

Метод количественной оценки осадков на основе измерений Himawari-8/9

А. И. Андреев^{1,2}, А. А. Филей^{1,2}, С. И. Мальковский¹, С. П. Королев¹

¹ Вычислительный центр ДВО РАН, Хабаровск, 680000, Россия
E-mail: a.andreev@dvrspod.ru

² Дальневосточный Центр НИЦ «Планета», Хабаровск, 680000, Россия

Представлен алгоритм оценки мгновенной интенсивности осадков по данным космических аппаратов Himawari-8/9. Алгоритм основан на использовании двух нейронных сетей трансформерной и сверточной архитектуры для предварительного расчёта маски полей осадков и оценки их мгновенной интенсивности. В качестве источника информации об осадках для обучения нейронной сети использовались измерения международного проекта по глобальному мониторингу осадков GPM (*англ.* Global Precipitation Measurements), основанного на данных различных спутниковых приборов активного и пассивного зондирования в микроволновом и инфракрасном спектре. При обучении нейронной сети учитывались спектральные, текстурные и микрофизические характеристики осадкообразующих облаков. Оценка точности полученных результатов интенсивности осадков была проведена с использованием данных об осадках из проекта GPM, а также данных прогностической модели CosmoRu-6 и наземных измерений осадкомеров в виде накопленной суммы осадков. Показано, что представленный алгоритм наиболее точно оценивает количество осадков, однако имеет тенденцию к переоценке их накопленных сумм, тогда как GPM и CosmoRu-6 склонны к их недооценке. Сравнение с продуктом GPM показало значение корня среднеквадратичной ошибки около 2,19 мм/ч.

Ключевые слова: осадки, нейронная сеть, Himawari

Одобрена к печати: 30.09.2024

DOI: 10.21046/2070-7401-2024-21-5-20-35

Введение

Количественная оценка осадков — одна из ключевых задач гидрометеорологии, точность решения которой во многом зависит от частоты получения информации и распределённой наблюдательной сети наземных метеостанций. В связи с этим для некоторых территорий возможности подобного мониторинга могут быть существенно ограничены (Levizzani, Cattani, 2019), например для труднодоступных регионов Сибири и Дальнего Востока России. Развитие современных спутниковых платформ и методов дистанционного зондирования значительно расширяет возможности анализа и прогнозирования осадков.

Для мониторинга осадков применяются спутниковые приборы микроволнового (МВ), а также инфракрасного (ИК) спектра, в том числе с учётом видимого диапазона (ВИК) спектра. МВ-зондирование осуществляется в основном с полярно-орбитальных космических аппаратов (КА), что ограничивает пространственно-временные масштабы наблюдений. С этой точки зрения более перспективны геостационарные КА ввиду большего территориального охвата, а также высокого пространственного (до 4 км в надире) и временного (от 10 мин) разрешения (Prigent, 2010). МВ-измерения чаще используются для уточнения количества осадков с геостационарных КА (Huffman et al., 2020; Sun et al., 2018).

Алгоритмы количественной оценки осадков на основе ВИК-измерений используют различные косвенные характеристики облаков, например температуру в канале 11 мкм (Arkin, 1979). Нередко эти данные дополняются измерениями в спектральном диапазоне 6–9 мкм, чувствительном к присутствию водяного пара в атмосфере (Kurino, 1997). Комбинации спектральных каналов также могут указывать на различные физические процессы в атмосфере. Например, высокая отражательная способность в видимом спектре при достаточно низкой температуре часто указывает на наличие осадков (King et al., 1995). Конвективные

и многослойные облака имеют более высокую температуру в канале 3,9 мкм, чем в канале 11 мкм (Ellrod, 1994), а разность яркостной температуры в каналах 6,7 и 11 мкм может служить индикатором присутствия глубокой конвекции и коррелирует с количеством осадков (Amorati et al., 2000). Для количественной оценки осадков помимо спектральных признаков также используются микрофизические характеристики облаков (Roebeling, Holleman, 2009; Liu et al., 2019). Для их расчёта применяются методы оценки оптической толщины, эффективного радиуса облачных частиц (Nakajima, King, 1990), фазового состава воды в облаке (Rossow, Schiffer, 1999) и ряд других параметров. Использование дополнительной пространственно-распределённой информации может быть полезно при анализе спутниковых изображений на предмет наличия осадков. Текстурные признаки и геометрические признаки, например линейный размер облаков, температурный градиент и его вариации, позволяют существенно повысить точность количественной оценки осадков (Hong et al., 2004; Mahrooghy et al., 2012).

Для учёта вышеуказанных признаков применяются различные алгоритмы. Первые алгоритмы для оценки осадков основывались на пороговых и регрессионных методах, однако вскоре им на смену пришли методы машинного обучения. Их преимуществом становится отсутствие необходимости ручного задания решающих правил, универсальность и гибкость применительно к любому формату входных данных. Так, в 1997 г. был представлен один из первых таких алгоритмов семейства PERSIANN (*англ.* Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks), основанный на использовании самоорганизующихся карт признаков SOFM (*англ.* Self-Organized Feature Maps). В качестве входной информации для алгоритма использовалась температура в канале 11 мкм с учётом информации из соседних пикселей (Hsu et al., 1997). Позднее была представлена версия PERSIANN-CCS (*англ.* Cloud Classification System), учитывающая стадии развития конвективной облачности применением процедуры предварительной кластеризации (Hong et al., 2004). В дальнейшем алгоритм был усовершенствован за счёт использования мультиспектральной информации в дополнение к текстурным характеристикам (Behrangi et al., 2009). Существенным шагом в использовании текстурной информации стало использование свёрточных нейронных сетей, извлекающих необходимые релевантные признаки из изображений в процессе своего обучения. На их основе были разработаны алгоритмы PERSIANN-CNN (*англ.* Convolutional Neural Network) и PERSIANN-cGAN (*англ.* conditional Generative-Adversarial Network), показавшие наибольшую точность среди ранее представленных решений (Hayatbini et al., 2019; Sadeghi et al., 2019).

Чтобы повысить точность количественной оценки осадков, предлагаются различные подходы, например использование моделей численного прогноза погоды (ЧПП) (Min et al., 2018; Tapiador et al., 2019). При этом стоит учитывать, что пространственное и временное разрешение таких моделей остаётся невысоким, что ограничивает их прямое использование в качестве источника входной информации. С другой стороны, данные ЧПП позволяют более точно смоделировать ряд микро- и макрофизических параметров облачности, расчёт которых основан на использовании спутниковых измерений.

Достаточно перспективны исследования, направленные на комбинирование измерений различных КА с целью создания глобальной карты осадков (Huffman et al., 2020). Это в свою очередь требует разработки методов оценки осадков для каждого спутникового прибора и процедур их взаимной калибровки.

В некоторых работах обсуждается проблема несбалансированности распределения осадков различной интенсивности, что часто приводит к их переоценке или недооценке алгоритмами на основе регрессии и машинного обучения. Предварительная классификация осадкообразующей облачности и использование алгоритмов на основе деревьев решений позволяет частично преодолеть эту проблему (Min et al., 2018; Hirose et al., 2019). Однако деревья решений плохо учитывают текстуру облачности, поэтому целесообразнее использовать для этой задачи свёрточные нейронные сети.

Нейросетевые методы непрерывно совершенствуются и предлагаются новые архитектуры сетей, позволяющие более эффективно решать поставленные задачи. Одной из послед-

них разработок в этой области представляется архитектура визуальных трансформеров для обработки изображений. Опыт показывает, что подобные архитектуры могут успешно применяться и для количественной оценки осадков (Jia et al., 2022), однако они достаточно требовательны к вычислительным ресурсам.

В целях оперативного расчёта карт осадков с наибольшей точностью на основе спутниковых наблюдений геостационарного КА Himawari-8/9 в настоящей работе предлагается алгоритм, учитывающий спектральную, текстурную и микрофизическую информацию об облачности. Алгоритм разрабатывался для северной части Азиатско-Тихоокеанского региона, где практически отсутствуют данные радиолокационных наблюдений за осадками, часто используемые при разработке подобных алгоритмов. Поэтому в качестве источника информации об осадках в работе использовались данные международного проекта GPM (англ. Global Precipitation Measurement). Представленный алгоритм основан на использовании двух нейронных сетей трансформерной и свёрточной архитектуры для обнаружения осадков и оценки их мгновенной интенсивности. Тестирование алгоритма осуществлялось с использованием наземных измерений сумм осадков, данных GPM, а также региональной модели ЧПП CosmoRu-6.

Используемые данные

Исследование проводилось для территории Азиатско-Тихоокеанского региона, ограниченной 35–60° с.ш., 100–160° в.д. Для данной территории характерно неравномерное распределение наземных метеорологических станций и сложный рельеф с протяжённой береговой линией (рис. 1).

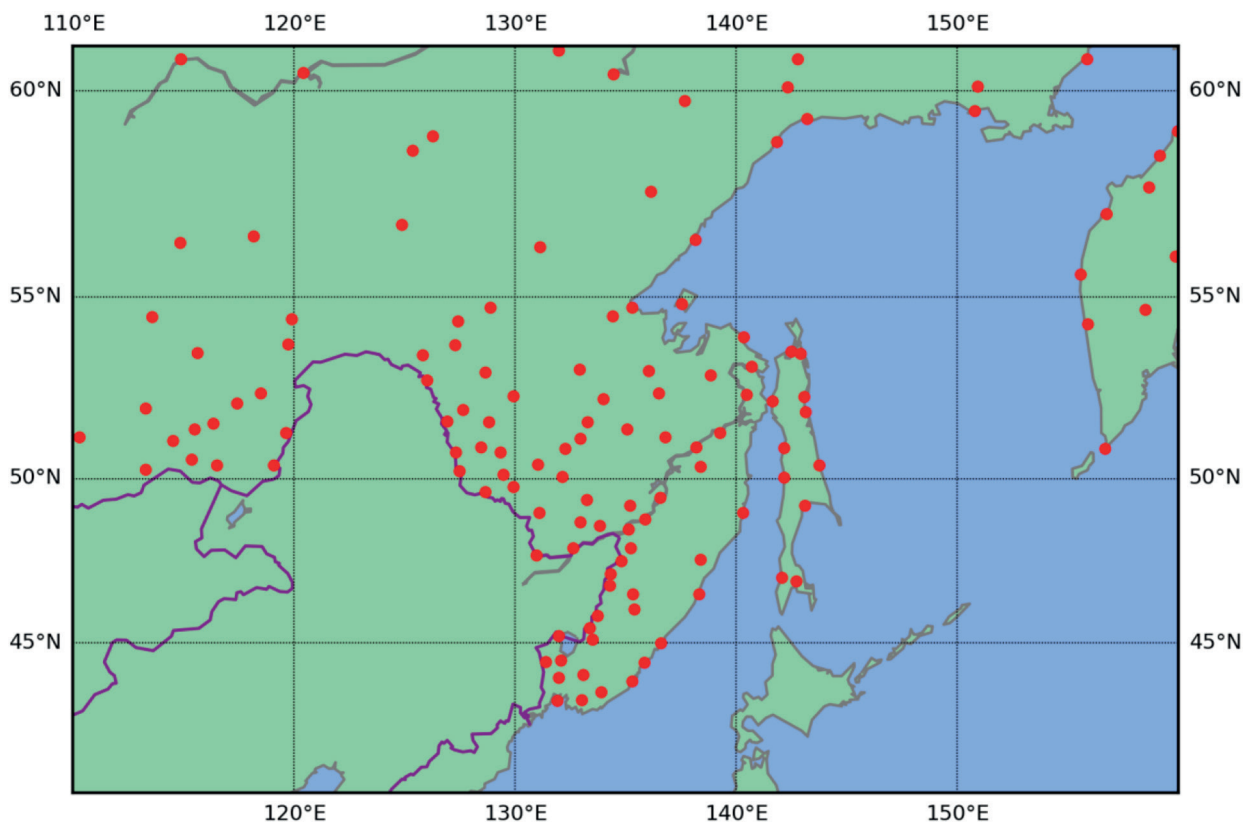


Рис. 1. Рассматриваемая территория; красным маркером отмечено расположение метеостанций, данные которых использовались для тестирования алгоритма

Спутниковые измерения

В качестве входных данных для алгоритма в работе используются измерения спектрорадиометра АНИ (*англ.* Advanced Himawari Imager), установленного на КА Himawari-8/9. Данные предоставлены Центром коллективного пользования (ЦКП) «ИКИ-Мониторинг». Все измерения выражены в единицах коэффициента спектральной яркости (КСЯ) для видимого диапазона и яркостной температуры для ИК-спектра.

Прогностические данные

Для расчёта микро- и макрофизических параметров облачности использовались данные о температуре, давлении и содержании водяного пара из прогностической модели ЧПП NCEP GFS (*англ.* National Centers of Environmental Prediction Global Forecast System). Каждому сроку наблюдений Himawari был сопоставлен ближайший по времени прогноз GFS с пространственным разрешением $0,5^\circ$ и временным шагом прогноза 3 ч.

В целях сравнительного тестирования алгоритма в работе также использовались данные ЧПП региональной модели CosmoRu-6 с пространственным разрешением $0,06^\circ$ ($6,6$ км) и временным шагом прогноза 3 ч (Ривин и др., 2019). Модель предназначена для территории Российской Федерации и была создана в рамках международного сотрудничества по проекту COSMO (*англ.* COnsortium for Small-scale MOdeling) (Doms, Baldauf, 2018) на основе прогностической модели ICON (*англ.* ICOSahedral Nonhydrostatic) (Giorgetta et al., 2018). Модель используется Гидрометцентром России (<https://method.meteorf.ru/>) и позволяет оценивать накопленную сумму осадков.

Данные об осадках

Основным источником информации об осадках в работе является продукт IMERG (*англ.* Integrated Multi-satellitE Retrievals for GPM), созданный в рамках международного проекта по глобальному мониторингу осадков GPM. Продукт IMERG стал результатом комплексирования измерений осадков по данным различных приборов активного и пассивного МВ- и ИК-спектров (Huffman et al., 2020).

В процессе формирования обучающих и тестовых выборок использовались версии продуктов IMERG Late Run и Final Run с набором данных IRprecipitation с пространственным разрешением $0,1^\circ$ и временным шагом 30 мин. Для расчёта указанных продуктов использовался нейросетевой алгоритм PERSIANN-CCS, входной информацией для которого являются ИК-измерения геостационарных КА (Huffman et al., 2020). Алгоритм осуществляет предварительную сегментацию исходного ИК-изображения на отдельные участки пикселей с осадками с последующей их группировкой в зависимости от размера и текстурных характеристик. Каждая такая группа характеризуется зависимостью между температурой в ИК-канале и интенсивностью осадков, калибруемой с учётом наземных радарных измерений осадков (Hong et al., 2004).

Набор данных IRprecipitation был выбран в качестве эталонного, поскольку координаты полей осадков в нём наиболее точно соответствуют положению облачности на изображениях Himawari. Для получения более достоверных измерений осадков при формировании выборок учитывался индекс QI (*англ.* Quality Index) из набора IMERG. Индекс рассчитывается на основе корреляции между измерениями спутникового радара GMI (*англ.* GPM Microwave Imager) и другими КА. В работе использовались измерения с индексом $QI > 0,65$ (значение выбрано как оптимальное между размером выборки и качеством данных).

Для тестирования алгоритма помимо продукта IMERG используются наземные измерения осадков на метеостанциях, представленные в виде накопленных полусуточных сумм за временные отрезки 0:00–12:00 и 12:00–0:00 UTC (*англ.* Coordinated Universal Time, всемирное координированное время) для августа 2023 г. для 141 станции на рассматриваемой территории.

Вспомогательная информация

Для учёта орографической информации в работе рассматривалась цифровая модель высоты рельефа над уровнем моря GLOBE (*англ.* Global Land One-kilometer Base Elevation, <http://www.ngdc.noaa.gov/mgg/topo/globe.html>). Дополнительно в качестве входной информации для алгоритма использовался зенитный угол наблюдения прибора в каждом пикселе изображения. Для каналов видимого диапазона осуществлялась коррекция КСЯ с учётом зенитного угла Солнца.

Расчёт параметров облачности

На основе измерений спектро радиометра АНІ рассчитывается ряд микро- и макрофизических параметров облачности, в частности: маска облачности, высота верхней границы облачности (ВВГО), фазовое состояние воды в облаке (ФСО), оптическая толщина, эффективный радиус облачных частиц, содержание воды и льда.

Маска облачности — базовый продукт, используемый при расчёте параметров облачности. Для её расчёта применялся нейросетевой текстурный алгоритм (Andreev, Shamilova, 2021), точность которого в светлое время суток составила 95 %, а в тёмное — около 76 % в сравнении с масками облачности по данным прибора VIIRS (*англ.* Visible Infrared Imaging Radiometer Suite), предоставленными Национальным управлением океанических и атмосферных исследований США NOAA (*англ.* National Oceanic and Atmospheric Administration). Снижение точности в тёмное время суток обусловлено неполным обнаружением слоистых форм облаков, не образующих осадки в рассматриваемом регионе (Wang, 2013). На основе маски облачности рассчитываются нижеописанные параметры.

Параметр ВВГО связан с тем или иным типом облачности. Для его оценки в работе используется алгоритм CLAVR-x (*англ.* CLOUDS from Advanced Very-high-resolution Radiometer extended), описанный в работе (Heidinger, Li, 2018). Метод расчёта основан на анализе уходящего ИК-излучения в каналах 11,2 и 12,4 мкм. С применением модели переноса излучения RTTOV (*англ.* Radiative Transfer for Television infrared observation satellite Operational Vertical sounder) и с учётом вертикальных профилей температуры, водяного пара и давления из модели NCEP GFS моделируются параметры интенсивности излучения для «чистого» неба и атмосферы над облачностью. Данные параметры используются для получения температуры ВВГО по методу оптимальной оценки (Poulsen et al., 2012), которая сопоставляется с соответствующим геопотенциальным уровнем температурного профиля из модели.

Оценка параметра ФСО осуществляется на основе анализа температуры облачности на верхней границе. Используя температурные пороги для ИК-измерений, облачность условно можно разделить на несколько фазовых состояний: капельная, смешанная (в том числе преимущественно-капельная или преимущественно кристаллическая) и кристаллическая. Выбор пороговых значений описан в работе (Key, Intrieri, 2000).

Образование осадков связано с ростом капель воды в облаке (Pruppacher, Klett, 1979) и может быть описано с использованием параметров оптической толщины τ и эффективного радиуса облачных частиц r_{eff} . Метод оценки этих параметров основан на анализе зависимости спектрального излучения в видимом диапазоне от τ , в то время как r_{eff} напрямую ассоциируется с интенсивностью излучения в ИК-диапазоне (Gasteiger et al., 2014). В тёмное время суток (при зенитном угле Солнца выше 70°) эти параметры оцениваются на основе разности яркостной температуры в каналах 11,2 и 12,4 мкм. Расчёт этих параметров проводился сравнением спектральной яркости с предварительно смоделированными значениями с помощью RTTOV для различных условий наблюдений и представленными в виде справочных таблиц.

Используя предварительно рассчитанные значения ФСО, τ и r_{eff} , можно оценить содержание воды LWP (*англ.* Liquid Water Path) и льда IWP (*англ.* Ice Water Path) в облаке:

$$LWP = \frac{5}{9} \rho_{water} r_{eff} \tau, \quad IWP = \frac{5}{9} \rho_{ice} r_{eff} \tau, \quad (1)$$

где $\rho_{water} = 1,0$ и $\rho_{ice} = 0,917$ — плотность воды и льда соответственно.

Формирование обучающих и тестовых выборок

Для обучения нейросетевого алгоритма были сформированы два набора данных. Первый набор состоит из сегментов размером 256×256 пикселей, полученных из исходных совмещённых изображений АНУ и полей осадков IMERG. Другой набор состоит из текстурных изображений размером 5×5 пикселей, где центральному пикселю сопоставлено значение интенсивности с соответствующей координатой из IMERG. Все изображения приведены к единому пространственному разрешению $0,1^\circ$, значение каждого канала изображения представляет собой тот или иной входной параметр для алгоритма, нормированный в диапазоне $[0, 1]$. В работе рассматривались осадки величиной не более 50 мм/ч исходя из их распределения для рассматриваемой территории (Li et al., 2020).

Объём выборки для задачи классификации составил около $8,8$ тыс. сегментов, а для решения регрессионной задачи — приблизительно $5,4$ млн текстурных изображений. Выборки формировались в период с мая по сентябрь 2022 и 2023 гг. Описанные выше обучающие выборки были поделены в соотношении $3:1:1$ для настройки алгоритмов и их итогового тестирования. Данные поделены таким образом, чтобы сроки наблюдений из одной части выборки не присутствовали в других частях.

Анализ используемых признаков

Для оценки вклада каждого используемого входного признака была построена отдельная регрессионная модель на основе метода деревьев решений (*англ.* Random Forest). Выбор в пользу этой модели обусловлен тем, что деревья решений, в отличие от нейронных сетей, лучше поддаются подобному анализу ввиду более высокой интерпретируемости принимаемых моделью решений. Кроме того, для их обучения требуется меньше вычислительных ресурсов, а сами деревья решений успешно применяются для решения задачи количественной оценки осадков (Hirose et al., 2019; Min et al., 2018).




Рис. 2. Распределение интенсивностей осадков в выборке для анализа признаков

Использованная модель Random Forest состояла из 100 деревьев с глубиной не более шести уровней и количеством признаков не более пяти на одно дерево. В качестве оценочной функции использовалась среднеквадратичная ошибка MSE (*англ.* Mean Squared Error). Выборка для обучения была сбалансирована, как показано на рис. 2. Обучение модели осуществлялось по методу кросс-валидации с количеством разбиений исходной выборки на пять частей. В табл. 1 представлены значения ошибки MSE, полученные при использовании того или иного набора параметров.

Таблица 1. Влияние входных признаков на точность оценки интенсивности осадков

ИК-каналы	Видимые каналы	Разность ИК-каналов	Параметры облачности	Высота рельефа	Зенитный угол наблюдения	MSE
+	–	–	–	–	–	7,189
	+	–	–	–	–	7,150
		+	–	–	–	7,075
		–	+	–	–	6,979
		–	–	+	–	6,979
		–	–	–	+	6,978

Для более детального анализа каждого признака применялись два метода. Первый метод основан на расчёте индекса Gini, являющегося мерой того, насколько каждый признак влияет на неопределённость модели и как часто он используется при формировании деревьев (Breiman, 2017). Чтобы учесть взаимную корреляцию между признаками, дополнительно для анализа применялся метод SHAP (англ. SHapley Additive exPlanations), суть которого заключается в измерении того, насколько изменение каждого признака влияет на итоговый результат (Lundberg, Lee, 2017). На рис. 3 представлены ранжированные результаты оценки вклада каждого признака.

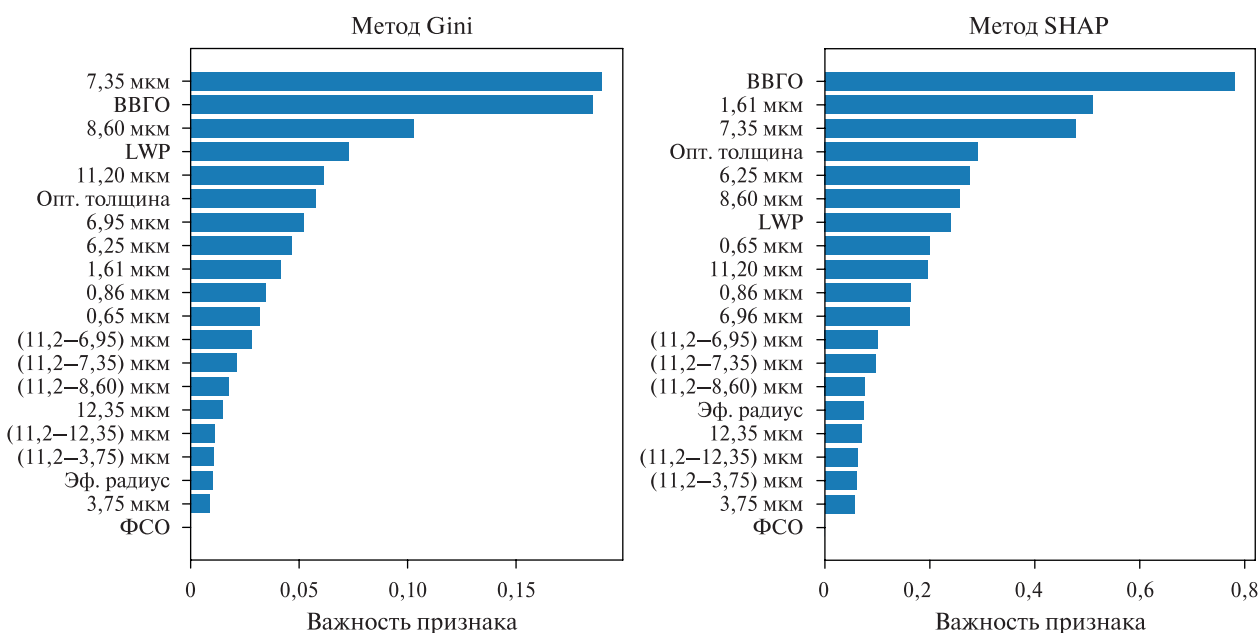


Рис. 3. Значимость используемых признаков по методу Gini (слева) и SHAP (справа)

Как видно из результатов (табл. 1, рис. 3), наибольший вклад вносят измерения в каналах, чувствительных к наличию водяного пара в атмосфере (6,25–7,35 мкм). Характеристика ВВГО также сильно коррелирует с количеством осадков, что объясняется зависимостью данного параметра от принадлежности к тому или иному типу облаков. Дополнительную информацию несут такие признаки, как КСЯ в видимом диапазоне (0,65–1,61 мкм) и низкая температура облака в ИК-диапазоне (11,20–12,35 мкм). Наименее информативным оказался параметр ФСО, не коррелирующий с количеством осадков и косвенно учитываемый IWP и LWP (1). Таким образом, все проанализированные признаки использовались в качестве входных данных для алгоритма расчёта осадков, который будет описан далее. Исключением являются ФСО и высота рельефа, не оказавшие существенного влияния на точность оценки осадков.

Алгоритм

Алгоритм состоит из нескольких основных этапов, отвечающих за формирование данных и расчёт карты осадков. Первоначально происходит загрузка измерений прибора АНІ и расчёт маски облачности. Затем на основе данных АНІ и GFS моделируются параметры облачности на верхней границе. В результате на вход классификационной и регрессионной модели поступает набор следующих параметров: КСЯ в каналах 0,65; 0,86 и 1,61 мкм; яркостная температура в каналах 3,75; 6,25; 6,95; 7,35; 8,60; 11,20 и 12,35 мкм; разности температуры в парах каналов: 3,75 и 11,20 мкм; 6,25 и 11,20 мкм; 7,35 и 11,20 мкм; 8,60 и 11,20 мкм; 11,20 и 12,35 мкм; параметры облачности (ВВГО, τ , r_{eff} , LWP, IWP), а также дополнительные параметры — зенитные углы Солнца и спутника.

Далее строятся карты осадков. С использованием нейросетевой модели визуального трансформера SWIN-Unet (*англ.* Shifted WINdow) (Cao et al., 2022) производится расчёт маски полей осадков. Затем с помощью регрессионной модели свёрточной нейронной сети оцениваются значения мгновенной интенсивности в каждом пикселе маски осадков. Архитектура этой модели была ранее представлена в работах, посвящённых классификации типов облачности (Крамарева и др., 2019) и расчёту облачной маски (Andreev, Shamilova, 2021), и предназначена для обработки текстурных изображений. В настоящей работе данная архитектура была преобразована в регрессионную удалением последнего усредняющего слоя субдискретизации, отвечающего за классификацию.

В процессе обучения моделей в качестве критерия минимизации ошибки при решении задачи классификации использовалась функция бинарной кросс-энтропии $loss_{class}$. Для регрессионной задачи в качестве такой функции применялась среднеквадратичная ошибка MSE (см. выражение для $loss_{reg}$):

$$loss_{class} = -\frac{1}{n} \sum_{i=1}^n \log y_i + (1 - \bar{y}_i) \log(1 - y_i),$$

$$loss_{reg} = \frac{1}{n} \sum_{i=1}^n C_i (y_i - \bar{y}_i),$$

$$C_i = \begin{cases} 0,01 & \text{для } \bar{y}_i \in [0,10) \\ 0,5 & \text{для } \bar{y}_i \in [10,20) \\ 1,0 & \text{для } \bar{y}_i \in [20,\infty) \end{cases},$$

где n — число примеров в выборке, y_i — выходное значение модели и \bar{y}_i — истинное значение (метка класса или значение интенсивности). Коэффициент C_i применяется для акцентирования внимания на статистически наименее представленную в обучающей выборке интенсивность. Коэффициенты были подобраны эмпирически, исходя из получаемых итоговых результатов.

Результаты и обсуждение

Полученные результаты оценивались на предмет корректности обнаружения осадков и точности оценки их интенсивности. С этой целью использовались метрики POD (*англ.* Probability Of Detection, вероятность обнаружения), FAR (*англ.* False Alarm Rate, коэффициент ложного обнаружения), CSI (*англ.* Critical Success Index, критический индекс успешности), F1-мера, корень среднеквадратичной ошибки RMSE (*англ.* Root Mean Square Error), смещение ошибки (*англ.* Bias), а также коэффициент корреляции Пирсона (*англ.* Pearson). Отметим, что в настоящей работе отрицательное значение Bias свидетельствует о переоценке интенсивности по сравнению с эталонным показателем, тогда как положительное означает обратное, т.е. недооценку реального количества осадков.

Для оценки точности обнаружения осадков используется прямой метод сопоставления пикселей с ближайшими географическими координатами между эталонным и тестируемым

изображениями масок. Точность полученной интенсивности оценивается схожим образом, однако в этом случае выбирается ближайшее к эталону значение в окне 3×3 пикселя при пространственном разрешении 0,1°. Это позволяет лучше учесть возможные координатно-временные рассогласования, вызванные как различием в углах наблюдения с различных приборов, так и несоответствием координат осадков у границы облака и у поверхности земли.

Для сравнения с фактическими измерениями на наземных станциях применяется подход на основе сравнения накопленных сумм осадков. Стоит отметить, что подобный подход применяется, например, для калибровки и валидации доплеровских метеорадаров (Павлюков и др., 2018; Amudha et al., 2014). В настоящей работе при расчёте 12-часовых сумм осадков использовалась следующая формула:

$$R_{sum} = \sum_{i=1}^{N-1} \frac{R_i}{60} (t_{i+1} - t_i),$$

где N — количество сроков наблюдений (для Himawari $N = 72$ с интервалом наблюдений 10 мин, для IMERG $N = 24$ с интервалом 30 мин); i — номер срока наблюдения; R_i — интенсивность осадков, выраженная в мм/ч; $(t_{i+1} - t_i)$ — временной интервал между сроками наблюдений.

В *табл. 2* приведены результаты сравнения нейросетевого алгоритма с набором данных IRprecipitation продукта GPM IMERG. Для более детального анализа в *табл. 3* приведены результаты сравнения для различных уровней интенсивности. Полученные оценки точности в целом говорят о достаточно высоком качестве алгоритма. Средняя вероятность обнаружения осадков POD имеет показатель около 0,82 при относительно небольшой доле ложных случаев FAR — около 0,25. Средняя ошибка RMSE для всех уровней интенсивности составила приблизительно 2,19 мм/ч. Полученные результаты достаточно близки к аналогичным показателям из других работ, в частности, POD варьируется в пределах 0,53–0,84 (Behrangi et al., 2009; Tapiador et al., 2019), FAR имеет значение 0,23–0,68 (Hayatbini et al., 2019; Tapiador et al., 2019), ошибка RMSE имеет величину 0,88–1,80 (Moraux et al., 2019; Sadeghi et al., 2019), а коэффициент корреляции принимает значения 0,32–0,51 (Behrangi et al., 2009; Moraux et al., 2019).

Ошибка RMSE, полученная авторами, несколько выше, чем в представленных работах, что во многом связано с точностью обучающих данных, которые могут быть подвержены ошибкам, особенно для северных территорий с горной местностью (Lu, 2022; Moazami, Najafi, 2021). Поэтому для более детального анализа были рассмотрены наземные измерения осадков.

Анализ проводился с 1 по 31 августа 2022 и 2023 гг. Август был выбран как месяц, в котором наблюдалось наибольшее количество осадков с высокой интенсивностью. Для указанного периода были получены оценки, представленные в *табл. 4*. Ввиду большого количества станций (141) в таблице приведена только часть из них, однако в последней строке представлены суммарные данные для 141 станции. Для сравнения также получены результаты для продукта IMERG и данных ЧПП региональной модели CosmoRu-6.

Таблица 2. Точность алгоритма в сравнении с данными GPM IMERG

Период	Подстилающая поверхность	POD	FAR	CSI	F1	RMSE, мм/ч	Bias, мм/ч	Pearson
День 23:00–6:00 UTC	Суша	0,81	0,26	0,63	0,76	2,29	–1,64	0,45
	Море	0,80	0,25	0,64	0,75	2,14	–1,50	0,45
	Береговая		0,26			2,12	–1,49	0,44
Ночь 12:00–18:00 UTC	Суша	0,85	0,22	0,65	0,82	2,53	–1,45	0,40
	Море	0,84	0,23	0,65	0,81	2,22	–1,14	0,39
	Береговая					2,19	–1,16	0,38
Сутки	Все типы	0,82	0,25	0,64	0,78	2,19	–1,43	0,49

Таблица 3. Ошибка RMSE (в мм/ч) в зависимости от уровня интенсивности осадков

Период	Подстилающая поверхность	<3	3–10	10–20	>20
День 23:00–6:00 UTC	Суша	1,27	4,07	8,91	15,25
	Море	1,28	3,87	8,52	12,12
	Береговая	1,26	3,89	8,61	13,05
Ночь 12:00–18:00 UTC	Суша	1,23	4,09	8,64	17,08
	Море	1,21	3,81	8,46	15,12
	Береговая	1,18	3,80	8,72	14,78
Сутки	Все типы	1,20	3,91	7,83	13,49

Таблица 4. Месячная сумма осадков (в мм) по состоянию на август 2023 г. на различных станциях по данным представленного алгоритма, GPM IMERG и модели CosmoRu-6

Станция	Фактическая сумма	Данные алгоритма	Данные IMERG	Данные CosmoRu
Алдан	34,0	25,5	12,5	31,8
Александровск-Сахалинский	42,9	73,5	36,0	66,1
Белогорск	175,6	118,0	80,9	118,8
Бикин	167,8	161,5	67,5	127,9
Биробиджан	121,0	105,5	67,3	83,8
Благовещенск	53,1	81,0	49,1	117,8
Большой Шантар	60,0	93,0	18,4	14,5
Владивосток	413,0	352,5	154,0	218,6
Зея	85,3	85,0	70,3	63,1
Комсомольск-на-Амуре	64,0	48,0	17,2	44,3
Магадан	35,0	34,5	32,5	30,3
Сковородино	12,0	12,0	5,5	9,6
Тында	74,0	85,0	28,3	53,0
Хабаровск	73,5	93,0	58,1	60,7
Чита	44,6	67,0	24,1	36,5
Южно-Сахалинск	185,1	174,5	54,3	189,2
Все станции (141)	10033	10383	4924	8210

Из полученных результатов следует, что нейросетевой алгоритм в большинстве случаев имеет наиболее близкие оценки сумм осадков к эталонным значениям, полученным на станциях. Однако для некоторых станций наблюдается переоценка этих сумм. В то же время продукт IMERG часто занижает фактическое значение суммы осадков. В целом можно отметить, что тестируемый алгоритм имеет склонность к переоценке количества осадков, тогда как IMERG и CosmoRu-6, наоборот, недооценивают эти значения.

Для визуальной оценки полученных результатов на *рис. 4* (см. с. 30) в качестве примера представлены карты интенсивности осадков, полученных с использованием нейросетевого алгоритма и продукта IMERG. Из рисунка видно, что поля осадков между алгоритмом и продуктом IMERG достаточно хорошо совпадают в большинстве случаев. Значения интенсивности также достаточно близки, при этом можно отметить, что ввиду лучшего пространственного разрешения прибора АНІ (0,018° в надире против 0,1° у IMERG) наблюдается более высокая детализация карт. С учётом полученных выше результатов, а также высокой скорости обработки (около 1 мин для расчёта сцены размером 1300×3800 пикселей), данный алгоритм может использоваться в качестве дополнительного источника информации об осадках при составлении прогнозов, в том числе для наукастинга.

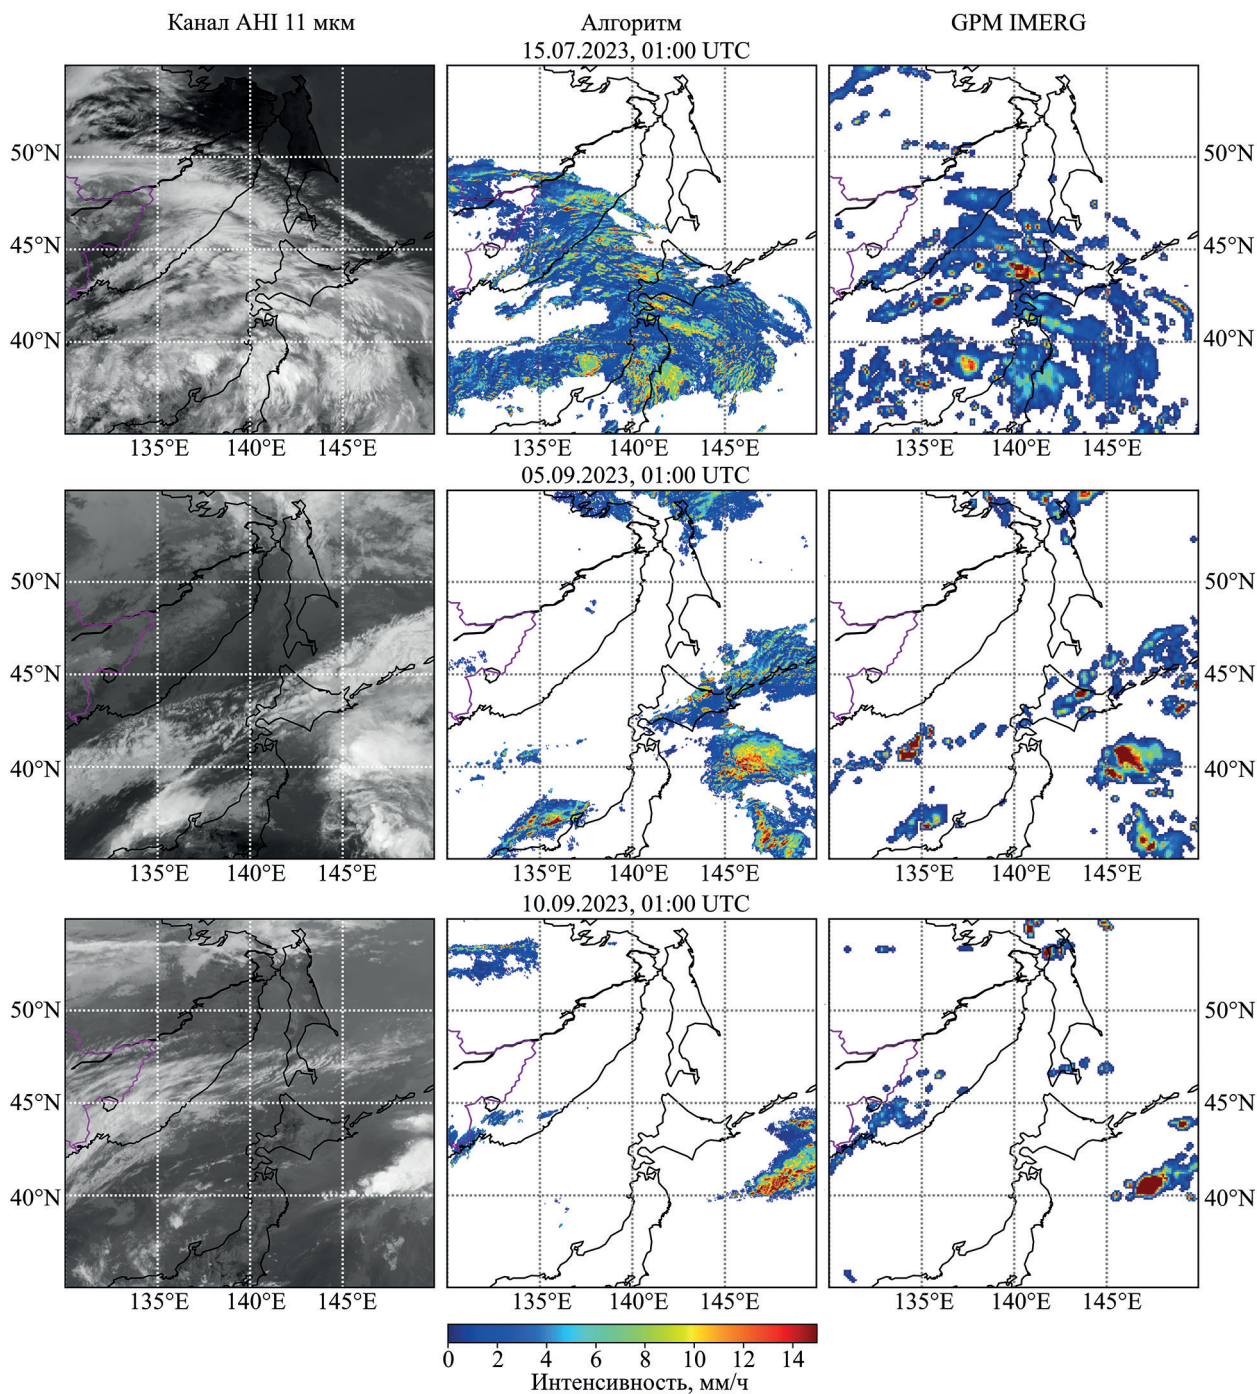


Рис. 4. Сравнение карт интенсивности осадков: ИК-канал 11 мкм прибора АНІ (слева, холодные области соответствуют светлым оттенкам), результаты расчёта представленным алгоритмом (в середине), данные GPM IMERG (справа)

Заключение

Предложен алгоритм оценки интенсивности осадки по данным измерений КА Himawari-8/9. Метод расчёта основан на использовании трансформерной и свёрточной нейросетевой архитектуры для предварительного обнаружения осадкообразующей облачности и последующей оценки количества осадков. При этом алгоритм использует спектральные, текстурные и микрофизические характеристики облачности.

Тестирование алгоритма проведено в сравнении с данными GPM IMERG и фактическими данными на наземных станциях. Анализ результатов тестирования показал, что алго-

ритм наиболее точно оценивает суммарное количество осадков, чем GPM IMERG и региональная численная модель CosmoRu-6, однако имеется тенденция к завышению значений интенсивности.

К достоинствам предложенного алгоритма можно отнести достаточно высокую точность и оперативность получения информации об осадках. Недостатком же становится его зависимость от эталонного источника данных при обучении алгоритма. В настоящей работе эта проблема отчасти решается за счёт процедуры отбраковки измерений на этапе формирования обучающей выборки с использованием индекса качества QI, однако для наиболее достоверных оценок интенсивности требуются более точные измерения, например, на основе наземных радиолокационных наблюдений в МВ-диапазоне. Алгоритм разрабатывался для территории, где практически отсутствовали какие-либо другие источники информации об осадках, что послужило причиной выбора GPM IMERG в качестве данных для обучения алгоритма. Однако представленный алгоритм может быть легко адаптирован для других геостационарных КА и территорий переобучением на соответствующих наборах данных.

Дальнейшее улучшение алгоритма возможно за счёт комплексирования информации об осадках из различных источников, например, калибровкой на основе МВ-измерений полярно-орбитальных КА. Другим направлением для исследований представляется возможность использования временного анализа серии изображений, предшествующих рассматриваемому сроку наблюдений, что позволит учесть динамику развития конвективной осадкообразующей облачности. Ансамблевый подход к построению модели для расчёта осадков также может способствовать повышению качества получаемой продукции.

Исследование выполнено за счёт гранта Российского научного фонда № 23-77-00011, <https://rscf.ru/project/23-77-00011/>. В работе использовались ресурсы ЦКП «ИКИ-Мониторинг».

Литература

1. Крамарева Л. С., Андреев А. И., Блощинский В. Д. и др. Использование нейронных сетей в задачах гидрометеорологии // Вычислительные технологии. 2019. Т. 24. № 6. С. 50–59. DOI: 10.25743/IST.2019.24.6.007.
2. Павлюков Ю. Б., Серебрянник Н. И., Корнев Д. П., Охрименко В. А., Травов А. В., Шумилин А. А., Ерошкина Н. А., Козырев А. В., Белякова Т. А. Методика валидации наблюдений доплеровских метеорологических радиолокаторов, установленных на наземной наблюдательной сети. Долгопрудный: ЦАО, 2018. 49 с. https://meteorad.ru/static/validation_method_2018.pdf.
3. Ривин Г. С., Розинкина И. А., Астахова Е. Д., Блинов Д. В., Бундель А. Ю., Кирсанов А. А., Шатунова М. В., Чубарова Н. Е., Алферов Д. Ю., Варенцов М. И., Захарченко Д. И., Копейкин В. В., Никитин М. А., Полохов А. А., Ревокатова А. П., Татаринович Е. В., Чурюлин Е. В. Система краткосрочного численного прогноза высокой детализации COSMO-Ru, ее развитие и приложения // Гидрометеорол. исслед. и прогнозы. 2019. № 4. С. 37–53.
4. Amorati R., Alberoni P. P., Levizzani V., Nanni S. IR-based satellite and radar rainfall estimates of convective storms over northern Italy // Meteorological Applications. 2000. V. 7. No. 1. P. 1–18. DOI: 10.1017/S1350482700001328.
5. Amudha B., Raj Y. E. A., Thampi S. B., Ramanathan R. M. Diagnostic and statistical approach to the validation of Doppler radar rainfall around Chennai during 2006–2010 // Indian J. Radio and Space Physics. 2014. V. 43(2). P. 163–177.
6. Andreev A. I., Shamilova Y. A. Cloud detection from the Himawari-8 satellite data using a convolutional neural network // Izvestiya, Atmospheric and Oceanic Physics. 2021. V. 57. No. 9. P. 1162–1170. DOI: 10.1134/S0001433821090401.
7. Arkin P. A. The relationship between fractional coverage of high cloud and rainfall accumulations during GATE over the B-scale array // Monthly Weather Review. 1979. V. 107. No. 10. P. 1382–1387. DOI: 10.1175/1520-0493(1979)107<1382:TRBFCO>2.0.CO;2.
8. Behrangi A., Hsu K., Imam B. et al. PERSIANN-MSA: A precipitation estimation method from satellite-based multispectral analysis // J. Hydrometeorology. 2009. V. 10. No. 6. P. 1414–1429. DOI: 10.1175/2009JHM1139.1.
9. Breiman L. Classification and regression trees. N. Y.: Routledge. 2017. 368 p. DOI: 10.1175/2009JHM1139.1.

10. Cao H., Wang Y., Chen J. et al. Swin-unet: Unet-like pure transformer for medical image segmentation // European Conf. Computer Vision. 2022. P. 205–218. DOI: 10.1007/978-3-031-25066-8_9.
11. Doms G., Baldauf M.A. A description of the nonhydrostatic regional COSMO-Model. Part I: Dynamics and numerics. 2018. 166 p. <http://www.cosmo-model.org/content/model/documentation/core/cosmo-DynsNumcs.pdf>.
12. Ellrod G.P. Potential use of GOES-I multispectral infrared imagery for nighttime detection of precipitation // Proc. 7th Conf. Satellite Meteorology and Oceanography / American Meteorological Society. 1994. P. 164–167.
13. Gasteiger J., Emde C., Mayer B. et al. Representative wavelengths absorption parameterization applied to satellite channels and spectral bands // J. Quantitative Spectroscopy and Radiative Transfer. 2014. V. 148. P. 99–115. DOI: 10.1016/j.jqsrt.2014.06.024.
14. Giorgetta M.A., Brokopf R., Cruieger T. et al. ICON-A, the atmosphere component of the ICON Earth system model: I. Model description // J. Advances in Modeling Earth Systems. 2018. V. 10. No. 7. P. 1613–1637. DOI: 10.1029/2017MS001242.
15. Hayatbini N., Kong B., Hsu K. et al. Conditional generative adversarial networks (cGANs) for near real-time precipitation estimation from multispectral GOES-16 satellite imageries—PERSIANN-cGAN // Remote Sensing. 2019. V. 11. No. 19. P. 2193. DOI: 10.3390/rs11192193.
16. Heidinger A., Li Y. AWG cloud height algorithm theoretical basis document / NOAA NESDIS Center for Satellite Applications and Research. 2018. 60 p. https://www.ssec.wisc.edu/~daves/ACHA_ATBD.pdf.
17. Hirose H., Shige S., Yamamoto M. K., Higuchi A. High temporal rainfall estimations from Himawari-8 multiband observations using the random-forest machine-learning method // J. Meteorological Society of Japan. Ser. II. 2019. V. 97. No. 3. P. 689–710. DOI: 10.2151/jmsj.2019-040.
18. Hong Y., Hsu K.L., Sorooshian S., Gao X. Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system // J. Applied Meteorology. 2004. V. 43. No. 12. P. 1834–1853. DOI: 10.1175/JAM2173.1.
19. Hsu K., Gao X., Sorooshian S., Gupta H. V. Precipitation estimation from remotely sensed information using artificial neural networks // J. Applied Meteorology and Climatology. 1997. V. 36. No. 9. P. 1176–1190. DOI: 10.1175/1520-0450(1997)036<1176:PEFRSI>2.0.CO;2.
20. Huffman G.J., Bolvin D.T., Braithwaite D. et al. Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG) // Satellite precipitation measurement. 2020. V. 1. P. 343–353. DOI: 10.1007/978-3-030-24568-9_19.
21. Jia Z., Yang S., Zhang J. et al. PRSOT: Precipitation retrieval from satellite observations based on transformer // Atmosphere. 2022. Vol. 13. No. 12. Article 2048. DOI: 10.3390/atmos13122048.
22. Key J.R., Intrieri J.M. Cloud particle phase determination with the AVHRR // J. Applied Meteorology and Climatology. 2000. V. 39. No. 10. P. 1797–1804. DOI: 10.1175/1520-0450-39.10.1797.
23. King P.W.S., Hogg W.D., Arkin P.A. The role of visible data in improving satellite rain-rate estimates // J. Applied Meteorology. 1995. V. 34. No. 7. P. 1608–1621. DOI: 10.1175/1520-0450-34.7.1608.
24. Kurino T. A satellite infrared technique for estimating “deep/shallow” precipitation // Advances in Space Research. 1997. V. 19. No. 3. P. 511–514. DOI: 10.1016/S0273-1177(97)00063-X.
25. Levizzani V., Cattani E. Satellite remote sensing of precipitation and the terrestrial water cycle in a changing climate // Remote sensing. 2019. V. 11. No. 19. Article 2301. DOI: 10.3390/rs11192301.
26. Li X.F., Blenkinsop S., Barbero R. et al. Global distribution of the intensity and frequency of hourly precipitation and their responses to ENSO // Climate Dynamics. 2020. V. 54. P. 4823–4839. DOI: 10.1007/s00382-020-05258-7.
27. Liu Q., Li Y., Yu M. et al. Daytime rainy cloud detection and convective precipitation delineation based on a deep neural Network method using GOES-16 ABI images // Remote Sensing. 2019. V. 11. No. 21. Article 2555. DOI: 10.3390/rs11212555.
28. Lu N. Evaluation of IMERG precipitation products in the Southeast Coastal Urban Region of China // Remote Sensing. 2022. V. 14. No. 19. Article 4947. DOI: 10.3390/rs14194947.
29. Lundberg S.M., Lee S.I. A unified approach to interpreting model predictions // Advances in neural information processing systems. // Proc. 31st Conf. Neural Information Processing Systems (NIPS 2017). 2017. V. 30. Article 10.
30. Mahrooghy M., Anantharaj V.G., Younan N.H. et al. On an enhanced PERSIANN-CCS algorithm for precipitation estimation // J. Atmospheric and Oceanic Technology. 2012. V. 29. No. 7. P. 922–932. DOI: 10.1175/JTECH-D-11-00146.1.
31. Min M., Bai C., Guo J. et al. Estimating summertime precipitation from Himawari-8 and global forecast system based on machine learning // IEEE Trans. Geoscience and Remote Sensing. 2018. V. 57. No. 5. P. 2557–2570. DOI: 10.1109/TGRS.2018.2874950.
32. Moazami S., Najafi M.R. A comprehensive evaluation of GPM-IMERG V06 and MRMS with hourly ground-based precipitation observations across Canada // J. Hydrology. 2021. V. 594. Article 125929. DOI: 10.1016/j.jhydrol.2020.125929.

33. *Moraux A., Dewitte S., Cornelis B., Munteanu A.* Deep learning for precipitation estimation from satellite and rain gauges measurements // *Remote Sensing*. 2019. V. 11. No. 21. Article 2463. DOI: 10.3390/rs11212463.
34. *Nakajima T., King M. D.* Determination of the optical thickness and effective particle radius of clouds from reflected solar radiation measurements. Part I: Theory // *J. Atmospheric Sciences*. 1990. V. 47. No. 15. P. 1878–1893. DOI: 10.1175/1520-0469(1990)047<1878:DOTOTA>2.0.CO;2.
35. *Poulsen C. A., Siddans R., Thomas G. E. et al.* Cloud retrievals from satellite data using optimal estimation: evaluation and application to ATSR // *Atmospheric Measurement Techniques*. 2012. V. 5. No. 8. P. 1889–1910. DOI: 10.5194/amt-5-1889-2012.
36. *Prigent C.* Precipitation retrieval from space: An overview // *Comptes Rendus Geoscience*. 2010. V. 342. No. 5. P. 380–389. DOI: 10.1016/j.crte.2010.01.00.
37. *Pruppacher H. R., Klett J. D.* *Microphysics of Clouds and Precipitation*. Dordrecht: Reidel, 1979. 714 p.
38. *Roebeling R. A., Holleman I.* SEVIRI rainfall retrieval and validation using weather radar observations // *J. Geophysical Research: Atmospheres*. 2009. V. 114. Iss. D21. DOI: 10.1029/2009JD012102.
39. *Rossow W. B., Schiffer R. A.* Advances in understanding clouds from ISCCP // *Bulletin of the American Meteorological Society*. 1999. V. 80. No. 11. P. 2261–2288. DOI: 10.1175/1520-0477(1999)080<2261:AIUCFI>2.0.CO;2.
40. *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. No. 12. P. 2273–2289. DOI: 10.1175/JHM-D-19-0110.1.
41. *Sun Q., Miao C., Ashouri H. et al.* A review of global precipitation data sets: Data sources, estimation, and intercomparisons // *Reviews of Geophysics*. 2018. V. 56. No. 1. P. 79–107. DOI: 10.1002/2017RG000574.
42. *Tapiador F. J., Marcos C., Sancho J. M.* The convective rainfall rate from cloud physical properties algorithm for Meteosat Second-Generation satellites: Microphysical basis and intercomparisons using an object-based method // *Remote Sensing*. 2019. V. 11. No. 5. Article 527. DOI: 10.3390/rs11050527.
43. *Wang P. K.* *Physics and dynamics of clouds and precipitation*. Cambridge: Cambridge University Press, 2013. 452 p. <https://doi.org/10.1017/CBO9780511794285>.

Method of quantitative rainfall estimation based on Himawari-8/9 measurements

A. I. Andreev^{1,2}, A. A. Filey^{1,2}, S. I. Malkovsky¹, S. P. Korolev¹

¹ *Computing Center FEB RAS, Khabarovsk 680000, Russia*

² *Far Eastern Center of SRC “Planeta”, Khabarovsk 680000, Russia*

E-mail: a.andreev@dvrpod.ru

The paper presents an algorithm for precipitation estimation based on data from Himawari-8/9 satellite. The algorithm is based on two neural networks of visual transformer and convolutional architectures for preliminary precipitation mask calculation and rain rate estimation. The data from the Global Precipitation Measurements (GPM) international project were used as a reference value of precipitation. These data are based on measurements from various active and passive microwave and infrared satellite instruments. The algorithm takes into account spectral, textural and microphysical parameters of clouds. An accuracy assessment was carried out using GPM data and ground-based rain gauges. The results of a comparison between the algorithm and regional numerical weather prediction model ComsoRu-6 are also given. It is shown that the presented algorithm most accurately estimates the amount of accumulated precipitation sums but it has a tendency to overestimate this value. On the other hand, GPM and CosmoRu-6 often underestimate precipitation. The comparison with GPM product showed a root mean squared error of about 2.19 mm/h.

Keywords: precipitation, rain rate, neural network, Himawari

Accepted: 30.09.2024

DOI: 10.21046/2070-7401-2024-21-5-20-35

References

1. Kramareva L. S., Andreev A. I., Bloshchinskiy et al., The use of neural networks in hydrometeorology problems, *Computational Technologies*, 2019, Vol. 24, No. 6, pp. 50–59 (in Russian), DOI: 10.25743/ICT.2019.24.6.007.
2. Pavlyukov Yu. B., Serebryannik N. I., Korenev D. P., Okhrimenko V. A., Travov A. V., Shumilin A. A., Yeroshkina N. A., Kozyrev A. V., Belyakova T. A., *Metodika validatsii nablyudenii doplerovskikh meteorologicheskikh radiolokatorov, ustanovlennykh na nazemnoi nablyudatel'noi seti* (Method for validating doppler weather radar observations installed on a ground observing network), Dolgoprudnyi: Central Aerological Observatory, 2018, 49 p., https://meteorad.ru/static/validation_method_2018.pdf.
3. Rivin G. S., Rozinkina I. A., Astakhova E. D., Blinov D. V., Bundel A. Yu., Kirsanov A. A., Shatunova M. V., Chubarova N. E., Alferov D. Yu., Varentsov M. I., Zakharchenko D. I., Kopeikin V. V., Nikitin M. A., Polyukhov A. A., Revokatova A. P., Tatarinovich E. V., Churyulin E. V., COSMO-Ru high-resolution short-range numerical weather prediction system: its development and applications, *Hydrometeorological Research and Forecasting*, 2019, Vol. 374. No. 4, pp. 37–53 (in Russian).
4. Amorati R., Alberoni P. P., Levizzani V., Nanni S., IR-based satellite and radar rainfall estimates of convective storms over northern Italy, *Meteorological Applications*, 2000, Vol. 7, No. 1, pp. 1–18, DOI: 10.1017/S1350482700001328.
5. Amudha B., Raj Y. E. A., Thampi S. B., Ramanathan R. M., Diagnostic and statistical approach to the validation of Doppler radar rainfall around Chennai during 2006–2010, *Indian J. Radio and Space Physics*, 2014, Vol. 43(2), pp. 163–177.
6. Andreev A. I., Shamilova Y. A., Cloud detection from the Himawari-8 satellite data using a convolutional neural network, *Izvestiya, Atmospheric and Oceanic Physics*, 2021, Vol. 57, No. 9, pp. 1162–1170, DOI: 10.1134/S0001433821090401.
7. Arkin P. A., The relationship between fractional coverage of high cloud and rainfall accumulations during GATE over the B-scale array, *Monthly Weather Review*, 1979, Vol. 107, No. 10, pp. 1382–1387, DOI: 10.1175/1520-0493(1979)107<1382:TRBFCO>2.0.CO;2.
8. Behrangi A., Hsu K., Imam B. et al., PERSIANN-MSA: A precipitation estimation method from satellite-based multispectral analysis, *J. Hydrometeorology*, 2009, Vol. 10, No. 6, pp. 1414–1429, DOI: 10.1175/2009JHM1139.1.
9. Breiman L., *Classification and regression trees*, New York: Routledge, 2017, 368 p., DOI: 10.1175/2009JHM1139.1.
10. Cao H., Wang Y., Chen J. et al., Swin-unet: Unet-like pure transformer for medical image segmentation, *European Conf. Computer Vision*, 2022, pp. 205–218, DOI: 10.1007/978-3-031-25066-8_9.
11. Doms G., Baldauf M. A., *A description of the nonhydrostatic regional COSMO-Model. Part I: Dynamics and numerics*, 2018, 166 p., <http://www.cosmo-model.org/content/model/documentation/core/cosmoDyncs-Numcs.pdf>.
12. Ellrod G. P., Potential use of GOES-I multispectral infrared imagery for nighttime detection of precipitation, *Proc. 7th Conf. Satellite Meteorology and Oceanography, American Meteorological Society*, 1994, pp. 164–167.
13. Gasteiger J., Emde C., Mayer B. et al., Representative wavelengths absorption parameterization applied to satellite channels and spectral bands, *J. Quantitative Spectroscopy and Radiative Transfer*, 2014, Vol. 148, pp. 99–115, DOI: 10.1016/j.jqsrt.2014.06.024.
14. Giorgetta M. A., Brokopf R., Crueger T. et al., ICON-A, the atmosphere component of the ICON Earth system model: I. Model description, *J. Advances in Modeling Earth Systems*, 2018, Vol. 10, No. 7, pp. 1613–1637, DOI: 10.1029/2017MS001242.
15. Hayatbini N., Kong B., Hsu K. et al., Conditional generative adversarial networks (cGANs) for near real-time precipitation estimation from multispectral GOES-16 satellite imageries—PERSIANN-cGAN, *Remote Sensing*, 2019, Vol. 11, No. 19, pp. 2193, DOI: 10.3390/rs11192193.
16. Heidinger A., Li Y., *AWG cloud height algorithm theoretical basis document*, NOAA NESDIS Center for Satellite Applications and Research, 2018, 60 p., https://www.ssec.wisc.edu/~daves/ACHA_ATBD.pdf.
17. Hirose H., Shige S., Yamamoto M. K., Higuchi A., High temporal rainfall estimations from Himawari-8 multiband observations using the random-forest machine-learning method, *J. Meteorological Society of Japan*, Ser. II, 2019, Vol. 97, No. 3, pp. 689–710, DOI: 10.2151/jmsj.2019-040.
18. Hong Y., Hsu K. L., Sorooshian S., Gao X., Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system, *J. Applied Meteorology*, 2004, Vol. 43, No. 12, pp. 1834–1853, DOI: 10.1175/JAM2173.1.
19. Hsu K., Gao X., Sorooshian S., Gupta H. V., Precipitation estimation from remotely sensed information using artificial neural networks, *J. Applied Meteorology and Climatology*, 1997, Vol. 36, No. 9, pp. 1176–1190, DOI: 10.1175/1520-0450(1997)036<1176:PEFRSI>2.0.CO;2.

20. Huffman G. J., Bolvin D. T., Braithwaite D. et al., Integrated multi-satellite retrievals for the global precipitation measurement (GPM) mission (IMERG), *Satellite precipitation measurement*, 2020, Vol. 1, pp. 343–353, DOI: 10.1007/978-3-030-24568-9_19.
21. Jia Z., Yang S., Zhang J. et al., PRSOT: Precipitation retrieval from satellite observations based on transformer, *Atmosphere*, 2022, Vol. 13, No. 12, Article 2048, DOI: 10.3390/atmos13122048.
22. Key J. R., Intrieri J. M., Cloud particle phase determination with the AVHRR, *J. Applied Meteorology and Climatology*, 2000, Vol. 39, No. 10, pp. 1797–1804, DOI: 10.1175/1520-0450-39.10.1797.
23. King P. W. S., Hogg W. D., Arkin P. A., The role of visible data in improving satellite rain-rate estimates, *J. Applied Meteorology*, 1995, Vol. 34, No. 7, pp. 1608–1621, DOI: 10.1175/1520-0450-34.7.1608.
24. Kurino T., A satellite infrared technique for estimating “deep/shallow” precipitation, *Advances in Space Research*, 1997, Vol. 19, No. 3, pp. 511–514, DOI: 10.1016/S0273-1177(97)00063-X.
25. Levizzani V., Cattani E., Satellite remote sensing of precipitation and the terrestrial water cycle in a changing climate, *Remote sensing*, 2019, Vol. 11, No. 19, Article 2301, DOI: 10.3390/rs11192301.
26. Li X. F., Blenkinsop S., Barbero R. et al., Global distribution of the intensity and frequency of hourly precipitation and their responses to ENSO, *Climate Dynamics*, 2020, Vol. 54, pp. 4823–4839, DOI: 10.1007/s00382-020-05258-7.
27. Liu Q., Li Y., Yu M. et al., Daytime rainy cloud detection and convective precipitation delineation based on a deep neural Network method using GOES-16 ABI images, *Remote Sensing*, 2019, Vol. 11, No. 21, Article 2555, DOI: 10.3390/rs11212555.
28. Lu N., Evaluation of IMERG precipitation products in the Southeast Costal Urban Region of China, *Remote Sensing*, 2022, Vol. 14, No. 19, Article 4947, DOI: 10.3390/rs14194947.
29. Lundberg S. M., Lee S. I., A unified approach to interpreting model predictions, *Proc. 31st Conf. Neural Information Processing Systems (NIPS 2017)*, 2017, Vol. 30, Article 10.
30. Mahrooghly M., Anantharaj V. G., Younan N. H. et al., On an enhanced PERSIANN-CCS algorithm for precipitation estimation, *J. Atmospheric and Oceanic Technology*, 2012, Vol. 29, No. 7, pp. 922–932, DOI: 10.1175/JTECH-D-11-00146.1.
31. Min M., Bai C., Guo J. et al., Estimating summertime precipitation from Himawari-8 and global forecast system based on machine learning, *IEEE Trans. Geoscience and Remote Sensing*, 2018, Vol. 57, No. 5, pp. 2557–2570, DOI: 10.1109/TGRS.2018.2874950.
32. Moazami S., Najafi M. R., A comprehensive evaluation of GPM-IMERG V06 and MRMS with hourly ground-based precipitation observations across Canada, *J. Hydrology*, 2021, V. 594, Article 125929, DOI: 10.1016/j.jhydrol.2020.125929.
33. Moraux A., Dewitte S., Cornelis B., Munteanu A., Deep learning for precipitation estimation from satellite and rain gauges measurements, *Remote Sensing*, 2019, Vol. 11, No. 21, Article 2463, DOI: 10.3390/rs11212463.
34. Nakajima T., King M. D., Determination of the optical thickness and effective particle radius of clouds from reflected solar radiation measurements. Part I: Theory, *J. Atmospheric Sciences*, 1990, Vol. 47, No. 15, pp. 1878–1893, DOI: 10.1175/1520-0469(1990)047<1878:DOTOTA>2.0.CO;2.
35. Poulsen C. A., Siddans R., Thomas G. E. et al., Cloud retrievals from satellite data using optimal estimation: evaluation and application to ATSR, *Atmospheric Measurement Techniques*, 2012, Vol. 5, No. 8, pp. 1889–1910, DOI: 10.5194/amt-5-1889-2012.
36. Prigent C., Precipitation retrieval from space: An overview, *Comptes Rendus Geoscience*, 2010, V. 342, No. 5, pp. 380–389, DOI: 10.1016/j.crte.2010.01.00.
37. Pruppacher H. R., Klett J. D., *Microphysics of Clouds and Precipitation*, Dordrecht: Reidel, 1979, 714 p.
38. Roebeling R. A., Holleman I., SEVIRI rainfall retrieval and validation using weather radar observations, *J. Geophysical Research: Atmospheres*, 2009, Vol. 114, Issue D21, DOI: 10.1029/2009JD012102.
39. Rossow W. B., Schiffer R. A., Advances in understanding clouds from ISCCP, *Bull. American Meteorological Society*, 1999, Vol. 80, No. 11, pp. 2261–2288, DOI: 10.1175/1520-0477(1999)080<2261:AIUCFI>2.0.CO;2.
40. 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, Vol. 20, No. 12, pp. 2273–2289, DOI: 10.1175/JHM-D-19-0110.1.
41. Sun Q., Miao C., Ashouri H. et al., A review of global precipitation data sets: Data sources, estimation, and intercomparisons, *Reviews of Geophysics*, 2018, Vol. 56, No. 1, pp. 79–107, DOI: 10.1002/2017RG000574.
42. Tapiador F. J., Marcos C., Sancho J. M., The convective rainfall rate from cloud physical properties algorithm for Meteosat Second-Generation satellites: Microphysical basis and intercomparisons using an object-based method, *Remote Sensing*, 2019, Vol. 11, No. 5, Article 527, DOI: 10.3390/rs11050527.
43. Wang P. K., *Physics and dynamics of clouds and precipitation*, Cambridge: Cambridge University Press, 2013, 452 p., <https://doi.org/10.1017/CBO9780511794285>.