

Детектирование облачного покрова с использованием нейронной сети по данным прибора МСУ-ГС космического аппарата «Арктика-М» № 1

В.Д. Блощинский^{✉1,2}, Л.С. Крамарева^{1,2}, Ю.А. Шамилова^{2*}

¹Вычислительный центр ДВО РАН
680000, г. Хабаровск, ул. Ким Ю Чена, 65

²Дальневосточный центр ФГБУ «НИЦ космической гидрометеорологии «Планета»
680000, г. Хабаровск, ул. Ленина, 18

Поступила в редакцию 13.07.2023;
после доработки 3.10.2023;
принята к печати 4.10.2023

Обнаружение облачности на спутниковых изображениях — одна из важнейших задач спутниковой метеорологии. От точности детектирования облачного покрова во многом зависит качество других гидрометеорологических продуктов. Представлен алгоритм детектирования облачности, основанный на сверточной нейронной сети с модифицированной архитектурой U-Net. В качестве входных данных используются много-спектральные спутниковые изображения, получаемые с прибора МСУ-ГС, установленного на космическом аппарате «Арктика-М» № 1. Точность работы алгоритма оценена с помощью метрик машинного обучения и сравнения полученных результатов с эталонными масками, составленными путем визуального дешифрирования спутникового изображения опытным специалистом-дешифровщиком. Проведено сравнение с аналогичными продуктами по данным приборов SEVIRI и VIIRS. Для областей, освещенных солнцем, маска облачности, полученная предлагаемым алгоритмом, имеет точность 92% по сравнению с эталонной, а для не освещенных — 89%.

Ключевые слова: МСУ-ГС, «Арктика-М», маска облачности, детектирование облачности, нейросетевой классификатор, U-Net; MSU-GS, Arktika-M, cloud mask, cloud detection, neural network classifier, U-Net.

Введение

В спутниковой метеорологии одной из важнейших задач является детектирование облачных образований. Технические возможности оптической и радиолокационной аппаратуры, устанавливаемой на современные космические аппараты (КА), позволяют проводить круглосуточные наблюдения различных объектов и явлений. Качество выходной гидрометеорологической продукции, такой как макро- и микрофизические параметры облачности и атмосферы, интенсивность осадков, температура поверхности океанов и суши, зависит от точности детектирования облачного покрова. Поэтому корректное и оперативное обнаружение облачности на спутниковом изображении остается актуальной задачей.

В феврале 2021 г. на высокоэллиптическую орбиту был запущен гидрометеорологический КА «Арктика-М» № 1. Таким образом появилась воз-

можность получать спутниковые изображения земного диска с захватом полярной шапки каждые 15 мин на шестичасовом интервале рабочего участка орбиты. Получаемая информация с КА «Арктика-М» № 1 — весомое дополнение к имеющемуся аэросиноптическому материалу при составлении оперативных прогнозов погоды и состояния атмосферы. Но для автоматического получения большинства спутниковых продуктов требуется точное обнаружение облачности, для которой будут выполняться дальнейшие расчеты, т.е. получение маски облаков.

Для решения такого рода задач существуют различные методы и технологии. К первой группе можно отнести алгоритмы точечного анализа изображения (по пикселям). В них используются пороговые значения какого-либо параметра для определения типа объекта по спутниковым данным (спектральные методы), а также дополнительные математические преобразования спутниковых данных, такие как вейвлет-преобразование, различные индексы изображений (NDWI, NDSI и т.д.) и др. Подобного рода алгоритмы достаточно просты в реализации и широко применяются для классификации типов подстилающей поверхности и детектирования облачности [1–4], но к их минусам можно отнести

* Владислав Дмитриевич Блощинский (v.bloshchinsky@dvrcpod.ru); Любовь Сергеевна Крамарева (kramareva@dvrcpod.ru); Юлия Андреевна Шамилова (shamilova_ya@dvrcpod.ru).

трудоемкость выбора самих пороговых значений, а также их сезонную и территориальную зависимость [5].

Ко второй группе можно отнести алгоритмы текстурного анализа данных, которые в настоящее время получают все большую распространенность в области дистанционного зондирования Земли. Они основаны либо на непосредственном анализе текстуры (например, с помощью расчета матриц GLCM или с применением алгоритмов кластеризации), либо на машинном обучении, где чаще всего используются сверточные нейронные сети [6–8]. Такие методы, по сравнению с алгоритмами попиксельного анализа, позволяют учесть больше входных признаков, которые могут быть выражены неявно, что в среднем дает возможность проводить более точный анализ изображений [5].

Цель настоящей работы — разработка алгоритма детектирования облачного покрова по данным прибора МСУ-ГС (многозональное сканирующее устройство гидрометеорологического обеспечения), установленного на КА «Арктика-М» № 1 с использованием нейронной сети. Архитектура сети подобна U-Net и позволяет проводить сегментацию изображения. Для обучения сети были использованы примеры масок облачности, полученные по результатам ручного дешифрирования спутниковых снимков.

Исходные данные

Основной целевой аппаратурой КА «Арктика-М» № 1 является МСУ-ГС, модернизированное для работы на высокоэллиптической орбите. Данный прибор позволяет получать изображения всего видимого диска Земли в трех видимых и семи инфракрасных участках спектра. Наличие инфракрасных каналов крайне важно ввиду того, что значительную часть времени Арктический регион не освещен солнцем во время полярной ночи. Спектральные характеристики и разрешение каналов прибора представлены в табл. 1.

Основная проблема при детектировании облачных образований по данным КА «Арктика-М» № 1 состоит в том, что конструктивным исполнением прибора МСУ-ГС не предусмотрен канал с центральной длиной волны, близкой к 1,6 мкм, который бы позволял с большой достоверностью отличать снег от облачности. В областях, освещенных солнцем, данная проблема частично решается использованием синтеза каналов с центральными длинами волн 0,9; 3,8 и 10,7 мкм. Но в областях, находящихся выше 60° с.ш. или не освещенных солнцем, такой способ разделения не эффективен.

Метод

Из-за конструктивных особенностей в приборе МСУ-ГС ограничено число инфракрасных каналов, которые бы позволили применить пороговые методики для детектирования облачности с высокой точностью. Целесообразнее рассмотреть подходы, опирающиеся на текстурный анализ, которые в меньшей степени зависят от региональных особенностей и спектральных характеристик спутникового прибора. Поэтому была рассмотрена возможность применения алгоритмов, опирающихся на текстурные признаки, присущие только классу подстилающей поверхности или облачности. Подобный опыт был описан в [9] для МСУ-ГС, установленного на КА «Электро-Л» № 2. Однако такой подход для данных КА «Арктика-М» № 1 давал низкую точность в областях, не освещенных солнцем, особенно на участках, где лед покрыт снегом. Эти участки характеризуются особенной текстурой, которую очень сложно обнаружить, если использовать для анализа входные данные малой размерности.

Такого рода проблема может быть решена с помощью сверточной искусственной нейронной сети, которая позволяет проводить сегментацию входного изображения большого размера. Одной из наиболее часто используемых и хорошо зарекомендовавших себя является архитектура U-Net,

Таблица 1

Характеристики каналов прибора МСУ-ГС

Канал	Спектральный диапазон/ центральная длина волны, мкм	Разрешение, км	Область применения
1	0,4–0,7/0,6	1	Детектирование облачности, слежение за облаками-трассерами для определения направления ветра, наблюдение аэрозоля
2	0,6–0,8/0,7		
3	0,7–0,9/0,9		
4	3,4–4,4/3,8	4	Детектирование облачности малых размеров
5	5,3 – 6,9/6,3		Детектирование низкой облачности, туманов, оценка температуры поверхности океанов (ТПО) и температуры поверхности суши (ТПС) в ночных условиях
6	7,0–8,9/8,0		Наблюдения за водяным паром, оценка скорости ветра, высоты полупрозрачной облачности
7	8,1–9,7/8,9		Наблюдения полупрозрачной слоистой облачности
8	8,7–10,6/9,7		Мониторинг общего содержания озона, оценка скорости ветра в нижней тропосфере
9	9,7–11,8/10,7		Оценка ТПО, ТПС, количества осадочной воды над океанами, слежение за облаками-трассерами для определения скорости и направления ветра, определение характеристик облачности
10	10,6–13,0/11,2		

которая состоит из двух частей: кодировщика и декодировщика, каждый из которых включает несколько «ступеней» сверточных слоев. Применение данной архитектуры позволяет достаточно эффективно и с высокой производительностью сегментировать изображения. Такой метод используется во многих областях компьютерного зрения, в том числе дистанционном зондировании Земли [10, 11].

В настоящей работе предлагается модифицированная архитектура U-Net. От классической [12] она отличается тем, что после слоев свертки дополнительно включены слои пакетной нормализации, что улучшает стабильность обучения. Также в связи между «ступенями» кодировщика и декодировщика включены слои внимания. Они были добавлены, так как при передаче информации от нижних уровней к более высоким может поступать много неверных или мешающих данных. Слой внимания в данном случае помогает нейронной сети определять полезные части входного изображения и наиболее важные параметры, на которых следует сфокусироваться для выполнения задачи. Предлагаемая архитектура изображена на рис. 1, где обозначены размерности слоев для каждого уровня и количество карт признаков в сверточных слоях.

Подобный подход к решению задачи был также представлен в [13], где детектирование облачности проводилось для данных высокого разрешения КА Landsat 8.

Для обучения нейросетевого классификатора необходимо подготовить набор данных, который включал бы в себя примеры многоканальных изображений, содержащих различные сочетания объектов, а в качестве эталона для обучения содержал бы маски, определяющие принадлежность каждого пикселя к одному из детектируемых классов.

Многоканальные изображения для сегментации набирались по спутниковым снимкам прибора

МСУ-ГС, где видимые каналы были приведены к разрешению 4 км. Опытным специалистом-дешифровщиком были присвоены классы облачности и подстилающей поверхности для каждого пикселя спутниковых снимков с июня 2022 по март 2023 г., выбранных случайным образом. Для определения облачности анализировались как сами изображения каналов спутникового прибора, так и информация с прогностической модели, синоптических карт и данные с других КА, а также изменения положения облачности во времени по серии снимков.

В рамках решения поставленной задачи было отобрано 40 снимков с КА «Арктика-М» № 1, каждый из которых был разбит на многоканальные изображения размером 256×256 пикселей, содержащие все каналы прибора МСУ-ГС. В качестве входных параметров была добавлена информация о зенитных углах солнца и наблюдения спутника, так как существует физическая зависимость значений яркостной температуры в каналах прибора от угла, под которым солнце освещает рассматриваемую область, и от угла, под которым ведется съемка этой области. Для улучшения качества обучения нейронной сети число изображений в выборке было увеличено путем их отражения по вертикали и горизонтали, а также поворота на 90° , 180° и 270° . Таким образом, итоговый набор был составлен из 17 тыс. многоканальных изображений.

Были проведены эксперименты на выявление наиболее информативных входных параметров, обеспечивающих наилучшую точность работы нейронной сети. Для этого поочередно исключались по одному, два и т.д. входных параметра и проводилось обучение. Таким образом было установлено, что для корректного обучения достаточно использовать восемь каналов прибора МСУ-ГС (каналы с центральными длинами волн 0,6; 0,7; 0,9; 3,8;




Рис. 1. Архитектура нейронной сети (N — количество входных параметров в многоканальном изображении)

6,3; 8,0; 10,7 и 11,2 мкм), зенитный угол солнца и зенитный угол наблюдения спутника.

Процесс обучения нейронной сети заключается в итерационной перенастройке весовых коэффициентов у нейронов заданным алгоритмом оптимизации. В качестве функции потерь была выбрана бинарная кросс-энтропия, так как она хорошо зарекомендовала себя при бинарной классификации. В качестве алгоритма оптимизации был выбран алгоритм Adam (adaptive moment estimation), в котором сочетаются идеи сохранения инерции и масштабирования градиента.

Результаты и обсуждение

Для оценки качества работы нейронной сети по детектированию облачности были рассчитаны метрики машинного обучения. Также проведено сравнение полученных результатов с маской, созданной специалистом-дешифровщиком по результатам визуального дешифрирования спутникового изображения. В дополнение проведено сравнение с аналогичным продуктом по данным приборов SEVIRI и VIIRS космических аппаратов Meteosat-11 и NOAA-20.

Обученная нейросетевая модель проверялась метриками машинного обучения на тестовой выборке. В качестве метрик, как и при обучении, были рассмотрены точность, полнота и f -мера. Дополнительно были рассчитаны метрики отдельно для территорий, освещенных и не освещенных солнцем. В табл. 2 представлены полученные результаты.

Таблица 2

Метрики машинного обучения для тестовой выборки, %

Территория	Точность	Полнота	f -мера
Полная	88,9	89,6	90,9
Освещена солнцем	96,7	95,6	93,6
Не освещена солнцем	84,5	83,9	88,9

Дополнительно к проверке метриками на тестовой выборке было проведено сравнение с аналогичными продуктами, построенными по данным прибора SEVIRI геостационарного КА Meteosat-11 в областях до 60° с.ш. и по данным прибора VIIRS полярно-орбитального КА NOAA-20 для области полярной шапки. Указанные выше продукты и маска облачности, определенная по предлагаемой методике на основе нейронной сети по данным КА «Арктика-М» № 1, также сравнивались с эталонными масками, полученными путем ручного дешифрирования изображений. Сравнения проводились по отдельно взятым полигонам с июля по октябрь 2022 г. Всего было выбрано 20 полигонов (10 для сравнения с маской по данным прибора SEVIRI и 10 для VIIRS).

На рис. 2 и 3 приведены примеры классификации, размеченные специалистом-дешифровщиком, маска, сформированная предлагаемым классифика-

тором, и маска по данным других КА. Для оценки совпадений масок рассчитывался процент совпавших по классам (облачность/не облачность) пикселей по отношению к общему числу пикселей. Таким образом, для полигонов, отобранных для сравнения с данными прибора SEVIRI, маска, сформированная предлагаемой методикой, совпадала с маской по данным SEVIRI на 93%. Для данных МСУ-ГС процент совпадения с результатами ручного дешифрирования изображений составил 92%, а для данных SEVIRI — 94%. Для полигонов, отобранных для сравнения с данными прибора VIIRS, процент совпадения масок по данным МСУ-ГС и VIIRS составил 84%. Процент совпадений с данными ручного дешифрирования для МСУ-ГС — 89%, а для VIIRS — 87%.

По результатам проведенной валидации и визуальной оценки результатов можно сделать вывод, что маски, созданные представленным в работе нейросетевым классификатором по данным МСУ-ГС, обладают высокой точностью детектирования облачности в областях, освещенных солнцем. При этом отмечаются проблемы в области, не освещенной солнцем, особенно для территорий выше 60° с.ш., связанные с особенностью распределения значений приземной температуры и температуры верхней границы облаков, а также гладкой структуры поверхности, покрытой снежным покровом. Также отмечается падение точности детектирования при больших значениях зенитного угла наблюдения спутника. Для углов >70° общая точность снижается до 86,7%; для областей, освещенных солнцем, — до 93,8%, а для не освещенных — до 83,2%. Это связано с искажениями из-за особенностей геометрии съемки поверхности Земли вблизи края наблюдаемого полудиска. При этом даже при отсутствии канала с центральной длиной волны, близкой к 1,6 мкм, предлагаемая методика детектирования облачности по данным МСУ-ГС сопоставима по точности с аналогичными продуктами, полученными по данным зарубежных КА.

Предлагаемый алгоритм должен детектировать облачность практически во всем диапазоне оптических толщин, так как для обучения нейронной сети при создании эталонных масок специалистом-дешифровщиком выделялась вся облачность, которая может быть определена по данным МСУ-ГС, установленного на КА «Арктика-М» № 1. Но ввиду того, что существует большая неопределенность в части съемки подобными спутниковыми приборами облаков с малой оптической толщиной (около 3–5) и дальнейшего определения их оптической толщины и характеристик [14], уверенное детектирование будет осуществляться для оптической толщины больше 5. Для меньших значений будут проявляться ошибки, особенно над поверхностью суши, где большое влияние имеют исходящее и отраженное излучение поверхности.




Рис. 2. Сравнение маски облачности по данным MSU-ГС с масками по данным SEVIRI в области, освещенной солнцем: *а* – спутниковое изображение в видимом диапазоне спектра прибора MSU-ГС; *б* – маска, полученная специалистом-дешифровщиком; *в* – маска, полученная предлагаемым классификатором; *г* – маска по данным SEVIRI




Рис. 3. Сравнение маски облачности по данным MSU-ГС с масками по данным VIIRS в области, неосвещенной солнцем: *а* – спутниковое изображение в инфракрасном диапазоне спектра прибора MSU-ГС; *б* – маска, полученная специалистом-дешифровщиком; *в* – маска, полученная предлагаемым классификатором; *г* – маска по данным VIIRS

Заключение

На основе нейронной сети с модифицированной архитектурой U-Net был разработан классификатор, позволяющий детектировать облачные образования на спутниковых изображениях с прибора МСУ-ГС космического аппарата «Арктика-М» № 1. Получаемые маски облаков не уступают по качеству аналогичным продуктам по данным SEVIRI и VIIRS. Представленный классификатор не требует настройки каких-либо значений и работает в любое время года. Для корректной работы необходимо использовать восемь каналов с длинами волн 0,6; 0,7; 0,9; 3,8; 6,3; 8,0; 10,7 и 11,2 мкм прибора МСУ-ГС, а также информацию о зенитных углах солнца и наблюдения спутника. Проведенная валидация показала, что возможны ошибки классификации в областях, не освещенных солнцем, из-за специфики используемых данных и на краях изображения из-за геометрического искажения при съемке поверхности.

Благодарности. В работе использовались ресурсы Центра коллективного пользования системами архивации, обработки и анализа данных спутниковых наблюдений Института космических исследований РАН для решения задач изучения и мониторинга окружающей среды (ЦКП «ИКИ-Мониторинг»).

Финансирование. Исследование выполнено при финансовой поддержке РФФИ (грант № 23-77-00011, <https://rscf.ru/project/23-77-00011/>).

Список литературы

1. Miller S., Lee T., Fennimore R. Satellite-based imagery techniques for daytime cloud/snow delineation from MODIS // J. Appl. Meteorol. 2005. V. 44. P. 987–997.
2. Hawotte F., Radoux J., Chomé G., Defourny P. Assessment of automated snow cover detection at high solar zenith angles with PROBA-V // Remote Sens. 2016. V. 8, N 9. P. 699.
3. Zhu Z., Woodcock C.E. Object-based cloud and cloud shadow detection in Landsat imagery // Remote Sens. Environ. 2012. V. 118. P. 83–94.
4. Jedlovec G. Automated detection of clouds in satellite imagery // Adv. Geosci. Remote Sens. 2009. P. 303–316.
5. Mahajan S., Fataniya B. Cloud detection methodologies: Variants and development — a review // Complex Intelligent Syst. 2020. V. 6. P. 251–261.
6. Chen Y., Fan R., Bilal M., Yang X., Wang J., Li W. Multilevel cloud detection for high-resolution remote sensing imagery using multiple convolutional neural networks // ISPRS Int. J. Geo-Inf. 2018. V. 7, N 5. P. 181.
7. Wen-Jia C., Jiang-Yong D., Juan M. Cloud detection via convolutional neural network in visible light remote sensing image // 2nd International Conference on Artificial Intelligence: Techniques and Applications (AITA 2017). China: DEStech Publications, 2017. P. 38–43.
8. Zhaoxiang Z., Iwasaki A., Xu G., Song J. Cloud detection on small satellites based on lightweight U-net and image compression // J. Appl. Remote Sens. 2019. V. 13, N 2. P. 026502.
9. Bloshchinskiy V.D., Kuchma M.O., Andreev A.I., Sorokin A.A. Snow and cloud detection using a convolutional neural network and low-resolution data from the Electro-L No. 2 Satellite // J. Appl. Remote Sens. 2020. V. 14, N 3. P. 034506.
10. Cao K., Zhang X. An Improved Res-UNet model for tree species classification using airborne high-resolution images // Remote Sens. 2020. V. 12. P. 1128.
11. Soni A., Koner R., Villuri V.G.K. M-UNet: Modified U-Net segmentation framework with satellite imagery / J. Mandal, S. Mukhopadhyay (eds.) // Proc. of the Global AI Congress 2019. Advances in Intelligent Systems and Computing. Singapore: Springer, 2020. V. 1112. P. 47–59.
12. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // N. Navab, J. Hornegger, W. Wells, A. Frangi (eds.). Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015. MICCAI 2015. Lecture Notes in Computer Science. Cham: Springer, 2015. V. 9351.
13. Guo Y., Cao X., Liu B., Gao M. Cloud detection for satellite imagery using attention-based U-Net convolutional neural network // Symmetry. 2020. V. 12, N 6. P. 1056.
14. Филей А.А. Восстановление оптической толщины и эффективного радиуса частиц облачности по данным дневных измерений спутникового радиометра МСУ-МП // Оптика атмосф. и океана. 2019. Т. 32, № 8. С. 650–656.

V.D. Bloshchinskiy, L.S. Kramareva, Yu.A. Shamilova. Cloud cover detection using a neural network based on MSU-GS instrument data of Arktika-M No 1 satellite.

The paper presents an algorithm based on a convolutional neural network with a modified U-Net architecture for detecting cloud formations in satellite images. Multispectral satellite images obtained from the MSU-GS instrument installed at Arktika-M No 1 satellite are used as input data. The accuracy of the algorithm was evaluated using machine learning metrics and comparing the results with reference masks compiled by manual decryption of the satellite images by an experienced decoder specialist. In addition, a comparison with similar products based on data of the SEVIRI and VIIRS instruments was conducted. For areas illuminated by the sun, the cloud mask obtained by the proposed algorithm has an accuracy of 92% compared to the reference mask, and for areas not illuminated by the sun, the accuracy is 89%.