

## Классификация облачности в ночное время суток по спутниковым данным VIIRS

А. В. Скороходов

*Институт оптики атмосферы им. В. Е. Зуева СО РАН, Томск, 634055, Россия  
E-mail: vazime@yandex.ru*

Представлены результаты исследования спутниковых данных радиометра VIIRS, полученных в ночное время суток, для классификации облачности. При этом использовались изображения видимого диапазона спектра на основе канала day/night рассматриваемого прибора. Это позволило использовать результаты текстурного анализа снимков для описания облачности. Определены граничные условия применимости изображений day/night для решения задачи распознавания типов облаков. Представлена ночная классификация облачности с учётом возможностей спутниковой аппаратуры. Предложен алгоритм распознавания типов облаков на основе применения вероятностной нейронной сети. Его реализация выполнена на основе технологии параллельных вычислений на графических процессорах общего назначения. Показаны результаты формирования системы эффективных классификационных характеристик облаков на основе метода усечённого перебора GRAD-II. Обсуждаются результаты классификации облачности в ночное время суток на основе тестовой выборки, а также экспертной оценки. При этом использовались спутниковые снимки, полученные при различных условиях съёмки. Обсуждаются результаты классификации отдельных разновидностей облаков в ночное время суток по данным VIIRS и дневное время по данным спектрорадиометра MODIS.

**Ключевые слова:** классификация облачности, ночное время суток, спутниковые данные, текстурные признаки, характеристики облаков, изображения day/night, VIIRS

Одобрена к печати: 13.04.2020

DOI: 10.21046/2070-7401-2020-17-3-240-251

### Введение

Межправительственная группа экспертов (IPCC — Intergovernmental Panel on Climate Change) в своих ежегодных докладах относит облачность к одному из основных источников неопределённости в происходящих изменениях климата на Земле (Bony et al., 2015). С одной стороны, усиление парникового эффекта, наблюдаемое уже несколько десятилетий, может привести к уменьшению относительной влажности воздуха, а впоследствии — к сокращению количества облаков (Pressel et al., 2019). С другой стороны, глобальное потепление способствует увеличению испаряемости и росту общей облачности (Fowler, Randal, 1996). Таким образом, неопределёнными являются так называемые обратные связи облаков (*англ.* cloud feedbacks). В настоящее время данные дистанционного зондирования Земли из космоса — это единственный надёжный источник информации о глобальном поле облачности. Однако даже существующие многолетние ряды спутниковых наблюдений за облаками не позволяют улучшить понимание их роли в происходящих климатических изменениях. Согласно данным Международного спутникового проекта по климатологии облачности (ISCCP — International Satellite Cloud Climatology Project), зарегистрировано её сокращение в последние несколько десятилетий (Young et al., 2018). Но в исследовании (Evan et al., 2007) показано, что такой тренд недостоверен, поскольку получен без учёта ряда факторов, например артефактов геометрии съёмки со спутников, и для прогнозирования будущих изменений климата непригоден. Тем не менее наблюдается увеличение количества облаков над Арктической зоной, связанное с сокращением площади многолетнего льда и проникновением тёплого Северо-Атлантического течения (Chernokulsky et al., 2017). При этом глобальное поле облачности неоднородно. Современный метеорологический стандарт разделяет облака на основе их морфологического описания по 27 разновидностям, включая 10 основных форм, их подтипы и некоторые сочетания (Код..., 2013). Однако отдельные типы облачности образуются под воздействием определённых атмосферных процессов и характеризуются различным воз-

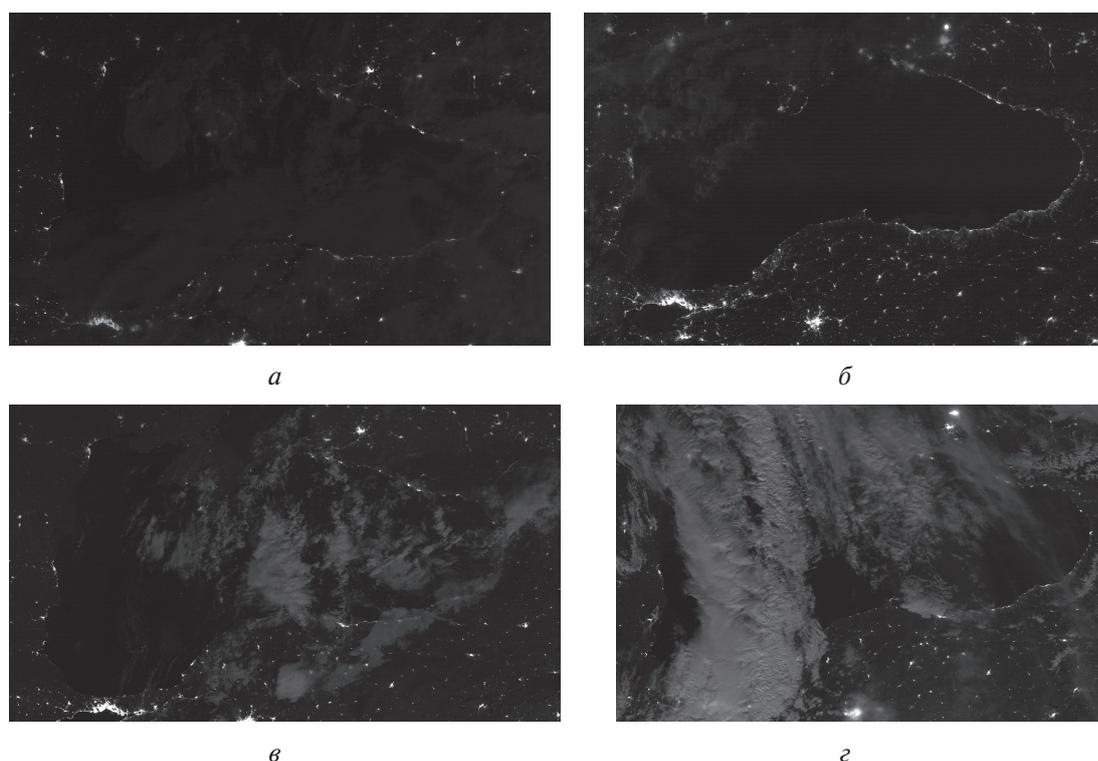
действием на климатическую систему планеты (Облака..., 1989). Так, облака нижнего яруса отражают значительную часть приходящего солнечного излучения назад в космическое пространство, частично поглощают его, а также препятствуют выхолаживанию подстилающей поверхности. Облачность верхнего яруса удерживает уходящую длинноволновую радиацию, усиливая тем самым парниковый эффект. Облака среднего яруса оказывают существенное влияние на тепловой баланс при прохождении атмосферных фронтов над определённой территорией. Кроме этого, степень воздействия облачности на климатическую систему планеты зависит от её многослойности и наличия разрывов в ней.

В настоящее время для выявления обратных связей облаков широко применяются методы математического моделирования. Основным недостатком существующих моделей является их низкое пространственное и временное разрешение. Так, в работе (Bretherton et al., 2005) обсуждается проблема моделирования быстроразвивающихся и самоагрегирующихся конвективных ячеек, время жизни которых не превышает нескольких часов. Для улучшения таких моделей необходимо привлекать информацию о процессах и явлениях, происходящих в системе «атмосфера – подстилающая поверхность», в подсеточном масштабе с пространственным разрешением менее 1 км. Такие сведения могут быть получены на основе результатов многолетней спутниковой съёмки современными системами дистанционного зондирования. На данный момент на орбите Земли функционирует большая группировка геостационарных и полярно-орбитальных аппаратов. Первые из них выделяются высокой периодичностью съёмки до нескольких минут, но её пространственное разрешение значительно ухудшается при приближении к полюсам (Davis, 2007). Системы второго типа сканируют земную поверхность в большом числе спектральных диапазонов практически с постоянным пространственным разрешением, покрывая всю территорию планеты снимками за время от одного до нескольких дней (Menzel, 2006). При этом общее количество полярно-орбитальных спутников позволяет получать изображения одного и того же участка Земли каждый час. Эти сведения могут быть использованы для изучения изменчивости характеристик облачности различных типов в течение суток. Однако для систем обоих типов актуальной является проблема интерпретации данных, полученных в ночное время, из-за отсутствия информации в видимом диапазоне спектра. Это исключает возможность надёжного визуального дешифрования спутниковых снимков. Основным подходом к решению указанной проблемы является анализ данных в инфракрасном диапазоне спектра. В частности, для анализа характеристик облачности в круглосуточном режиме такой способ применяется в работе (Волкова, 2013). Главный недостаток данного подхода заключается в сходстве спектральных характеристик у некоторых типов облачности (особенно одного яруса) и размытость структуры изображений облачного поля. Поэтому эффективность такого способа зависит не только от возможностей инфракрасной съёмки отдельным прибором, но и от результатов трудоёмкого выделения спектральных особенностей для различных разновидностей облаков.

Однако в настоящее время существует возможность применения другого подхода. В 2011 г. был запущен спутник Suomi-NPP с радиометром VIIRS на борту (Жижин и др., 2017). Уникальность данного прибора заключается в использовании датчиков низкого уровня освещённости для получения изображения в видимом диапазоне спектра (0,5–0,9 мкм) в ночное время суток. Указанные сенсоры позволяют регистрировать отражённое излучение от «слабых» источников света: атмосферы, городов, звёзд и Луны. Это обеспечивает возможность применения классических методов обработки изображений, например текстурного анализа, показавшего свою эффективность при решении задачи классификации облачности по типам (Bankert et al., 2009; Liu et al., 2009; Skorokhodov et al., 2019). В 2017 г. был запущен первый спутник серии JPSS — NOAA-20, также оборудованный радиометром VIIRS. В течение следующего десятилетия планируется увеличение этой группировки до пяти аппаратов. Это позволит получать снимки одной и той же территории планеты несколько раз за ночное время суток. Данные спутники представляются перспективной заменой Terra и Aqua, расчётный ресурс которых превышен уже в четыре раза (Xiong et al., 2011). Поэтому целью настоящей работы стало определение возможностей радиометра VIIRS для исследования характеристик различных типов облачности в ночное время суток.

## Исходные данные

Восстановление характеристик облачности осуществлялось на основе изображений видимого диапазона спектра, полученных по данным канала day/night (day and night band — DNB) радиометра VIIRS. Отличительной особенностью указанных снимков является практически постоянное пространственное разрешение 750 м на всей 3000-километровой полосе сканирования при отсутствии «эффекта бабочки». Это даёт возможность надёжно восстанавливать значения текстурных признаков по краям съёмочной полосы. Стандартный размер DNB-изображений составляет 4064×3232 пикселя, что позволяет охватывать участки макросистем облаков значительных размеров. Однако возможности ежедневного мониторинга объектов в видимом диапазоне спектра являются ограниченными из-за меняющихся условий съёмки. В первую очередь к ним относятся углы положения Солнца и Луны, от которых зависит освещённость её диска (фаза). На *рис. 1* показаны фрагменты спутниковых снимков VIIRS акватории Чёрного моря, полученных при различных параметрах съёмки в ночное время суток. На *рис. 1* видно, что при неблагоприятных условиях сканирования поверхности Земли на DNB-изображениях виден только свет от искусственных источников в населённых пунктах. Уменьшение зенитного угла Луны и увеличение площади освещённости её диска позволяют получать снимки, аналогичные дневным сценам, на которых не только видны контуры облаков, но и проявляются особенности текстуры их отдельных типов.



*Рис. 1.* Фрагменты DNB-изображений акватории Чёрного моря при зенитных углах Луны и освещённости её диска соответственно: *а* — 75° и 69 %; *б* — 81° и 72 %; *в* — 43° и 88 %; *г* — 55° и 97 %

Анализ нескольких DNB-изображений, полученных при различных параметрах съёмки, позволил определить их граничные условия применимости на основе методики, предложенной в работе (Астафуров, Скороходов, 2011). Установлено, что при зенитных углах Луны менее 75° и освещённости её диска менее 72 % текстура облачности и подстилающей поверхности на рассматриваемых спутниковых снимках становится неразличимой, несмотря на использование алгоритмов улучшения изображений, направленных на повышение яркости и контраста. Для умеренных широт этим условиям удовлетворяют 10–12 дней в месяце,

что делает DNB-изображения перспективным источником информации для оценки суточной изменчивости структуры облачных полей в исследовательских целях. С учётом информации о фазах Луны были найдены характерные образцы для 16 разновидностей облаков (Skorokhodov et al., 2019). Для этого применялась методика сопоставления архивных данных сети наземных метеостанций, расположенных в умеренных широтах, и экспертная оценка DNB-изображений. При этом использовался тематический продукт CLDPROP\_12, содержащий информацию о таких характеристиках облачности, как высота, давление и температура её верхней границы, микроструктура и эффективная излучательная способность (Askerman et al., 2019). При дневной съёмке VIIRS восстанавливаются ещё и оптическая толщина, эффективный радиус частиц, водозапас и ряд других параметров. Их отсутствие для ночных сцен наряду с более низким, чем у MODIS, пространственным разрешением снимков не позволило разделить характерные образцы для следующих типов облачности: высокослоистых и слоисто-дождевых, перисто-слоистых и перисто-кучевых, а также слоисто-кучевых и их сочетания с кучевыми, наблюдаемыми одновременно. Поэтому было принято решение об объединении типов и их эталонов. Итоговая классификация облаков, используемая при дешифрировании ночных сцен VIIRS, представлена в *табл. 1*.

*Таблица 1. Ночная классификация облаков для радиометра VIIRS*

Семейство	Тип
Облака верхнего яруса	Перистые нитевидные (Ci fib) Перистые плотные (Ci sp) Перисто-слоистые и перисто-кучевые (Cs и Cc)
Облака среднего яруса	Высокослоистые и слоисто-дождевые (As и Ns) Высококучевые кучевообразные (Ac cuf) Высококучевые волнистообразные (Ac und)
Облака нижнего яруса	Слоисто-кучевые кучевообразные (Sc cuf) Слоисто-кучевые волнистообразные (Sc und) Слоистые (St)
Облака вертикального развития	Кучевые плоские (Cu hum) Кучевые средние и мощные (Cu med/cong) Кучево-дождевые лысые (Cb calv) Кучево-дождевые волосатые (Cb cap)

Описание облачности было основано на использовании текстурных признаков, рассчитываемых на основе подходов Gray-Level Co-occurrence Matrix (GLCM), Gray-Level Difference Vector (GLDV), Sum And Difference Histogram (SADH), One-Dimensional Signal Histogram (ODSH), используемых в работе (Astafurov et al., 2017), а также физических характеристик, содержащихся в продукте CLDPROP\_12. Общее число классификационных характеристик составило 137. Очевидно, что набор информативных признаков, сформированный в исследовании (Skorokhodov et al., 2019) для данных спектрометрического прибора MODIS, не будет являться таковым для данных VIIRS по нескольким причинам. Различаются значения пространственного разрешения снимков в видимом диапазоне спектра у обоих приборов, величины длины волны, возможности восстановления физических характеристик облаков и их классификации. Поэтому необходимо заново формировать систему информативных признаков, что будет обсуждаться в следующем разделе.

### Алгоритм классификации облачности

В качестве классификатора для решения задачи разделения облачности на основе данных VIIRS, полученных в ночное время суток, использовалась вероятностная нейронная сеть. Эффективность данного метода была подтверждена в работе (Skorokhodov et al., 2019) при распознавании типов облаков по спутниковым снимкам MODIS. Основным достоинством

указанного классификатора является фактическое отсутствие процедуры обучения, которое существенно сокращает время поиска информативных признаков на основе алгоритмов усечённого перебора. Вероятностная нейронная сеть состоит из трёх вычислительных слоёв. На её вход подаётся набор значений характеристик исследуемого фрагмента облачности. Первый слой состоит из  $M$  нейронов, соответствующих объёму обучающей выборки. В настоящей работе для каждого типа облачности было найдено по 1000 характерных образцов. Каждый эталон представляет собой набор значений текстурных признаков, рассчитанных по фрагменту DNB-изображения размером  $21 \times 21$  пиксель, а также физических параметров облаков, восстановленных для его центра из продукта CLDPROP\_12. Выходом нейронов первого слоя являются уровни активности, вычисляемые на основе нормированной функции Гаусса. Второй слой состоит из  $N$  нейронов-сумматоров, определяющих суммарный отклик каждого класса на исследуемый образец. В третьем слое содержится всего один нейрон, моделирующий операцию сравнения. На выход сети подаётся номер класса с наибольшим уровнем активности, соответствующий заданному типу облачности. В соответствии с *табл. 1* объём обучающей выборки  $M$  равняется 13 000 образцам, а количество нейронов-сумматоров  $N$  составляет 13 по числу распознаваемых разновидностей облаков.

Процедура классификации облачности по данным VIIRS в ночное время суток состоит из нескольких этапов:

1. DNB-изображение VIIRS сканируется скользящим окном размером  $21 \times 21$  со смещением 1 пиксель по горизонтали и вертикали.
2. Для каждого положения скользящего окна выполняется проверка зенитного угла Луны и освещённости её диска на соответствие с граничными условиями на основе продукта  $V(J1/NP)03DNB$  в зависимости от спутника (NOAA-20/Suomi-NPP).
3. Для удовлетворяющих этапу 2 положений скользящих окон выполняется проверка на соответствие их центральных пикселей облачности на основе её маски из продукта CLDPROP\_12.
4. Для удовлетворяющих этапу 3 положений скользящих окон выполняется расчёт информативных характеристик облаков.
5. Полученный набор значений предъявляется на вход вероятностной нейронной сети.
6. Центральный пиксель исследуемого фрагмента изображения перекрашивается в соответствии с цветом определённого на этапе 5 типа облачности, заданного заранее легендой.
7. Цвет центральных пикселей, не прошедших проверку на этапах 2 и 3, остаётся без изменений. Кроме этого, «засвеченные облачные пиксели», относящиеся к ярким искусственным источникам света, перекрашиваются в чёрный цвет на основе соответствующего флага из продукта DNB. Результаты классификации облачности в этих точках не учитываются. Решение данной проблемы является перспективным направлением развития настоящей работы.

Поиск информативных признаков осуществлялся на основе метода усечённого перебора GRAD-II из работы (Астафуров, Скороходов, 2017). Основная суть данного подхода заключается в последовательном добавлении наиболее эффективных комбинаций признаков, называемых гранулами, в систему классификационных характеристик и удалении наихудших из неё. При этом на каждой итерации GRAD-II происходит оценка результатов классификации тестовой выборки. Таким образом, на каждом шаге в информативный набор добавляется комбинация признаков, улучшающая результаты классификации наибольшего количества типов облачности, а затем удаляется ухудшающая наибольшие из них. Процедура перебора выполняется до тех пор, пока ни одна из рассматриваемых гранул не позволяет повысить оценки качества распознавания. В настоящей работе была сформирована тестовая выборка, состоящая из 100 образцов для каждого типа облачности из *табл. 1*. При этом рассматривались данные VIIRS, не используемые для поиска обучающих образцов. На основе методики GRAD-II была сформирована система классификационных характеристик облаков, состоящая из 58 признаков, которая представлена в *табл. 2*.

Таблица 2. Система информативных признаков облаков для классификации облачности по данным радиометра VIIRS в ночное время суток

Физические характеристики:	фазовый состав, температура верхней границы, высота верхней границы, давление на верхней границе			
	GLCM	GLDV	SADH	ODSH
	Второй угловой момент 45° Локальная однородность 0° Контраст 0°, 45°, 90°, 135° Суммарное среднее 0°, 45°, 90°, 135° Суммарная дисперсия 0°, 45°, 90°, 135° Дифференциальное среднее 0°, 45°, 90°, 135° Дифференциальная дисперсия 0°, 45°, 90°, 135° Информационная мера-1 90°	Математическое ожидание 0°, 90° Стандартное отклонение 0°, 45°, 90°, 135° Второй угловой момент 0° Энтропия 45° Контраст 0°, 45°, 90°, 135° Кластерное затенение 0°, 45°, 90°, 135° Кластерная рельефность 0°, 45°, 90°, 135°	Стандартное отклонение 0°, 45° Энтропия 0°, 45°, 90°, 135° Кластерная рельефность 0°, 45°, 90°, 135°	Вариация

Задача классификации облачности по типам на основе спутниковых данных становится вычислительно сложной из-за размеров изображений и тематической продукции VIIRS, количества характеристик облачности и структуры нейронной сети. Поэтому реализация разработанного алгоритма осуществлялась применением технологии параллельных вычислений на графических процессорах общего назначения NVIDIA CUDA. Этот подход позволяет выполнять одновременную обработку однотипных данных достаточно простым алгоритмом (ядром). В настоящей работе в качестве ядерной функции использовалась реализация вероятностной нейронной сети. Это даёт возможность обрабатывать одновременно несколько положений скользящего окна, число которых зависит от параметров оборудования. Здесь применялась система, агрегирующаяся двумя видеокартами GeForce GTX 1080 Ti, что позволило запускать несколько тысяч потоков одновременно. При этом время обработки одного комплекта спутниковых данных VIIRS, полученного в ночное время суток, сократилась с 4–6 ч при использовании CPU уровня Intel Core-i5 и технологии OpenMP до 2–5 мин на GPU в зависимости от количества облаков на снимке. Следует отметить, что и формирование системы эффективных классификационных характеристик осуществлялось применением технологии NVIDIA CUDA.

### Обсуждение результатов классификации облачности в ночное время суток

Оценка достоверности классификации облачности по спутниковым данным VIIRS, полученных в ночное время суток, выполнялась на основе двух подходов, принятых в этой области. Первый из них заключается в формировании тестовой выборки сопоставлением архивных данных сети наземных метеостанций с результатами дистанционного зондирования Земли из космоса. Этот набор обрабатывается разработанным алгоритмом, и вычисляются следующие оценки, принятые в данной области (Кравцов, 2016):

$$R_i = \frac{TP_i}{TP_i + FN_i}, \quad P_i = \frac{TP_i}{TP_i + FP_i} \quad \text{и} \quad F_i = 2 \frac{P_i R_i}{P_i + R_i},$$

где  $TP_i$ ,  $FN_i$  — количество соответственно правильно и неправильно проклассифицированных образцов для  $i$ -го типа облачности при  $i = 1, 2, \dots, 13$ ;  $FP_i$  — число образцов других разновидностей облаков, ошибочно отнесённых к нему. Как уже говорилось выше, объём тестовой

выборки для каждой разновидности облаков одинаковый и равняется 100 фрагментам спутниковых снимков, полученных в ночное время суток. Следует отметить, что выбор образцов осуществлялся при различных условиях съёмки — как хороших, так и близких к неблагоприятным. В *табл. 3* приведены оценки результатов классификации облачности на основе тестовых выборок по данным VIIRS и MODIS, взятым из работы (Skorokhodov et al., 2019) для сравнения.

Таблица 3. Результаты классификации тестовой выборки

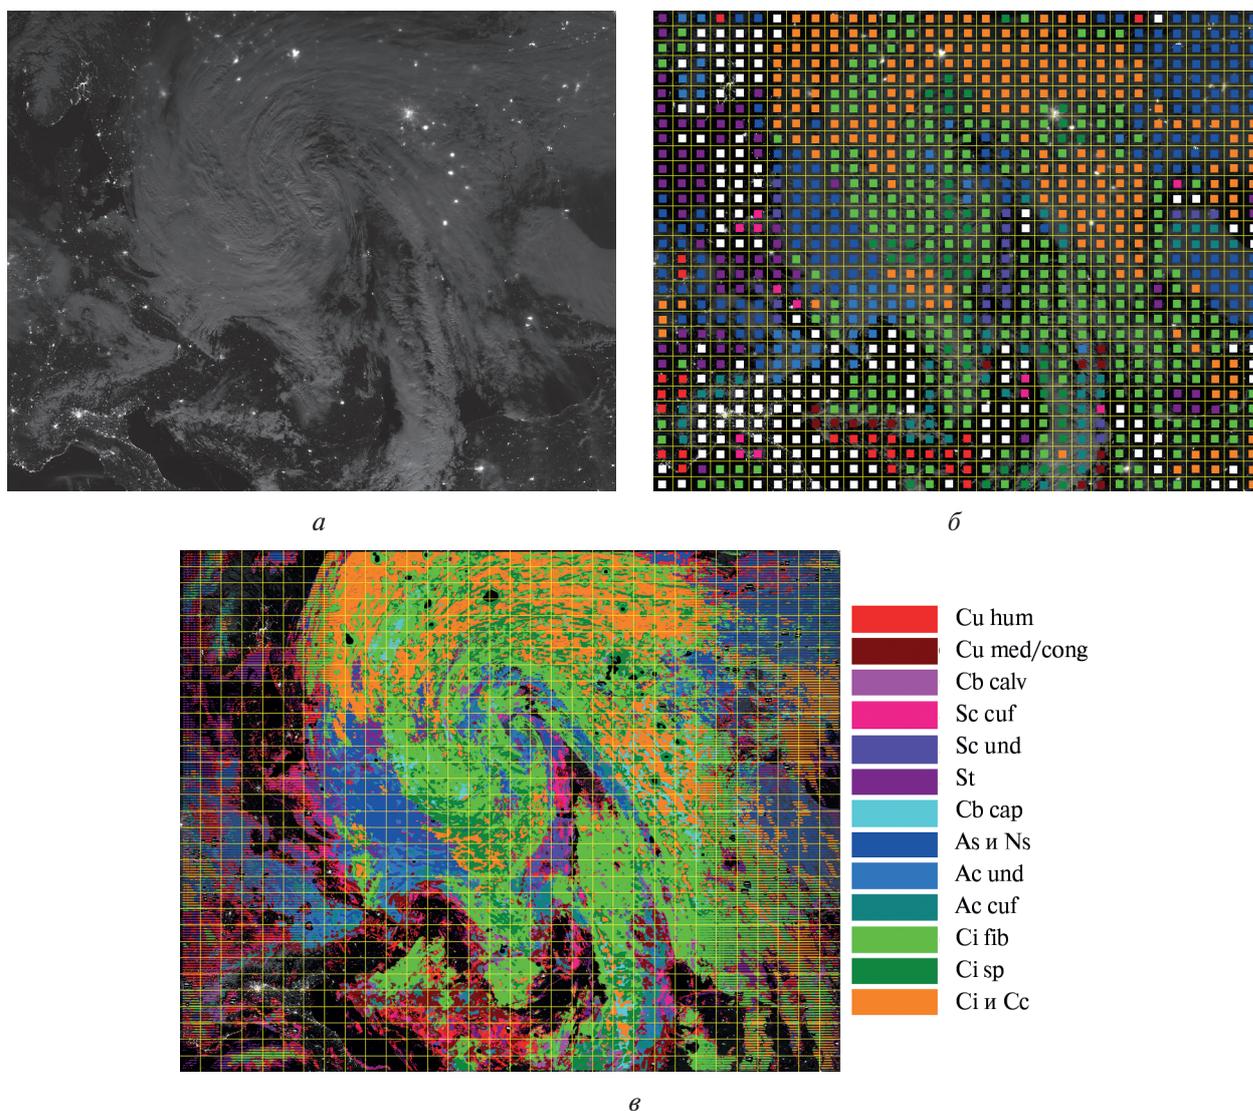
Тип облаков	VIIRS			MODIS
	$R_i$	$P_i$	$F_i$	$R_i$
Кучевые плоские (Cu hum)	0,94	0,85	0,89	1,00
Кучевые средние и мощные (Cu med/cong)	0,88	0,95	0,91	0,94
Кучево-дождевые лысые (Cb calv)	0,88	0,88	0,88	0,88
Кучево-дождевые волосатые (Cb cap)	0,82	0,80	0,81	1,00
Слоисто-кучевые кучевообразные (Sc cuf)	0,88	0,86	0,87	0,96
Слоисто-кучевые волнистообразные (Sc und)	0,90	0,91	0,90	0,76
Слоистые (St)	0,90	0,98	0,94	0,96
Высокослоистые (As)	0,92	0,83	0,87	0,72
Слоисто-дождевые (Ns)				0,72
Высококучевые кучевообразные (Ac cuf)	0,82	0,91	0,86	0,78
Высококучевые волнистообразные (Ac und)	0,90	0,86	0,88	0,88
Перистые нитевидные (Ci fib)	0,74	0,90	0,81	0,80
Перистые плотные (Ci sp)	0,90	0,80	0,85	0,64
Перисто-слоистые (Cs)	0,88	0,86	0,87	0,72
Перисто-кучевые (Cc)				0,92
<b>Среднее</b>	<b>0,87</b>	<b>0,88</b>	<b>0,87</b>	<b>0,85</b>

Из *табл. 3* видно, что достоверность распознавания в целом для обоих радиометров достаточно хорошо согласуется между собой. Однако по отдельным типам облачности имеются значительные расхождения. Наибольшие отличия  $R_i$  наблюдаются у Cb cap, Sc und и Ci sp. Анализ ошибок классификации показал, что классификатор для VIIRS относит тестовые образцы Cb cap к Ci sp и наоборот. Поскольку оба этих типа часто наблюдаются вместе, то такие ошибки вполне допустимы. Для улучшения достоверности их распознавания необходимо привлекать дополнительную информацию, например о водозапасе. Тестовые образцы Sc und, для которых высота верхней границы облаков находилась в районе 2500 м, были отнесены к Ac und, текстура изображения которых является достаточно схожей. Низкую вероятность правильной классификации Ci fib в ночное время суток можно объяснить размытостью их структуры и отсутствием канала поглощения водяного пара у радиометра VIIRS. В целом высокие значения  $P_i$  и  $F_i$  подтверждают эффективность разработанного классификатора.

Согласно второму подходу к анализу качества классификации облачности происходит экспертная оценка спутниковых изображений с разбиением их на отдельные участки, которые маркируются вручную. Удобнее всего выделять на снимках прямоугольные области. В каждом таком участке определяется преобладающий тип облачности. Затем выполняется обработка спутникового снимка разработанным алгоритмом и производится его сопоставление с промаркированными вручную изображениями. Далее вычисляется следующая оценка:

$$H = \frac{S^R}{S^T},$$

где  $S^R$  — число совпадений мнения классификатора с экспертной оценкой;  $S^T$  — общее количество промаркированных областей. На *рис. 2* показан результат классификации облачности по спутниковому снимку VIIRS, сделанному в ночное время суток над территорией Европы 02.04.2018 в 00:18 UTC. Зенитный угол Луны меняется от  $70^\circ$  на юге до  $50^\circ$  на севере, а освещённость её диска — от 96 % на западе до 97 % на востоке. В центре снимка (см. *рис. 2а*) расположен фронт окклюзии, что облегчает его маркировку и сопоставление. Результат экспертной оценки показан на *рис. 2б*, где цветом квадрата обозначается преобладающий тип облачности в области  $127 \times 101$  пиксель.



*Рис. 2.* Результаты классификации облачности: *а* — по спутниковому снимку VIIRS; *б* — экспертной оценкой; *в* — разработанным алгоритмом

Сопоставление вручную промаркированного изображения с результатом автоматического распознавания показало, что мнение эксперта и классификатора совпало в  $S^R = 779$  случаях из  $S^T = 960$  возможных. При оценке не учитывался первый и последний столбец фрагментов сетки из-за искажений, создаваемых «эффектом бабочки» в тематическом продукте CLDPOROP\_12. Таким образом, вероятность правильной классификации исследуемого снимка составила  $H = 0,81$ , что близко к среднему значению  $R_i$ , полученному при обработке тестовой выборки. Наибольшие разногласия, по мнению эксперта, наблюдаются на участках, свободных от облаков, а также при распознавании типа облачности верхнего яруса

Ci fib, Ci sp и Cs. Следует отметить, что расположение облаков конкретных разновидностей на *рис. 2в* хорошо согласуется со структурой облачной системы фронта окклюзии по типу холодного фронта согласно работе (Беспалов и др., 2011). Однако DNB-изображение, показанное на *рис. 2а*, получено при относительно благоприятных условиях съёмки. Их ухудшение неизбежно приведёт к уменьшению величины  $H$  вследствие ошибок как эксперта из-за уменьшения яркости и контрастности снимков, так и классификатора по причине размывания текстуры и границ облаков. Для подтверждения этого требуется проведение дополнительных исследований, что можно рассматривать в качестве перспективного направления развития данной работы.

## Заключение

Основным результатом работы является алгоритм классификации облачности по спутниковым данным радиометра VIIRS, полученным в ночное время суток. Данный метод основан на применении вероятностной нейронной сети, текстурном анализе изображений и восстановлении физических характеристик облаков. Предложена ночная классификация облачности с учётом результатов исследования характерных образцов для её различных типов. Объединены в один класс высокослоистые и слоисто-дождевые облака, а также перисто-слоистые и перисто-кучевые. Для их эффективного разделения необходимо привлекать дополнительную информацию, например о водозапасах и оптической толщине облачности, которая отсутствует в продукте CLDPROP\_12 для ночного времени суток. Определены граничные условия применимости DNB-изображений для надёжной классификации облаков: зенитный угол Луны —  $75^\circ$ , а освещённость её диска —  $72\%$ . Данные ограничения используются в разработанном алгоритме наряду с маской облачности при сканировании спутниковых снимков скользящим окном. Усреднённые оценки точности и полноты результатов классификации тестовой выборки, состоящей из образцов, полученных при различных условиях съёмки, составили 0,87 и 0,88 соответственно. Проведено сопоставление результатов классификации отдельных разновидностей облаков по данным VIIRS с аналогичными показателями, достигнутыми при использовании спутниковых снимков MODIS, которое показало их хорошую согласованность. Регистрируемые при этом расхождения несущественны из-за значительного сходства характеристик различных типов облачности, которые часто наблюдаются одновременно, например Cb cap и Ci sp. Выполнено сопоставление результатов классификации разработанным алгоритмом с экспертной оценкой спутниковых снимков, продемонстрировавшее хорошую согласованность с итогами анализа тестовой выборки. При этом рассматривались эпизоды наблюдения таких атмосферных процессов, как фронты, облачные системы которых хорошо изучены (см. *рис. 2*). Результаты настоящей работы подтверждают эффективность использования данных VIIRS, полученных в ночное время суток, для исследования характеристик облачности. Поскольку граничным условиям удовлетворяют 10–12 DNB-изображений в месяц, то для непрерывного мониторинга они малопригодны. Однако такие снимки могут быть использованы для изучения суточной изменчивости характеристик отдельных типов облачности, информация о которой необходима для улучшения понимания роли облаков в происходящих климатических изменениях. Это следует отнести к перспективным направлениям развития данной работы.

Работа в части разработки алгоритма классификации облачности по данным VIIRS в ночное время суток выполнена при финансовой поддержке Российского научного фонда в рамках научного проекта № 19-71-00049, а в части изучения изменчивости характеристик облаков — в рамках государственного задания Института оптики атмосферы им. В. Е. Зуева СО РАН (рег. № АААА-А17-117021310142-5).

## Литература

1. Астафуров В. Г., Скороходов А. В. Сегментация спутниковых снимков по текстурным признакам на основе нейросетевых технологий // Исслед. Земли из космоса. 2011. № 6. С. 10–20.
2. Астафуров В. Г., Скороходов А. В. Формирование системы информативных классификационных характеристик при решении задачи классификации облачности по спутниковым данным MODIS // Труды СПИИРАН. 2017. Т. 53. № 4. С. 118–139.
3. Беспалов Д. П., Девяткин А. М., Довгалюк Ю. А., Кондратюк В. И., Кулешов Ю. В., Светлова Т. П., Суворов С. С., Тимофеев В. И. Атлас облаков. СПб.: Д'АРТ, 2011. 248 с.
4. Волкова Е. В. Оценки 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. Жижин М. Н., Элидж К. Д., Пойда А. А. Мультиспектральное дистанционное зондирование ночной поверхности Земли // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 3. С. 9–26.
6. Крацов Г. А. Вычисления на классификациях. Оценка классификаторов // Электронное моделирование. 2016. Т. 38. № 6. С. 15–24.
7. Код для оперативной передачи данных приземных метеорологических наблюдений с сети станций Росгидромета / Федеральная служба по гидрометеорологии и мониторингу окружающей среды (Росгидромет). М., 2013. 79 с.
8. Облака и облачная атмосфера: справ. / под ред. Мазина И. П., Хргиана А. Х. Л.: Гидрометеиздат, 1989. 647 с.
9. Ackerman S. A., Frey R., Heidinger A., Li Y., Walther A., Platnik S., Meyer K. G., Wind G., Amarasinghe N., Wang C., Marchant B., Holz R. E., Dutcher S., Hubanks P. EOS MODIS and SNPP VIIRS Cloud Properties: User Guide for the Climate Data Record Continuity Level-2 Cloud Top and Optical Properties Product (CLDPROP). Greenbelt: Goddard Space Flight Center, 2019. 65 p.
10. Astafurov V. G., Kuriyanovich K. V., Skorokhodov A. V. A statistical model for describing the texture of cloud cover images from satellite data // Russian Meteorology and Hydrology. 2017. V. 42(4). P. 248–257.
11. Bankert R. L., Mitrescu C., Miller S. W., Wade R. H. Comparison of GOES cloud classification algorithms employing explicit and implicit physics // J. Applied Meteorology and Climatology. 2009. V. 48. P. 1411–1421.
12. Bony S., Stevens B., Frierson D. M. W., Jakob C., Kageyama M., Pincus R., Shepherd T. G., Sherwood S. C., Siebesma A. P., Sobel A. H., Watanabe M., Webb M. J. Clouds, circulation and climate sensitivity // Nature Geoscience. 2015. V. 8. P. 261–268.
13. Bretherton C. S., Blossey P. N., Khairoutdinov M. An energy-balance analysis of deep convective self-aggregation above uniform SST // J. Atmospheric Sciences. 2005. V. 62. P. 4273–4292.
14. Chernokulsky A. V., Esau I., Bulygina O. N., Davy R., Mokhov I. I., Outten S., Semenov V. A. Climatology and interannual variability of cloudiness in the Atlantic Arctic from surface observations since the late nineteenth century // J. Climate. 2017. V. 30. P. 2103–2020.
15. Davis G. History of the NOAA satellite program // J. Applied Remote Sensing. 2007. V. 1. P. 012504–012504.
16. Evan A. T., Heidinger A. K., Vimont D. J. Arguments against a physical long-term trend in global ISCCP cloud amounts // Geophysical Research Letters. 2007. V. 34. L04701.
17. Fowler L. D., Randall D. A. Liquid and Ice Cloud Microphysics in the CSU General Circulation Model. Part III: Sensitivity to Modeling Assumptions // J. Climate. 1996. V. 9. P. 561–586.
18. Liu Y., Xia J., Shi C. X., Hong Y. An improved cloud classification algorithm for China's FY-2C multi-channel images using artificial neural network // Sensors. 2009. V. 9. P. 5558–5579.
19. Menzel W. P. Remote sensing applications with meteorological satellites. Madison: University of Wisconsin, 2006. 307 p.
20. Pressel K. G., Kaul C. M., Schneider T. Possible climate transitions from breakup of stratocumulus decks under greenhouse warming // Nature Geoscience. 2019. V. 12. P. 163–167.
21. Skorokhodov A. V., Astafurov V. G., Evsutkin T. V. Application of statistical models of image texture and physical parameters of clouds for their classification on MODIS satellite images // Izvestiya, Atmospheric and Oceanic Physics. 2019. V. 55(9). P. 1053–1064.
22. Xiong X., Wenny B. N., Angal A., Barnes W., Salomonson V. Summary of Terra and Aqua MODIS long-term performance // Proc. IGARSS. 2011. P. 4006–4009.
23. Young A. H., Knapp K. R., Inamdar A., Hankins W., Rossow W. B. The International Satellite Cloud Climatology Project H-Series climate data record product // Earth System Science Data. 2018. V. 10. P. 583–593.

## Nighttime cloud classification by VIIRS satellite data

A. V. Skorokhodov

Zuev Institute of Atmospheric Optics SB RAS, Tomsk 634055, Russia  
E-mail: vazime@yandex.ru

The analysis results of VIIRS satellite data obtained at nighttime for cloud classification are presented. We used visible light spectrum images of the day/night band of this sensor. This made it possible to use the results of texture analysis for images to describe clouds. The boundary conditions for the applicability of day/night images to solve the problem of cloud type recognition are determined. The nighttime cloud classification is presented taking into account the capabilities of satellite device. An algorithm for cloud type recognition based on the use of a probabilistic neural network is proposed. The software is based on the technology of parallel computing by general-purpose graphic processors. The search results of informative features for clouds based on the GRAD-II truncated enumeration method are presented. The nighttime cloud classification results based on the test sample and expert evaluation are discussed. We used satellite images obtained under various sensing conditions. The classification results of individual cloud types at nighttime by VIIRS and daytime by MODIS are discussed.

**Keywords:** cloud classification, nighttime, satellite data, texture features, cloud properties, day/night images, VIIRS

Accepted: 13.04.2020

DOI: 10.21046/2070-7401-2020-17-3-240-251

### References

1. Astafurov V. G., Skorokhodov A. V., Segmentatsiya sputnikovyx snimkov po teksturnym priznakam na osnove neirosetevykh tekhnologii (Segmentation of satellite images by textural parameters based on Neural Network Technologies), *Issledovanie Zemli iz kosmosa*, 2011, No. 6, pp. 10–20.
2. Astafurov V. G., Skorokhodov A. V., Formirovanie sistemy informativnykh klassifikatsionnykh kharakteristik pri reshenii zadachi klassifikatsii oblachnosti po sputnikovym dannym MODIS (Formation of a set of informative classification features for solving cloud classification problem using MODIS satellite data), *Trudy SPIIRAN*, 2017, Vol. 53, No. 4, pp. 118–139.
3. Bespalov D. P., Devyatkin A. M., Dovgalyuk Yu. A., Kondratyuk V. I., Kuleshov Yu. V., Svetlova T. P., Suvorov S. S., Timofeev V. I., *Atlas oblakov* (Cloud Atlas), Saint Petersburg: D'ART, 2011, 248 p.
4. Volkova E. V., Otsenki parametrov oblachnogo pokrova, osadkov i opasnykh yavlenii pogody po dannym radiometra AVHRR s MISZ serii NOAA kruglosutochno v avtomaticheskom rezhime (Automatic estimation of cloud cover and precipitation parameters obtained by AVHRR NOAA for day and night conditions), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2013, Vol. 10, No. 3, pp. 66–74.
5. Zhizhin M. N., Elvidzh K. D., Poida A. A., Mul'tispektral'noe distantsionnoe zondirovanie nochnoi poverkhnosti Zemli (Multispectral nighttime remote sensing of the Earth), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, Vol. 14, No. 3, pp. 9–26.
6. Kravtsov G. A., Vychisleniya na klassifikatsiyakh. Otsenka klassifikatorov (Classification calculations. Classifier Assessment), *Elektronnoe modelirovanie*, 2016, Vol. 38, No. 6, pp. 15–24.
7. *Kod dlya operativnoi peredachi dannyykh prizemnykh meteorologicheskikh nablyudenii s seti stantsii Rosgidrometa* (Land station surface synoptic code FM 12-IX SYNOP), Moscow, 2013, 79 p.
8. *Oblaka i oblachnaya atmosfera* (Clouds and cloudy atmosphere), Mazin I. P., Khragian A. Kh. (eds.), Leningrad: Gidrometeoizdat, 1989, 647 p.
9. Ackerman S. A., Frey R., Heidinger A., Li Y., Walther A., Platnik S., Meyer K. G., Wind G., Amarasinghe N., Wang C., Marchant B., Holz R. E., Dutcher S., Hubanks P., *EOS MODIS and SNPP VIIRS Cloud Properties: User Guide for the Climate Data Record Continuity Level-2 Cloud Top and Optical Properties Product (CLDPROP)*, Greenbelt: Goddard Space Flight Center, 2019, 65 p.
10. Astafurov V. G., Kuriyanovich K. V., Skorokhodov A. V., A statistical model for describing the texture of cloud cover images from satellite data, *Russian Meteorology and Hydrology*, 2017, Vol. 42(4), pp. 248–257.
11. Bankert R. L., Mitrescu C., Miller S. W., Wade R. H., Comparison of GOES cloud classification algorithms employing explicit and implicit physics, *J. Applied Meteorology and Climatology*, 2009, Vol. 48, pp. 1411–1421.

12. Bony S., Stevens B., Frierson D. M. W., Jakob C., Kageyama M., Pincus R., Shepherd T. G., Sherwood S. C., Siebesma A. P., Sobel A. H., Watanabe M., Webb M. J., Clouds, circulation and climate sensitivity, *Nature Geoscience*, 2015, Vol. 8, pp. 261–268.
13. Bretherton C. S., Blossey P. N., Khairoutdinov M., An energy-balance analysis of deep convective self-aggregation above uniform SST, *J. Atmospheric Sciences*, 2005, Vol. 62, pp. 4273–4292.
14. Chernokulsky A. V., Esau I., Bulygina O. N., Davy R., Mokhov I. I., Outten S., Semenov V. A., Climatology and interannual variability of cloudiness in the Atlantic Arctic from surface observations since the late nineteenth century, *J. Climate*, 2017, Vol. 30, pp. 2103–2020.
15. Davis G., History of the NOAA satellite program, *J. Applied Remote Sensing*, 2007, Vol. 1, pp. 012504–012504.
16. Evan A. T., Heidinger A. K., Vimont D. J., Arguments against a physical long-term trend in global ISCCP cloud amounts, *Geophysical Research Letters*, 2007, Vol. 34, L04701.
17. Fowler L. D., Randall D. A., Liquid and Ice Cloud Microphysics in the CSU General Circulation Model. Part III: Sensitivity to Modeling Assumptions, *J. Climate*, 1996, Vol. 9, pp. 561–586.
18. Liu Y., Xia J., Shi C. X., Hong Y., An improved cloud classification algorithm for China's FY-2C multi-channel images using artificial neural network, *Sensors*, 2009, Vol. 9, pp. 5558–5579.
19. Menzel W. P., *Remote sensing applications with meteorological satellites*, Madison: University of Wisconsin, 2006, 307 p.
20. Pressel K. G., Kaul C. M., Schneider T., Possible climate transitions from breakup of stratocumulus decks under greenhouse warming, *Nature Geoscience*, 2019, Vol. 12, pp. 163–167.
21. Skorokhodov A. V., Astafurov V. G., Evsutkin T. V., Application of statistical models of image texture and physical parameters of clouds for their classification on MODIS satellite images, *Izvestiya, Atmospheric and Oceanic Physics*, 2019, Vol. 55(9), pp. 1053–1064.
22. Xiong X., Wenny B. N., Angal A., Barnes W., Salomonson V., Summary of Terra and Aqua MODIS long-term performance, *Proc. IGARSS*, 2011, pp. 4006–4009.
23. Young A. H., Knapp K. R., Inamdar A., Hankins W., Rossow W. B., The International Satellite Cloud Climatology Project H-Series climate data record product, *Earth System Science Data*, 2018, Vol. 10, pp. 583–593.