хаб

Традиционно у классических свёрточных нейронных сетей присутствуют проблемы с детектированием кучно расположенных небольших объектов, и до недавнего времени распознавать объекты, подобные тем, что представлены на изображениях выше, было проблематично. Однако на текущий момент разработаны архитектуры нейронных сетей, базирующиеся на деформируемых свёрточных фильтрах, деконволюирующих свёрточных фильтрах и формировании области интереса с учётом ориентации объекта (Ding et al., 2018; Sun et al., 2022) и демонстрирующие достаточно высокие показатели точности. На рис. 8 и 9 представлены примеры изображений с результатами распознавания объектов на аэрофотоснимках.




Рис. 8. Результаты детекции объектов на аэрофотоснимке с использованием сети ROI Transformer (Ding et al., 2018)




Рис. 9. Результаты детекции объектов на аэрофотоснимке с использованием сети CHODNet (Sun et al., 2022)

Взаимодействие с некооперируемыми объектами

Ещё одна область, где активно исследуется возможность применения искусственных нейронных сетей, — взаимодействие с некооперируемыми объектами. На текущий момент существует два направления, в которых ведутся разработки архитектур нейронных сетей для решения данной задачи.

Первое — это решения end-to-end (рис. 10), в которых на вход нейросетевого алгоритма подаётся изображение, содержащее некооперируемый объект, а на выходе получают параметры относительной навигации (Garcia et al., 2021; Phisannurawong et al., 2020).

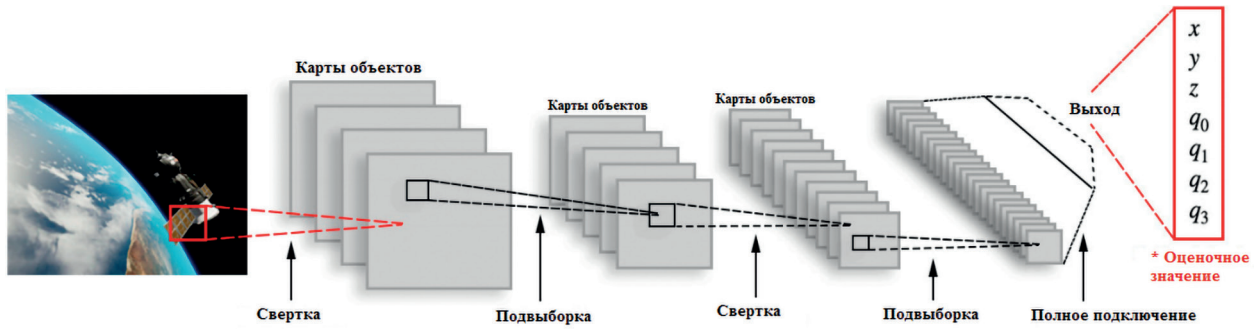


Рис. 10. Архитектура end-to-end для определения параметров относительной навигации некооперируемого объекта

Несмотря на свою компактность, на текущий момент подобные алгоритмы обладают достаточно низкой точностью: около 1 м по положению и 8° по углам ориентации.

Второй подход представляет собой трёхэтапную процедуру: выделение области интереса, содержащей объект, детекцию ключевых точек (рис. 11) на некооперируемом объекте и последующее определение параметров относительной навигации сопоставлением координат ключевых точек с трёхмерной моделью объекта с использованием классических методов оценки параметров модели (МНК (метод наименьших квадратов, *англ.* Ordinary Least Squares — OLS), RANSAC (*англ.* RANdom SAmple Consensus) и т. д.). Существующие на текущий момент решения (Xu et al., 2020) демонстрируют высокую точность определения ключевых точек в условиях сложной светооптической обстановки и расстояния до объекта в диапазоне до 50 м (рис. 12, см. с. 15).

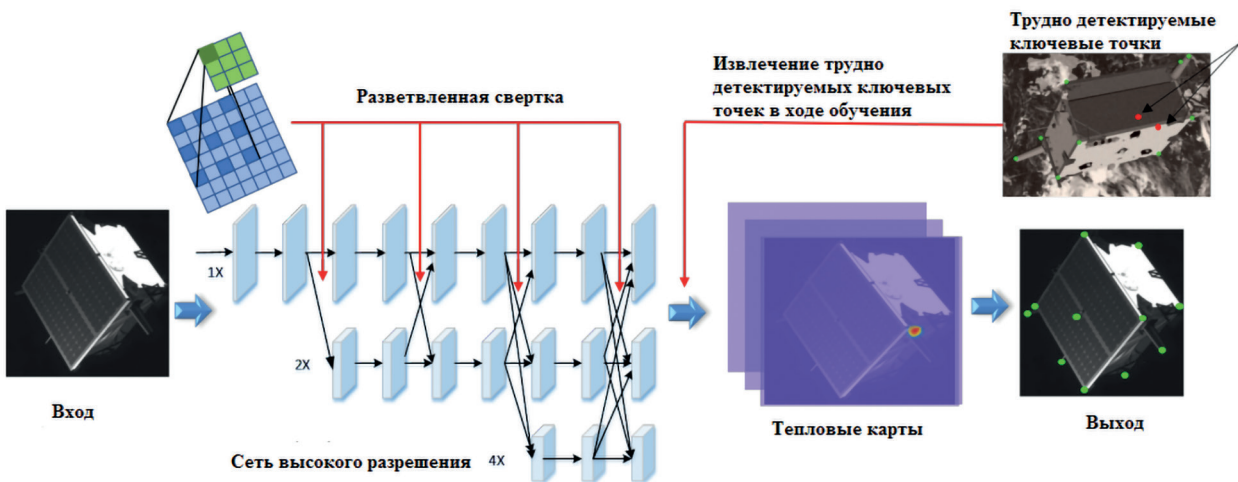


Рис. 11. Архитектура для определения положения ключевых точек на некооперируемом объекте




Рис. 12. Результаты детектирования ключевых точек в различных условиях

Применение в миссиях дальнего космоса

Один из наиболее комплексных классов космических задач на текущий момент — исследование планет и их спутников с помощью планетоходов. Посадка планетохода входит в число сложнейших этапов подобных миссий. Вследствие невозможности предсказания места посадки с достаточно высокой точностью необходимо иметь возможность проанализировать актуальный рельеф поверхности на предмет опасных и непригодных точек непосредственно перед началом посадки с орбиты, а затем корректировать снижение в реальном времени, анализируя структуру рельефа в более высоком разрешении. Решение подобной задачи, основанное на использовании исключительно оптических датчиков, без привлечения лидаров, ToF-камер (англ. Time of Flight) и искусственного интеллекта, может обладать довольно низкой надёжностью. Управление планетоходом после посадки также оказывается достаточно сложной задачей. Учитывая, что управление, к примеру, марсоходом в реальном времени невозможно, взаимодействие строится на анализе окружающей обстановки и загрузке в марсоход коротких программ, которые тот выполняет автономно. Подобный алгоритм действий может привести к аварии в том случае, если при формировании задания не были учтены какие-либо особенности поверхности (камень, песок и т.п.), а марсоход не в состоянии самостоятельно с высокой степенью надёжности анализировать окружающую обстановку в моменты автономной работы. Кроме всего прочего, необходимо отметить сложности с передачей полученной информации и оптимальным расходом ресурсов планетохода (построение оптимального маршрута на основании состава рельефа, положения Солнца и т.д.). Качество решения всех вышеперечисленных проблем может быть улучшено использованием более интеллектуальных алгоритмов при обработке информации с оптических датчиков планетоходов. Одной из наиболее масштабных попыток создания автономной интеллектуальной системы управления планетоходом стала исследовательская программа MAARS (англ. Machine learning-based Analytics for Automated Rover Systems) (Ono et al., 2020), проводимая сотрудниками отдела робототехники Лаборатории реактивного движения (англ. Jet Propulsion Laboratory (JPL) Robotics) Калифорнийского технологического института (англ. California Institute of Technology). В ходе этой программы разрабатывается целый комплекс обучаемых

алгоритмов для обеспечения автономного управления марсоходом и улучшения алгоритмов посадки. Основным направлением, на котором сконцентрировано исследование, выступает разработка алгоритмов сегментации рельефа поверхности под общим названием SPOC (*англ.* Soil Property and Object Classification Algorithm) (*рис. 13*). На текущий момент разработаны варианты наземного и бортового исполнения, решающие задачу анализа рельефа как с высоты орбиты, так и на поверхности Марса. На основе результатов работы алгоритма на орбите происходит выбор места посадки и формирование стратегических планов маршрута марсохода. С помощью данных, формируемых алгоритмом на поверхности, в совокупности со стереоизмерениями разрабатываются оптимальные с точки зрения безопасности и расходования ресурсов планетохода локальные и глобальные планы маршрутов. В частности, SPOC интегрирован с нейросетью VeeGer-TerramechanicsNet (*рис. 14*), которая обучена с использованием террамеханической модели марсохода и выдаёт информацию о затратах энергии при выборе того или иного пути движения.

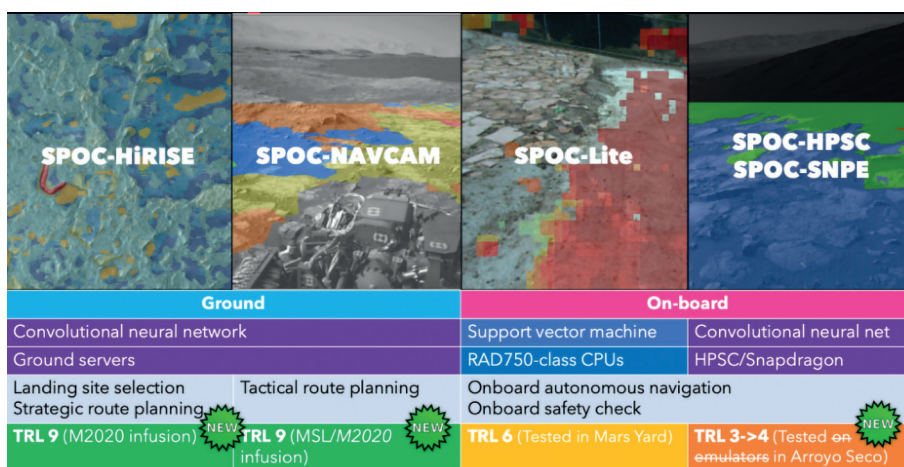




Рис. 13. Семейство алгоритмов SPOC. Варианты исполнения и степень готовности



а



б

Рис. 14. Результаты работы VeeGer-TerramechanicsNet при анализе различных участков поверхности



Рис. 15. Изображения с марсохода и их текстовое описание

Кроме того, результаты работы SPOC используются рекуррентной нейронной сетью, которая на базе выделенных на предыдущем этапе признаков формирует текстовое описание зафиксированного марсоходом изображения (рис. 15), в первую очередь передающееся на Землю, и на его основании принимается решение о передаче основного массива информации. Данный подход предоставляет возможность каталогизировать и классифицировать изображения, что облегчает работу исследователей, позволяя им запрограммировать марсоход на формирование выборок изображений с определённым набором свойств.

Развитие вычислительных устройств космического назначения

В заключение необходимо коснуться перспектив развития вычислительных устройств космического назначения, способных выполнять вышерассмотренные алгоритмы в реальном времени.

Наземные вычислительные устройства ушли далеко вперёд, и на текущий момент использование алгоритмов искусственного интеллекта даже во встраиваемых устройствах происходит за счёт использования малогабаритных графических процессоров. Процессоры космического назначения, вследствие необходимости обеспечения радиационной стойкости, традиционно отстают по совокупности параметров (Lentaris et al., 2018). Рисунок 16 (см. с. 18) демонстрирует эту тенденцию.

Однако в последние несколько лет ситуация начала меняться. В рамках программы SpaceCube (НАСА — Национальное управление по авиации и исследованию космического пространства, *англ.* NASA — National Aeronautics and Space Administration) на Международной космической станции апробируются мощные вычислительные устройства, которые базируются на радиационно стойком ПЛИС (программируемая логическая интегральная схема, *англ.* programmable logic device — PLD) и мощном ПЛИС наземного назначения. Схема работы заключается в выполнении сложных вычислений на мощном ПЛИС, в то время как ПЛИС космического назначения контролирует его состояние (рис. 17, см. с. 18).

Наиболее значимым прорывом в разработке вычислительных устройств космического назначения представляется программа High-Performance Spaceflight Computing (HPSC, NASA) (Dennehy, Wolf, 2019; Gretok et al., 2019; Powell, 2018). В ходе её создания были разработаны радиационно стойкие многоядерные вычислительные устройства, базирующиеся на процессоре ARM Cortex-A53, которые, помимо всего прочего, предоставляют возможность

горизонтального масштабирования и объединения 2–4 устройств в один вычислительный кластер (рис. 18, см. с. 19).

В совокупности с аппаратной схемой, разработанной в рамках программы SpaceCube (рис. 19, см. с. 19), вычислитель, базирующийся на HPSC, становится сопоставим по мощности с вычислителями наземного назначения.

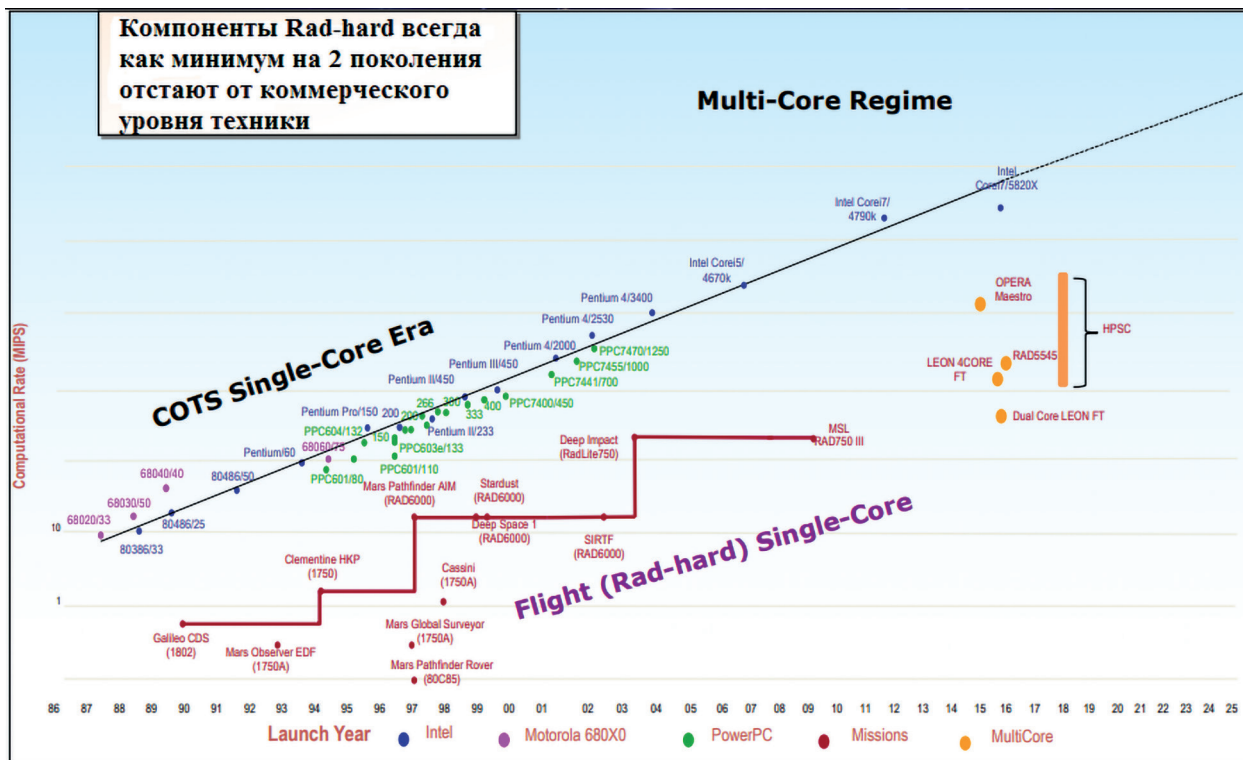


Рис. 16. Изображения с марсохода и их текстовое описание

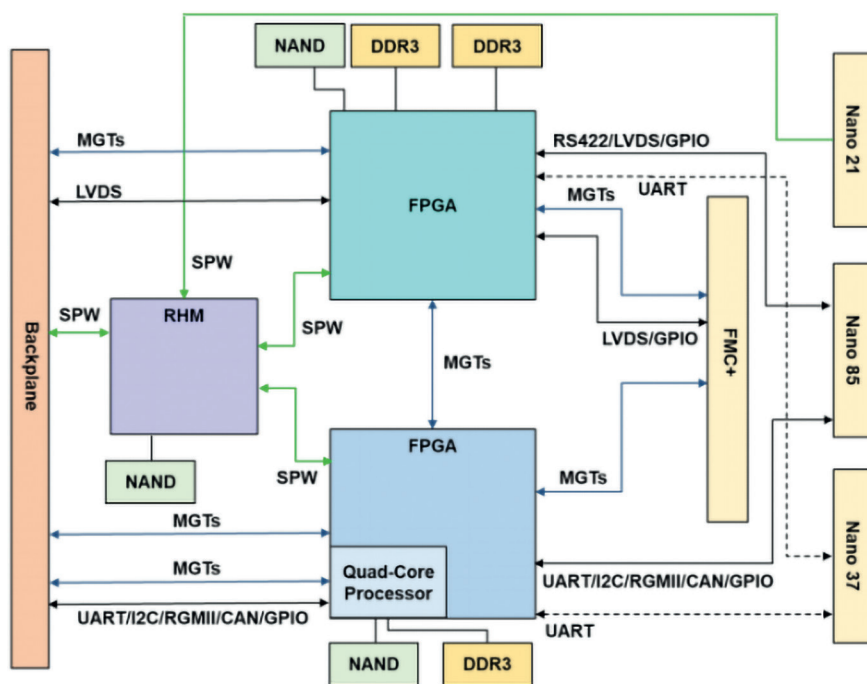


Рис. 17. Аппаратная схема вычислительного устройства, разработанного в рамках программы SpaceCube v 3.0

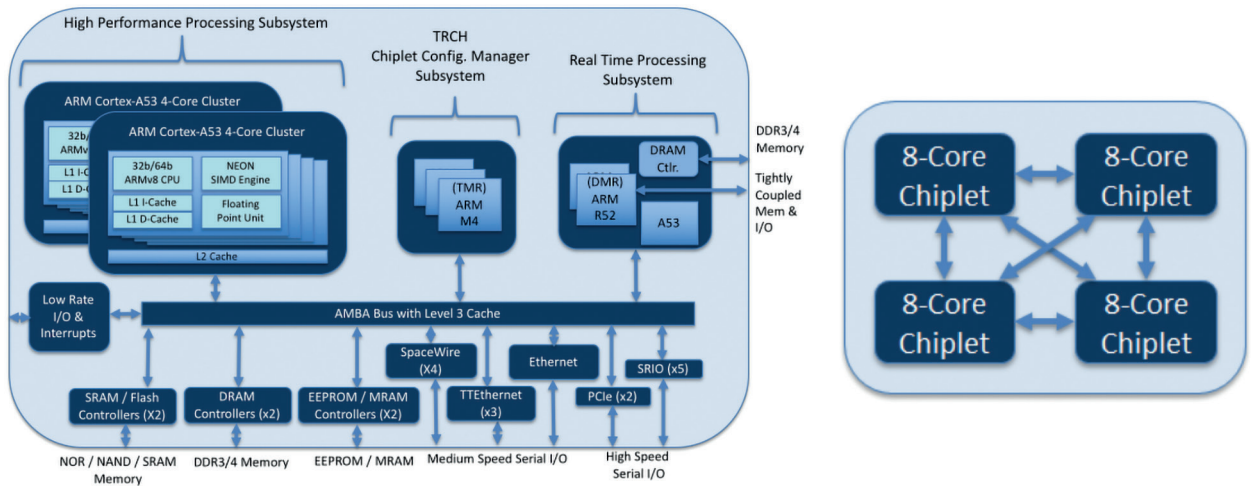


Рис. 18. Аппаратная схема HPSC

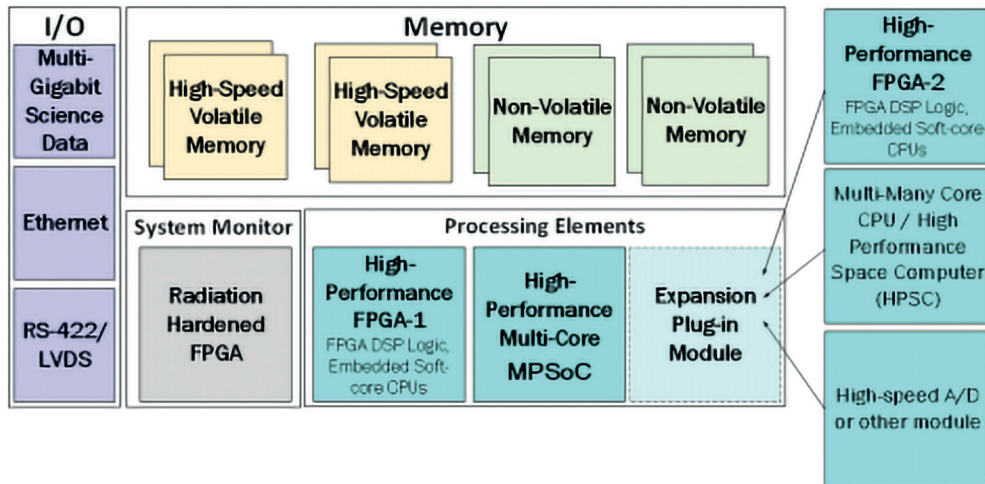


Рис. 19. Аппаратная схема HPSC + SpaceCube

Заключение

Алгоритмы искусственного интеллекта применительно к задачам космического назначения стремительно развиваются. Использование многих из них в рамках наземной обработки уже сейчас может принести существенную пользу в самых разных классах задач. Работы, которые ведутся в направлении разработки радиационно-стойких высокопроизводительных вычислительных устройств, позволяют предположить, что уже через 10–20 лет многие алгоритмы могут быть представлены в бортовом исполнении, что дополнительно увеличит эффективность работы околоземных КА, позволит осуществлять миссии в дальнем космосе со значительно более высокой степенью надёжности и автономности и предоставит возможность решить те задачи, которые на данный момент кажутся невыполнимыми.

Литература

1. *Dennehy C.J., Wolf A.* A NASA Viewpoint on On-Board Processing Challenges to Support Optical Navigation and Other GN&C Critical Functions: oral presentation // European Workshop on On-Board Data Processing (OBDP2019). 25–27 Feb. 2019. Noordwijk, Netherlands.
2. *Ding J., Xue N., Long Y., Xia G., Lu Q.* Learning RoI Transformer for Detecting Oriented Objects in Aerial Images. 2018. 19 p. URL: <https://arxiv.org/pdf/1812.00155.pdf>.

3. Garcia A., Musallam M. A., Gaudilliere V., Ghorbel E., Ismaeil K. A., Perez M., Aouada D. LSPnet: A 2D Localization-oriented Spacecraft Pose Estimation Neural Network. 2021. 9 p. URL: <https://arxiv.org/pdf/2104.09248.pdf>.
4. Gretok E. W., Kain E. T., George A. D. Comparative Benchmarking Analysis of Next-Generation Space Processors // IEEE Aerospace Conf. 2–9 March 2019. Big Sky, MT, USA. 55 p.
5. Jeppesen J. H., Jacobsen R. H., Inceoglu F., Toftegaard T. S. A cloud detection algorithm for satellite imagery based on deep learning // Remote Sensing of Environment. 2019. V. 229. P. 247–259. DOI: 10.1016/j.rse.2019.03.039.
6. Lentaris G., Maragos K., Stratakos I., Papadopoulos L., Papanikolaou O., Lourakis M., Zabulis X., Arjona-Gonzalez D., Furano G. High-Performance Embedded Computing in Space: Evaluation of Platforms for Vision-Based Navigation // Aerospace Information Systems. 2018. V. 15. No. 4. P. 178–192. DOI: 10.2514/1.IO10555.
7. Manning J., Langerman D., Ramesh B., Gretok E., Wilson C., George A., MacKinnon J., Crum G. Machine-Learning Space Applications on SmallSat Platforms with TensorFlow // 32nd Annual Small Satellites Conf. 4–9 Aug. 2018. Utah, USA. 2018. Art. No. SSC18-WKVII-03. 8 p.
8. Ono M., Rothrock B., Otsu K., Higa S., Iwashita Y., Didier A., Islam T., Laporte C., Sun V., Stack K., Sawoniewicz J., Daftry S., Timmaraju V., Sahnouné S., Mattann C. A., Lamarre O., Ghosh S., Qiu D., Nomura S., Roy H., Sarabu H., Hedrick G., Folsom L., Suehr S., Park H. MAARS: Machine learning-based Analytics for Automated Rover Systems // IEEE Aerospace Conf. 7–14 March 2020. Big Sky, MT, USA. 2020. Art. No. 19891560. 17 p. DOI: 10.1109/AERO47225.2020.9172271.
9. Paoletti M. E., Haut J. M., Plaza J., Plaza A. Deep learning classifiers for hyperspectral imaging: A review // ISPRS J. Photogrammetry and Remote Sensing. 2019. V. 158. P. 279–317. DOI: 10.1016/j.isprsjprs.2019.09.006.
10. Perryman N., Schwarz T., Cook T., Roffe S., Gillette A., Gretok E., Garrett T., Sabogal S., George A., Lopez R. STP-H7-CASPR: A Transition from Mission Concept to Launch // 35th Annual Small Satellite Conf. 7–12 Aug. 2021, Utah, USA. 2021. Art. No. SSC21-WKII-08. 16 p.
11. Phisannupawong T., Kamsing P., Torteeka P., Channumsin S., Sawangwit U., Hematulin W., Jarawan T., Somjit T., Yooyen S., Delahaye D., Boonsrimuang P. Vision-Based Spacecraft Pose Estimation via a Deep Convolutional Neural Network for Noncooperative Docking Operations // Aerospace. 2020. No. 7(9). Art. No. 126. 22 p. DOI: 10.3390/aerospace7090126.
12. Powell W. High-Performance Spaceflight Computing (HPSC) project Overview // Radiation Hardened: Electronics Technology (RHET) Conf. 5–8 Nov. 2018, Phoenix, AZ. 2018. 29 p. URL: <https://ntrs.nasa.gov/api/citations/20180007636/downloads/20180007636.pdf>.
13. Roffe S., Schwarz T., Cook T., Perryman N., Goodwill J., Gretok E., Phillips A., Moran M., Garrett T., George A. CASPR: Autonomous Sensor Processing Experiment for STP-H7. 2020. URL: <https://digitalcommons.usu.edu/cgi/viewcontent.cgi?article=4666&context=smallsat>.
14. Sun X., Wang P., Yan Z., Xu F., Wang R., Diao W., Chen J., Li J., Feng Y., Xu T., Weinmann M., Hinz S., Wang C., Fu K. FAIR1M: A benchmark dataset for fine-grained object recognition in high-resolution remote sensing imagery // ISPRS J. Photogrammetry and Remote Sensing. 2022. V. 184. P. 116–130. DOI: 10.1016/j.isprsjprs.2021.12.004.
15. Xu J., Song B., Yang X., Nan X. An Improved Deep Keypoint Detection Network for Space Targets Pose Estimation // Remote Sensing. 2020. V. 12(23). Art. No. 3857. 21 p. DOI: 10.3390/rs12233857.

Review of modern approaches to image processing in problems of space exploration

B. A. Yumatov, E. V. Belinskaya, R. V. Bessonov, A. N. Vasileiskaya

*Space Research Institute RAS, Moscow 117997, Russia
E-mail: bumatov@gmail.com*

In the past decade, there have been significant changes in approaches to solving problems of technical vision. In almost all existing problems, classical approaches have been superseded by artificial intelligence algorithms and, in particular, by neural networks, which show noticeably higher accuracy and in

some cases open the possibility of obtaining practically applicable results in tasks where there were no working solutions before. An additional incentive for the above changes was the widespread availability of powerful computing devices, in particular graphic processors, which currently have dimensions that allow them to be used in embedded systems and thus solve applied problems in real time. Space in this case is no exception and, with some delay, gets on the rails of general trends. The article discusses the existing precedents for the use of artificial intelligence algorithms in space exploration, as well as the research and work that is being done in this direction. The issue of on-board execution of such algorithms is discussed, a brief review is given of existing and future developments in the field of space computing devices, the characteristics of which suggest the possibility of executing resource-intensive and parallel algorithms on them.

Keywords: machine vision, image processing, artificial intelligence, neural networks, convolutional neural networks, remote sensing, non-cooperative interaction, planet rover, computing devices

Accepted: 02.08.2022

DOI: 10.21046/2070-7401-2022-19-4-9-22

References

1. Dennehy C. J., Wolf A., A NASA Viewpoint on On-Board Processing Challenges to Support Optical Navigation and Other GN&C Critical Functions, *European Workshop on On-Board Data Processing (OBDP2019)*, 25–27 Feb. 2019, Noordwijk, Netherlands.
2. Ding J., Xue N., Long Y., Xia G., Lu Q., *Learning Rot Transformer for Detecting Oriented Objects in Aerial Images*, 2018, 19 p., available at: <https://arxiv.org/pdf/1812.00155.pdf>.
3. Garcia A., Musallam M. A., Gaudilliere V., Ghorbel E., Ismaeil K. A., Perez M., Aouada D., *LSPnet: A 2D Localization-oriented Spacecraft Pose Estimation Neural Network*, 2021, 9 p., available at: <https://arxiv.org/pdf/2104.09248.pdf>.
4. Gretok E. W., Kain E. T., George A. D., Comparative Benchmarking Analysis of Next-Generation Space Processors, *IEEE Aerospace Conf.*, 2–9 March 2019, Big Sky, MT, USA, 55 p.
5. Jeppesen J. H., Jacobsen R. H., Inceoglu F., Toftegaard T. S., A cloud detection algorithm for satellite imagery based on deep learning, *Remote Sensing of Environment*, 2019, Vol. 229, pp. 247–259, DOI: 10.1016/j.rse.2019.03.039.
6. Lentaritis G., Maragos K., Stratakos I., Papadopoulos L., Papanikolaou O., Lourakis M., Zabulis X., Arjona-Gonzalez D., Furano G., High-Performance Embedded Computing in Space: Evaluation of Platforms for Vision-Based Navigation, *Aerospace Information Systems*, 2018, Vol. 15, No. 4, pp. 178–192, DOI: 10.2514/1.IO10555.
7. Manning J., Langerman D., Ramesh B., Gretok E., Wilson C., George A., MacKinnon J., Crum G., Machine-Learning Space Applications on SmallSat Platforms with TensorFlow, *32nd Annual Small Satellites Conf.*, 4–9 Aug. 2018, Utah, USA, 2018, Art. No. SSC18-WKVII-03, 8 p.
8. Ono M., Rothrock B., Otsu K., Higa S., Iwashita Y., Didier A., Islam T., Laporte C., Sun V., Stack K., Sawoniewicz J., Daftry S., Timmaraju V., Sahnoune S., Mattann C. A., Lamarre O., Ghosh S., Qiu D., Nomura S., Roy H., Sarabu H., Hedrick G., Folsom L., Suehr S., Park H., MAARS: Machine learning-based Analytics for Automated Rover Systems, *IEEE Aerospace Conf.*, 7–14 March 2020, Big Sky, MT, USA, 2020, Art. No. 19891560, 17 p., DOI: 10.1109/AERO47225.2020.9172271.
9. Paoletti M. E., Haut J. M., Plaza J., Plaza A., Deep learning classifiers for hyperspectral imaging: A review, *ISPRS J. Photogrammetry and Remote Sensing*, 2019, Vol. 158, pp. 279–317, DOI: 10.1016/j.isprsjprs.2019.09.006.
10. Perryman N., Schwarz T., Cook T., Roffe S., Gillette A., Gretok E., Garrett T., Sabogal S., George A., Lopez R., STP-H7-CASPR: STP-H7-CASPR: A Transition from Mission Concept to Launch, *35th Annual Small Satellite Conf.*, 7–12 Aug. 2021, Utah, USA, 2021, Art. No. SSC21-WKII-08, 16 p.
11. Phisannupawong T., Kamsing P., Torteeka P., Channumsin S., Sawangwit U., Hematulin W., Jarawan T., Somjit T., Yooyen S., Delahaye D., Boonsrimuang P., Vision-Based Spacecraft Pose Estimation via a Deep Convolutional Neural Network for Noncooperative Docking Operations, *Aerospace*, 2020, No. 7(9), Art. No. 126, 22 p., DOI: 10.3390/aerospace7090126.
12. Powell W., High-Performance Spaceflight Computing (HPSC) project Overview, *Radiation Hardened: Electronics Technology (RHET) Conf.*, 5–8 Nov. 2018, Phoenix, AZ, 2018, 29 p., available at: <https://ntrs.nasa.gov/api/citations/20180007636/downloads/20180007636.pdf>.
13. <https://digitalcommons.usu.edu/cgi/viewcontent.cgi?article=4666&context=smallsat>.

14. Sun X., Wang P., Yan Z., Xu F., Wang R., Diao W., Chen J., Li J., Feng Y., Xu T., Weinmann M., Hinz S., Wang C., Fu K., FAIR1M: A benchmark dataset for fine-grained object recognition in high-resolution remote sensing imagery, *ISPRS J. Photogrammetry and Remote Sensing*, 2022, Vol. 184, pp. 116–130, DOI: 10.1016/j.isprsjprs.2021.12.004.
15. Xu J., Song B., Yang X., Nan X. An Improved Deep Keypoint Detection Network for Space Targets Pose Estimation, *Remote Sensing*, 2020, Vol. 12(23), Art. No. 3857, 21 p., DOI: 10.3390/rs12233857.