

А.И. АНДРЕЕВ, М.О. КУЧМА, С.И. МАЛЬКОВСКИЙ, А.А. ФИЛЕЙ  
**RAINCAST: ГИБРИДНЫЙ АЛГОРИТМ НАУКАСТИНГА  
ИНТЕНСИВНОСТИ ОСАДКОВ ПО ДАННЫМ СПУТНИКОВЫХ  
НАБЛЮДЕНИЙ КА HIMAWARI-8/9**

*Андреев А.И., Кучма М.О., Мальковский С.И., Филей А.А.* **RainCast: Гибридный алгоритм наукастинга интенсивности осадков по данным спутниковых наблюдений КА Himawari-8/9.**

**Аннотация.** В работе предложен алгоритм RainCast (Rain Rate NowCast), предназначенный для краткосрочного прогноза интенсивности осадков на срок до двух часов. Данное направление метеорологии, в англоязычной литературе получившее название «наукастинг» (nowcasting), является одним из наиболее востребованных информационных продуктов во многих сферах человеческой деятельности. Вместе с тем, его доступность может быть сильно ограничена имеющейся наземной инфраструктурой. В настоящей работе авторами поставлена цель создания алгоритма прогноза осадков, предназначенного для одной из таких территорий на примере Азиатско-Тихоокеанского регионе с использованием спутниковых измерений космического аппарата Himawari-8/9. Предложенный алгоритм объединяет преимущества детерминированного и статистического подходов к задаче прогноза и основан на использовании двух нейросетевых моделей. Первая модель осуществляет предварительный прогноз общего направления движения осадков на мезомасштабном уровне с помощью физически-обусловленной нейронной сети NowcastNet. Вторая модель на основе архитектуры CasFormer служит для постобработки полученного прогноза методом диффузий с целью повышения его детализации. Разработанный с использованием данного метода гибридный алгоритм RainCast позволяет получать краткосрочный прогноз интенсивности осадков на срок до двух часов с частотой каждые 10 минут и пространственным разрешением 2 км/пиксель на основе спутниковых измерений в инфракрасном диапазоне. Спутниковые измерения используются для расчета интенсивности осадков по ранее предложенному авторами алгоритму. На основе карт осадков сформированы обучающие, валидационные и тестовые наборы данных, применяемые для обучения, настройки алгоритма и оценки качества прогнозов соответственно. Для предложенного алгоритма RainCast, а также применяемых в мировой практике актуальных решений, таких как NowcastNet, CasFormer, Earthformer, было проведено обучение с использованием сформированных наборов данных, после чего для указанных алгоритмов был рассчитан ряд показателей качества получаемых прогнозов. Из полученных результатов можно сделать вывод, что предложенный в настоящей работе гибридный алгоритм RainCast имеет более высокое качество прогноза в сравнении с другими вышеперечисленными решениями при равных условиях. Для валидационного набора данных на территории Дальневосточного региона при прогнозе алгоритмом RainCast с заблаговременностью 2 часа были получены следующие показатели для последнего спрогнозированного кадра: корень среднеквадратической ошибки RMSE составил 0.88 мм/ч, вероятность обнаружения POD – 0.78, коэффициент корреляции Пирсона – 0.75, индекс структурного сходства SSIM – 0.91, а пиковое отношение сигнала к шуму PSNR – 36.63. Дополнительно проведенный визуальный анализ прогнозов подтвердил, что наиболее близкие к фактическим наблюдениям результаты имеет предложенный гибридный региональный алгоритм RainCast.

**Ключевые слова:** наукастинг, осадки, интенсивность осадков, прогноз осадков, Himawari, RainCast, диффузионные модели.

**1. Введение.** Термином «наукастинг» английский метеоролог Кит Браунинг обозначил в 80-х годах прошлого века «детализированное описание текущего состояния погоды и прогноз изменений, которые ожидаются в течение первых 2 ч» [1]. Его востребованность связана с его способностью обеспечивать потребителей более детализированной информацией, чем это позволяют другие виды метеорологических прогнозов. В особенности это важно при прогнозе опасных явлений погоды, многие из которых характеризуются коротким жизненным циклом и небольшой пространственной протяженностью. Поля интенсивности осадков были исторически первым элементом наукастинга [2]. Несмотря на расширение круга прогнозируемых метеорологических параметров, осадки остаются ключевым объектом исследований и моделирования на всех пространственно-временных масштабах, включая наукастинг.

В контексте данной работы под наукастингом понимается краткосрочный (заблаговременностью до двух часов) прогноз интенсивности осадков. Несмотря на то, что для целей прогноза осадков важны приземные и аэрологические наблюдения, лишь системы дистанционного зондирования могут адекватным образом обеспечить пространственный охват с высоким разрешением. Для краткосрочного прогноза осадков наилучшим образом подходят радиолокационные наблюдения, позволяющие отображать поля облачности и осадков в реальном масштабе времени с достаточной дискретностью. Однако на значительных территориях Сибири и Дальнего Востока России на текущий момент необходимые оперативные радиолокационные системы отсутствуют. Альтернативной возможностью количественной и качественной оценки осадкообразующей облачности с высоким пространственно-временным разрешением на этих территориях могут быть измерения геостационарных и высокоэллиптических космических аппаратов (КА). Развитие в последние годы возможностей российских и зарубежных КА гидрометеорологического назначения [3] позволило рассматривать эти данные в качестве базовой информации для создания прогностических алгоритмов. Так, в рамках российской космической программы производится пополнение спутниковой группировки новыми КА гидрометеорологического назначения. В частности, запланированы запуски новых высокоэллиптических КА серии «Артика-М» для наблюдений за Арктическим регионом, а также геостационарных КА серии «Электро-Л». Запуск подобных аппаратов позволит значительно расширить горизонты наблюдений, особенно для труднодоступных регионов. Для эффективного усвоения этих

спутниковых данных требуется создание и обработка технологий получения информационной продукции. В связи с этим в настоящей работе используются данные зарубежного геостационарного КА Himawari-8/9.

Для прогноза интенсивности осадков, полученных с помощью спутниковых наблюдений, чаще всего применяются методы на основе алгоритмов оптического потока и машинного обучения. Первые из них, в силу своей линейности [4], недостаточно эффективны для прогноза конвективной осадкообразующей облачности [5, 6, 7], быстро меняющейся во времени [8]. С другой стороны, появление современных нейросетевых архитектур для обработки изображений позволило значительно продвинуться в развитии альтернативных методов прогноза [9, 10]. Искусственные нейронные сети (ИНС) хорошо учитывают нелинейные зависимости на основе данных и не требуют явного задания физических закономерностей и моделей, по которым осуществляется прогноз [6]. Это дает возможность принять во внимание большое количество второстепенных факторов, которые сложно учесть классическими методами экстраполяции. Но при всем многообразии стремительно развивающихся нейросетевых архитектур спутниковые данные, в отличие от радарных, недостаточно точно позволяют учесть трехмерную (3-D) структуру облака, что требует от исследователей поиска комбинированных подходов, с помощью которых можно не только максимально точно определять перемещение потенциально осадкообразующей облачности, но и прогнозировать на требуемые сроки динамику высоковариативных элементов такой облачности.

В настоящей работе предлагается алгоритм RainCast для краткосрочного прогноза осадков по спутниковым данным на примере КА Himawari-8/9 на территории Дальневосточного региона России. В качестве источника информации об осадках авторы используют результаты расчета собственного алгоритма по данным этого спутника. Предлагаемый алгоритм RainCast сочетает преимущества статистического и детерминированного подходов и основан на идее постобработки с помощью диффузионной модели ИНС. Полученные результаты показали высокое качество прогноза, достигающее уровня точности лучших из представленных ранее решений, что подтверждается численными и визуальными оценками.

**2. Текущее состояние исследований.** С появлением первых нейросетевых архитектур для прогноза осадков на примере сверточнорекуррентных моделей ConvLSTM [11] и TrajGRU [12] было показано, что ИНС имеют высокий потенциал в решении данной задачи.

Отмечается, что сверточные сети обладают высокой скоростью обработки, однако недостаточно хорошо справляются с обработкой временных последовательностей [7]. С другой стороны, рекуррентные сети лучше выявляют временные связи между кадрами, но имеют высокую вычислительную сложность [13]. Чтобы увеличить продолжительность прогноза, рассматриваются различные варианты архитектур специальных ячеек памяти для хранения контекстуальной информации в рекуррентных архитектурах, таких как PredRNN2 [14]. Кроме того, рассматриваются варианты прогноза путем его декомпозиции на составляющие изменения интенсивности пикселей (transient variation) и общего перемещения облачности (motion trend), как, например, в модели MotionRNN [15]. Чтобы компенсировать недостаток рекуррентных архитектур в виде потери контекста при большой продолжительности прогноза, применяются архитектуры трансформеров, такие как Earthformer [16] и Rainformer [17]. Ключевым элементом подобных архитектур является встроенный механизм внимания, позволяющий эффективно использовать информацию из любого кадра всей входной последовательности, что в свою очередь положительно влияет на качество прогноза и позволяет достичь наилучших показателей точности [7, 13].

Вышеперечисленные модели относятся к классу детерминированных [18, 19]. С их помощью можно достаточно точно прогнозировать общее направление движения осадкообразующей облачности, однако прогноз локальных явлений затруднен из-за их высокой вариативности [20]. Под локальными явлениями понимается осадкообразующая облачность малого масштаба, чаще всего состоящая из групп отдельных облаков с линейным размером порядка 10 пикселей. Для таких явлений подобные модели предсказывают усредненные значения интенсивности осадков, из-за чего прогноз получается размытым, а детализация изображений быстро снижается [7, 18, 21]. С другой стороны, статистические методы, такие как генеративно-сопоставительные (Generative Adversarial Network, GAN) и диффузионные сети, осуществляют прогноз, проецируя его из вероятностного распределения всех возможных значений интенсивности [16, 20]. Такой подход позволяет повысить детализацию и достичь реалистичности изображений, однако, в силу стохастической природы подобных моделей, прогноз может несколько варьироваться от случая к случаю для одних и тех же исходных данных [6, 19].

Диффузионные и GAN модели позволяют достичь наилучших результатов с точки зрения заблаговременности прогнозов, а также

резкости и детализации спрогнозированных изображений [22, 23]. Идея GAN-моделей основана на теории игр и заключается в использовании двух ИНС – генератора и дискриминатора, конкурирующих между собой. GAN позволяют создавать реалистичные изображения, однако их обучение является достаточно трудоемким процессом из-за возникающей нестабильности и коллапса мод (mode collapse) [22, 24, 25], а генерируемые изображения нередко содержат артефакты [18, 24]. В качестве примера GAN-модели можно привести модель DGMR (Deep Generative Model of Rainfall) [20], имеющую одни из лучших показателей точности вместе с высокой детализацией и четкостью изображений. При этом DGMR использует одновременно два дискриминатора при обучении для контроля временной и пространственной компоненты прогноза. Для повышения достоверности прогноза осадков высокой интенсивности в некоторых случаях в модель интегрируются элементы физики. Например, в работе [26] предложена модель NowcastNet на основе GAN, ключевой идеей которой стало использование вспомогательной ИНС EvolutionNet, реализующей физический закон непрерывности потока. Здесь можно отметить, что использование физических принципов или данных численного прогноза погоды (ЧПМ) [24, 27, 28] в комбинации с ИНС в том или ином виде положительно влияет на качество прогнозов не только GAN-моделей [1, 23], но и других нейросетевых архитектур в целом [29, 30].

Недостатки моделей на основе GAN удается преодолеть путем использования диффузионных ИНС [24, 30], достигающих при этом схожих результатов [22, 25]. Однако проблемами диффузионных моделей являются высокая вычислительная сложность, необходимость тонкой настройки архитектуры ИНС и подбора гиперпараметров обучения [32], вследствие чего получаемые изображения имеют низкое разрешение. Чтобы улучшить разрешение, можно использовать диффузионные ИНС для уточнения имеющегося прогноза, сделанного с помощью другой модели. Например, авторами работы [18] предложена модель CasCast, используемая для постобработки исходного детерминированного прогноза на примере сети-трансформера Earthformer. CasCast достигает уровня точности, схожего с GAN-моделью NowcastNet, но с учетом преимуществ диффузионного подхода. Подобный принцип использовали авторы [25], представившие свой вариант

диффузионной модели DiffCast для постобработки детерминированного прогноза.

Хотя предлагаемые различными авторами нейросетевые модели, как правило, обучаются на общедоступных данных, в основном на основе наземных радиолокационных измерений (НКО-7 [12]) и реже – с использованием спутниковых наблюдений (SEVIR [33]), их практическое применение сопряжено с рядом ограничений. Точность прогнозов таких моделей во многом зависит от соответствия обучающих данных характеристикам конкретных региональных условий и используемых средств наблюдений. В связи с этим в данной работе предложена методика формирования специализированной обучающей выборки, адаптированной под особенности целевого региона и тип оборудования, что позволяет повысить качество прогноза осадков для заданных условий.

**3. Используемые данные.** В работе рассматривается Азиатско-Тихоокеанский регион с учетом морской акватории, ограниченный  $35\text{--}60^\circ$  с.ш. и  $100\text{--}160^\circ$  в.д. На большей части региона характерен муссонный климат, характерными чертами которого являются суровая малоснежная зима и относительно теплое, обильное осадками лето. Годовое количество осадков, за исключением Приморья, где оно местами достигает 800 мм, мало отличается от средней полосы Европейской части России и составляет порядка 450–600 мм в год. Однако распределение осадков в течение года имеет существенные особенности по сравнению с указанным регионом: они обильны в период теплой части года и исключительно малы в зимнее время. Дожди на Дальнем Востоке носят ливневой характер, охватывают большие территории и отличаются высокой интенсивностью. В некоторых случаях за одни сутки выпадает до 150–250 мм [34].

Для решения задачи краткосрочного прогноза осадков для рассматриваемой территории требуются данные об осадках с высокой временной дискретностью. Поскольку на территории Дальнего Востока плотность сети наземных наблюдений остается крайне невысокой, в работе используются спутниковые измерения спектрорадиометра АНИ (Advanced Himawari Imager), установленного на геостационарном КА Himawari-8/9. Данный прибор предоставляет изображения облачности и подстилающей поверхности с частотой 10 минут в 16 различных диапазонах электромагнитного спектра. Пространственное разрешение составляет 0.5 км/пиксель для канала с центральной длиной волны 0.645 мкм, 1 км/пиксель для видимых и коротковолновых инфракрасных каналов (до 3,85 мкм) и 2

км/пиксель в надире для остальных инфракрасных каналов (в настоящей работе все каналы приведены к единому разрешению 2 км/пиксель).

Для получения мгновенных значений интенсивности осадков по измерениям прибора АНІ авторами ранее был разработан алгоритм [35], основанный на использовании двух ИНС трансформерной и сверточной архитектур, одна из которых предназначена для обнаружения осадкообразующей облачности и расчета маски осадков, а другая позволяет оценить значение интенсивности осадков в каждом пикселе маски. Для обучения алгоритма использовались данные, предоставляемые в рамках проекта GPM (Global Precipitation Measurements) по глобальному мониторингу осадков путем комбинирования измерений различных КА [36]. Использование данных GPM непосредственно для краткосрочного прогноза осадков затруднено по причине задержки в их получении от 4 часов, что связано с необходимостью накопления измерений различных приборов. Разработанный авторами алгоритм для оценки осадков позволяет получать их оперативно с исходным пространственно-временным разрешением прибора АНІ практически сразу после получения спектральных измерений, что крайне важно для решения рассматриваемой задачи, где требуются наиболее актуальные данные для прогноза.

Для разработки прогностического алгоритма авторами были сформированы обучающий, тестовый и валидационный наборы данных, охватывающие временной период с 2020 по 2024 год. Данные представляют собой последовательности изображений интенсивности осадков размером 512×512 пикселей для всей рассматриваемой территории. Каждая последовательность состоит из 21 изображения, из которых входными являются первые 9. Интенсивности осадков выражены в мм/ч и нормированы в диапазоне [0, 1]. Таким образом, общая продолжительность последовательности с учетом временного разрешения прибора АНІ составляет 210 минут. Исходная выборка, состоящая из 20 тысяч последовательностей, была разделена на наборы данных, предназначенные для обучения нейросетевых моделей (80% от общего объема выборки), их проверки и настройки (2%), а также итогового тестирования (18%).

**4. Метод.** Предлагаемый алгоритм RainCast объединяет преимущества детерминированного [25] и статистического [18] подходов, что в равной степени позволяет акцентировать внимание на прогнозе осадков как на мезомасштабном, так и на локальном уровне.

На рисунке 1 представлена блок-схема алгоритма прогноза, детали которого будут описаны ниже.

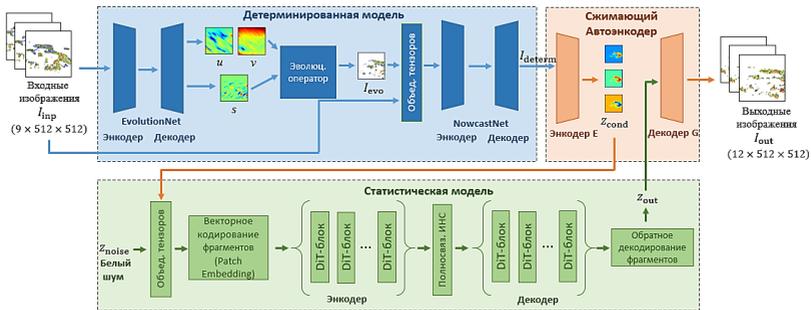


Рис. 1. Блок-схема алгоритма наукастинга осадков RainCast

**4.1. Детерминированная модель.** Работа алгоритма RainCast начинается с подготовки общего прогноза осадков без учета локальной облачности при помощи детерминированной модели. Для этого в настоящей работе используется модель-генератора из GAN-архитектуры NowcastNet [26]. Данная модель имеет одни из наиболее высоких показателей точности в задаче прогноза осадков [24, 29]. В ее состав интегрирована вспомогательная модель EvolutionNet, являющаяся нейросетевой реализацией физического принципа непрерывности потока, что делает модель NowcastNet физически обусловленной.

Обучение модели NowcastNet осуществляется в два этапа. На первом этапе происходит обучение подсети EvolutionNet, выходной информацией которой являются карты признаков  $s$ ,  $u$  и  $v$ , первая из которых связана с изменением интенсивности осадков, а две другие – с перемещением облачного массива в двух проекциях. Эволюционный оператор, действуя на последний входной кадр, перемещает пиксели в соответствии с полями  $u$  и  $v$ , а затем прибавляет интенсивность  $s$ , в результате чего формируется спрогнозированный кадр  $I^{evo}$  [26]. Следуя работе [26], для обучения модели EvolutionNet использовалась следующая целевая функция потерь:

$$L_{evonet} = L_{accum} + 0.01 \cdot L_{motion}, \quad (1)$$

$$L_{\text{accum}} = \sum_{t=1}^T (L_{\text{wdis}}(I_t, I_t^{\text{evo bili}}) + L_{\text{wdis}}(I_t, I_t^{\text{evo}})), \quad (2)$$

$$L_{\text{motion}} = \sum_{t=1}^T (\|\nabla u_t \odot \sqrt{w(I_t)}\|_{L_2}^2 + \|\nabla v_t \odot \sqrt{w(I_t)}\|_{L_2}^2), \quad (3)$$

$$L_{\text{wdis}}(I_t, I_t^{\text{evo}}) = \|(I_t - I_t^{\text{evo}}) \odot w(I_t)\|_{L_1}, \quad (4)$$

где  $L_{\text{accum}}$  – ошибка прогноза значений интенсивности,  $L_{\text{motion}}$  – ошибка прогноза положения пикселей с осадками,  $L_{\text{wdis}}$  – взвешенное значение ошибки с учетом интенсивности осадков, представляющее собой  $L_1$  норму,  $T$  – количество спрогнозированных кадров,  $I_t$  – фактическое значение интенсивности из обучающей выборки для кадра с номером  $t$ ,  $I_t^{\text{evo}}$  и  $I_t^{\text{evo bili}}$  – интенсивность, полученная в результате действия эволюционного оператора с интерполяцией по методу ближайшего соседа и билинейной интерполяцией соответственно,  $\odot$  – операция поэлементного умножения тензоров,  $w(I_t)$  – весовой коэффициент, применяемый для нормированной в диапазоне  $[0,1]$  интенсивности при ее максимальном значении, равном 50 мм/ч:

$$w(I_t) = \begin{cases} 0.5, & \text{если } I_t < 0.2 \\ 1 + I_t, & \text{если } I_t \geq 0.2 \end{cases}. \quad (5)$$

Градиент полей  $u$  и  $v$  рассчитывается приближенно путем применения операции свертки с фильтром Собеля [26]. Обучение модели EvolutionNet осуществлялось с использованием метода оптимизации Adam [37] с коэффициентом скорости обучения  $10^{-3}$  на протяжении первых 100 эпох, после чего производилось дообучение сети с уменьшенным коэффициентом, равным  $10^{-4}$ . Далее весовые коэффициенты модели EvolutionNet фиксировались, а выход модели  $I^{\text{evo}}$  объединялся с входными кадрами  $I^{\text{inp}}$ , после чего полученный тензор подавался на вход автоэнкодера NowcastNet (рисунок 1). Для обучения детерминированной модели NowcastNet использовалась

взвешенная функция потерь в виде суммы  $L_1$  и  $L_2$  норм, обеспечивающая сбалансированное значение ошибки между различными уровнями интенсивности [7]:

$$L_{\text{determ}} = \frac{1}{N} \sum_{t=1}^T (\|I_t - I_t^{\text{determ}}\|_{L_1} + \|I_t - I_t^{\text{determ}}\|_{L_2}), \quad (6)$$

где  $N$  – суммарное количество пикселей в кадре. Аналогично EvolutionNet, обучение осуществлялось с использованием метода Adam с коэффициентом скорости обучения, равным  $10^{-3}$ , уменьшенным на этапе дообучения до  $10^{-4}$  спустя 100 обучающих эпох. Выходной прогноз  $I_t^{\text{determ}}$  модели NowcastNet использовался в дальнейшем в качестве входной информации для статистической модели.

**4.2. Статистическая модель.** Вторым шагом работы алгоритма RainCast является применение статистического подхода на основе диффузионной ИНС. Это позволяет уточнить исходный детерминированный прогноз, недостатком которого является низкая точность прогнозирования локальных областей осадков из-за применения детерминированной функции потерь, приводящей к потере детализации [20]. Диффузионная ИНС позволяет реконструировать изображение таким образом, чтобы оно выглядело максимально похожим на фактическое изображение осадков. Статистическая модель обучается находить характерные паттерны на изображениях на основе обучающей выборки и дотраивать изображение, дополняя его недостающими деталями.

**4.2.1. Сжимающий автоэнкодер.** Для уменьшения вычислительной сложности при использовании диффузионного подхода в настоящей работе используется обученный по методу GAN вариационный автоэнкодер VQGAN (Vector Quantised Variational Autoencoder trained as GAN), применяемый для сжатия изображений с минимальными потерями в точности [38, 39].

Автоэнкодер состоит из двух частей – энкодера  $E$  и декодера  $G$ . Энкодер сжимает исходное изображение из пространства  $I_t \in \mathbb{R}^{H \times W \times C}$  в новое скрытое представление  $z_t = E(I_t) \in \mathbb{R}^{h \times w \times c}$ , где  $H, W, C$  и  $h, w, c$  – размерности длины, ширины и количества каналов исходного ( $512 \times 512 \times 12$ ) и сжатого ( $64 \times 64 \times 8$ ) изображений. Декодер осуществляет обратное преобразование:  $\bar{I}_t = G(z_t) = G(E(I_t))$ . В процессе осуществления прогноза (рисунок 1) энкодеру  $E$  передается

результат работы детерминированной модели  $I^{\text{determ}}$ , в результате чего формируется тензор  $z^{\text{cond}}$ . Данный тензор задает начальные условия для прогноза с помощью статистической модели, описанной ниже. Выходной информацией энкодера является тензор  $z^{\text{out}}$ . Его декодирование осуществляется при помощи декодера G, результатом работы которого являются спрогнозированные изображения  $I^{\text{out}}$ .

Процесс обучения автоэнкодера заключается в демонстрации эталонных изображений  $I_t$  из исходной выборки. Целевой функцией минимизации при этом является комбинированная функция потерь [40]:

$$L_{\text{AE}} = \min_{E,D} \max_D (L_1(I_t, \bar{I}_t) - L_{\text{adv}}(\bar{I}_t) + \log D(I_t) + L_{\text{reg}}(I_t; \bar{I}_t)), \quad (7)$$

где  $L_{\text{adv}}$  – генеративно-состязательная функция потерь [39],  $L_{\text{reg}}$  – регуляризационный параметр на основе дивергенции Кульбака-Лейблера [41], умноженный на коэффициент  $10^{-6}$ , D – модель дискриминатора из работы [18]. Первые 25 тыс. итераций обучения проходят при условии  $L_{\text{adv}}(\bar{I}_t) + \log D(I_t) = 0$ . Общее количество обучающих итераций составляет 200 тыс.

**4.2.2. Диффузионная модель.** В качестве диффузионной модели в настоящей работе используется модель CasFormer [18], основанная на архитектуре трансформера DiT (Diffusion Transformer) [42]. Модель принимает в качестве входных данных результаты детерминированного прогноза, сжатые с использованием энкодера E в скрытое представление  $z^{\text{cond}}$ . Выходной информацией модели является скорректированный прогноз  $z^{\text{out}}$ , который затем реконструируется до полного изображения осадков с помощью декодера G.

Принцип работы диффузионной модели состоит из прямого и обратного процесса. При прямом процессе к исходному изображению  $I_0 = I_t^{\text{determ}}$ , преобразованному в скрытое представление  $z_0 = E(I_0)$  итеративно добавляется случайный шум  $q(z_k | z_{k-1}) = N(\sqrt{\alpha_k} z_{k-1}, \beta_k \sigma^2), 1 \leq k \leq K$ , где  $\beta_k = 1 - \alpha_k$ ,  $k$  – номер итерации процесса зашумления,  $K$  – количество итераций зашумления,  $\alpha$  – коэффициент, регулирующий количество добавляемого шума на каждой итерации,  $N$  – распределение Гаусса с

параметрами математического ожидания и дисперсии соответственно,  $\sigma$  – величина дисперсии значений пикселей изображения. При обратном процессе полученное совместное распределение факторизуется на произведение условных распределений  $p_{\theta}(z_{0:K}) = p(z_K) \prod_{i=K}^{i=1} p_{\theta}(z_{i-1} | z_i)$ . Диффузионная модель  $\Psi$  с параметрами  $\theta$  обучается прогнозировать шум  $q$  на каждом шаге  $k$  из распределения  $p_{\theta}(z_{k-1} | z_k)$ . Более подробно принцип работы диффузионных моделей описан в работе [43].

Следуя [18], для обучения диффузионной модели CasFormer использовался оптимизатор AdamW с коэффициентом скорости обучения, линейно меняющимся в диапазоне от  $10^{-3}$  до  $10^{-6}$  на протяжении 300 тыс. итераций. Целевой функцией минимизации является:

$$L_{diff} = \left\| N(0, 1) - \Psi_{\theta}(z_k, k, z_{cond}) \right\|, \quad (8)$$

где  $z_k = \sqrt{\alpha_k} z_{k-1} + \sqrt{1 - \alpha_k} \sigma$ ,  $z_{cond} = E(\bar{I}_0)$ .

Для обучения всех описанных моделей использовались 8 графических ускорителей NVIDIA A6000 с объемом видеопамати каждого ускорителя 48 Гб. Количество примеров, демонстрируемое ИНС за одну обучающую итерацию (batch size) в расчете на одну видеокарту, принимался равным 20, 4, 3 и 8 для моделей EvolutionNet, NowcastNet, автоэнкодера и CasFormer соответственно. Итоговый расчет прогноза с использованием обученного алгоритма осуществлялся на видеокарте RTX2080 с объемом видеопамати 8 Гб. Полное время расчета карты осадков для рассматриваемой территории занимает менее 10 минут, что позволяет использовать данный алгоритм для оперативного расчета прогноза осадков.

**5. Оценка результатов.** Для оценки точности полученных результатов рассчитывался ряд оценочных метрик с использованием предварительно сформированной тестовой выборки, не использовавшейся при обучении или настройке ИНС. При оценке качества прогноза рассматривался ряд показателей. В частности, показатель корня среднеквадратичной ошибки (Root Mean Square Error, RMSE) и коэффициент корреляции Пирсона (Pearson Correlation Coefficient, PCC) позволяют оценить близость спрогнозированных значений интенсивностей осадков к их фактическим наблюдениям для всех пикселей изображения:

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}}, \quad (9)$$

$$\text{PCC} = \frac{\sum_{i=1}^n (x_i - \langle x \rangle)(y_i - \langle y \rangle)}{\sqrt{\sum_{i=1}^n (x_i - \langle x \rangle)^2 \sum_{i=1}^n (y_i - \langle y \rangle)^2}}, \quad (10)$$

где  $x_i$  и  $y_i$  – спрогнозированный и эталонный пиксели,  $n$  – общее количество пикселей одного изображения ( $512 \times 512$ ),  $\langle x \rangle$  – среднее значение по всему изображению.

Бинарные показатели качества прогноза, такие как коэффициент ложного обнаружения (False Alarm Ratio, FAR), вероятность обнаружения (Probability of Detection, POD) и критический индекс успешности (Critical Success Index, CSI), лучше подходят для оценки способности модели прогнозировать наличие или отсутствие осадков в каждом пикселе. Для получения бинарных изображений применялось пороговое значение 0.1 мм/ч. Чтобы оценить точность прогноза осадков средней и высокой интенсивности выше 5 мм/ч, в работе дополнительно рассматривается метрика  $\text{CSI}_{5\text{мм/ч}}$  с соответствующим пороговым значением интенсивности.

$$\text{FAR} = \text{FP} / (\text{TP} + \text{FP}), \quad (11)$$

$$\text{CSI} = \text{TP} / (\text{TP} + \text{FP} + \text{FN}), \quad (12)$$

где FP – количество ложноположительных, TP – истинно положительных и FN – ложноотрицательных случаев (к положительному классу относятся пиксели, где присутствуют осадки).

Для оценки структурного сходства спрогнозированных и эталонных изображений использовались показатель соотношения сигнал/шум (Peak-to-Signal Noise Ratio, PSNR) и индекс структурной схожести (Structural Similarity Index, SSIM).

$$\text{PSNR} = 20 \log_{10}(y^{\max}) - 10 \log_{10}(\text{MSE}), \quad (13)$$

$$\text{SSIM} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}, \quad (14)$$

где  $\mu^{\max}$  – максимально возможное значение пикселя, равное 50 мм/ч,  $\mu_x$  и  $\mu_y$  – средние значения для спрогнозированного и эталонного изображения,  $\sigma_x$  и  $\sigma_y$  – их дисперсия,  $\sigma_{xy}$  – ковариация,  $c_1 = (0.01L)^2$ ,  $c_2 = (0.03L)^2$ ,  $L = 2^b - 1 = 255$  – динамический диапазон интенсивности пикселей,  $b$  – разрядность (8 бит на пиксель).

Ниже перечислены модели, для которых проводилось сравнение. Выбор этих моделей основывается на том, что они являются последними достижениями в области краткосрочного прогноза осадков и, по утверждениям их авторов, обладают высокой точностью. Помимо этого, архитектуры этих моделей либо частично использовались в настоящей работе в качестве основы для создания модернизированного алгоритма, либо схожи по принципу действия и работы.

а. Оригинальная модель NowcastNet-GAN [26]. Данная статистическая модель имеет в своем составе два дискриминатора для контроля пространственной и временной компонент прогноза и демонстрирует одни из лучших результатов [24, 29].

б. Модель генератора NowcastNet из работы [26]. С целью сравнения детерминированного и статистического подхода, авторы отдельно обучили модель сверточного генератора с использованием детерминированной функции потерь на основе суммы среднеквадратичной и средней абсолютной ошибок (формула 6). Как и в оригинальной работе, в состав модели включена вспомогательная ИНС EvolutionNet.

в. Детерминированная трансформерная модель Earthformer [16]. Исходя из сравнительного анализа различных архитектур [7], обладающая одним из лучших результатов в задаче прогноза осадков.

г. Диффузионная модель CasFormer + Earthformer, описанная в работе [18]. В оригинальной работе авторы использовали данную модель в качестве демонстрации работы своей модели CasCast [15], предназначенной для улучшения детерминированных результатов прогноза.

В рамках эксперимента все перечисленные модели были предварительно обучены на полученном авторами обучающем наборе

данных в соответствии с описаниями в оригинальных работах. Тестовая выборка, полученная авторами, состоит из 3.6 тысяч примеров последовательностей изображений интенсивностей осадков на протяжении с 2022 по 2024 гг. на территории Дальневосточного региона. В таблице 1 представлены значения метрик, рассчитанные для двенадцатого выходного кадра каждой модели, что соответствует прогнозу на 120 минут.

Таблица 1. Сравнение моделей для прогноза осадков на 120 минут (кадр № 12)

Model	RMSE	PCC	POD	FAR	CSI	CSI <sub>5 мм/ч</sub>	SSIM	PSNR
Earthformer	1.09	0.56	0.80	0.34	0.57	0.57	0.88	34.49
NowcastNet	0.88	0.73	0.73	0.13	0.68	0.70	0.92	36.73
NowcastNet-GAN	0.94	0.71	0.77	0.29	0.63	0.71	0.90	35.87
Earthformer + Casformer	1.20	0.51	0.74	0.38	0.52	0.60	0.85	32.95
RainCast	0.88	0.75	0.78	0.27	0.65	0.72	0.91	36.63

На рисунке 2 представлены значения метрик для каждого спрогнозированного кадра.

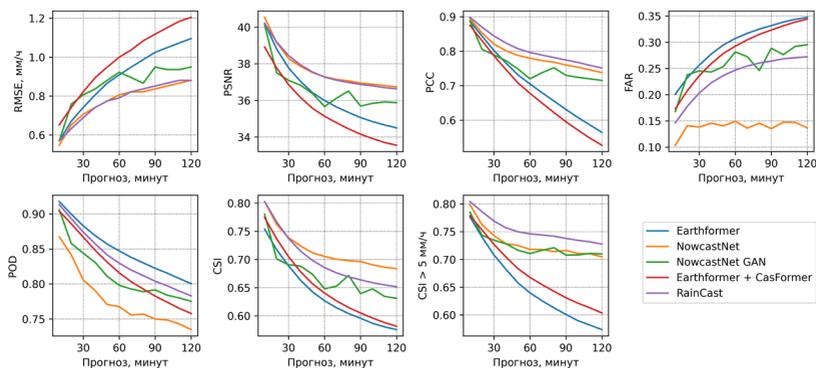


Рис. 2. Изменение показателей качества прогнозов тестируемых моделей с течением времени

Анализ полученных результатов позволяет сделать вывод, что наилучшие показатели точности были достигнуты детерминированной моделью NowcastNet и предложенной в данной работе моделью RainCast. На рисунках 3 и 4 приведены примеры прогноза осадков, сделанные с использованием тестируемых моделей.

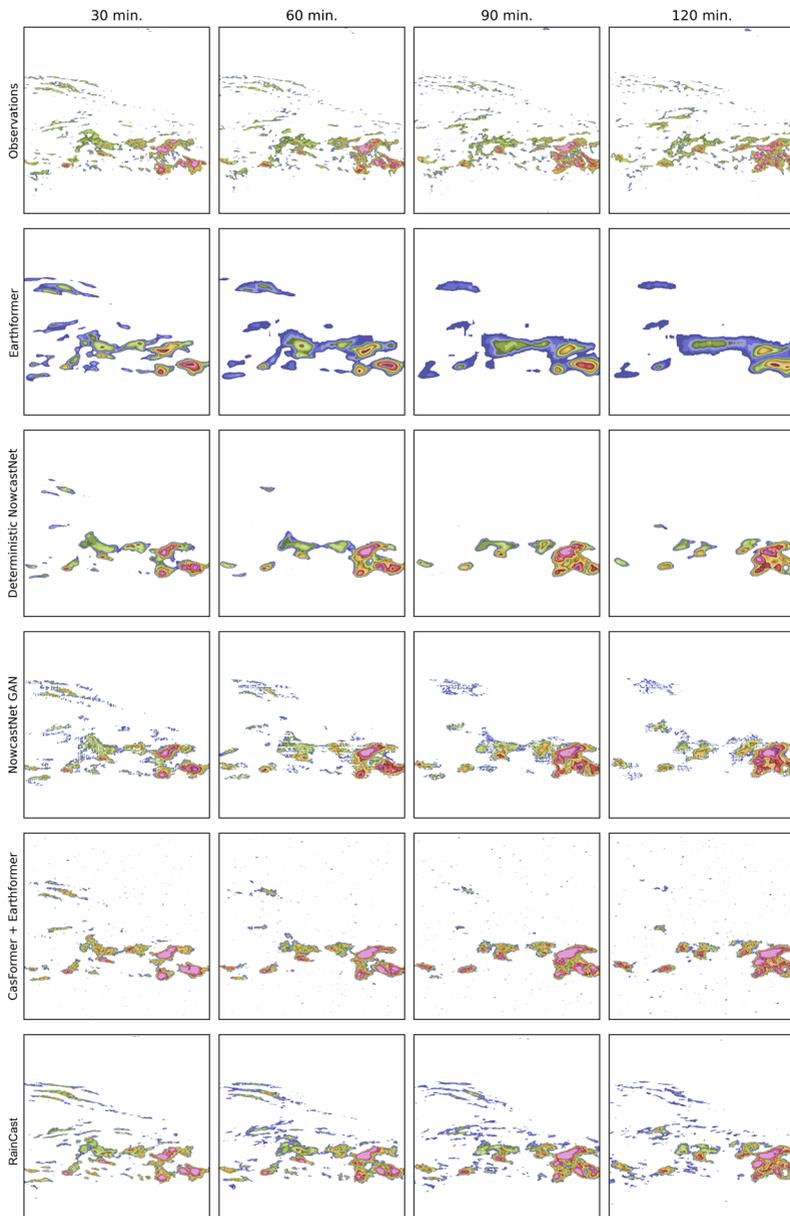


Рис. 3. Пример прогноза осадков от 01-08-2023 16:20 UTC, сделанный с использованием тестируемых моделей

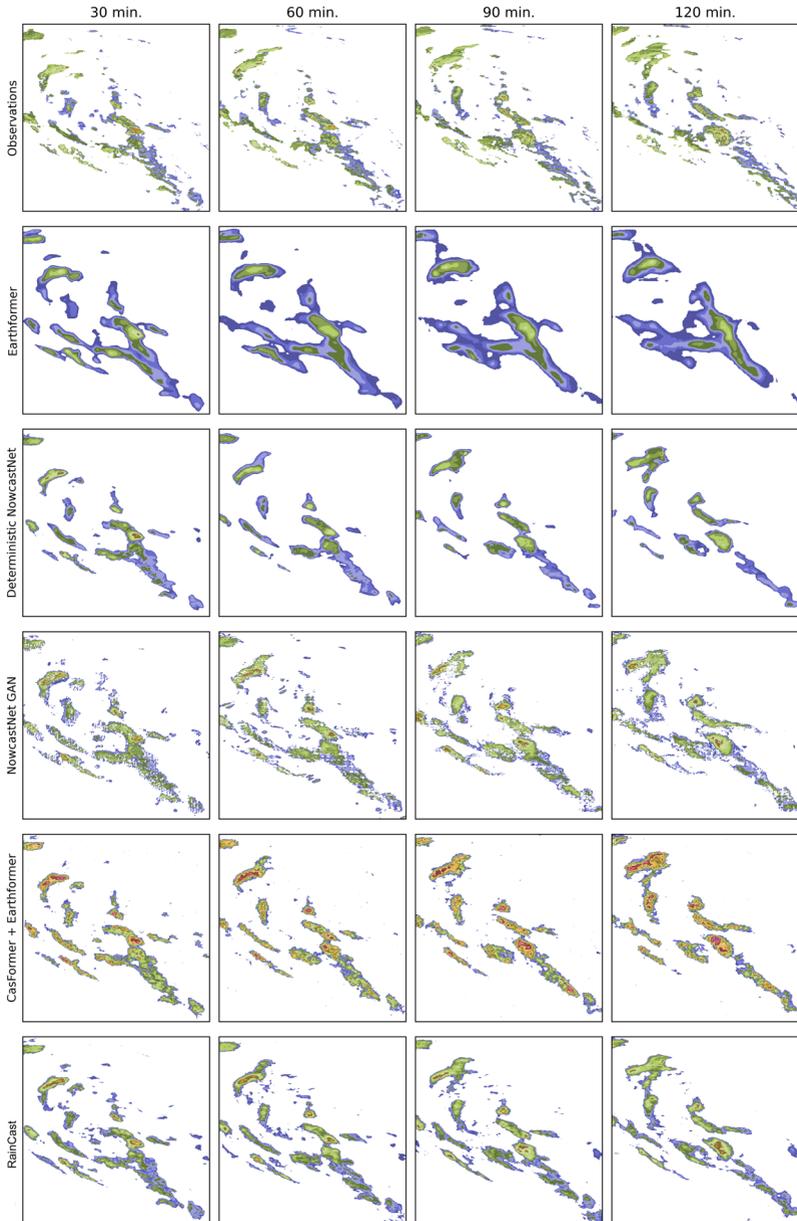


Рис. 4. Пример прогноза осадков от 10-12-2023 6:20 UTC, сделанный с использованием тестируемых моделей

Прогноз модели RainCast имеет наилучшие показатели среди всех моделей по метрикам PCC и  $CSI_{5\text{мм/ч}}$ , равным 0.75 и 0.72 соответственно. По таким показателям, как FAR, SSIM и PSNR, он незначительно уступает прогнозу детерминированной модели NowcastNet, а по показателю RMSE эти модели близки друг к другу. При этом показатель POD для NowcastNet имеет наихудшее значение, равное 0.73, в то время как наилучшие результаты по этому показателю были достигнуты предложенной гибридной моделью RainCast и детерминированной моделью Earthformer (0.78 и 0.80 соответственно).

Исходя из полученных данных и визуального анализа, можно сделать вывод о том, что детерминированная модель NowcastNet имеет склонность к недооценке осадков, тогда как Earthformer, напротив, существенно переоценивает их количество. В частности, показатель FAR для NowcastNet имеет значение 0.13, а для Earthformer он равен 0.34. На рисунках 3 и 4 данная ситуация также хорошо прослеживается.

Если сравнить прогноз двух лучших моделей – детерминированного NowcastNet и гибридного RainCast, можно отметить, что для первой модели наблюдается существенное снижение детализации при прогнозе локальной облачности (рисунок 5).

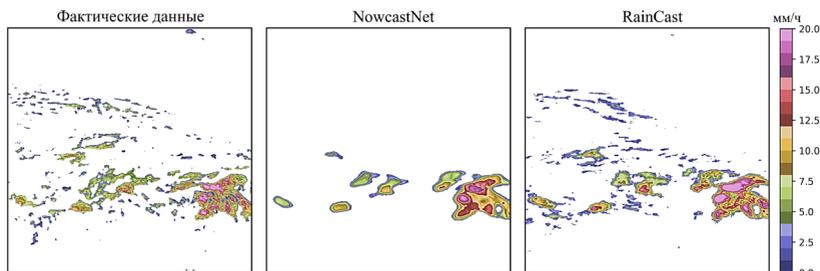


Рис. 5. Сравнение моделей NowcastNet и RainCast, прогноз на 120 минут

Одновременно с этим, несмотря на лучшее визуальное соответствие полей осадков у модели RainCast, значения рассчитанных показателей качества у нее несколько ниже. Это связано с тем, что поля осадков, спрогнозированные с помощью этой модели, немного смещены от их фактического положения. Как следствие, это приводит к ухудшению показателей, учитывающих подобные различия. Если обратить внимание на показатель  $CSI_{5\text{мм/ч}}$ , то он является наилучшим среди всех моделей, поскольку в этом случае оцениваются только средние и крупные осадки.

По большинству показателей (таблица 1) и исходя из визуального анализа прогнозов среди тестируемых моделей на рисунках 3 и 4 наименее точный прогноз имеет модель Earthformer, что проявляется в виде большого размытия и низкой детализации изображений. Прогноз модели NowcastNet-GAN имеет некоторое количество артефактов, проявляющихся в виде зернистости, но в целом локальная облачность спрогнозирована достаточно точно. Прогноз, полученный с помощью гибридной модели RainCast также обладает большим количеством деталей и высокой резкостью изображений, как и в случае с NowcastNet-GAN. Прогноз детерминированной модели NowcastNet хорошо совпадает с фактическими данными для крупных облачных массивов, что подтверждают рассчитанные оценки точности из таблицы 1. Однако, как было отмечено выше, детерминированные модели гораздо хуже справляются с прогнозом локальной облачности, что видно на примере модели Earthformer. Таким образом, принимая во внимание результаты проведенного численного и визуального анализа прогнозов, можно сделать вывод о том, что наиболее близкие к фактическим наблюдениям результаты имеет предложенная гибридная модель RainCast.

**8. Заключение.** В работе предложен алгоритм RainCast краткосрочного прогноза интенсивности осадков на срок до 2-х часов с использованием наблюдений геостационарного КА Himawari-8/9. В основе алгоритма лежит подход, суть которого заключается в получении предварительного прогноза с помощью детерминированной модели и его последующего уточнения с использованием диффузионной ИНС. Особенностью предложенного алгоритма является использование данных геостационарного спутникового прибора в региональных условиях при отсутствии наземных источников информации об осадках. Алгоритм построен на основе актуальных решений и объединяет в себе преимущества детерминированного и статистического прогноза. В частности, в качестве источника детерминированного прогноза использовалась физически обусловленная модель NowcastNet, обученная с использованием детерминированного подхода. Чтобы повысить детализацию прогноза, использовалась статистическая диффузионная модель CasFormer. Для обучения и тестирования вышеуказанных моделей были сформированы соответствующие наборы данных с применением разработанного ранее алгоритма для оценки интенсивности осадков по данным прибора АНН Himawari-8/9.

Сравнение разработанного алгоритма RainCast с аналогичными детерминированными и статистическими моделями на основе GAN и диффузионного подхода показало, что статистический подход, основанный на использовании GAN и диффузий, позволяет существенно улучшить качество прогнозов, выполненных с помощью детерминированных моделей, особенно для локальной осадкообразующей облачности. Однако процедура обучения этих моделей достаточно трудоемка. В частности, для ИНС на основе GAN требуется тонкая настройка гиперпараметров модели в процессе обучения. Диффузионные модели нуждаются в применении дополнительной ИНС, предназначенной для сжатия данных.

При этом статистические модели позволяют лишь приблизительно оценить расположение локальной облачности. Как следствие, несмотря на заметно более высокое качество статистического прогноза при визуальном сравнении изображений, значения численных показателей качества, таких как RMSE, POD, FAR и др., могут ухудшиться в сравнении с детерминированным прогнозом. Это объясняется тем, что ввиду малых размеров локальной облачности, даже небольшая ошибка в прогнозе ее положения приводит к снижению показателей качества. Чтобы решить эту проблему, в работе использовался показатель CSI для значений интенсивности осадков выше 5 мм/ч при рассмотрении основных облачных массивов на мезомасштабном уровне. Для более объективной численной оценки качества прогноза необходимо исследовать другие показатели.

Дополнительное сравнение двух актуальных моделей, сверточной NowcastNet и трансформерной Earthformer, показало, что интеграция физических принципов в ИНС положительно влияет на точность прогноза осадков. В частности, в NowcastNet используется нейросетевая реализация закона непрерывности потока в виде подсети EvolutionNet. При этом, как было отмечено ранее, трансформеры и рекуррентные сети более эффективны с точки зрения обработки временных последовательностей, чем сверточные ИНС. Поэтому в дальнейших работах целесообразно исследовать возможности по улучшению качества прогнозов путем реализации других физических принципов, а также использования данных численного моделирования в качестве начальных условий для прогноза.

Разработанный алгоритм RainCast предназначен для прогноза осадков на территории Дальневосточного региона по данным КА Himwari-8/9. Однако он может быть адаптирован для использования измерений других космических систем, таких как КА серии «Электро-

Л» и «Арктика-М». Для этого требуется формирование соответствующих обучающих наборов данных, учитывающих особенности измерений данных КА. Поскольку входными данными алгоритма RainCast являются изображения интенсивностей осадков, для их получения требуется разработка соответствующих алгоритмов оценки осадков, учитывающих территориально-климатические особенности рассматриваемого региона.

### Литература

1. Browning K.A. Review Lecture: Local weather forecasting // Proc. of the Royal Society A. Mathematical and Physical Sciences. 1980. vol. 371. pp. 179–211. DOI: 10.1098/rspa.1980.0076.
2. Киктев Д.Б., Муравьев А.В., Смирнов А.В. Наукастинг метеорологических параметров и опасных явлений: опыт реализации и перспективы развития // Гидрометеорологические исследования и прогнозы. 2019. № 4(374). С. 92–111.
3. Observing Systems Capability Analysis and Review Tool // Geneva, Switzerland: World Meteorological Organization. 2021. URL: <http://www.wmo-sat.info/oscar/> (дата обращения: 01.04.2021).
4. Simonenko E. V., Chudin A. O., Davidenko A. N. The differential method for calculation of cloud motion vectors // Russian Meteorology and Hydrology. 2017. vol. 42. no. 3. pp. 159–167. DOI: 10.3103/S1068373917030037.
5. Marrocu M., Massidda L. Performance comparison between deep learning and optical flow-based techniques for nowcast precipitation from radar images // Forecasting. 2020. vol. 2. no. 2. pp. 194–210. DOI: 10.3390/forecast2020011.
6. Prudden R., Adams S., Kangin D., Robinson N., Ravuri S., Mohamed S., Arribas A. A review of radar-based nowcasting of precipitation and applicable machine learning techniques // arXiv preprint arXiv:2005.04988. 2020. DOI: 10.48550/arXiv.2005.04988.
7. An S., Oh T.-J., Sohn E., Kim D. Deep learning for precipitation nowcasting: A survey from the perspective of time series forecasting // Expert Systems with Applications. 2025. vol. 268. pp. 126301. DOI: 10.1016/j.eswa.2024.126301.
8. Tao W. K., Moncrieff M. W. Multiscale cloud system modeling // Reviews of Geophysics. 2009. vol. 47. no. 4. DOI: 10.1029/2008RG000276.
9. Tan J., Huang Q., Chen S. Deep learning model based on multi-scale feature fusion for precipitation nowcasting // Geoscientific Model Development. 2024. vol. 17. no. 1. pp. 53–69. DOI: 10.5194/gmd-17-53-2024.
10. Kong D., Zhi X., Ji Y., Yang C., Wang Y., Tian Y., Li G., Zeng X. Precipitation Nowcasting Based on Deep Learning over Guizhou, China // Atmosphere. 2023. vol. 14. no. 5. DOI: 10.3390/atmos14050807.
11. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting // Advances in Neural Information Processing Systems. 2015. vol. 28. pp. 1–9.
12. Shi X., Gao Z., Lausen L., Wang H., Yeung D.-Y., Wong W., Woo W. Deep learning for precipitation nowcasting: A benchmark and a new model // Advances in Neural Information Processing Systems: 31st Conference on Neural Information Processing Systems (NIPS 2017). 2017. vol. 30.
13. Han K., Wang Y., Chen H., Chen X., Guo J., Liu Z. A Survey on Vision Transformer // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2023. vol. 45. no. 1. pp. 87–110. DOI: 10.1109/TPAMI.2022.3152247.

14. Wang Y., Wu H., Zhang J., Gao Z., Wang J., Philip S.Y., Long M. PredRNN: A Recurrent Neural Network for Spatiotemporal Predictive Learning // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2023. vol. 45. no. 2. pp. 2208–2225. DOI: 10.1109/TPAMI.2022.3165153.
15. Wu H., Yao Z., Wang J., Long M. MotionRNN: A Flexible Model for Video Prediction with Spacetime-Varying Motions // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA, 2021. pp. 15430–15439. DOI: 10.1109/CVPR46437.2021.01518.
16. Gao Z., Shi X., Wang H., Zhu Y., Wang Y.B., Li M., Yeung D.Y. Earthformer: Exploring space-time transformers for earth system forecasting // Advances in Neural Information Processing Systems 35: Annual Conference on Neural Information Processing Systems (NeurIPS 2022). 2022. vol. 35. pp. 25390–25403.
17. Bai C., Sun F., Zhang J., Song Y., Chen S. Rainformer: Features extraction balanced network for radar-based precipitation nowcasting // IEEE Geoscience and Remote Sensing Letters. 2022. vol. 19. pp. 1–5. DOI: 10.1109/LGRS.2022.3162882.
18. Gong J., Bai L., Ye P., Xu W., Liu N., Dai J., Yang X., Ouyang W. CasCast: Skillful high-resolution precipitation nowcasting via cascaded modelling // arXiv preprint arXiv:2402.04290. 2024. DOI: 10.48550/arXiv.2402.04290.
19. Wen P., Bai L., He M., Filippi P., Zhang F., Bishop T.F., Wang Z., Hu K. DuoCast: Duo-Probabilistic Meteorology-Aware Model for Extended Precipitation Nowcasting // arXiv preprint arXiv:2412.01091. 2024. DOI: 10.48550/arXiv.2412.01091.
20. Ravuri S., Lenc K., Willson M., Kangin D., Lam R., Mirowski P., Fitzsimons M., Athanassiadou M., Kashem S., Madge S., Prudden R., Mandhane A., Clark A., Brock A., Simonyan K., Hadsell R., Robinson N., Clancy E., Arribas A., Mohamed S. Skillful precipitation nowcasting using deep generative models of radar // Nature. 2021. vol. 597. pp. 672–677. DOI: 10.1038/s41586-021-03854-z.
21. Кучма М.О., Мальковский С.И., Андреев А.И., Блощинский В.Д. Нейросетевые методы наукастинга осадков: обзор и апробация существующих решений // Современные проблемы дистанционного зондирования Земли из космоса. 2023. Т. 20. № 6. С. 35–48. DOI: 10.21046/2070-7401-2023-20-6-35-48.
22. Nai C., Pan B., Chen X., Tang Q., Ni G., Duan Q., Lu B., Xiao Z., Liu X. Reliable precipitation nowcasting using probabilistic diffusion models // Environmental Research Letters. 2024. vol. 19. no. 3. DOI: 10.1088/1748-9326/ad2891.
23. Yin J., Meo C., Cher Z.B., Lica M., Wang Y., Imhoff R., Uijlenhoet R., Dauwels J. Precipitation Nowcasting Using Physics Informed Discriminator Generative Models // 32nd European Signal Processing Conference (EUSIPCO). Lyon, France, 2024. pp. 967–971. DOI: 10.23919/EUSIPCO63174.2024.10715141.
24. Wang R., Fung J.C.H., Lau A.K.H. Skillful precipitation nowcasting using physical-driven diffusion networks // Geophysical Research Letters. 2024. vol. 51. no. 24. DOI: 10.1029/2024GL110832.
25. Yu D., Li X., Ye Y., Zhang B., Luo C., Dai K., Wang R., Chen X. DiffCast: A Unified Framework via Residual Diffusion for Precipitation Nowcasting // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA, 2024. pp. 27758–27767. DOI: 10.1109/CVPR52733.2024.02622.
26. Zhang Y., Long M., Chen K., Xing L., Jin R., Jordan M.I., Wang J. Skillful nowcasting of extreme precipitation with NowcastNet // Nature. 2023. vol. 619. pp. 526–532. DOI: 10.1038/s41586-023-06184-4.
27. Kim W., Jeong C.H., Kim S. Improvements in deep learning-based precipitation nowcasting using major atmospheric factors with radar rain rate // Computers & Geosciences. 2024. vol. 184. DOI: 10.1016/j.cageo.2024.105529.
28. Rahimi R., Ravirathinam P., Ebtehaj A., Behrang A., Tan J., Kumar V. Global precipitation nowcasting of Integrated Multi-satellitE Retrievals for GPM: A U-Net

- convolutional LSTM architecture // *Journal of Hydrometeorology*. 2024. vol. 25. no. 6. pp. 947–963. DOI: 10.1175/JHM-D-23-0119.1.
29. Das P., Posch A., Barber N., Hicks M., Duffy K., Vandal T., Singh D., Werkhoven K., van Werkhoven K., Ganguly A.R. Hybrid physics-AI outperforms numerical weather prediction for extreme precipitation nowcasting // *NPJ Climate and Atmospheric Science*. 2024. vol. 7. no. 1. DOI: 10.1038/s41612-024-00834-8.
30. Xu Q., Shi Y., Bamber J., Tuo Y., Ludwig R., Zhu X.X. Physics-aware machine learning revolutionizes scientific paradigm for machine learning and process-based hydrology // *arXiv preprint arXiv:2310.05227*. 2023. DOI: 10.48550/arXiv.2310.05227.
31. Leinonen J., Hamann U., Nerini D., Germann U., Franch G. Latent diffusion models for generative precipitation nowcasting with accurate uncertainty quantification // *arXiv preprint arXiv:2304.12891*. 2023. DOI: 10.48550/arXiv.2304.12891.
32. Chen T. On the importance of noise scheduling for diffusion models // *arXiv preprint arXiv:2301.10972*. 2023. DOI: 10.48550/arXiv.2301.10972.
33. Veillette M., Samsi S., Mattioli C. SEVIR: A storm event imagery dataset for deep learning applications in radar and satellite meteorology // *Advances in Neural Information Processing Systems: 34th Conference on Neural Information Processing Systems (NeurIPS 2020)*. 2020. vol. 33. pp. 22009–22019.
34. Бикбулатова Г.Г. Исследование распределения атмосферного увлажнения на территории Сибири и Дальнего Востока // *Омский научный вестник*. 2011. Т. 1(104). С. 232–235.
35. Андреев А.И., Филей А.А., Мальковский С.И. Метод количественной оценки осадков на основе измерений Himawari-8/9 // *Современные проблемы дистанционного зондирования Земли из космоса*. 2024. Т. 21. № 5. С. 20–35. DOI: 10.21046/2070-7401-2024-21-5-20-35.
36. Huffman G.J., Bolvin D.T., Braithwaite D., Hsu K.L., Joyce R.J., Kidd C., Nelkin E.J., Sorooshian S., Stocker E.F., Tan J., Wolff D.B., Xie P. Integrated Multi-satellite Retrievals for the Global Precipitation Measurement (GPM) Mission (IMERG) // *Satellite Precipitation Measurement // Advances in Global Change Research*. 2020. vol. 67. pp. 343–353. Springer, Cham. DOI: 10.1007/978-3-030-24568-9\_19.
37. Kingma D.P., Ba J. Adam: A method for stochastic optimization // *arXiv preprint arXiv:1412.6980*. 2017. DOI: 10.48550/arXiv.1412.6980.
38. Rombach R., Blattmann A., Lorenz D., Esser P., Ommer B. High-Resolution Image Synthesis with Latent Diffusion Models // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2022. pp. 10674–10685. DOI: 10.1109/CVPR52688.2022.01042.
39. Esser P., Rombach R., Ommer B. Taming Transformers for High-Resolution Image Synthesis // *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021. pp. 12868–12878. DOI: 10.1109/CVPR46437.2021.01268.
40. Goodfellow I. J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets // *Advances in Neural Information Processing Systems: Annual Conference on Neural Information Processing Systems*. 2014. vol. 27. pp. 2672–2680.
41. Kingma D.P., Welling M. Auto-encoding variational bayes // *arXiv preprint arXiv:1312.6114*. 2013. DOI: 10.48550/arXiv.1312.6114.
42. Peebles W., Xie S. Scalable Diffusion Models with Transformers // *IEEE/CVF International Conference on Computer Vision (ICCV)*. Paris, France, 2023. pp. 4172–4182. DOI: 10.1109/ICCV51070.2023.00387.
43. Ho J., Jain A., Abbeel P. Denoising diffusion probabilistic models // *Advances in neural information processing systems*. 2020. vol. 33. pp. 6840–6851.

**Андреев Александр Иванович** — научный сотрудник, лаборатория информационных и вычислительных систем, Вычислительный центр Дальневосточного отделения Российской академии наук; младший научный сотрудник, отдел разработки и внедрения НИОКР, ДЦ ФГБУ «НИЦ «Планета». Область научных интересов: компьютерная оптика, обработка изображений, машинное обучение, дистанционное зондирование Земли. Число научных публикаций — 51. a.andreev@dvrpcod.ru; улица Ленина, 18, 680000, Хабаровск, Россия; р.т.: +7(4212)214-311.

**Кучма Михаил Олегович** — канд. техн. наук, научный сотрудник, лаборатория информационных и вычислительных систем, Вычислительный центр Дальневосточного отделения Российской академии наук; младший научный сотрудник, отдел разработки и внедрения НИОКР, ДЦ ФГБУ «НИЦ «Планета». Область научных интересов: дистанционное зондирование Земли, обработка данных, геоданные, машинное обучение, искусственный интеллект. Число научных публикаций — 55. m.kuchma@dvrpcod.ru; улица Ленина, 18, 680000, Хабаровск, Россия; р.т.: +7(4212)214-311.

**Мальковский Сергей Иванович** — канд. техн. наук, старший научный сотрудник, лаборатория информационных и вычислительных систем, Вычислительный центр Дальневосточного отделения Российской академии наук. Область научных интересов: высокопроизводительные вычисления, гибридные вычислительные системы, GRID, параллельные алгоритмы, искусственный интеллект, компьютерное моделирование. Число научных публикаций — 90. sergey.malkovsky@ccfebras.ru; улица Ким Ю Чена, 65, 680000, Хабаровск, Россия; р.т.: +7(4212)703-913.

**Филей Андрей Александрович** — канд. физ.-мат. наук, старший научный сотрудник, лаборатория информационных и вычислительных систем, Вычислительный центр Дальневосточного отделения Российской академии наук; научный сотрудник, отдел разработки и внедрения НИОКР, ДЦ ФГБУ «НИЦ «Планета». Область научных интересов: дистанционное зондирование Земли, обработка данных, физическое моделирование, машинное обучение. Число научных публикаций — 55. andreym-61@mail.ru; улица Ким Ю Чена, 65, 680000, Хабаровск, Россия; р.т.: +7(4212)214-311.

**Поддержка исследований.** Исследование выполнено за счет гранта Российского научного фонда № 23-77-00011, <https://rscf.ru/project/23-77-00011/>. В работе использовались ресурсы Центра коллективного пользования системами архивации, обработки и анализа данных спутниковых наблюдений Института космических исследований Российской академии наук для решения задач изучения и мониторинга окружающей среды (ЦКП «ИКИ-Мониторинг»).

A. ANDREEV, M. KUCHMA, S. MALKOVSKY, A. FILEI  
**RAINCAST: A HYBRID PRECIPITATION NOWCASTING  
ALGORITHM USING THE HIMAWARI-8/9 SATELLITE  
MEASUREMENTS**

*Andreev A., Kuchma M., Malkovsky S., Filei A. RainCast: A Hybrid Precipitation Nowcasting Algorithm Using the Himawari-8/9 Satellite Measurements.*

**Abstract.** This paper proposes an algorithm for short-term rain rate forecasting, RainCast (Rain Rate NowCast), for up to two hours. This area of meteorology, known as 'nowcasting', is one of the most important tools in many areas of human activity. However, its availability may be severely limited by existing ground infrastructure. In this paper, the authors aim to create a precipitation forecasting algorithm for one such territory using the Asia-Pacific region as an example, based on satellite measurements from the Himawari-8/9 spacecraft. The algorithm combines the advantages of deterministic and statistical approaches to solve the forecasting problem and is based on two neural networks. The first model, a modified version of the physically constrained neural network NowcastNet, generates a preliminary forecast of the general direction of precipitation movement at the mesoscale level. The second model, based on the CasFormer architecture, employs diffusion methods to post-process the initial forecast, refining fine-scale details. The resulting hybrid algorithm, named RainCast, enables short-term precipitation forecasting (up to 2 hours) with high spatiotemporal resolution (2 km, updated every 10 minutes), utilizing solely infrared satellite measurements. Satellite data are converted into precipitation intensity using the algorithm previously developed by the authors. Based on precipitation maps, training, validation, and test datasets were compiled for the algorithm development and forecast quality assessment. The proposed RainCast algorithm was trained on these datasets and compared with other state-of-the-art solutions such as NowcastNet, Casformer, and Earthformer. Analysis of performance metrics demonstrated that the hybrid RainCast algorithm achieves comparable accuracy. For a 2-hour forecast, the Root Mean Square Error (RMSE) was 0.88, the Probability of Detection (POD) was 0.78, the Pearson Correlation Coefficient (PCC) was 0.75, the Structural Similarity Index Measure (SSIM) was 0.91, and the Peak Signal-to-Noise Ratio (PSNR) was 36.63. Visual analysis of the forecasts confirmed that RainCast produces results closest to actual observations, primarily due to the diffusion model's ability to refine fine-scale spatial and temporal precipitation patterns.

**Keywords:** nowcasting, precipitation, rain rate, rainfall forecasting, Himawari, RainCast, diffusion models.

## References

1. Browning K.A. Review Lecture: Local weather forecasting // Proc. of the Royal Society A. Mathematical and Physical Sciences. 1980. vol. 371. pp. 179–211. DOI: 10.1098/rspa.1980.0076.
2. Kiktev D.B., Muravyov A.V., Smirnov A.V. [Nowcasting of meteorological parameters and hazardous phenomena: implementation experience and development prospects]. *Gidrometeorologicheskie issledovaniya i prognozy – Hydrometeorological research and forecasts*. 2019. no. 4(374). pp. 92–111. (In Russ.).
3. Observing Systems Capability Analysis and Review Tool. Geneva, Switzerland: World Meteorological Organization. 2021. Available at: <http://www.wmo-sat.info/oscar/> (дата accessed 01.04.2021).

4. Simonenko E. V., Chudin A. O., Davidenko A. N. The differential method for calculation of cloud motion vectors. *Russian Meteorology and Hydrology*. 2017. vol. 42. no. 3. pp. 159–167. DOI: 10.3103/S1068373917030037.
5. Marrocu M., Massidda L. Performance comparison between deep learning and optical flow-based techniques for nowcast precipitation from radar images. *Forecasting*. 2020. vol. 2. no. 2. pp. 194–210. DOI: 10.3390/forecast2020011.
6. Prudden R., Adams S., Kangin D., Robinson N., Ravuri S., Mohamed S., Arribas A. A review of radar-based nowcasting of precipitation and applicable machine learning techniques. *arXiv preprint arXiv:2005.04988*. 2020. DOI: 10.48550/arXiv.2005.04988.
7. An S., Oh T.-J., Sohn E., Kim D. Deep learning for precipitation nowcasting: A survey from the perspective of time series forecasting. *Expert Systems with Applications*. 2025. vol. 268. pp. 126301. DOI: 10.1016/j.eswa.2024.126301.
8. Tao W. K., Moncrieff M. W. Multiscale cloud system modeling. *Reviews of Geophysics*. 2009. vol. 47. no. 4. DOI: 10.1029/2008RG000276.
9. Tan J., Huang Q., Chen S. Deep learning model based on multi-scale feature fusion for precipitation nowcasting. *Geoscientific Model Development*. 2024. vol. 17. no. 1. pp. 53–69. DOI: 10.5194/gmd-17-53-2024.
10. Kong D., Zhi X., Ji Y., Yang C., Wang Y., Tian Y., Li G., Zeng X. Precipitation Nowcasting Based on Deep Learning over Guizhou, China. *Atmosphere*. 2023. vol. 14. no. 5. DOI: 10.3390/atmos14050807.
11. Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W., Woo W. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems*. 2015. vol. 28. pp. 1–9.
12. Shi X., Gao Z., Lausen L., Wang H., Yeung D.-Y., Wong W., Woo W. Deep learning for precipitation nowcasting: A benchmark and a new model. *Advances in Neural Information Processing Systems: 31st Conference on Neural Information Processing Systems (NIPS 2017)*. 2017. vol. 30.
13. Han K., Wang Y., Chen H., Chen X., Guo J., Liu Z. A Survey on Vision Transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023. vol. 45. no. 1. pp. 87–110. DOI: 10.1109/TPAMI.2022.3152247.
14. Wang Y., Wu H., Zhang J., Gao Z., Wang J., Philip S.Y., Long M. PredRNN: A Recurrent Neural Network for Spatiotemporal Predictive Learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023. vol. 45. no. 2. pp. 2208–2225. DOI: 10.1109/TPAMI.2022.3165153.
15. Wu H., Yao Z., Wang J., Long M. MotionRNN: A Flexible Model for Video Prediction with Spacetime-Varying Motions. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Nashville, TN, USA, 2021. pp. 15430–15439. DOI: 10.1109/CVPR46437.2021.01518.
16. Gao Z., Shi X., Wang H., Zhu Y., Wang Y.B., Li M., Yeung D.Y. Earthformer: Exploring space-time transformers for earth system forecasting. *Advances in Neural Information Processing Systems 35: Annual Conference on Neural Information Processing Systems (NeurIPS 2022)*. 2022. vol. 35. pp. 25390–25403.
17. Bai C., Sun F., Zhang J., Song Y., Chen S. Rainformer: Features extraction balanced network for radar-based precipitation nowcasting. *IEEE Geoscience and Remote Sensing Letters*. 2022. vol. 19. pp. 1–5. DOI: 10.1109/LGRS.2022.3162882.
18. Gong J., Bai L., Ye P., Xu W., Liu N., Dai J., Yang X., Ouyang W. CasCast: Skillful high-resolution precipitation nowcasting via cascaded modelling. *arXiv preprint arXiv:2402.04290*. 2024. DOI: 10.48550/arXiv.2402.04290.
19. Wen P., Bai L., He M., Filippi P., Zhang F., Bishop T.F., Wang Z., Hu K. DuoCast: Duo-Probabilistic Meteorology-Aware Model for Extended Precipitation Nowcasting. *arXiv preprint arXiv:2412.01091*. 2024. DOI: 10.48550/arXiv.2412.01091.

20. Ravuri S., Lenc K., Willson M., Kangin D., Lam R., Mirowski P., Fitzsimons M., Athanassiadou M., Kashem S., Madge S., Prudden R., Mandhane A., Clark A., Brock A., Simonyan K., Hadsell R., Robinson N., Clancy E., Arribas A., Mohamed S. Skilful precipitation nowcasting using deep generative models of radar. *Nature*. 2021. vol. 597. pp. 672–677. DOI: 10.1038/s41586-021-03854-z.
21. Kuchma M.O., Malkovsky S.I., Andreev A.I., Bloshchinskiy V.D. [Neural network approaches to precipitation nowcasting: A review and test of existing methods]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa – Current problems in remote sensing of the Earth from space*. 2023. vol. 20. no. 6. pp. 35–48. DOI: 10.21046/2070-7401-2023-20-6-35-48. (In Russ.).
22. Nai C., Pan B., Chen X., Tang Q., Ni G., Duan Q., Lu B., Xiao Z., Liu X. Reliable precipitation nowcasting using probabilistic diffusion models. *Environmental Research Letters*. 2024. vol. 19. no. 3. DOI: 10.1088/1748-9326/ad2891.
23. Yin J., Meo C., Cher Z.B., Lica M., Wang Y., Imhoff R., Uijlenhoet R., Dauwels J. Precipitation Nowcasting Using Physics Informed Discriminator Generative Models. 32nd European Signal Processing Conference (EUSIPCO). Lyon, France, 2024. pp. 967–971. DOI: 10.23919/EUSIPCO63174.2024.10715141.
24. Wang R., Fung J.C.H., Lau A.K.H. Skillful precipitation nowcasting using physical-driven diffusion networks. *Geophysical Research Letters*. 2024. vol. 51. no. 24. DOI: 10.1029/2024GL110832.
25. Yu D., Li X., Ye Y., Zhang B., Luo C., Dai K., Wang R., Chen X. DiffCast: A Unified Framework via Residual Diffusion for Precipitation Nowcasting. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA, 2024. pp. 27758–27767. DOI: 10.1109/CVPR52733.2024.02622.
26. Zhang Y., Long M., Chen K., Xing L., Jin R., Jordan M.I., Wang J. Skilful nowcasting of extreme precipitation with NowcastNet. *Nature*. 2023. vol. 619. pp. 526–532. DOI: 10.1038/s41586-023-06184-4.
27. Kim W., Jeong C.H., Kim S. Improvements in deep learning-based precipitation nowcasting using major atmospheric factors with radar rain rate. *Computers & Geosciences*. 2024. vol. 184. DOI: 10.1016/j.cageo.2024.105529.
28. Rahimi R., Ravirathinam P., Ebtehaj A., Behrangi A., Tan J., Kumar V. Global precipitation nowcasting of Integrated Multi-satellitE Retrievals for GPM: A U-Net convolutional LSTM architecture. *Journal of Hydrometeorology*. 2024. vol. 25. no. 6. pp. 947–963. DOI: 10.1175/JHM-D-23-0119.1.
29. Das P., Posch A., Barber N., Hicks M., Duffy K., Vandal T., Singh D., Werkhoven K., van Werkhoven K., Ganguly A.R. Hybrid physics-AI outperforms numerical weather prediction for extreme precipitation nowcasting. *NPJ Climate and Atmospheric Science*. 2024. vol. 7. no. 1. DOI: 10.1038/s41612-024-00834-8.
30. Xu Q., Shi Y., Bamber J., Tuo Y., Ludwig R., Zhu X.X. Physics-aware machine learning revolutionizes scientific paradigm for machine learning and process-based hydrology. *arXiv preprint arXiv:2310.05227*. 2023. DOI: 10.48550/arXiv.2310.05227.
31. Leinonen J., Hamann U., Nerini D., Germann U., Franch G. Latent diffusion models for generative precipitation nowcasting with accurate uncertainty quantification. *arXiv preprint arXiv:2304.12891*. 2023. DOI: 10.48550/arXiv.2304.12891.
32. Chen T. On the importance of noise scheduling for diffusion models. *arXiv preprint arXiv:2301.10972*. 2023. DOI: 10.48550/arXiv.2301.10972.
33. Veillette M., Samsi S., Mattioli C. SEVIR: A storm event imagery dataset for deep learning applications in radar and satellite meteorology. *Advances in Neural Information Processing Systems: 34th Conference on Neural Information Processing Systems (NeurIPS 2020)*. 2020. vol. 33. pp. 22009–22019.

34. Bikbulatova G.G. [A study of the distribution of atmospheric hydration in Siberia and the Far East]. *Omskij nauchnyj vestnik – Omsk scientific messenger*. 2011. vol. 1(104). pp. 232–235. (In Russ.).
35. Andreev A.I., Filey A.A., Malkovsky S.I., Korolev S.P. [Method of quantitative rainfall estimation based on Himawari-8/9 measurements]. *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa – Current problems in remote sensing of the Earth from space*. 2024. vol. 21. no. 5. pp. 20–35. DOI: 10.21046/2070-7401-2024-21-5-20-35. (In Russ.).
36. Huffman G.J., Bolvin D.T., Braithwaite D., Hsu K.L., Joyce R.J., Kidd C., Nelkin E.J., Sorooshian S., Stocker E.F., Tan J., Wolff D.B., Xie P. Integrated Multi-satellite Retrievals for the Global Precipitation Measurement (GPM) Mission (IMERG). *Satellite Precipitation Measurement. Advances in Global Change Research*. 2020. vol. 67. pp. 343–353. Springer, Cham. DOI: 10.1007/978-3-030-24568-9\_19.
37. Kingma D.P., Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2017. DOI: 10.48550/arXiv.1412.6980.
38. Rombach R., Blattmann A., Lorenz D., Esser P., Ommer B. High-Resolution Image Synthesis with Latent Diffusion Models. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2022. pp. 10674–10685. DOI: 10.1109/CVPR52688.2022.01042.
39. Esser P., Rombach R., Ommer B. Taming Transformers for High-Resolution Image Synthesis. *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021. pp. 12868–12878. DOI: 10.1109/CVPR46437.2021.01268.
40. Goodfellow I. J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial nets. *Advances in Neural Information Processing Systems: Annual Conference on Neural Information Processing Systems*. 2014. vol. 27. pp. 2672–2680.
41. Kingma D.P., Welling M. Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*. 2013. DOI: 10.48550/arXiv.1312.6114.
42. Peebles W., Xie S. Scalable Diffusion Models with Transformers. *IEEE/CVF International Conference on Computer Vision (ICCV)*. Paris, France, 2023. pp. 4172–4182. DOI: 10.1109/ICCV51070.2023.00387.
43. Ho J., Jain A., Abbeel P. Denoising diffusion probabilistic models. *Advances in neural information processing systems*. 2020. vol. 33. pp. 6840–6851.

**Andreev Aleksandr** — Researcher, Laboratory of information and computing systems, Computing Center of the Far Eastern Branch of the Russian Academy of Sciences; Junior researcher, R& D development and implementation department, Far-Eastern Center of the Federal State Budgetary Institution «State Research Center of Space Hydrometeorology «Planeta». Research interests: computer optics, image processing, machine learning, remote sensing. The number of publications — 51. a.andreev@dvrpcod.ru; 18, Lenina St., 680000, Khabarovsk, Russia; office phone: +7(4212)214-311.

**Kuchma Mikhail** — Ph.D., Researcher, Laboratory of information and computing systems, Computing Center of the Far Eastern Branch of the Russian Academy of Sciences; Junior researcher, R& D development and implementation department, Far-Eastern Center of the Federal State Budgetary Institution «State Research Center of Space Hydrometeorology «Planeta». Research interests: remote sensing, data processing, geodata, machine learning, artificial intelligence. The number of publications — 55. m.kuchma@dvrpcod.ru; 18, Lenina St., 680000, Khabarovsk, Russia; office phone: +7(4212)214-311.

**Malkovsky Sergey** — Ph.D., Senior researcher, Laboratory of information and computing systems, Computing Center of the Far Eastern Branch of the Russian Academy of Sciences.

Research interests: high-performance computing, hybrid computing systems, GRID, parallel algorithms, artificial intelligence, computer modeling. The number of publications — 90. sergey.malkovsky@ccfebras.ru; 65, Kim Yu Chen St., 680000, Khabarovsk, Russia; office phone: +7(4212)703-913.

**Filei Andrei** — Ph.D., Senior researcher, Laboratory of information and computing systems, Computing Center of the Far Eastern Branch of the Russian Academy of Sciences; Researcher, R&D development and implementation department, Far-Eastern Center of the Federal State Budgetary Institution «State Research Center of Space Hydrometeorology «Planeta». Research interests: remote sensing, data processing, physical modeling, machine learning. The number of publications — 55. andreyvm-61@mail.ru; 65, Kim Yu Chen St., 680000, Khabarovsk, Russia; office phone: +7(4212)214-311.

**Acknowledgements.** The research was supported by the Russian Science Foundation (grant 23-77-00011, <https://rscf.ru/en/project/23-77-00011/>). The resources of the Satellite Data Archiving, Processing, and Analysis System Common Use Center for Solving Problems of Environmental Research and Monitoring of the Space Research Institute of the Russian Academy of Sciences were used.