

Программный комплекс восстановления параметров облачности по спутниковым данным ВПО-СД

А. А. Филей, А. И. Андреев, Ю. А. Шамилова

Дальневосточный центр НИЦ «Планета», Хабаровск, 680000, Россия
E-mail: andreym-61@mail.ru

Рассмотрены функциональные возможности программного комплекса восстановления параметров облачности по спутниковым данным ВПО-СД. По измерениям в каналах спутниковых приборов (таких, как МСУ-МР (многоканальное сканирующее устройство малого разрешения), МСУ-ГС (многозональное сканирующее устройство гидрометеорологического обеспечения), АНІ (англ. Advanced Himawari Imager), AVHRR (англ. Advanced Very High Resolution Radiometer), АМІ (англ. Advanced Meteorological Imager), SEVIRI (англ. Spinning Enhanced Visible and InfraRed Imager) и др.) комплекс позволяет получать информацию об оптических и микрофизических параметрах облачности, высоте верхней границы, проводить классификацию типов облачности, определять зоны осадков и их интенсивность. В работе кратко изложена информация об алгоритмах и методиках восстановления каждого из параметров облачности. Комплекс ВПО-СД имеет кросс-платформенное исполнение, гибкую настройку обработки спутниковой информации и работает в полностью автоматическом режиме. В нём реализованы методики и алгоритмы на основе спектрального и нейросетевого анализа спутниковых данных. По мере использования данных новых спутниковых приборов алгоритмы и методики комплекса проходят доработку с учётом функциональных особенностей этих приборов. Восстановленные параметры облачности сохраняются в цифровых и растровых форматах данных и посредством разработанных геоинформационных систем доступа «Арктика-М» (<https://apps.dvrcpod.ru/arcticgis/>) и «Метеор-М» (<https://apps.dvrcpod.ru/meteorgis/>) предоставляются территориальным управлениям по гидрометеорологии и мониторингу окружающей среды, авиационным метеорологам, а также органам государственной власти и МЧС.

Ключевые слова: ВПО-СД, спутниковые данные, параметры облачности, нейронные сети

Одобрена к печати: 12.12.2023

DOI: 10.21046/2070-7401-2024-21-1-106-121

Введение

Известно, что облака участвуют в круговороте воды в природе и влияют на многие процессы, протекающие в атмосфере и формирующие погоду. Отсюда следует необходимость в точных наблюдениях за облаками для проверки климатических моделей прогноза погоды и мониторинга изменения климата. Одним из важных и эффективных инструментов для получения обширной информации о свойствах облачности на сегодняшний день являются данные дистанционного зондирования Земли из космоса. Регистрируя электромагнитное излучение, космические аппараты (КА) способны наблюдать за облачностью в глобальном масштабе с высоким временным и пространственным разрешением, позволяя получать информацию об эволюции и времени жизни облачной системы. Взаимодействие электромагнитного излучения с облаками зависит от многих параметров, таких как высота облачности, геометрическая толщина, оптические и микрофизические параметры, типы и водозапас облачности и др. Расчёт этих параметров становится одной из главных задач при обработке данных дистанционного зондирования Земли. С этой целью в Дальневосточном центре НИЦ «Планета» был разработан и внедрён в оперативную практику программный комплекс восстановления параметров облачности по спутниковым данным ВПО-СД. В программном комплексе реализованы методики и алгоритмы на основе спектрального и нейросетевого анализа спутниковых данных. Восстановление параметров облачности осуществляется для широкого спектра спутниковых приборов, таких как MODIS (англ. Moderate Resolution Imaging Spectroradiometer), АНІ (англ. Advanced Himawari Imager), АВІ (англ. Advanced Baseline Imager), AVHRR (англ. Advanced Very High Resolution Radiometer), МСУ-МР (многоканаль-

ное сканирующее устройство малого разрешения), МСУ-ГС (многозональное сканирующее устройство гидрометеорологического обеспечения), SEVIRI (*англ.* Spinning Enhanced Visible and InfraRed Imager) и др. Пакет ВПО-СД — специализированный многофункциональный программный комплекс обработки спутниковых данных для получения информации о параметрах облачности, который не уступает по своим функциональным возможностям таким программным продуктам, как CLAVR-X (*англ.* Clouds from AVHRR Extended System, <http://cimss.ssec.wisc.edu/clavr/>), SAFNWC/PPS (*англ.* Satellite Application Facility on support to Nowcasting/Polar Platform System, <https://www.nwcsaf.org/>) или КПМ (Комплексная пороговая методика) (Волкова, 2013). Комплекс направлен на решение широкого круга задач, в первую очередь на удовлетворение потребностей профильных специалистов в области синоптической метеорологии и гидрологии. Новизна и практическая ценность ВПО-СД заключается в том, что реализованные в нём алгоритмы по восстановлению параметров облачности сочетают в себе как классические спектральные методики, так и методики, основанные на машинном обучении, в частности нейронных сетях. Комплекс имеет кросс-платформенное исполнение и работает в полностью автоматическом режиме, позволяет получать информацию об оптических и микрофизических параметрах облачности, высоте верхней границы, проводить классификацию типов облачности, определять зоны осадков и их интенсивность. Результаты работы комплекса по восстановлению параметров облачности сопоставлялись с результатами алгоритмов, разработанных для зарубежных спутниковых приборов. По результатам сопоставления искомые параметры облачности находятся в допустимых пределах погрешности измерений.

Описание программного комплекса

Программный комплекс ВПО-СД написан на языках программирования Python и Fortran, обладает модульной структурой, где каждый из модулей имеет определённое функциональное назначение. Общая схема работы комплекса представлена на *рис. 1* (см. с. 108).

Работа программного комплекса начинается с распаковки спутниковых данных. Так как данные от разных спутниковых приборов могут быть представлены в разных единицах измерения, то осуществляется их преобразование к терминам коэффициента отражения (КО) и яркостной температуры. Кроме этого, рассчитываются географическая привязка и углы наблюдения спутникового прибора: спутниковый зенитный угол, солнечный зенитный угол, относительный азимутальный угол. Полный список спутниковых приборов, данные которых поддерживает комплекс ВПО-СД на момент написания настоящей работы, представлен в *таблице*.

Список приборов, представленный в *таблице*, не исчерпывающий. По мере запуска на орбиту нового спутникового прибора программный комплекс дорабатывается с учётом характеристик данного прибора. Для каждого спутникового прибора из *таблицы* в зависимости от его спектральных характеристик предварительно строятся справочные таблицы, которые содержат информацию об оптических свойствах объёмного рассеяния кристаллов льда и капель воды в каналах прибора. Справочные таблицы содержат КО, которые моделируются с помощью быстрой радиационной модели на основе программного кода DISORT (*англ.* Discrete Ordinates Radiative Transfer) (Buras et al., 2011), входящего в состав библиотеки libradtran (Mayer et al., 2020). Для моделирования оптических свойств объёмного рассеяния кристаллов льда облачности используется модель рассеяния Baum (Baum et al., 2005a, b), а для капель воды — модель Hu (Hu, Stamnes, 1993). Выбор в пользу модели Baum был сделан по причине её широкого распространения при восстановлении оптических и микрофизических параметров облачности по данным таких радиометров, как MODIS, АНІ, АВІ и др. (Walther, Heidinger, 2012). Справочные таблицы включены в блок статической информации на *рис. 1*. Кроме этого, в блок статической информации включены сезонные карты альбедо (Vidort, Vorbas, 2014) и коэффициентов излучения (Vorbas, Ruston, 2010), которые были получены с сайта <https://saf.eumetsat.int/>. Информация об альбедо и коэффициентах излучения необходима для решения обратной задачи переноса излучения в атмосфере.

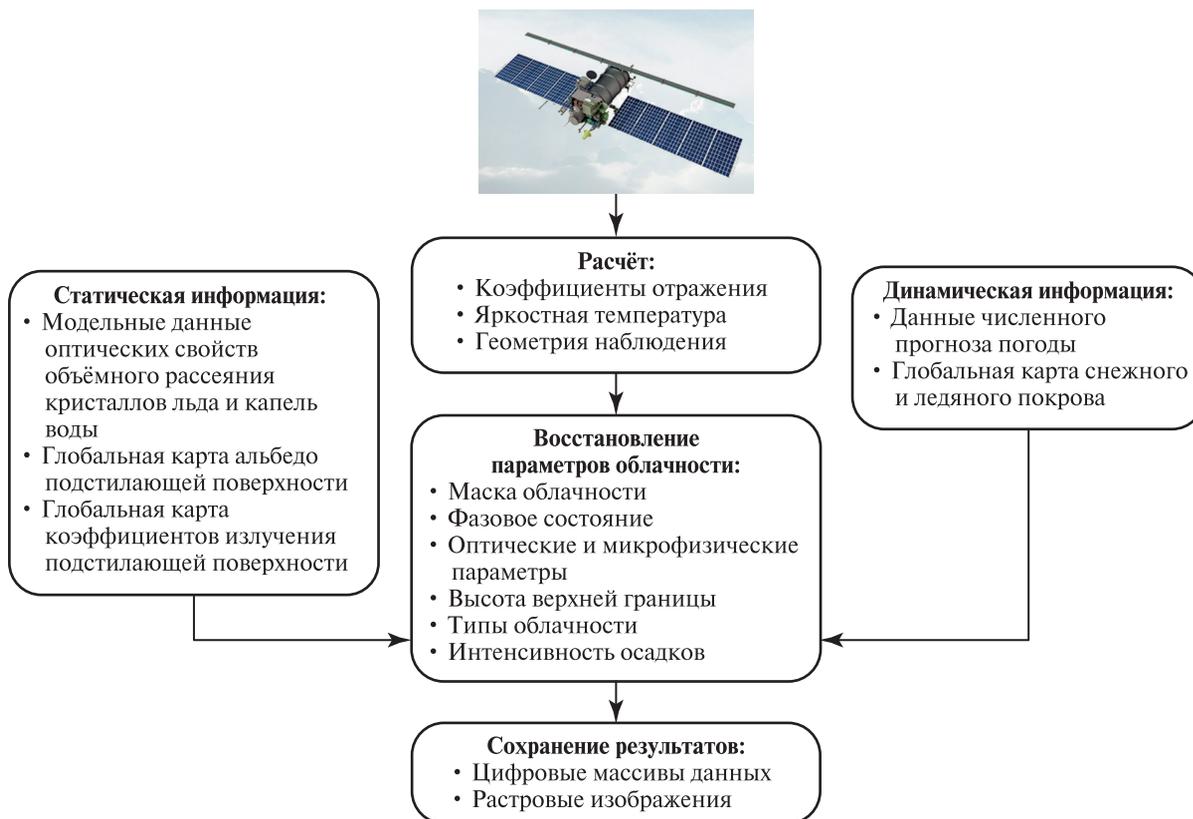


Рис. 1. Общая схема работы комплекса ВПО-СД

Список поддерживаемых комплексом ВПО-СД спутниковых приборов

Спутниковый прибор	Источник данных
MODIS (КА Aqua, Terra)	modis.gsfc.nasa.gov
AVHRR (КА серии NOAA, MetOp)	avl.class.noaa.gov, nwp-saf.eumetsat.int
AHI (КА Himawari-8/9)	www.jma.go.jp
AMI (КА GK-2A)	nmsc.kma.go.kr
AGRI (КА FY-4B)	fy4.nsmc.org.cn
VIIRS (КА Suomi-NPP, NOAA-20/21)	avl.class.noaa.gov, cimss.ssec.wisc.edu
SEVIRI (КА серии Meteosat)	navigator.eumetsat.int
МСУ-МР (КА серии «Метеор-М»)	www.dvrcpod.ru
МСУ-ГС (КА серии «Электро-Л», «Арктика-М»)	www.dvrcpod.ru

Примечание: AMI — *англ.* Advanced Meteorological Imager; AGRI — *англ.* Advanced Geostationary Radiation Imager; VIIRS — *англ.* Visible Infrared Imaging Radiometer Suite; NPP — *англ.* The National Polar-orbiting Operational Environmental Satellite System Preparatory Project; NOAA — *англ.* National Oceanic and Atmospheric Administration; MetOp — *англ.* Meteorological Operational; GK-2A — GEO-KOMPSAT-2A (*англ.* Geostationary Korea Multi-Purpose Satellite – 2A); FY-4B — Feng-Yun-4B.

Данные численного прогноза погоды (ЧПП) в блоке динамической информации (см. рис. 1) скачиваются с сайта www.ncei.noaa.gov и файлового сервера [ftp.ssec.wisc.edu](ftp://ssec.wisc.edu) во время оперативной работы программного комплекса для каждого сеанса съёмки. Пользователь может сам задавать пространственное разрешение прогностической информации, равное 0,5 или 1,0°. Прогностическая информация служит для расчёта пропускания атмосферы, необходимого для решения уравнения теплопереноса при восстановлении температуры верхней

границы облачности и последующего расчёта её высоты. Карта снежного покрова используется для определения оптических и микрофизических параметров облачности по измерениям в коротковолновой области спектра.

С помощью статической и динамической информации восстанавливаются параметры облачности с использованием спектрального и нейросетевого подходов. Результаты восстановления записываются в цифровые (hdf5, tiff) и растровые (jpg) массивы данных. Подробно о методике и алгоритмах восстановления параметров облачности написано в следующем разделе настоящей работы.

Восстановление параметров облачности

Маска облачности

Восстановление информационных продуктов облачности начинается с детектирования маски облачности. Маска облачности используется для точного определения границ облачных зон, что крайне важно для процедур расчёта информационных продуктов, связанных с облачностью. Алгоритм построения масок облачности основан на применении свёрточных нейронных сетей (СНС), и его базовые основы описаны в работе (Андреев и др., 2019). В качестве входных данных используются многоспектральные спутниковые изображения облачности и поверхности Земли, получаемые со спутникового прибора, а также информация о зенитном угле Солнца для каждого пикселя изображения.

Алгоритм обнаружения облачности основан на применении метода спектрального и текстурного анализа. Для этого из исходных изображений спектральных каналов формируются многоканальные текстуры размером 5×5 пикселей, где каждый канал текстуры относится к определённому спектральному диапазону. Центральный пиксель текстуры соответствует одному из возможных классов (подстилающая поверхность/снежный покров/облачность), соседние же пиксели несут информацию об окружающем контексте и структуре рассматриваемой поверхности. Для обучения СНС формируются наборы данных из размеченных вручную специалистами-дешифровщиками текстур достаточного объёма (порядка нескольких десятков тысяч примеров), включающие все возможные виды облачности, земли, водной поверхности и др.

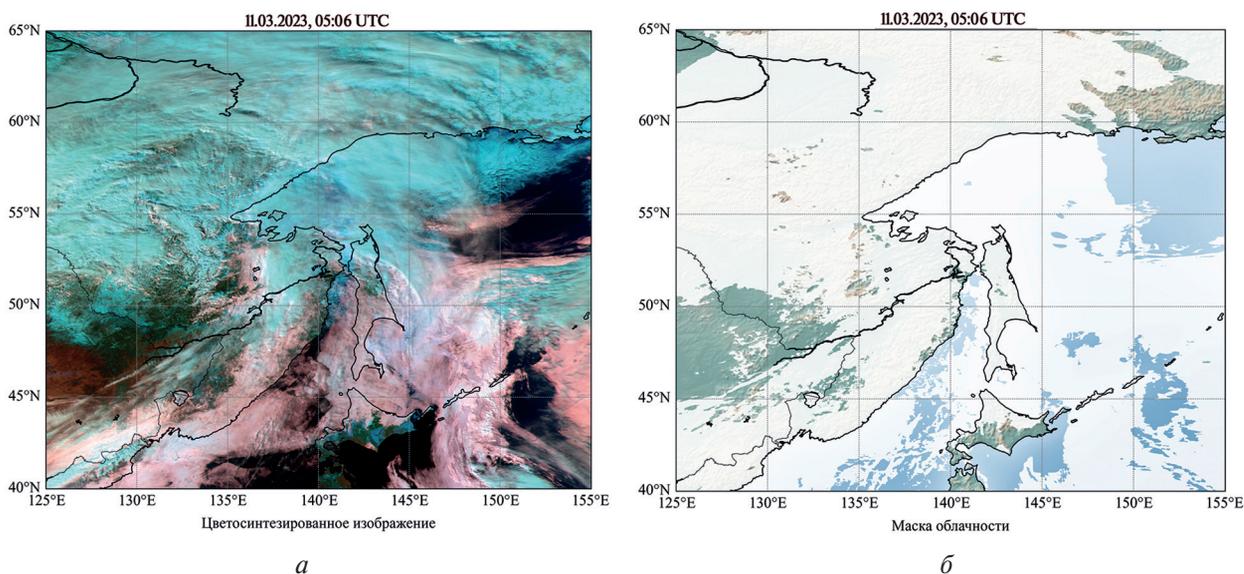


Рис. 2. Информационная продукция по данным спутникового прибора МСУ-МР КА «Метеор-М» № 2-2: *а* — цветосинтезированное изображение; *б* — маска облачности

Архитектура СНС представляет собой полносвёрточный нейросетевой классификатор. На её вход подаются совокупности текстур, а на выходе нейронная сеть выдаёт спрогнозированные вероятности того, к какому классу относится рассматриваемый центральный пиксель. Для итогового определения класса выбирается наибольшее значение из полученных вероятностей. Методом скользящего окна проводится классификация для каждого пикселя. По завершении работы алгоритма на выходе формируется маска с размерностью, соответствующей исходному спутниковому изображению, содержащая цифровую информацию о том, к какому из возможных классов относится рассматриваемый пиксель изображения. Используется три класса с соответствующими кодами: 0 — класс чистой земли или воды; 1 — класс снежного покрова; 2 — класс облачности. Пример детектированной маски облачности с применением указанного алгоритма по данным спутникового прибора МСУ-МР КА «Метеор-М» № 2-2 показан на *рис. 2* (см. с. 109). Маска облачности на *рис. 2а* выделена белым цветом. Оцениваемая точность обнаружения облачности сильно зависит от условий наблюдений (освещённости, наличия снега и льда, учёта тонкой перистой облачности и других факторов) и варьируется от 84 до 97 % в сравнении с результатами ручного дешифрирования специалистами и масками, рассчитываемыми по данным приборов MODIS и VIIRS.

Фазовое состояние облачности

Методика определения фазового состояния облачности (ФСО), которая реализована в программном комплексе ВПО-СД, подробно описана в работе (Филей, 2019а). В основе методики принято утверждение, что ФСО различных форм облачности определяется их температурным режимом. Для оптически толстых облаков яркостная температура на длине волны 11 мкм ($T_{я11}$) будет близка к фактической температуре облака. То есть для определения ФСО могут использоваться простые температурные пороги, при которых вода всегда будет в виде капель, а лёд — в виде кристаллов. С большой долей вероятности оптически толстые облака при $T_{я11} < 243$ К всегда будут состоять из кристаллов льда, а при $T_{я11} > 273$ К — из капель воды. Помимо капель воды и кристаллов льда, облака могут иметь смешанную фазу. При отсутствии вертикальных движений смешанные облака неустойчивы: капли замерзают или испаряются, кристаллы растут. Время полной кристаллизации такого смешанного облака зависит от таких параметров, как температура и влажность облака, концентрация кристаллов. Согласно статистическим данным о повторяемости ФСО умеренных широт от температуры, максимальная вероятность появления смешанных облаков достигается при температуре 243–273 К. На основе данного температурного диапазона происходит деление смешанных облаков на «преимущественно капельные» и «преимущественно кристаллические». Деление происходит с использованием формулы доли кристаллов льда в облаке (Sundqvist et al., 1989):

$$p = 1 - 1,058 \left[1 - \exp \left(- \left(\frac{T_{я11} - 232}{24,04} \right)^2 \right) \right],$$

где p — доля кристаллов льда в облаке.

Если p равно 0,25–0,5, то облако «преимущественно капельное», а если p равно 0,5–0,75 — «преимущественно кристаллическое».

Сопоставление результатов оценок ФСО представленного алгоритма с результатами алгоритмов, разработанных для зарубежных спутниковых приборов AVHRR и ABI (Pavolonis, 2010), показало, что доля совпадения оценок ФСО составляет свыше 80 %.

Стоит отметить, что при определении ФСО само облако рассматривается как одномерный плоскопараллельный слой. То есть представленная методика не позволяет оценивать фазовое состояние многослойной облачности. Случаи, когда кристаллическая облачность покрывает капельную, нередки, и в таких ситуациях алгоритм определения ФСО может давать ошибку. Для решения данной проблемы требуется разработка алгоритма обнаружения многослойной облачности. Тем более что существующие методики обнаружения многослойной облачности по данным пассивных спутниковых приборов позволяют это делать при

условии, что оптическая толщина облачности (τ_c) не больше восьми (Pavolonis, Heidinger, 2004). Методика обнаружения многослойной облачности и оценка её ФСО будет реализована в комплексе ВПО-СД в ходе будущих исследований по этому направлению.

Пример восстановленного ФСО облачности по данным спутникового прибора АМІ КА GK-2A показан на *рис. 3*.

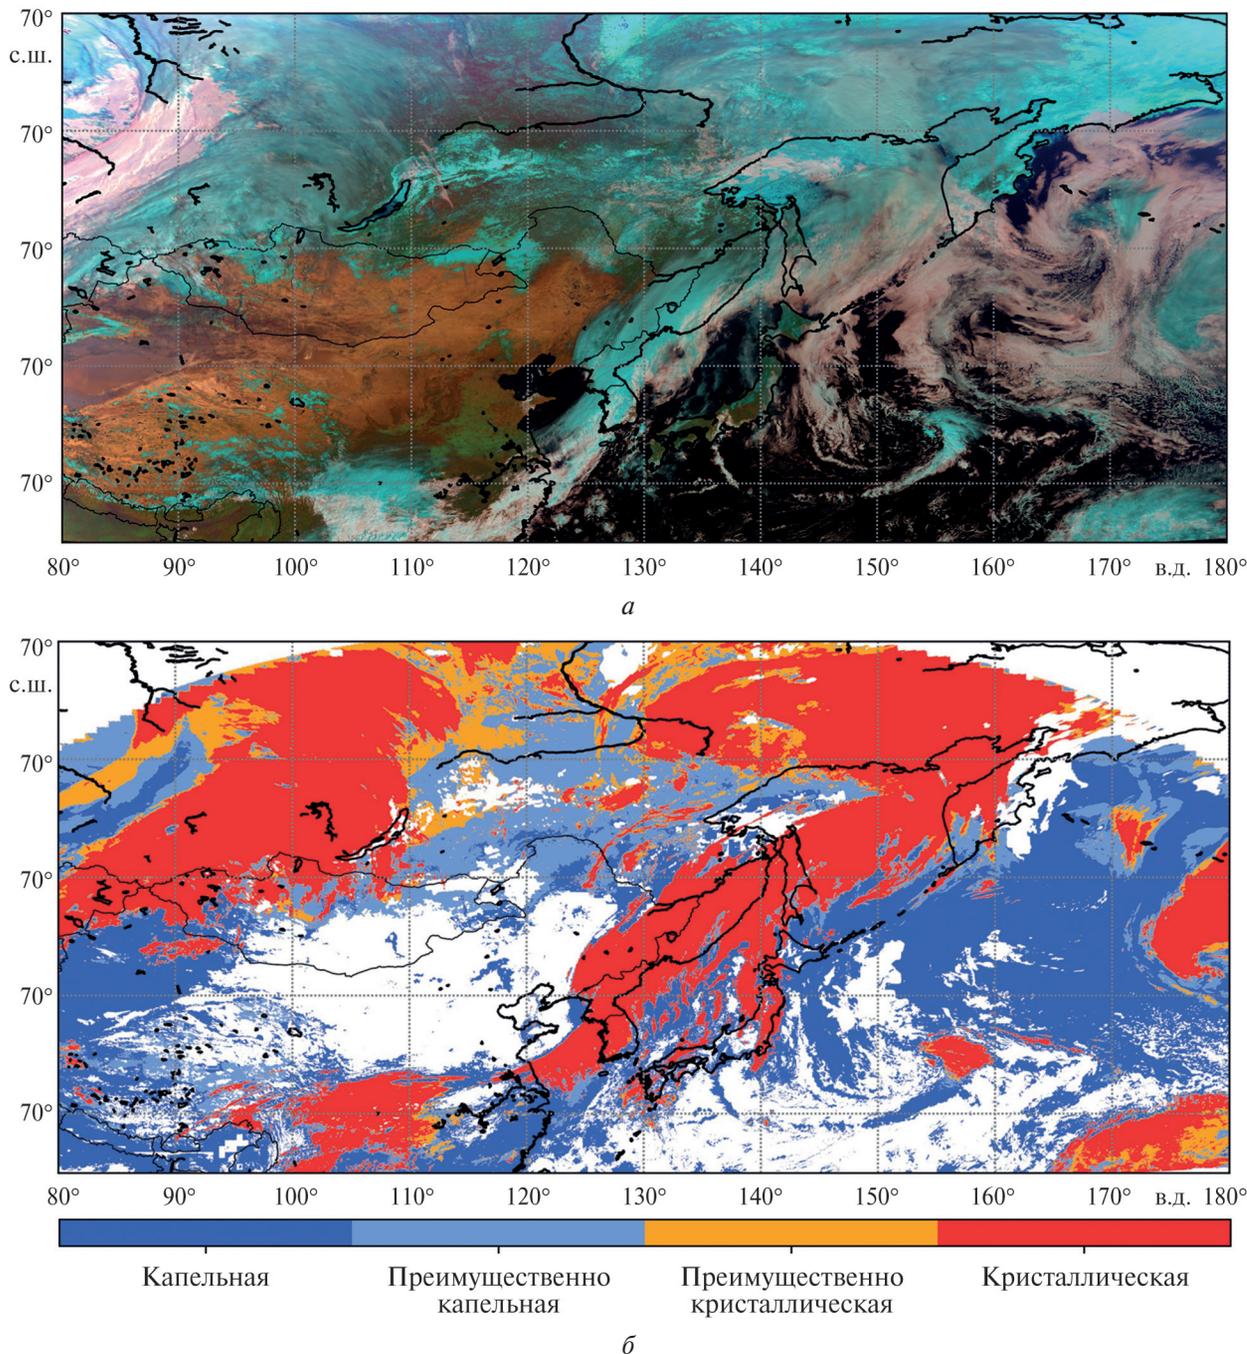


Рис. 3. Информационная продукция по данным спутникового прибора АМІ КА GK-2A за 12.03.2023, 02:30 UTC (*англ.* Coordinated Universal Time, всемирное координированное время): *а* — цветосинтезированное изображение; *б* — фазовое состояние облачности

Водозапас, оптическая толщина и эффективный радиус частиц облачности

Содержание воды (льда) в облачности характеризуется такой величиной, как водозапас (*англ.* Liquid Water Path — LWP), и является одним из важнейших параметров, влияющих на

радиационные процессы, протекающие в атмосфере и формирующие погоду. Показатель LWP позволяет специалистам оценить общую массу сконденсированной воды в облаке с целью прогноза погоды, проверки климатических моделей и мониторинга изменения климата. Оценить LWP можно, зная информацию об оптической толщине и эффективном радиусе (r_e) частиц облачности. Принцип определения τ_c и r_e основан на том, что КО облачности в видимой (ВД) части спектра связан, прежде всего, с её оптической толщиной, в то время как в ближней инфракрасной (БИК), наоборот, напрямую зависит от размера частиц (Филей, 2019б). В программном комплексе ВПО-СД для определения τ_c и r_e используется комбинация каналов 0,6 и 1,6 мкм. При отсутствии канала с длиной волны 1,6 мкм (приборы AVHRR КА серии NOAA, МСУ-ГС КА серий «Электро-Л» и «Арктика-М») используется канал с длиной волны 3,7 мкм. В основе восстановления τ_c и r_e лежит использование справочных таблиц, содержащих рассчитанные значения КО для кристаллов льда и капель воды в зависимости от различных сценариев наблюдения и освещения. Для каждого пикселя, помеченного маской облачности, в зависимости от фазового состояния и геометрии наблюдения проводится сопоставление измеренных спутниковым радиометром и смоделированных (из справочной таблицы) значений КО с целью определения значений τ_c и r_e .

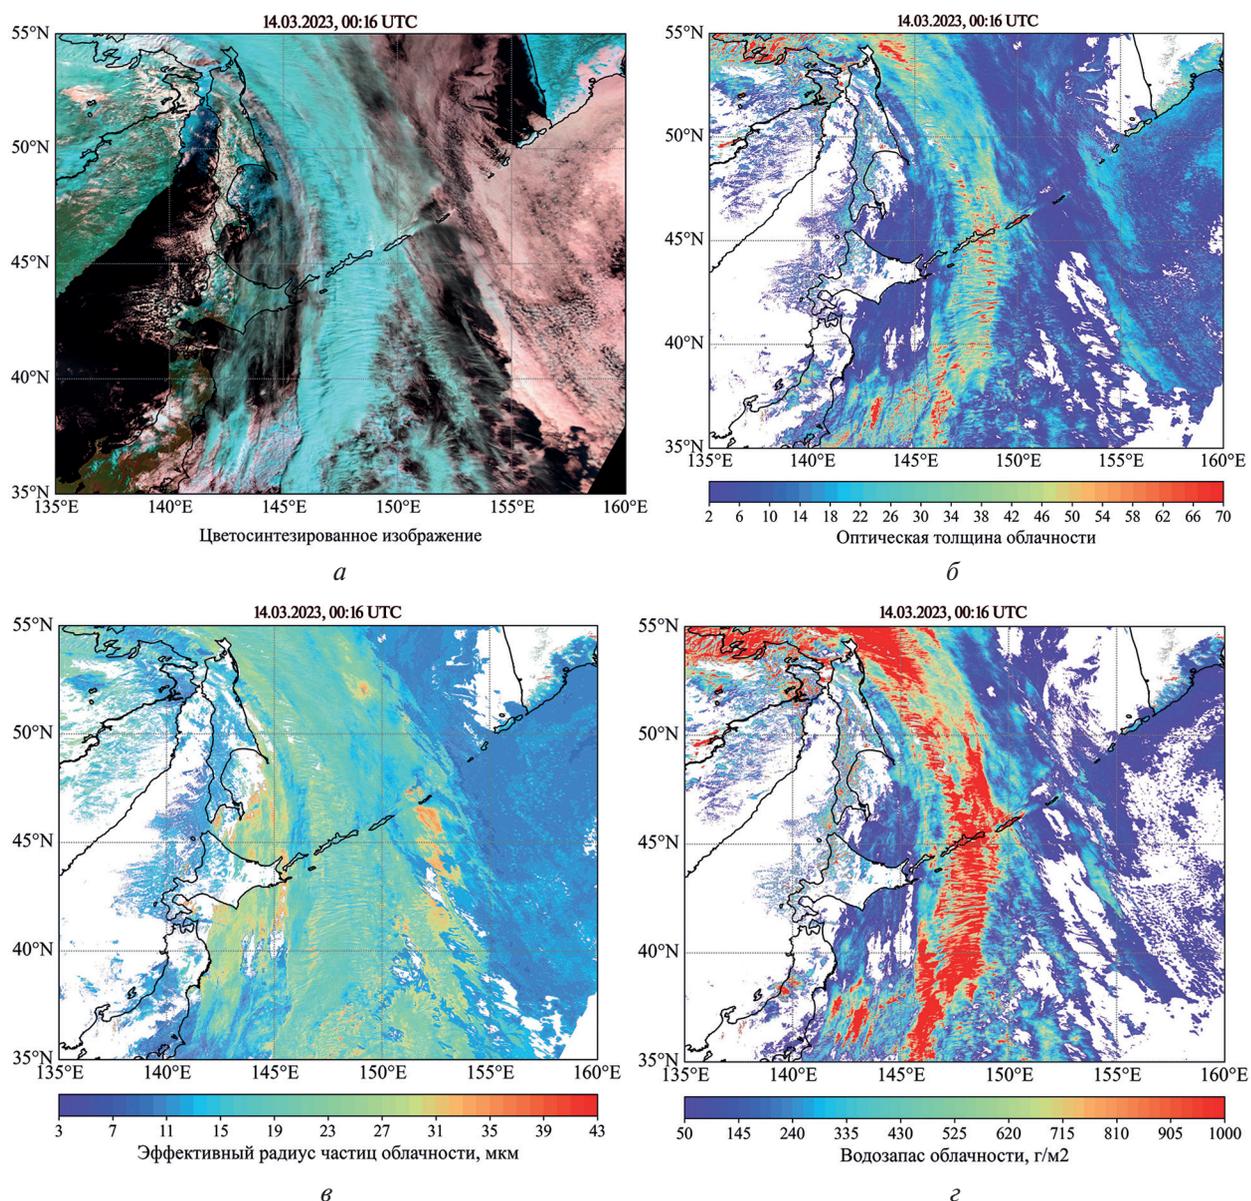


Рис. 4. Информационная продукция по данным спутникового прибора AVHRR КА MetOp-B: а — цветосинтезированное изображение; б — оптическая толщина; в — эффективный радиус; з — водозапас

Подробно об этой процедуре написано в работе (Филей, 2019б). После определения τ_c и r_e рассчитывается LWP по следующей формуле (Мазин, Хргиан, 1989):

$$LWP = \frac{3}{4} \tau_c r_e \rho, \tag{1}$$

где ρ — плотность частицы (1 г/см^3 — капли воды; $0,917 \text{ г/см}^3$ — кристаллы льда).

Выражение (1) позволяет оценить общую массу сконденсированной воды в столбе облачного слоя. Представленная методика определения оптических и микрофизических параметров облачности становится альтернативой подходу, ранее опубликованному в работе (Волкова, 2018). Сопоставление результатов оценок τ_c , r_e и LWP представленного алгоритма с результатами алгоритмов, разработанных для зарубежных спутниковых приборов (Wolter et al., 2012), показало, что восстановленные оптические и микрофизические параметры находятся в допустимых пределах среднеквадратической ошибки (*англ.* Root Mean Square Error — RMSE), за исключением случаев некорректного определения ФСО, в частности для многослойной облачности (Филей, 2019а).

Примеры восстановленных оценок τ_c , r_e и LWP по данным спутникового прибора AVHRR КА MetOp-B показаны на *рис. 4* (см. с. 112).

Температура, высота, давление на верхней границе облачности

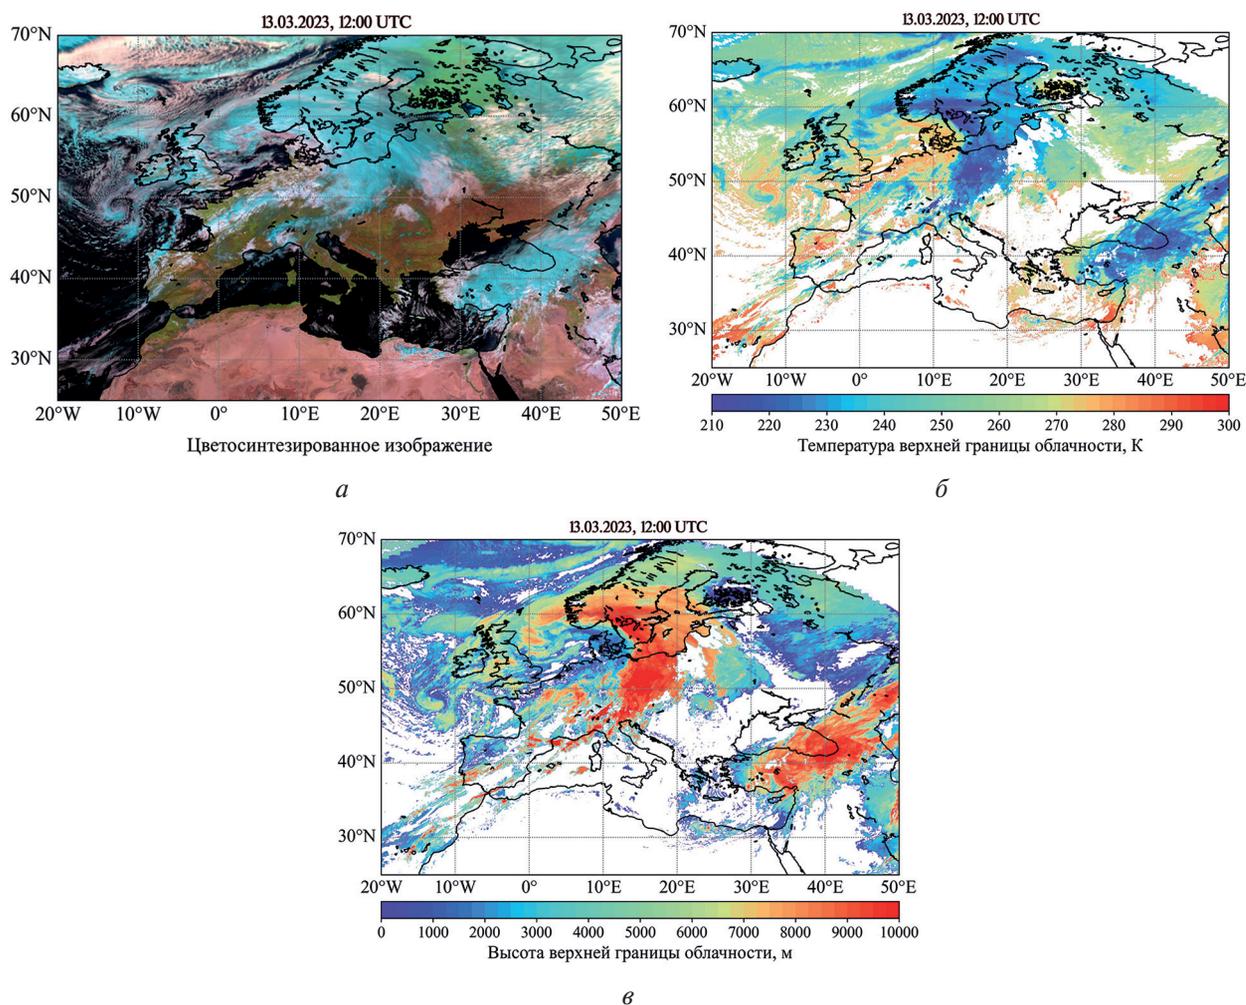


Рис. 5. Информационная продукция по данным спутникового прибора SEVIRI КА Meteosat-11: *а* — цветосинтезированное изображение; *б* — температура верхней границы облачности; *в* — высота верхней границы облачности

Высота верхней границы (H_{cld}) — один из ключевых параметров для изучения роли облаков в формировании климата и влияния на радиационные процессы, а также роли в глобальном круговороте воды. Методика восстановления H_{cld} основана на анализе уходящего инфракрасного (ИК) излучения в каналах спутникового прибора на длинах волн 11 и 12 мкм с целью оценки температуры верхней границы облачности (T_{cld}). Интенсивность ИК-излучения в каналах спутникового прибора можно выразить следующим выражением:

$$R_{obs}(\lambda) = (1 - \varepsilon_\lambda) \cdot (R_{clr,\lambda} - R_{ac,\lambda}) + R_{ac,\lambda} + \varepsilon_\lambda t_{ac,\lambda} B(\lambda, T_{cld}), \quad (2)$$

где R_{obs} — интенсивность ИК-излучения; ε — коэффициент излучения облака; R_{clr} — интенсивность излучения «чистого» неба; R_{ac} — интенсивность излучения атмосферы над облаком; t_{ac} — коэффициент пропускания атмосферы над облаком; B — функция Планка; λ — длина волны.

Сравнением измеренной и вычисленной с помощью выражения (2) интенсивности ИК-излучения в каналах спутникового прибора путём решения обратной задачи оценивается T_{cld} . Подробно об этом подходе написано в работе (Филей, 2020). Рассчитанные значения T_{cld} сопоставляются с прогностической информацией о вертикальном распределении температуры в атмосфере из модели ЧПП с целью поиска уровня атмосферы, температура на котором будет близка к T_{cld} . Искомому уровню атмосферы будет соответствовать определённая высота, равная H_{cld} . Результаты сравнения восстановленных оценок H_{cld} с данными спутникового лидара CALIOP (*англ.* Cloud-Aerosol Lidar with Orthogonal Polarization) показали высокую согласованность с коэффициентом корреляции 0,85 и RMSE, равной 1,25 км, что говорит об эффективности предложенной методики.

Примеры восстановленных оценок T_{cld} и H_{cld} по данным спутникового прибора SEVIRI КА Meteosat-11 показаны на *рис. 5* (см. с. 113).

Типы облачности

Метод классификации типов облачности реализован в несколько этапов на основе алгоритмов машинного обучения: свёрточной и полносвязной нейронных сетях. В качестве исходных данных используются микрофизические параметры облачности и высота её верхней границы, а также географическая широта и маска облачности. Входные данные преобразуются в текстуры и векторы. Подробно о типизации облачности с помощью методов машинного обучения написано в работах (Астафуров, Скороходов, 2015; Крамарева и др., 2019).

На первом этапе работы алгоритма осуществляется предварительная классификация различных форм облачности в зависимости от яруса (нижний, средний и верхний). При этом наибольшее внимание уделяется распознаванию облачных систем фронтального и внутримассового характера с конвективными явлениями; в частности, выделяются классы осадкообразующих форм: кучево-дождевые облака (в том числе с наковальной) и слоисто-дождевые. Помимо этого, выявляются классы многослойной и полупрозрачной перистой облачности. В качестве классификатора на данном этапе используется модель полносвязной нейронной сети, состоящей из четырёх скрытых слоёв. Основными предикторами для классификации являются оптическая толщина облачности, высота её верхней границы и эффективный радиус облачных частиц.

На втором этапе проводится уточнение форм облачности нижнего яруса и вертикального развития в начальной стадии. В частности, классифицируются формы слоистых, кучевых и слоисто-кучевых облаков над морем и сушей. Для наиболее эффективного разделения указанных форм применяется текстурный подход. С использованием изображений облачности в видимом канале 0,6 мкм с применением свёрточного нейросетевого классификатора удаётся с достаточно высокой степенью точности детектировать слоисто-кучевообразные формы облаков, для которых наблюдаются схожие микрофизические параметры (эффективный радиус, оптическая толщина).

Поскольку алгоритмы классификации, применяемые в данной работе, имеют статистическую природу, а разметка обучающих данных представляется достаточно трудоёмкой операцией, в редких сценах могут допускаться ошибки классификации. В связи с этим на заключительном этапе выполняется пост-коррекция ошибок, основанная на оценке допустимости физических величин и экспертных знаниях.

Таким образом, с использованием предварительно рассчитанных микро- и макропараметров облачности формируются карты типов облачности для различных спутниковых приборов. На *рис. 6* представлен пример такой карты по данным спутникового прибора АНИ КА Himawari-9. Проведённая оценка точности классификации по данным наземных наблюдений составила не менее 81 % для осадкообразующих форм облачности, и решением Центральной методической комиссии по прогнозам от 26 сентября 2018 г. технология расчёта карт типов облачности внедрена в оперативную практику Гидрометцентра ФГБУ «Дальневосточное управление по гидрометеорологии и мониторингу окружающей среды» (<https://method.meteorf.ru/>).

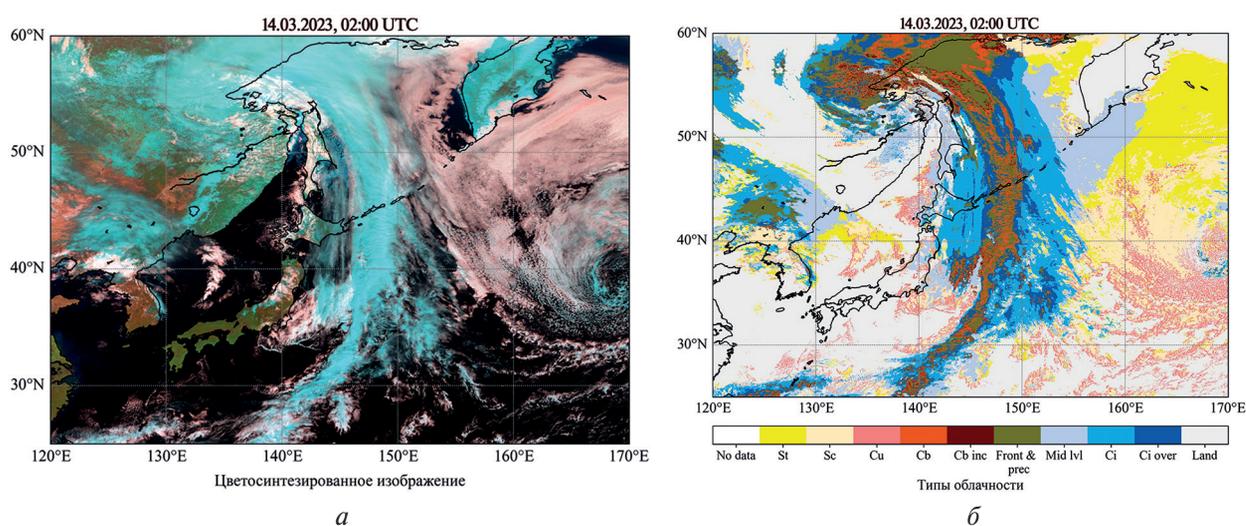


Рис. 6. Информационная продукция по данным спутникового прибора АНИ КА Himawari-9: *a* — цветосинтезированное изображение; *б* — типы облачности

Интенсивность осадков

Информация о распределении осадков играет ключевую роль при прогнозе паводковых ситуаций, ведущих к значительному материальному и экономическому ущербу. Рассчитываемые с использованием спутниковых приборов карты интенсивности осадков способны существенно дополнить и уточнить эту информацию, особенно в труднодоступных районах с редкой сетью наземных наблюдений. Кроме того, подобные сведения могут быть использованы в климатических исследованиях, а также в целях дальнейшего краткосрочного прогнозирования осадков.

Ввиду ограниченности наземных наблюдений за осадками на рассматриваемой территории в качестве «эталонной» информации при формировании обучающих выборок для разработки алгоритмов оценки интенсивности осадков использовались данные международного проекта по спутниковому мониторингу осадков GPM (*англ.* Global Precipitation Measurement, <https://gpm.nasa.gov>). Последние представлены в виде продукта IMERG (*англ.* Integrated Multi-satellitE Retrievals for GPM), включающего в себя глобальную карту измерений интенсивностей с различных спутниковых приборов в ИК- и микроволновом диапазонах, доступных на момент наблюдения (Huffman et al., 2020).

Технология расчёта интенсивности осадков основана на работе двух модулей (Андреев и др., 2022). Первый модуль решает задачу обнаружения осадков и представляет собой свёр-

точный нейросетевой автоэнкодер на основе архитектуры UNet (Ronneberger et al., 2015). Автоэнкодер использует в качестве исходной информации сегменты изображений размером 256×256 пикселей, где каждый канал сегмента представляет собой спектральный канал, а также ряд предварительно рассчитанных микрофизических параметров облачности (высота верхней границы, оптическая толщина и эффективный радиус частиц). Выходной информацией модуля становится сегмент маски полей осадков, применяемый в дальнейшем для расчёта мгновенной интенсивности осадков.

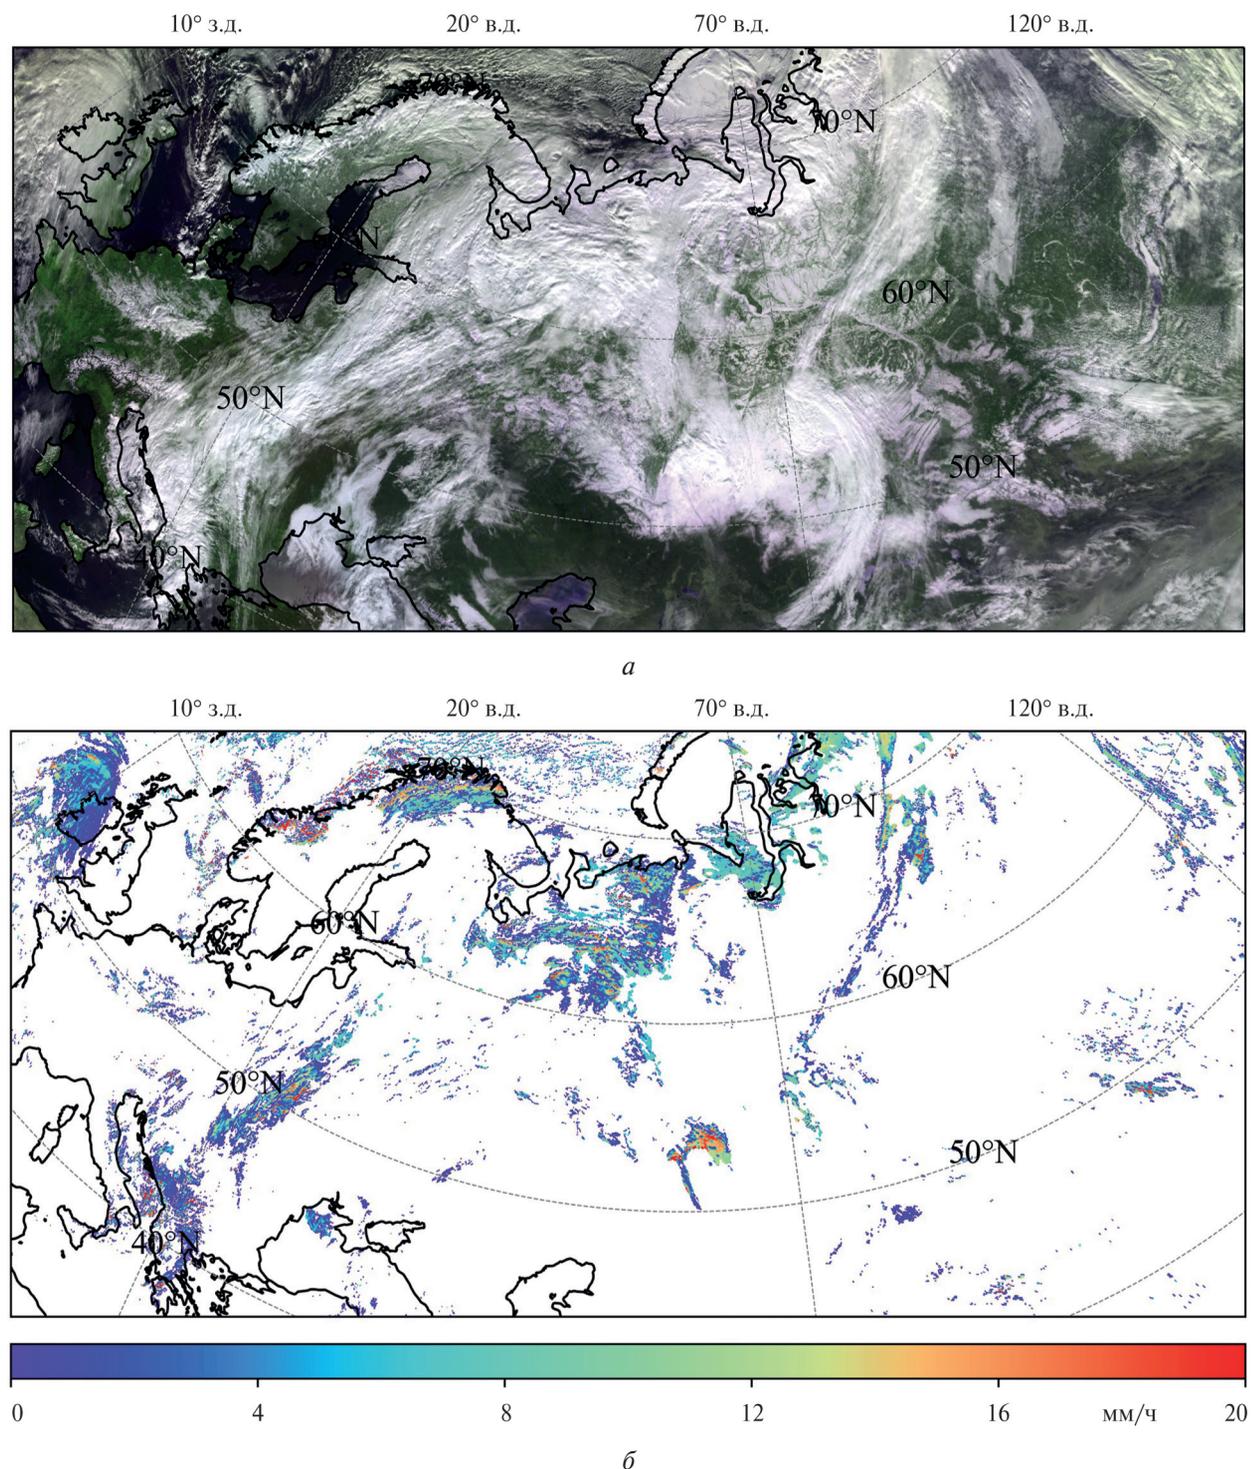


Рис. 7. Информационная продукция по данным спутникового прибора МСУ-ГС КА «Арктика-М» № 1 за 15.03.2023 в 1800 UTC: *а* — цветосинтезированное изображение; *б* — интенсивность осадков

В основе второго модуля лежит регрессионная СНС, предназначенная для моделирования взаимосвязи между мгновенным значением интенсивности, микрофизическими параметрами облачности, значениями в спектральных каналах прибора и вспомогательной текстурной информацией. Модель использует текстуры размером 5×5 пикселей, где каждый канал представлен тем или иным предиктором. Текстуры формируются для каждого пикселя маски осадков. Выходом нейронной сети является значение интенсивности в диапазоне $[0, 50]$, выраженное в миллиметрах в час (мм/ч). С подобным подходом оценки интенсивности осадков можно ознакомиться в работе (Sadeghi et al., 2019).

Результаты проведённой валидации по данным тестового набора данных GPM показали уровень точности, соответствующий большинству работ в этой области. В частности, были получены оценки RMSE 1,33 мм/ч и коэффициента корреляции 0,45 в светлое и тёмное время суток при вероятности обнаружения осадков около 73 %. Сравнение накопленных сумм осадков с мая по август 2023 г. по 87 станциям на территории Дальнего Востока России показало хорошее соответствие разработанного алгоритма (1383 мм) фактическим данным (1033 мм).

На *рис. 7* (см. с. 116) представлен пример карты интенсивности осадков, рассчитанной с использованием разработанного алгоритма.

Практическое применение

Программный комплекс ВПО-СД предоставляет на сегодняшний день наиболее полную информацию о параметрах облачности для использования в оперативной работе Дальневосточного центра НИЦ «Планета». Получаемые с его помощью информационные продукты визуализируются на базе веб-технологий в виде разработанных геоинформационных систем (ГИС) доступа к данным КА «Арктика-М» № 1 (<https://apps.dvrcpod.ru/arcticgis/>) и КА серии «Метеор-М» (<https://apps.dvrcpod.ru/meteororgis/>). Представленными ГИС активно пользуются территориальные управления по гидрометеорологии и мониторингу окружающей среды, авиационные метеорологи, а также органы государственной власти и Министерство Российской Федерации по делам гражданской обороны, чрезвычайным ситуациям и ликвидации последствий стихийных бедствий. На *рис. 8* показаны веб-интерфейсы ГИС «Арктика-М» и «Метеор-М».

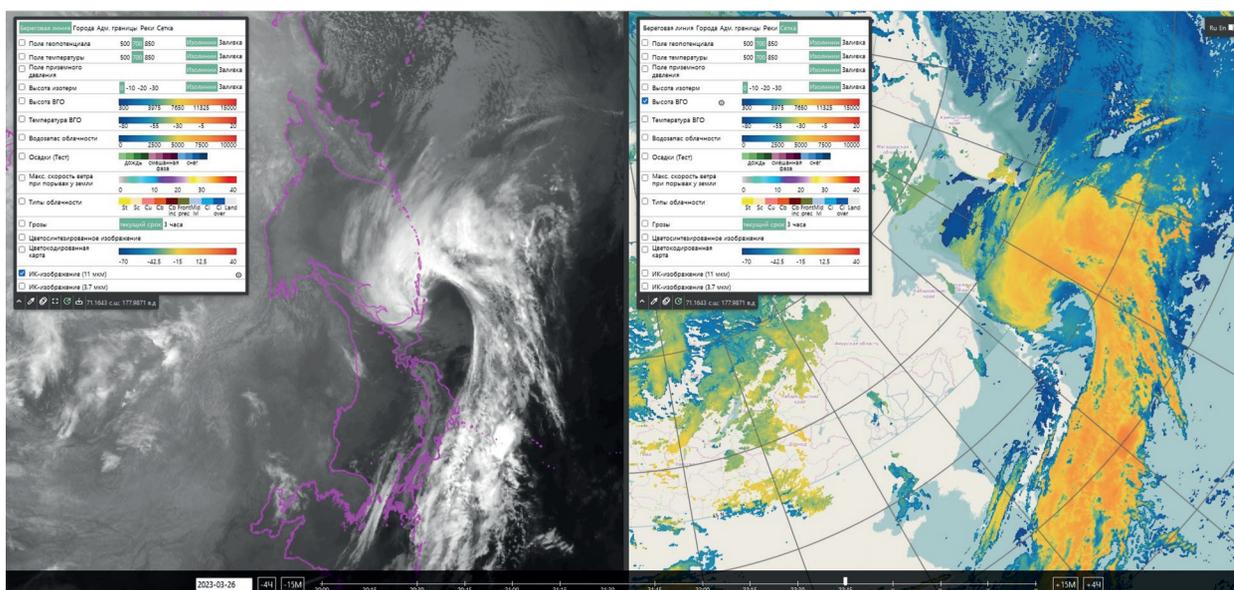


Рис. 8а. Веб-интерфейс ГИС КА «Арктика-М»

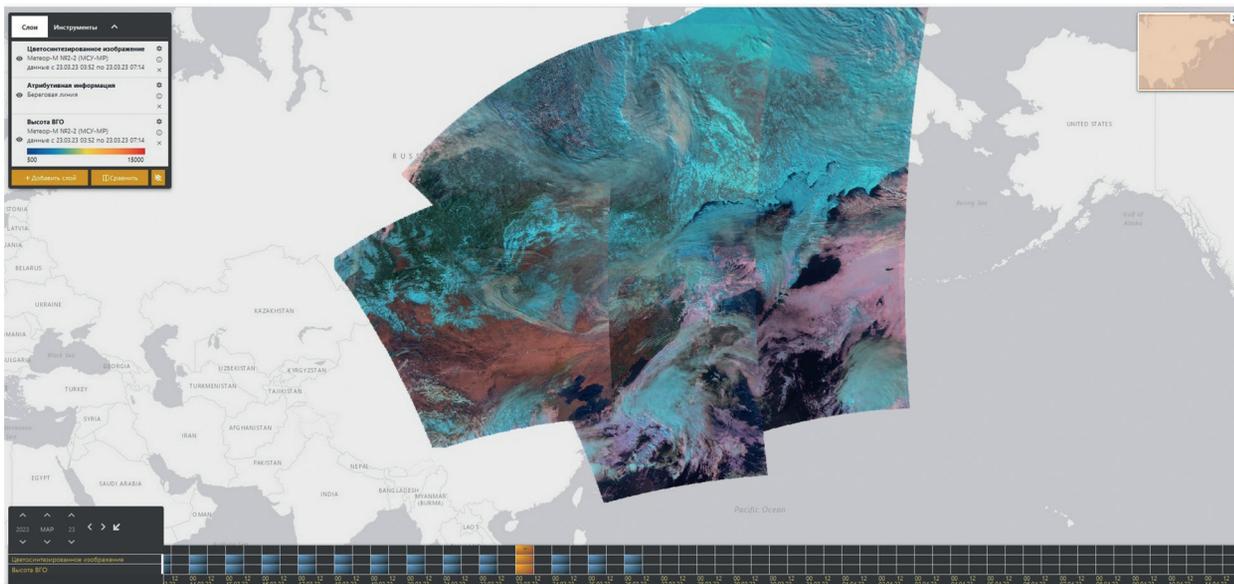


Рис. 8б. Веб-интерфейс ГИС КА «Метеор-М»

Заключение

Представленный в работе программный комплекс ВПО-СД является в настоящее время одним из наиболее удобных инструментов для восстановления параметров облачности по данным российских спутниковых приборов. Кросс-платформенность, автоматический режим работы и гибкая настройка обработки данных позволяют адаптировать комплекс для решения определённых задач пользователя. Реализованные в ВПО-СД методы искусственного интеллекта и спектрального анализа для восстановления параметров облачности подтверждают свою высокую точность и производительность. Программный комплекс ВПО-СД постоянно совершенствуется, по мере запуска на орбиту новых спутниковых приборов алгоритмы и методики проходят доработку с учётом функциональных особенностей этих приборов.

Литература

1. Андреев А. И., Шамилова Ю. А., Холодов Е. И. Применение сверточной нейронной сети для детектирования облачности по данным прибора МСУ-МР спутника «Метеор-М» № 2 // Метеорология и гидрология. 2019. № 7. С. 44–53. DOI: 10.31857/S0205961421010036.
2. Андреев А. И., Филей А. А., Давиденко А. Н. Усовершенствованный метод оценки интенсивности осадков по данным геостационарного КА Himawari-8 // Материалы 20-й Международ. конф. «Современные проблемы дистанционного зондирования Земли из космоса». 2022. С. 16. DOI: 10.21046/20DZZconf-2022a.
3. Астафуров В. Г., Скороходов А. В. Классификация многоярусной облачности по данным MODIS с использованием технологии нейронных сетей и методов нечёткой логики // Современные проблемы дистанционного зондирования Земли из космоса. 2015. Т. 12. № 6. С. 162–173.
4. Волкова Е. В. Оценка параметров облачного покрова, осадков и опасных явлений погоды по данным радиометра AVHRR с МИСЗ серии NOAA круглосуточно в автоматическом режиме // Современные проблемы дистанционного зондирования Земли из космоса. 2013. Т. 10. № 3. С. 66–74.
5. Волкова Е. В. Определение микрофизических параметров облачного покрова по спутниковым данным // Современные проблемы дистанционного зондирования Земли из космоса. 2018. Т. 15. № 4. С. 265–279. DOI: 10.21046/2070-7401-2018-15-4-265-279.
6. Крамарева Л. С., Андреев А. И., Блощинский В. Д. и др. Использование нейронных сетей в задачах гидрометеорологии // Вычисл. технологии. 2019. Т. 24. № 6. С. 50–59. DOI: 10.25743/ICT.2019.24.6.007.
7. Мазин И. П., Хргиан А. Х. Облака и облачная атмосфера: справ. Л.: Гидрометиздат, 1989. 647 с.

8. Филей А. А. (2019а) Определение фазового состояния облачности по данным спутникового радиометра МСУ-МР космического аппарата «Метеор-М» № 2 // Оптика атмосферы и океана. 2019. Т. 32. № 5. С. 376–380. DOI: 10.15372/AOO20190506.
9. Филей А. А. (2019б) Восстановление оптической толщины и эффективного радиуса частиц облачности по данным дневных измерений спутникового радиометра МСУ-МР // Оптика атмосферы и океана. 2019. Т. 32. № 8. С. 650–656. DOI: 10.15372/AOO20190807.
10. Филей А. А. Восстановление высоты верхней границы облачности по данным спутникового прибора МСУ-МР КА «Метеор-М» № 2-2 // Оптика атмосферы и океана. 2020. Т. 33. № 12. С. 918–925. DOI: 10.15372/AOO20201203.
11. Baum B. A., Heymsfield A. J., Yang P., Bedka S. T. (2005a) Bulk scattering models for the remote sensing of ice clouds. Part I: Microphysical data and models // J. Applied Meteorology and Climatology. 2005. V. 44. P. 1885–1895. DOI: 10.1175/JAM2308.1.
12. Baum B. A., Yang P., Heymsfield A. J. et al. (2005b) Bulk scattering models for the remote sensing of ice clouds. Part II: Narrowband models // J. Applied Meteorology and Climatology. 2005. V. 44. P. 1896–1911. DOI: 10.1175/JAM2309.1.
13. Borbas E., Ruston B. C. The RTTOV UWiremis IR land surface emissivity module: technical documentation. EUMETSAT, NWP-SAF, 2010. 25 p.
14. Buras R., Dowling T., Emde C. New secondary-scattering correction in DISORT with increased efficiency for forward scattering // J. Quantitative Spectroscopy and Radiative Transfer. 2011. V. 112(12). P. 2028–2034. DOI: 10.1016/j.jqsrt.2011.03.019.
15. Hu Y. X., Stamnes K. An accurate parameterization of the radiative properties of water clouds suitable for use in climate models // J. Climate. 1993. V. 6. P. 728–742. DOI: 10.1175/1520-0442(1993)006<0728:AAPOTR>2.0.CO;2.
16. Huffman G. J., Levizzani V., Kidd C. et al. Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG) // Satellite Precipitation Measurement. Cham: Springer, 2020. V. 67. P. 343–353. DOI: 10.1007/978-3-030-24568-9_19.
17. Mayer B., Kylling A., Emde C. et al. LibRadtran user's guide. 2020. 153 p. <http://www.libradtran.org/doc/libRadtran.pdf> (accessed 21.03.2023).
18. Pavolonis M. J. GOES-R Advanced Baseline Imager (ABI) Algorithm Theoretical Basis Document for Cloud Type and Cloud Phase. 2010. 86 p. https://www.star.nesdis.noaa.gov/goesr/docs/ATBD/Cloud_Phase.pdf (accessed 05.12.2023).
19. Pavolonis M. J., Heidinger A. K. Daytime cloud overlap detection from AVHRR and VIIRS // J. Applied Meteorology. 2004. V. 43. P. 762–778. DOI: 10.1175/2099.1.
20. Ronneberger O., Fischer P., Brox T. U-net: Convolutional Networks for Biomedical Image Segmentation // Intern. Conf. Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015. V. 9351. P. 234–241. DOI: 10.48550/arXiv.1505.04597.
21. Sadeghi M., Asanjan A. A., Faridzad M. et al. PERSIANN-CNN: Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks — Convolutional Neural Networks // J. Hydrometeorology. 2019. V. 20. P. 2273–2289. DOI: 10.1175/JHM-D-19-0110.1.
22. Sundqvist H., Berge E., Kristjánsson J. E. Condensation and Cloud Parameterization Studies with a Mesoscale Numerical Weather Prediction Model // Monthly Weather Review. 1989. V. 117. P. 1641–1657. DOI: 10.1175/1520-0493(1989)117<1641:CACPSW>2.0.CO;2.
23. Vidort J., Borbas E. Land surface VIS/NIR BRDF atlas for RTTOV-11: model and validation against SEVIRI land SAF albedo product // Quarterly J. Royal Meteorological Society. 2014. V. 140(684). 10 p. DOI: 10.1002/qj.2288.
24. Walther A., Heidinger A. K. Implementation of the Daytime Cloud Optical and Microphysical Properties Algorithm (DCOMP) in PATMOS-x // J. Applied Meteorology and Climatology. 2012. V. 51. P. 1371–1390. DOI: 10.1175/JAMC-D-11-0108.1.

CPR-SD: A software package for cloud parameters retrieval from satellite data

A. A. Filei, A. I. Andreev, Yu. A. Shamilova

Far Eastern Center of SRC "Planeta", Khabarovsk 680000, Russia

E-mail: andreyvm-61@mail.ru

The paper presents functional capabilities of a software package for retrieving cloud parameters from satellite data called CPR-SD. This software allows to obtain information about optical and micro-physical parameters of cloudiness, cloud height, cloud types, precipitation fields and rain rate using measurements of various satellite instruments (MSU-MR, MSU-GS, AHI, AVHRR, AMI, SEVIRI, etc.). The paper briefly outlines the information about the algorithms and methods for retrieving each of the cloud parameters. The CPR-SD has a cross-platform design, flexible configuration for processing the satellite information and operates in fully automatic mode. It implements methods and algorithms based on spectral and neural network analysis of satellite data. When data from new satellite instruments is available, the algorithms and methods of the CPR-SD are refined taking into account the functional features of these instruments. The retrieved cloudiness parameters saved in digital and raster data formats are provided by geographic information access systems Arctica-M (<https://apps.dvrcpod.ru/arcticgis/>) and Meteor-M (<https://apps.dvrcpod.ru/meteorgis/>). This information is distributed among Russia's territorial departments for hydrometeorology and environmental monitoring, aviation meteorologists, as well as government agencies and the Ministry of Civil Defence, Emergencies and Disaster Relief.

Keywords: CPR-SD, satellite data, cloudiness parameters, neural networks

Accepted: 12.12.2023

DOI: 10.21046/2070-7401-2024-21-1-106-121

References

1. Andreev A. I., Shamilova Y. A., Kholodov E. I., Using Convolutional Neural Networks for Cloud Detection from Meteor-M No. 2 MSU-MR Data, *Russian Meteorology and Hydrology*, 2019, Vol. 44, No. 7, pp. 459–466, DOI: 10.31857/S0205961421010036.
2. Andreev A. I., Filei A. A., Davidenko A. N., An improved method for estimating precipitation from data from the geostationary satellite Himawari-8, *Materialy 20-i Mezhdunarodnoi konferentsii "Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa"* (Proc. 20th Intern. Conf. "Current Problems in Remote Sensing of the Earth from Space"), 2022, 16 p. (in Russian), DOI: 10.21046/20DZZconf-2022a.
3. Astafurov V. G., Skorokhodov A. V., Multi-layer cloud classification from MODIS data using neural network technology and fuzzy logic approach, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2015, Vol. 13, No. 6, pp. 162–173 (in Russian).
4. Volkova E. V., Retrieval of cloud microphysical properties from satellite observations, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2018, Vol. 15, No. 4, pp. 265–279 (in Russian), DOI: 10.21046/2070-7401-2018-15-4-265-279.
5. Volkova E. V., Automatic estimation of cloud cover and precipitation parameters obtained by AVHRR NOAA for day and night condition, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2013, Vol. 10, No. 3, pp. 66–74 (in Russian).
6. Kramareva L. S., Andreev A. I., Bloschinskiy V. D. et al., The use of neural networks in hydrometeorology problems, *Vychislitel'nye tekhnologii*, 2019, Vol. 24, No. 6, pp. 50–59 (in Russian), DOI: 10.25743/ICT.2019.24.6.007.
7. Mazin I. P., Hrgian A. Kh., *Oblaka i oblachnaya atmosfera* (Clouds and cloudy atmosphere), Leningrad: Gidrometizdat, 1989, 647 p (in Russian).
8. Filei A. A. (2019a), Determination of cloud phase using MSU-MR measurements on-board Meteor-M No. 2, *Optika atmosfery i okeana*, 2019, Vol. 32, No. 5, pp. 376–380 (in Russian), DOI: 10.15372/AOO20190506.
9. Filei A. A. (2019b), Retrieval of the cloud optical depth and particle effective radii from MSU-MR daytime measurements, *Optika atmosfery i okeana*, 2019, Vol. 32, No. 8, pp. 650–656 (in Russian), DOI: 10.15372/AOO20190807.

10. Filei A. A., Retrieval of the cloud top height from using Meteor-M No. 2-2 MSU-MR measurements, *Optika atmosfery i okeana*, 2020, Vol. 33, No. 12, pp. 918–925 (in Russian), DOI: 10.15372/AOO20201203.
11. Baum B. A., Heymsfield A. J., Yang P., Bedka S. T. (2005a), Bulk scattering models for the remote sensing of ice clouds. Part I: Microphysical data and models, *J. Applied Meteorology and Climatology*, 2005, Vol. 44, pp. 1885–1895, DOI: 10.1175/JAM2308.1.
12. Baum B. A., Yang P., Heymsfield A. J. et al. (2005b), Bulk scattering models for the remote sensing of ice clouds. Part II: Narrowband models, *J. Applied Meteorology and Climatology*, 2005, Vol. 44, pp. 1896–1911, DOI: 10.1175/JAM2309.1.
13. Borbas E., Ruston B. C., *The RTTOV UWiremis IR land surface emissivity module: technical documentation*, EUMETSAT, NWP-SAF, 2010, 25 p.
14. Buras R., Dowling T., Emde C., New secondary-scattering correction in DISORT with increased efficiency for forward scattering, *J. Quantitative Spectroscopy and Radiative Transfer*, 2011, Vol. 112(12), pp. 2028–2034, DOI: 10.1016/j.jqsrt.2011.03.019.
15. Hu Y. X., Stamnes K., An accurate parameterization of the radiative properties of water clouds suitable for use in climate models, *J. Climate*, 1993, Vol. 6, pp. 728–742, DOI: 10.1175/1520-0442(1993)006<0728:AA POTR>2.0.CO;2.
16. Huffman G. J., Levizzani V., Kidd C. et al., Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG), In: *Satellite Precipitation Measurement*, Cham: Springer, 2020, Vol. 67, pp. 343–353, DOI: 10.1007/978-3-030-24568-9_19.
17. Mayer B., Kylling A., Emde C. et al., *LibRadtran user's guide*, 2020, 153 p. URL: <http://www.libradtran.org/doc/libRadtran.pdf> (accessed 21.03.2023).
18. Pavolonis M. J., *GOES-R Advanced Baseline Imager (ABI) Algorithm Theoretical Basis Document for Cloud Type and Cloud Phase*, 2010, 86 p., https://www.star.nesdis.noaa.gov/goesr/docs/ATBD/Cloud_Phase.pdf (accessed 05.12.2023).
19. Pavolonis M. J., Heidinger A. K., Daytime cloud overlap detection from AVHRR and VIIRS, *J. Applied Meteorology*, 2004, Vol. 43, pp. 762–778, DOI: 10.1175/2099.1.
20. Ronneberger O., Fischer P., Brox T., U-net: Convolutional Networks for Biomedical Image Segmentation, In: *Intern. Conf. Medical Image Computing and Computer-Assisted Intervention*, Cham: Springer, 2015, Vol. 9351, pp. 234–241, DOI: 10.48550/arXiv.1505.04597.
21. Sadeghi M., Asanjan A. A., Faridzad M. et al., PERSIANN-CNN: Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks, *J. Hydrometeorology*, 2019, Vol. 20, pp. 2273–2289, DOI: 10.1175/JHM-D-19-0110.1.
22. Sundqvist H., Berge E., Kristjánsson J. E., Condensation and Cloud Parameterization Studies with a Mesoscale Numerical Weather Prediction Model, *Monthly Weather Review*, 1989, Vol. 117, pp. 1641–1657, DOI: 10.1175/1520-0493(1989)117<1641:CACPSW>2.0.CO;2.
23. Vidort J., Borbas E., Land surface VIS/NIR BRDF atlas for RTTOV-11: model and validation against SEVIRI land SAF albedo product, *Quarterly J. Royal Meteorological Society*, 2014, Vol. 140(684), 10 p., DOI: 10.1002/qj.2288.
24. Walther A., Heidinger A. K., Implementation of the Daytime Cloud Optical and Microphysical Properties Algorithm (DCOMP) in PATMOS-x, *J. Applied Meteorology and Climatology*, 2012, Vol. 51, pp. 1371–1390, DOI: 10.1175/JAMC-D-11-0108.1.