

Наукастинг движения облачности по данным КА Himawari-8/9 с использованием гибридной нейросетевой модели HybridCloudCast

В. Д. Блошинский^{1,2}, С. И. Мальковский¹, Л. С. Крамарева^{1,2},
А. В. Бородицкая^{1,2}, С. П. Королев¹

¹ Вычислительный центр ДВО РАН, Хабаровск, 680000, Россия
E-mail: sergey.malkovsky@ccfebras.ru

² Дальневосточный центр НИЦ «Планета», Хабаровск, 680000, Россия
E-mail: v.bloshchinsky@dvcopod.ru

Представлен алгоритм наукастинга движения облачности в Азиатско-Тихоокеанском регионе по спутниковым изображениям в инфракрасном диапазоне с геостационарных космических аппаратов Himawari-8/9. Алгоритм основывается на разработанной авторами гибридной нейросетевой модели HybridCloudCast, объединяющей преимущества детерминированного и статистического подходов в задаче краткосрочного прогнозирования. Первый из них обеспечивает качественное предсказание эволюции облачности за счёт применения физически обоснованной модели, а второй, использующий диффузионную нейронную сеть, позволяет повысить детализацию и визуальное качество прогнозных изображений. В качестве входной информации для HybridCloudCast использовались изображения с яркостной температурой канала № 14 прибора AHI (англ. Advanced Himawari Imager). В дополнение к спутниковым изображениям нейросетевая модель применяет безоблачный композит, позволяющий улучшить точность прогноза за счёт учёта яркостных характеристик подстилающей поверхности. Разработанная модель HybridCloudCast формирует краткосрочный прогноз, временное разрешение которого составляет 10 мин, а пространственное — 2 км. Проведённая валидация показала, что по точности предложенный алгоритм не уступает аналогам, обеспечивая при этом более высокое временное разрешение. Модель способна формировать прогнозные изображения на трёхчасовом горизонте с ошибкой RMSE (англ. Root Mean Squared Error), не превышающей 12 К, и коэффициентом корреляции не ниже 0,84.

Ключевые слова: наукастинг, облачность, нейронная сеть, Himawari, HybridCloudCast

Одобрена к печати: 29.09.2025
DOI: 10.21046/2070-7401-2025-22-6-52-65

Введение

Наукастинг, представляющий собой краткосрочный прогноз метеорологических процессов на временных горизонтах от нескольких минут до нескольких часов, является важным направлением современной прикладной метеорологии. В контексте анализа атмосферной конвекции он направлен на оперативную оценку эволюции облачности с высоким пространственно-временным разрешением.

Малые конвективные ячейки и мезомасштабные конвективные системы, возникающие вследствие нестационарных термодинамических процессов в тропосфере, часто приводят к опасным гидрометеорологическим явлениям — ливням, порывистому ветру и турбулентности, особенно опасным для авиации (Chen H. et al., 2024; Guo et al., 2022). Поэтому наукастинг движения облачности играет важную роль в раннем обнаружении зон развития конвекции и оценке вероятности развития опасных атмосферных явлений.

В спутниковой метеорологии такой вид краткосрочного прогноза основывается на последовательном анализе изображений, получаемых, в основном, с геостационарных метеорологических космических аппаратов (КА). Такие КА обеспечивают высокую частоту съёмки в видимом и инфракрасном (ИК) диапазонах, что делает их незаменимыми в регионах с ограниченной наземной сетью наблюдений, а также акваторий морей и океанов.

Дальневосточный регион Российской Федерации относится к числу территорий с недостаточной плотностью радиолокационных и наземных пунктов наблюдений, что делает разработку и применение технологий наукастинга по спутниковым данным особенно актуальными. Такие методы имеют большое значение для решения ряда прикладных задач: от обеспечения авиационной безопасности до оптимизации работы солнечных электростанций и управления рисками, связанными с опасными явлениями погоды.

Цель настоящей работы — разработка алгоритма наукастинга движения облачности в Азиатско-Тихоокеанском регионе на основе спутниковой информации в инфракрасном диапазоне электромагнитного спектра. Алгоритм основан на применении нейросетевого подхода и ориентирован на формирование не только точного прогноза, приближенного к реальным спутниковым данным, но и корректных изображений, учитывающих физические принципы динамики облачности в атмосфере.

Текущее состояние исследований

На современном этапе развития методов и алгоритмов дистанционного зондирования Земли и краткосрочного прогнозирования атмосферных процессов выделяют две основные группы подходов к наукастингу движения облачности по спутниковым данным. В первую группу входят традиционные методы, к которым относятся алгоритмы оптического потока и их модификации (Baker, Matthews, 2004; Wood-Bradley et al., 2012; Zhuk et al., 2017). Они позволяют эффективно отслеживать перемещение облаков, но сталкиваются с трудностями при воспроизведении изменений их структуры из-за гипотезы о постоянстве яркости. Также к этой группе принадлежит вероятностный подход STEPS (англ. Short-Term Ensemble Prediction System), позволяющий оценивать неопределенность прогноза, но склонный к сглаживанию мелкомасштабных деталей из-за использования стохастических возмущений (Smith et al., 2024).

Вторая группа включает нейросетевые методы, позволяющие моделировать сложные нелинейные зависимости в спутниковых наблюдениях без явной параметризации физических процессов (Prudden et al., 2020). Такие методы автоматически выявляют скрытые шаблоны в многомерных данных, за счёт чего обеспечивают более детализированное описание эволюции облачности, особенно в условиях активной конвекции. Нейросетевые архитектуры можно разделить на детерминированные и статистические. Первые из них формируют однозначное прогнозное поле, а вторые позволяют учитывать неопределенность и создают прогноз исходя из вероятностного распределения возможных состояний атмосферных процессов.

Одними из первых архитектур искусственных нейронных сетей (ИНС), используемых для решения задач наукастинга, стали свёрточные рекуррентные модели, относящиеся к классу детерминированных. К ним относится модель ConvLSTM, показавшая хорошие результаты в прогнозировании осадков с горизонтом прогноза до двух часов (Shi et al., 2015). Дальнейшее развитие получили архитектуры на специализированных ячейках памяти, например, PredRNN2 (Wang Y. et al., 2023), но они имеют ограничения в виде затухания градиентов и потери контекста при увеличении длины входной последовательности. Для преодоления этих ограничений применяют трансформерные архитектуры, использующие механизм самовнимания. В качестве примера подобных моделей можно привести модель DaYu (Wei et al., 2024), позволившую продлить заблаговременность прогноза, но при этом имевшую чрезмерное сглаживание выходных полей к концу трёхчасового интервала прогноза.

В общем виде детерминированные модели обеспечивают устойчивый прогноз направления и скорости движения облачности, но ограничены по времени из-за накопления ошибок и потери деталей (Кучма и др., 2023; Ehsani et al., 2022; Tran, Song, 2019). С другой стороны, статистические модели, такие как генеративно-состязательные нейронные сети (англ. Generative Adversarial Networks — GAN), формируют более реалистичные прогнозные поля. Примерами успешных решений являются модели TS-RainGAN (Wang R. et al., 2023)

и NowcastNet (Zhang et al., 2023), продемонстрировавшие высокое качество прогноза осадков по радиолокационным данным. Однако и GAN-сети имеют минусы, к которым можно отнести проблему вариативности результатов прогноза, нестабильность обучения и наличие артефактов на изображениях (Wen et al., 2025).

Одним из перспективных направлений статистических методов, способным частично преодолеть ограничения GAN-сетей, являются диффузионные ИНС. Эти модели основаны на принципе последовательного добавления и удаления шума в процессе обучения, что позволяет формировать прогнозные поля с высокой детализацией и физически обоснованной структурой. Примером успешного применения в задачах краткосрочного прогнозирования стала модель LDCast (Leinonen et al., 2023), предназначенная для научастинга осадков по радиолокационным данным, а также модель SATcast (Chen et al., 2025), разработанная для научастинга движения облачности по спутниковым данным. В последнем примере дополнительно использовались прогностические данные из модели FuXi (Chen L. et al., 2024), что позволило значительно продлить заблаговременность прогноза движения конвективной облачности до 24 ч. Однако такие модели требуют существенных вычислительных ресурсов и тщательной настройки гиперпараметров (Chen, 2023). Тем не менее при корректной реализации они способны обеспечить хорошее качество прогноза, особенно в задачах, где важна физическая правдоподобность и воспроизведение мелкомасштабных деталей (Nai et al., 2024).

В рамках настоящей работы рассматривается разработанная авторами гибридная нейросетевая модель HybridCloudCast, архитектура которой основана на объединении детерминистического и статистического подходов, что позволяет использовать преимущества обоих направлений — устойчивость прогноза и его пространственную детализацию. Основная идея заключается в последовательной обработке информации: сначала формируется начальный прогноз с помощью детерминистической модели, который затем уточняется с использованием диффузионной ИНС (Gong et al., 2024). Такой гибридный подход направлен на компенсацию недостатков детерминированных моделей, которые, несмотря на высокую стабильность и воспроизводимость результатов, склонны к сглаживанию мелкомасштабных деталей из-за минимизации среднеквадратичных или корреляционных функций потерь.

Используемые данные

В работе рассматривается Азиатско-Тихоокеанский регион с областью интереса в диапазоне от 30 до 60° с.ш. и от 100 до 180° в.д., включая Восточный Китай, Дальний Восток России, Японское и Охотское моря. Указанный регион характеризуется сложной пространственно-временной изменчивостью атмосферных процессов, обусловленной взаимодействием муссонных течений и активной циклонической деятельностью.

В качестве источника информации был выбран инфракрасный канал с центральной длиной волны 11,2 мкм (канал № 14) многоспектрального сканера АНІ (*англ. Advanced Himawari Imager*), установленного на космических аппаратах серии Himawari. Этот КА обеспечивает непрерывное наблюдение за состоянием атмосферы и подстилающей поверхности с высокой частотой съёмки (каждые 10 мин) в 16 спектральных диапазонах, включая видимый, ближний инфракрасный и тепловой диапазоны. Выбранный канал относится к атмосферному окну прозрачности, в котором поглощение излучения водяным паром минимально. Это позволяет эффективно регистрировать тепловое излучение облаков и подстилающей поверхности, что делает его полезным для выявления и отслеживания конвективной облачности, имеющей преобладающее значение в задаче научастинга с точки зрения потенциального формирования опасных явлений погоды.

На вход нейросетевой модели подавались изображения со значениями яркостной температуры канала № 14, представленные матрицей 512×512 пикселей с пространственным разрешением 2 км на пиксель. Данные были организованы в виде последовательностей, каждая из которых состояла из 30 кадров. При этом первые 10 изображений последователь-

ности использовались в качестве входных данных, а следующие 20 кадров — в качестве целевой выходной последовательности, покрывающей временной горизонт в 200 мин. В качестве дополнительного входного канала для нейросетевой модели применялся безоблачный композит, под которым понимается оценка яркостной температуры подстилающей поверхности. Он формировался для каждого часового временного интервала в сутках (0, 1, 2, ..., 23 ч) на основе двухнедельной истории наблюдений.

Для обучения нейросетевой модели все значения яркостной температуры были нормализованы в диапазоне от 0 до 1 для улучшения сходимости обучения. Итоговая выборка, данные для которой были получены в период наблюдений с 2020 по 2024 г., составила 21 тыс. примеров последовательностей и безоблачных композитов. Выборка была случайным образом разделена на обучающий (80 %), валидационный (10 %) и тестовый (10 %) наборы.

Описание модели

Предлагаемая гибридная модель HybridCloudCast для научастинга движения облачности основана на объединении детерминистического и статистического подходов. В качестве базовой детерминистической модели используется модифицированная в настоящей работе версия генератора из GAN-архитектуры NowcastNet. Выбор этой модели обусловлен её высокими показателями точности в задачах научастинга осадков, особенно на начальных этапах прогноза, а также реализацией в ней физически обоснованного модуля, моделирующего принципы динамики атмосферы. Для дальнейшего улучшения пространственно-временной структуры прогноза и увеличения чёткости мелких деталей применяется метод статистической постобработки на основе диффузионной сети, предложенный в работе (Gong et al., 2024). Данный этап обеспечивает реконструкцию локальных градиентов и восстановление структуры облачных образований. Общая блок-схема нейросетевой модели приведена на рис. 1.

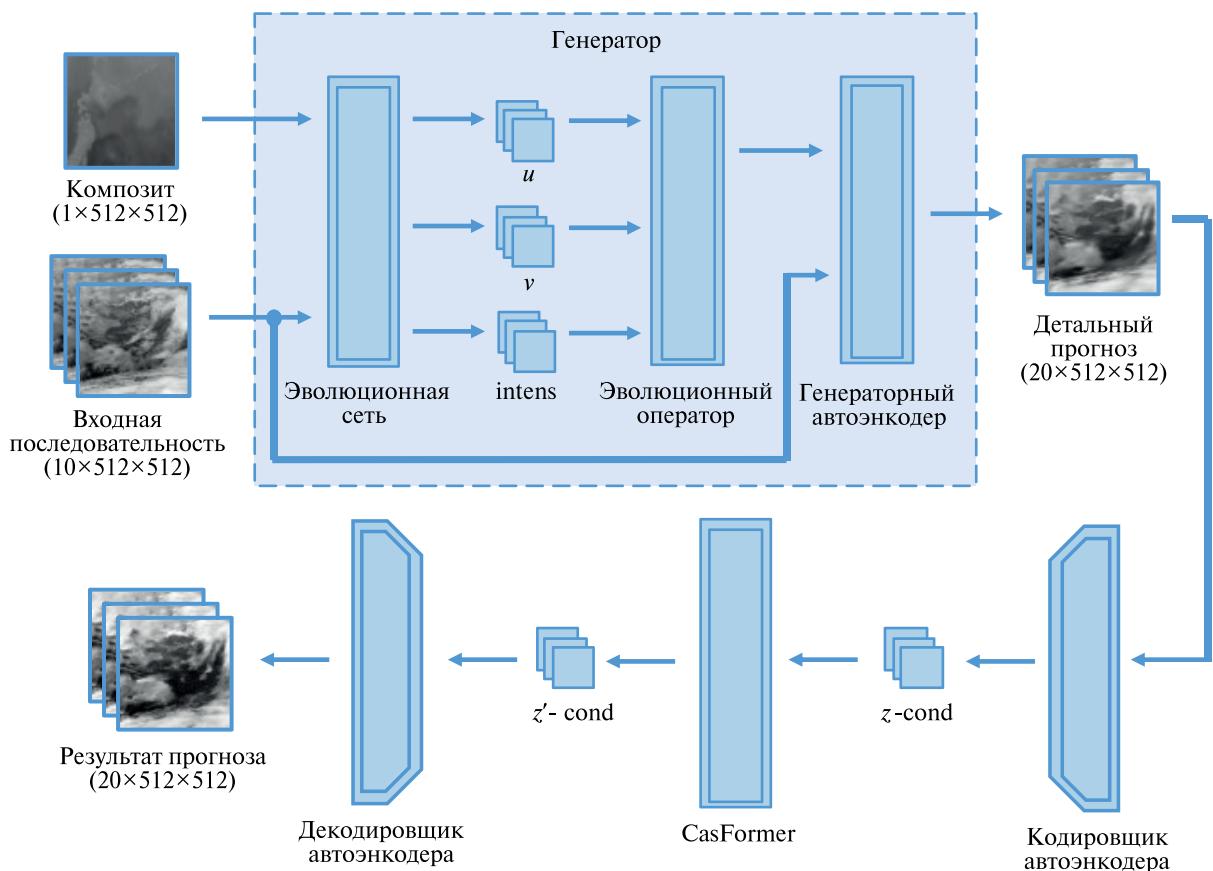


Рис. 1. Схема нейросетевой модели HybridCloudCast

Блок «Генератор» (далее G), представленный на *рис. 1*, является модифицированной версией генератора из архитектуры NowcastNet. Исходные изображения яркостной температуры, обозначенные на *рис. 1* как «Входная последовательность» (далее VP), поступают в подсеть «Эволюционная сеть» (далее EN), которая вместе с преобразователем «Эволюционный оператор» (далее EO) реализует принципы динамической эволюции полей яркостной температуры, основанные на законе сохранения непрерывности потока. На выходе EN формируются три карты признаков: u и v — компоненты горизонтального и вертикального смещения пикселей изображения, а также intens — карта изменений яркостной температуры. Эти параметры используются EO для построения предварительных прогнозных кадров. Процесс формирования происходит итерационно, начиная с последнего известного кадра из VP. Финальным этапом формирования детерминистического прогноза становится обработка объединённой информации из VP и промежуточных прогнозных кадров с помощью автоэнкодерной архитектуры, обозначенной на *рис. 1* как «Генераторный автоэнкодер». На выходе формируются окончательные кадры детерминистического прогноза, отмеченные на схеме как «Детальный прогноз».

Модификация генератора, заимствованного из архитектуры NowcastNet, заключалась в интеграции дополнительного модуля обработки, предназначенного для учёта информации о подстилающей поверхности на основе кадров безоблачного композита, обозначенных на *рис. 1* как «Композит». Она обусловлена необходимостью корректного моделирования процессов горизонтального перемещения облачных масс при возникновении участков с отсутствующей или частично рассеивающейся облачностью. Интегрированный в состав EN модуль обработки композита реализован в виде свёрточной сети на основе кодирующей части архитектуры U-Net. На *рис. 2* представлена полная схема модифицированной EN, включающая данный модуль, обозначенный как «Композитный модуль».

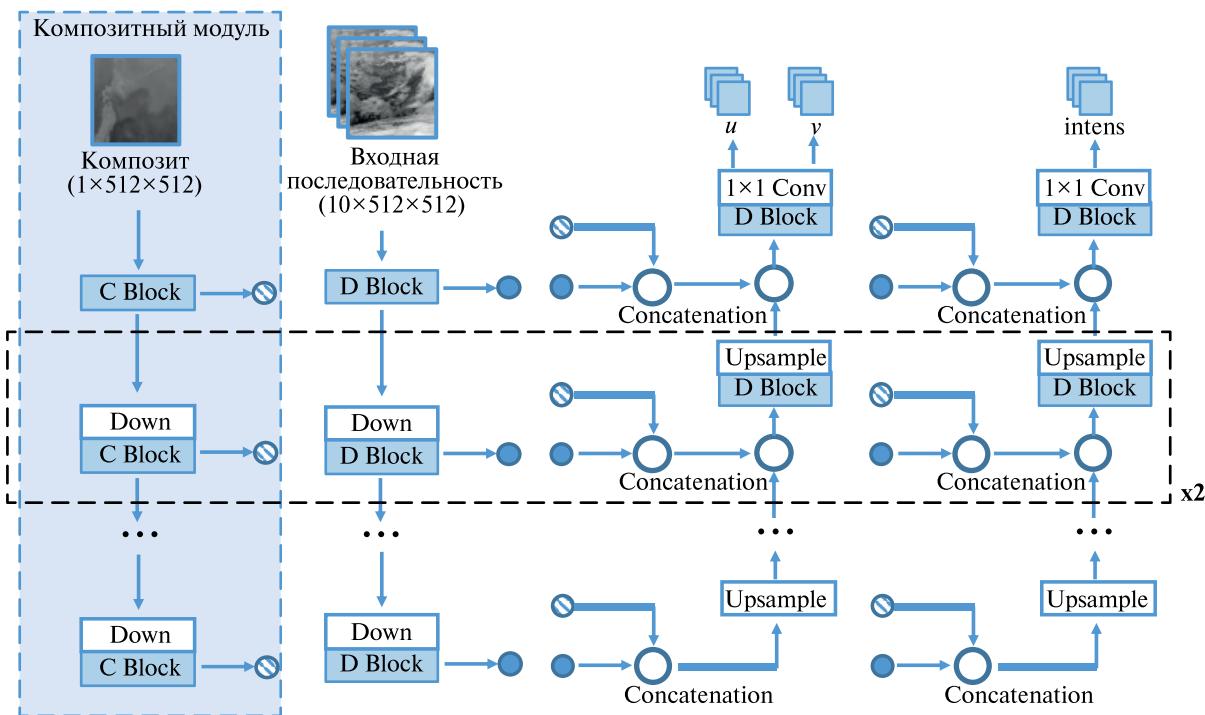


Рис. 2. Схема модифицированной EN

В его основе лежат блоки C Block. В отличие от оригинальных D Block, использованных в архитектуре NowcastNet, данные блоки не содержат параллельных ветвей обработки сигнала с последующим объединением, что делает их линейными по отношению к потоку информации. Тем не менее каждый C Block состоит из стандартных функциональных эле-

ментов: свёрточного слоя с ядром размером 3×3 (3×3 Conv), за которым следуют слой пакетной нормализации (англ. Batch Normalization — BN) и слой активации с функцией ReLU, полное описание и параметры которых приведены в работе (Zhang et al., 2023). Выходы каждого уровня этого модуля объединяются с соответствующими слоями EN, обеспечивая передачу информации о подстилающей поверхности в декодирующую часть сети.

Статистическая часть разработанной модели HybridCloudCast основана на объединении диффузионной сети с вариационным автоэнкодером VQGAN (англ. Vector Quantised Variational Autoencoder trained as GAN) (Gong et al., 2024). Одна из ключевых особенностей диффузионных моделей заключается в их вычислительной сложности, связанной с необходимостью многократного шумоподавления для формирования выходного кадра. Для снижения этой нагрузки используется автоэнкодер типа VQGAN, преобразующий данные в компактное скрытое пространство с минимальными потерями информации. Он состоит из кодировщика и декодировщика, обозначенных на рис. 1 как «Кодировщик автоэнкодера» (далее E) и «Декодировщик автоэнкодера» (далее D) соответственно. Кодировщик преобразует входные кадры яркостной температуры в дискретное скрытое представление, а декодировщик восстанавливает изображение после обработки в скрытом пространстве.

В качестве диффузионной ИНС в настоящей работе используется модель CasFormer (Gong et al., 2024), основанная на архитектуре DiT (англ. Diffusion Transformer) — трансформера с диффузионным механизмом (Peebles, Xie, 2023). Эта модель представляет собой нейронную сеть, ориентированную на восстановление структуры многомерных пространственных полей из зашумлённого представления. Диффузионная ИНС обучена определять (генерировать) шум, который на этапе обратного процесса итеративно вычитается из зашумлённого изображения. Каждый шаг обратного процесса формирует более устойчивое и детализированное представление выходного поля, что позволяет получать прогнозы с физически корректной структурой и сохранением мелкомасштабных деталей.

Обработка прогноза в рамках статистического подхода реализуется в несколько этапов. На первом этапе выходные кадры детерминистического прогноза с использованием E преобразуются в компактное скрытое представление, обозначенное на рис. 1 как z-cond. Далее модель CasFormer обрабатывает это представление и генерирует его стохастически изменённый аналог, отмеченный на рис. 1 как z'-cond. На завершающем этапе скорректированное скрытое представление с помощью D преобразуется обратно в пиксельное пространство, формируя окончательные прогнозные кадры, обозначенные на рис. 1 как «Результат прогноза».

Обучение нейросетевой модели

Обучение разработанной нейросетевой модели HybridCloudCast проводилось в два этапа. На первом этапе осуществлялась настройка детерминистической части, формирующей предварительный прогноз динамики облачных структур. Подход к обучению данной части архитектуры был взят из работы (Zhang et al., 2023), реализующей GAN-архитектуру NowcastNet, и адаптирован с учётом особенностей используемых данных. На первом шаге обучалась только модифицированная EN с использованием алгоритма оптимизации Adam (Kingma, Ba, 2017). В отличие от оригинальной задачи прогнозирования осадков в настоящей работе применялась комбинированная функция потерь, включающая две метрики: среднеквадратическая ошибка (англ. Mean Squared Error — MSE) и индекс структурного сходства (англ. Structural Similarity Index — SSIM), что позволило учитывать как точность воспроизведения яркостной температуры, так и пространственную структуру облаков:

$$L_{\text{det}} = \alpha \cdot \text{MSE}(I, I_{\text{evo}}) + \beta (1 - \text{SSIM}(I, I_{\text{evo}})),$$

где I — реальные значения яркостной температуры из обучающей выборки; I_{evo} — значения, полученные на выходе EO; α и β — весовые коэффициенты (10 и 5 соответственно), балансирующие вклад каждой составляющей.

Следующим шагом обучения модели HybridCloudCast стало дообучение полной детерминистической модели G. На данном этапе весовые коэффициенты EN оставались «замороженными», что позволило сохранить устойчивое представление динамики облачности, полученное на предыдущем этапе. Целевой функцией потерь была ранее определённая функция L_{dep} , но в отличие от первого шага, где в качестве предсказанного значения использовался выход EO, здесь I_{evo} представлял собой результат, сгенерированный уже после прохождения через автоэнкодерную часть. Сам процесс обучения проводился аналогично предыдущему шагу.

На втором этапе осуществлялось обучение статистической части архитектуры. Этот процесс включал в себя несколько шагов. На первом шаге проводилась предварительная настройка автоэнкодерного модуля, состоящего из E и D. Процесс заключался в минимизации расхождения между исходными изображениями яркостной температуры и их реконструкцией, полученной после прохождения через автоэнкодер (Gong et al., 2024).

Вторым шагом стало обучение диффузионной сети CasFormer, отвечающей за вероятностное уточнение прогноза. Оно проводилось с использованием оптимизатора AdamW и целевой функции потерь на основе MSE (Gong et al., 2024):

$$L_{dif} = \text{MSE}(\varepsilon, \varepsilon_{dif}),$$

где ε — истинное скрытое представление изображения яркостной температуры из обучающей выборки, полученное с помощью E; ε_{dif} — восстановленное скрытое представление после процедуры вычитания шумовых составляющих, сгенерированных нейронной сетью.

Для формирования обучающей выборки, используемой при обучении диффузионной ИНС, был задействован предварительно обученный E. С его помощью были получены скрытые представления как для реальных кадров из обучающей выборки, так и для прогнозных кадров, сгенерированных моделью G.

Для реализации процесса обучения всех рассмотренных частей модели HybridCloudCast использовался вычислительный комплекс на базе четырёх графических ускорителей NVIDIA A5000 24 ГБ. Распределение вычислений между устройствами осуществлялось с учётом вычислительной сложности и объёма каждой из моделей.

Обсуждение результатов

Для оценки качества работы разработанной модели HybridCloudCast использовались метрики, рассчитанные на основе тестовой выборки, данные которой не участвовали в процессе обучения и настройки параметров нейросетевых моделей. В качестве основных показателей точности восстановления пиксельных значений были выбраны корень среднеквадратической ошибки RMSE (англ. Root Mean Squared Error) и коэффициент корреляции Пирсона PCC (англ. Pearson Correlation Coefficient). Эти метрики позволяют оценить степень соответствия предсказанных и истинных значений в пикселе, акцентируясь на точности воспроизведения моделью радиометрической информации. Для анализа структурного и текстурного соответствия использовались метрики пикового отношения сигнал/шум PSNR (англ. Peak Signal-to-Noise Ratio) и SSIM. Метрика PSNR широко применяется в задачах оценки качества изображений, но при этом базируется исключительно на среднеквадратической ошибке и не учитывает особенности восприятия визуальной информации человеком, что может приводить к противоречивым оценкам. Например, размытые изображения с низкой текстурной вариативностью могут демонстрировать высокие значения PSNR, несмотря на потерю детализации. Метрика SSIM учитывает три аспекта восприятия (яркость, контраст и структуру) и более адекватно отражает визуальное сходство. Однако этот индекс чувствителен к пространственным сдвигам и локальным деформациям, что немногого ограничивает его применимость в задачах с нестационарной динамикой облаков. Учитывая ограничения традиционных пиксельных и структурных метрик, которые усредняют информацию по всему полю изображения и могут не отражать локальные особенности пространственного распределения облач-

ности, в качестве дополнительного критерия был использован FID (англ. Frechet Inception Distance) (Heusel et al., 2018). Эта метрика оценивает расстояние между многомерными распределениями реальных и сгенерированных изображений в пространстве признаков, извлечённых с помощью предобученной сети Inception-v3. Критерий FID позволяет частично компенсировать указанные недостатки, так как оценивает информацию как о локальной текстуре и чёткости изображений, так и об их статистической достоверности, что даёт более комплексную оценку, сочетающую точность восстановления интенсивности и качество изображения. В практическом применении значения метрики FID в диапазоне от 0 до 5 можно рассматривать как почти идеальное соответствие; от 5 до 20 — как хорошее, с едва заметными искажениями; от 20 до 50 — как удовлетворительное, с явно выраженным искажениями и шумами; а свыше 50 — как неудовлетворительное, характеризующееся сильными артефактами и размытостью.

Оценка качества прогнозирующей способности модели HybridCloudCast проводилась с учётом её иерархической структуры и охватывала три ключевых этапа формирования краткосрочного прогноза. Первый этап — прогноз, полученный с помощью EN в сочетании с EO. Второй этап — результат, сформированный моделью G. Третий этап — прогноз после статистической обработки. Полученные результаты оценки представлены в таблице, в которой приведены усреднённые значения метрик по всем прогнозируемым кадрам. Дополнительно на рис. 3 отображено изменение значений метрик в зависимости от временного горизонта прогноза.

Рассчитанные метрики по данным тестовой выборки

Этап	RMSE, K	PCC	SSIM	PSNR	FID
EN+EO	6,81	0,89	0,72	26,76	108,05
Генератор	6,07	0,92	0,77	28,06	66,73
HybridCloudCast	10,54	0,87	0,66	23,01	19,78

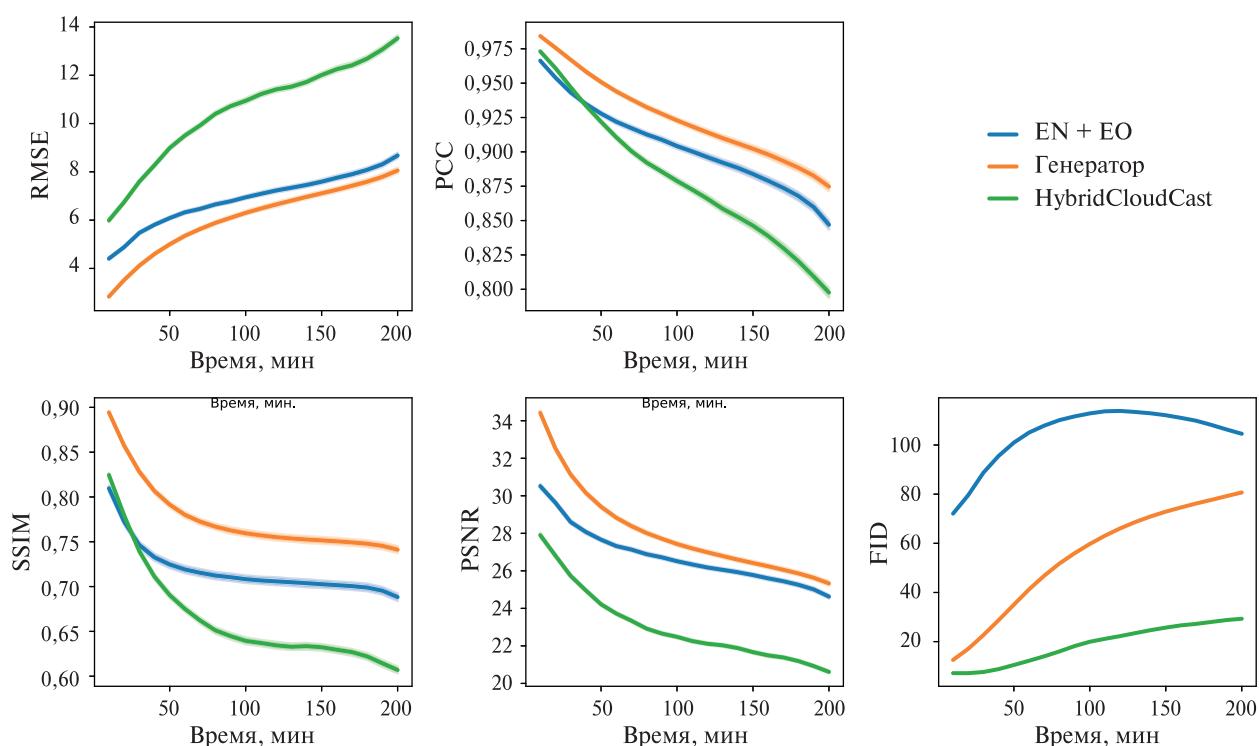
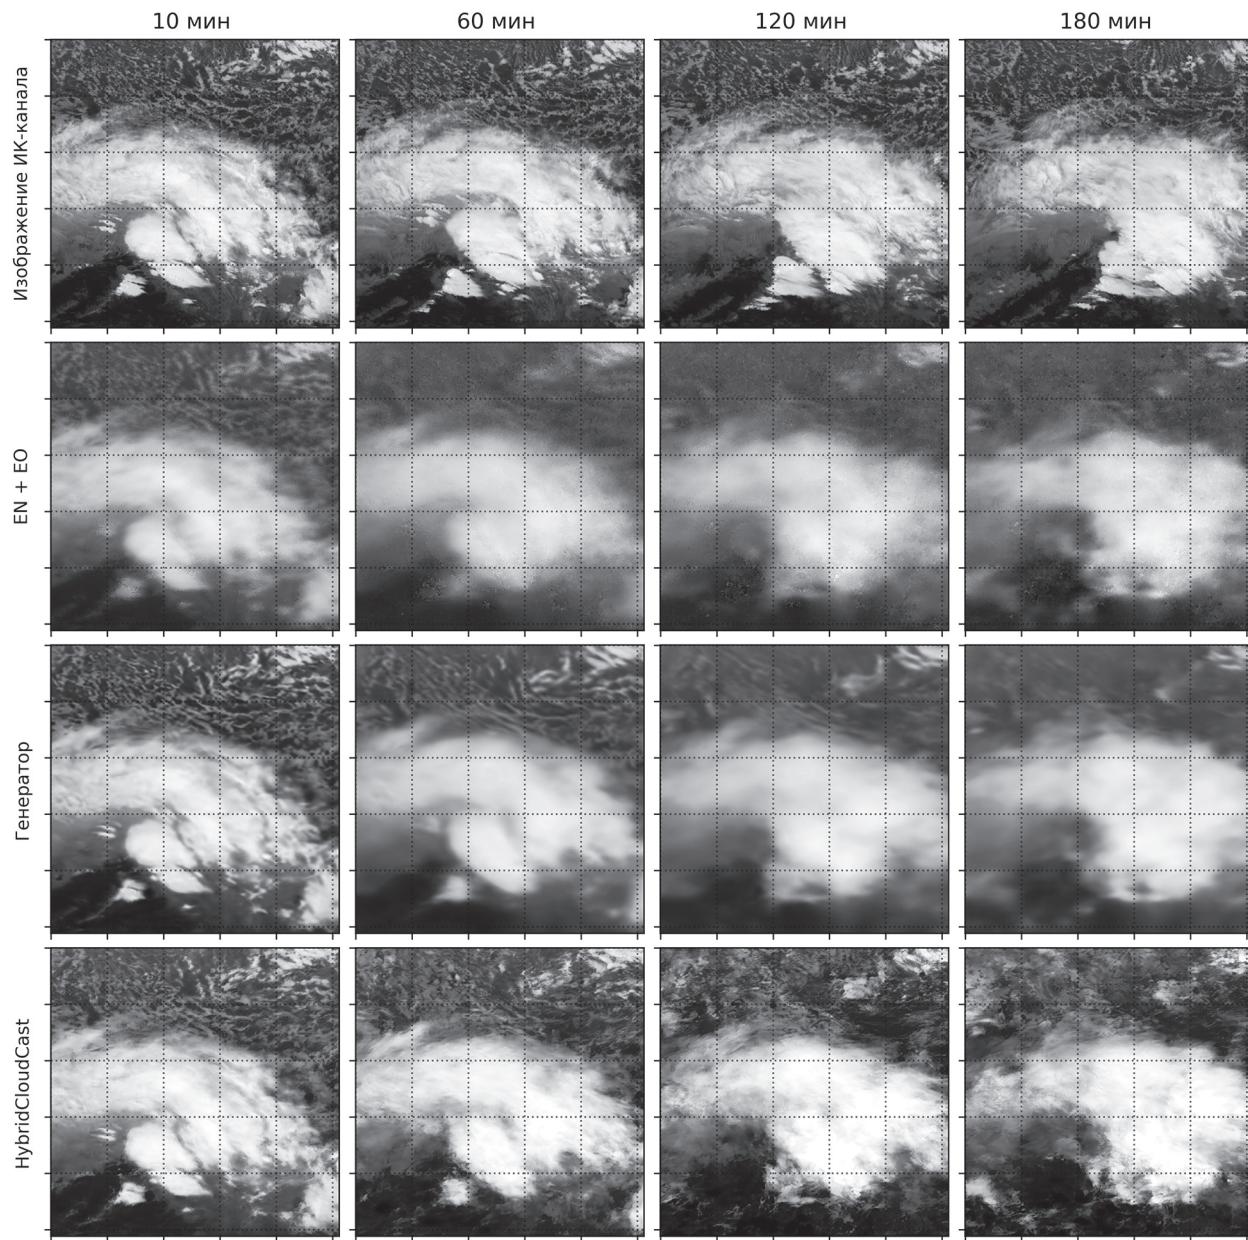


Рис. 3. Метрики качества краткосрочного прогноза по времени

Проведённый анализ результатов позволил выявить определённые особенности поведения метрик и визуального качества прогнозных полей на разных этапах обработки. По количественным оценкам наиболее высокие значения метрик точности (RMSE и PCC) демонстрирует детерминистическая часть модели, что говорит о её способности обеспечивать устойчивое и воспроизводимое приближение к реальным наблюдениям. Вместе с тем анализ по метрике FID показывает, что в целом модель HybridCloudCast обеспечивает формирование визуально реалистичных изображений, наиболее приближенных к оригинальным, при сохранении сопоставимой точности восстановления значений яркостной температуры в пикселях.



Rис. 4. Пример прогноза движения облачности для различных этапов обработки

Визуальный анализ прогнозных кадров на различных этапах обработки, пример которых представлен на *рис. 4*, показал, что выход детерминистической модели склонен к сглаживанию мелкомасштабных деталей. Это связано с характером используемых функций потерь,

ориентированных на минимизацию глобальных ошибок. В то же время применение статистической обработки позволило частично восстановить чёткость границ и пространственную детализацию, улучшив физическую корректность прогнозных изображений. Несмотря на возможное снижение численных метрик из-за увеличения локальной вариабельности такой подход обеспечивает более реалистичное представление облачности, что подтверждает целесообразность применения гибридного подхода.

Следует отметить, что в редких случаях статистическая постобработка может генерировать ложные облачные структуры, т.е. участки с повышенной яркостной температурой, отсутствующие в детерминистическом прогнозе или слабо выраженные относительно подстилающей поверхности. Такие артефакты несистемны и наблюдаются на локальных участках площадью не более 50 пикселей. Возникновение подобных ошибок связано с тем, что модель стремится к оптимальному восстановлению всей последовательности в целом, а не к точному воспроизведению каждого кадра. Это позволяет улучшить структурную согласованность и визуальное качество прогноза, но при этом может приводить к локальным отклонениям. Кроме того, статистическая постобработка увеличивает контраст изображений, что улучшает интерпретируемость облачности, но может вносить искажения в яркостную температуру, завышая её интенсивность. Таким образом, для минимизации локальных артефактов и сохранения физической корректности прогноза необходимы дальнейшие исследования используемой функции потерь.

В дополнение к визуальному анализу и оценке по тестовой выборке было проведено сравнение с существующими решениями по ключевым метрикам в конце трёхчасового прогноза. В качестве первой модели для сравнения была выбрана SATcast, основанная на диффузионном (статистическом) подходе. Она достигает значений RMSE около 10 К, а РСС 0,86. У предложенной модели HybridCloudCast соответствующие показатели составляют 12 К и 0,84. Данное различие в точности может быть связано с тем, что SATcast дополнительно использует данные численных моделей погоды в качестве входной информации, в то время как HybridCloudCast формирует прогноз только на основе последовательности спутниковых изображений яркостной температуры. Второй моделью сравнения стала DaYu, основанная на трансформерной архитектуре. Поскольку она является полностью детерминированной, её результаты целесообразно сопоставлять с детерминистической частью HybridCloudCast (модель G). Разработчики DaYu в своей работе указывают RMSE около 9 К и РСС 0,91, тогда как для модели G эти показатели составляют 7 К и 0,89 соответственно, что свидетельствует о более высокой точности приближения значений яркостной температуры к реальным наблюдениям. Таким образом, различия по метрикам укладываются в пределы статистической погрешности, что подтверждает сопоставимую способность моделей отслеживать пространственно-временную динамику облачности. При этом HybridCloudCast обеспечивает формирование прогнозных изображений, приближенных к реальным, используя в качестве исходных данных только последовательности изображений яркостной температуры спутникового прибора.

Стоит также отметить, что важным преимуществом разработанной модели является её временная дискретизация: прогноз формируется с шагом в 10 мин, тогда как у большинства аналогов этот интервал составляет один час. Такое высокое временное разрешение даёт дополнительные возможности для оперативного анализа метеорологических процессов, особенно в условиях быстро меняющейся конвекции.

Ещё одно важное достоинство HybridCloudCast — способность достаточно точно воспроизводить эволюцию малых конвективных ячеек, пример которых приведён на *рис. 5* (см. с. 62). Такие образования представляют особый интерес с практической точки зрения, поскольку часто ассоциируются с возникновением локальных опасных погодных явлений. Анализ показал, что модель сохраняет адекватное описание таких конвективных процессов в течение первых двух часов прогноза. Далее наблюдается потеря интенсивности и усиление эффектов размытия облачных структур, что связано с накоплением ошибок в процессе экстраполяции и ограниченными способностями модели восстанавливать локальные нестационарные процессы на основе только спутниковых данных.

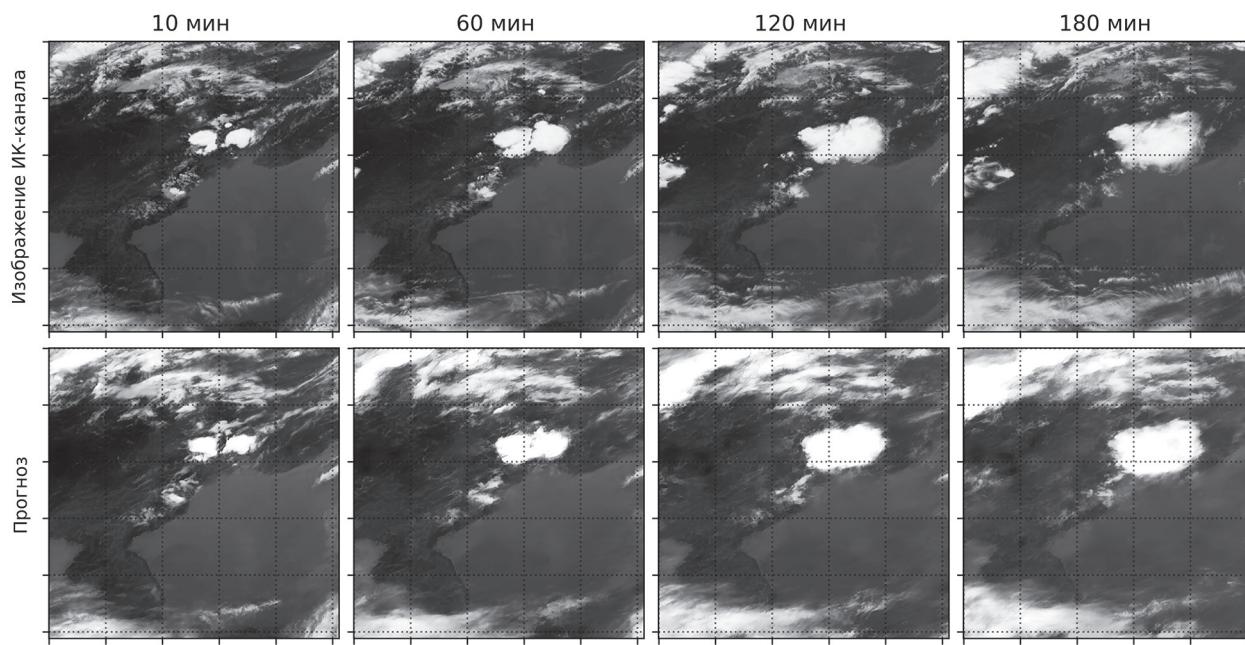


Рис. 5. Пример прогноза движения малых конвективных ячеек

Заключение

В работе представлены результаты исследования, в рамках которого была разработана гибридная нейросетевая модель HybridCloudCast для наукастинга движения облачности в Азиатско-Тихоокеанском регионе на основе данных инфракрасного канала № 14 (11,2 мкм) прибора AHI, установленного на геостационарные КА серии Himawari. Ключевой особенностью предложенного алгоритма является объединение детерминистического и статистического подходов: первый из них обеспечивает качественное предсказание динамики облачных систем за счёт применения физически обоснованной модели, тогда как второй, реализованный в виде диффузационной сети, позволяет восстанавливать мелкомасштабные детали и повышает визуальное качество прогнозных изображений. Использование безоблачного композита дополнительно улучшает точность прогноза за счёт учёта яркостных характеристик подстилающей поверхности, что особенно важно при частичном рассеивании облачности.

Проведённый анализ показал, что HybridCloudCast демонстрирует конкурентоспособные результаты по сравнению с аналогичными алгоритмами, обеспечивая при этом более высокое временное разрешение. Модель способна формировать прогнозы с RMSE, не превышающей 12 К, и коэффициентом корреляции не ниже 0,84. При этом было установлено, что максимальная заблаговременность достаточно точно описания мелкомасштабных конвективных процессов в среднем ограничена двумя часами, после чего наблюдается потеря контраста и детализации. Тем не менее, несмотря на необходимость дальнейшей оптимизации отдельных частей нейросетевой модели, разработанный алгоритм может быть использован в оперативной метеорологии для анализа быстро меняющихся атмосферных процессов, особенно в условиях активной конвекции и ограниченной наземной инфраструктуры наблюдений.

Разработанная нейросетевая модель HybridCloudCast предназначена для наукастинга движения облачности на основе спутниковых данных, поступающих с геостационарных КА серии Himawari. Однако она потенциально может быть адаптирована для работы с данными других метеорологических спутников, включая российские КА серии «Электро-Л» и «Арктика-М», оснащённые многоспектральными сканерами МСУ-ГС (Многозональное сканирующее устройство гидрометеорологического обеспечения). Для этого требуется формирование новых обучающих выборок, учитывающих специфику измерений МСУ-ГС.

Исследование выполнено за счёт 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»).

Литература

1. Кучма М. О., Мальковский С. И., Андреев А. И., Блощинский В.Д. Нейросетевые методы научакстинга 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.
2. Baker S., Matthews I. Lucas–Kanade 20 years on: A unifying framework // Intern. J. Computer Vision. 2004. V. 56. P. 221–255. DOI: 10.1023/B:VISI.0000011205.11775.fd.
3. Chen T. On the importance of noise scheduling for diffusion models // <https://arxiv.org/>. arXiv:2301.10972. 2023. 12 p. DOI: 10.48550/arXiv.2301.10972.
4. Chen H., Shi X., Nie X. et al. Tropical aviation turbulence induced by the interaction between a jet stream and deep convection // J. Geophysical Research: Atmospheres. 2024. V. 129. Iss. 18. Article e2024JD04076. DOI: 10.1029/2024JD040763.
5. Chen H., Zhong X., Zhai Q. et al. Skillful nowcasting of convective clouds with a cascade diffusion model // <https://arxiv.org/>. arXiv:2502.10957. 2025. 15 p. DOI: 10.48550/arXiv.2502.10957.
6. Chen L., Zhong X., Li H. et al. A machine learning model that outperforms conventional global subseasonal forecast models // Nature Communications. 2024. V. 15. Article 6425. DOI: 10.1038/s41467-024-50714-1.
7. Ehsani M. R., Zarei A., Gupta H. V. et al. NowCasting-nets: Representation learning to mitigate latency gap of satellite precipitation products using convolutional and recurrent neural networks // IEEE Trans. Geoscience and Remote Sensing. 2022. V. 60. Article 4706021. 21 p. DOI: 10.1109/TGRS.2022.3158888.
8. 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 // Proc. 41st Intern. Conf. on Machine Learning. 2024. Article 633. P. 15809–15822.
9. Guo Y., Zhong M., Chen X. et al. A thunderstorm gale forecast method based on the objective classification and continuous probability // Atmosphere. 2022. V. 13. No. 8. Article 1308. DOI: 10.3390/atmos13081308.
10. Heusel M., Ramsauer H., Unterthiner T. et al. GANs trained by a two time-scale update rule converge to a local Nash equilibrium // <https://arxiv.org/>. arXiv:1706.08500. 2018. 38 p. DOI: 10.48550/arXiv.1706.08500.
11. Kingma D. P., Ba J. L. Adam: A method for stochastic optimization // <https://arxiv.org/>. arXiv:1412.6980v9. 2017. 15 p. DOI: 10.48550/arXiv.1412.6980.
12. Leinonen J., Hamann U., Nerini D. et al. Latent diffusion models for generative precipitation nowcasting with accurate uncertainty quantification // <https://arxiv.org/>. arXiv:2304.12891. 2023. 18 p. DOI: 10.48550/arXiv.2304.12891.
13. Nai C., Pan B., Chen X. et al. Reliable precipitation nowcasting using probabilistic diffusion models // Environmental Research Letters. 2024. V. 19. No. 3. Article 034039. DOI: 10.1088/1748-9326/ad2891.
14. Peebles W., Xie S. Scalable diffusion models with transformers // IEEE/CVF Intern. Conf. on Computer Vision (ICCV). Paris, France, 2023. P. 4172–4182. DOI: 10.1109/ICCV51070.2023.00387.
15. Prudden R., Adams S., Kangin D. et al. A review of radar-based nowcasting of precipitation and applicable machine learning techniques // <https://arxiv.org/>. arXiv:2005.04988. 2020. 17 p. DOI: 10.48550/arXiv.2005.04988.
16. Shi X., Chen Z., Wang H., Yeung D., Wong W., Woo W. Convolutional LSTM Network: A machine learning approach for precipitation nowcasting // Proc. 29th Intern. Conf. on Neural Information Processing Systems. 2015. V. 1. P. 802–810.
17. Smith J., Birch C., Marsham J. et al. Evaluating pySTEPS optical flow algorithms for convection nowcasting over the Maritime Continent using satellite data // Natural Hazards and Earth System Sciences. 2024. V. 24. P. 567–582. DOI: 10.5194/nhess-24-567-2024.
18. Tran Q.-K., Song S.-k. Computer vision in precipitation nowcasting: Applying image quality assessment metrics for training deep neural networks // Atmosphere. 2019. V. 10. No. 5. Article 244. DOI: 10.3390/atmos10050244.
19. Wang R., Su L., Wong W. K. et al. Skillful radar-based heavy rainfall nowcasting using task-segmented generative adversarial network // IEEE Trans. Geoscience and Remote Sensing. 2023. V. 61. Article 4103613. 13 p. DOI: 10.1109/TGRS.2023.3295211.

20. Wang Y., Wu H., Zhang J. et al. PredRNN: A Recurrent Neural Network for Spatiotemporal Predictive Learning // IEEE Trans. Pattern Analysis and Machine Intelligence. 2023. V. 45. No. 2. P. 2208–2225. DOI: 10.1109/TPAMI.2022.3165153.
21. Wei X., Zhang F., Zhang R. et al. DaYu: Data-driven model for geostationary satellite observed cloud images forecasting // <https://arxiv.org/>. arXiv:2411.10144. 2024. 12 p. DOI: 10.48550/arXiv.2411.10144.
22. Wen P., He M., Filippi P. et al. DuoCast: Duo-probabilistic diffusion for precipitation nowcasting // <https://arxiv.org/>. arXiv:2412.01091. 2025. 9 p. DOI: 10.48550/arXiv.2412.01091.
23. Wood-Bradley P., Zapata J., Pye J. Cloud tracking with optical flow for short-term solar forecasting // Proc. 50th Annual AuSES Conf. (Solar 2012). Australian Solar Energy Soc., 2012. 6 p.
24. Zhang Y., Long M., Chen K. et al. Skilful nowcasting of extreme precipitation with NowcastNet // Nature. 2023. V. 619. P. 526–532. DOI: 10.1038/s41586-023-06184-4.
25. Zhuk S., Tchrakian T., Akhriev A. et al. Where computer vision can aid physics: dynamic cloud motion forecasting from satellite images // <https://arxiv.org/>. arXiv:1710.00194. 2017. 17 p. DOI: 10.48550/arXiv.1710.00194.

Nowcasting of cloud motion based on Himawari-8/9 satellite data using the HybridCloudCast hybrid neural network model

V. D. Bleshchinskiy^{1,2}, S. I. Malkovsky¹, L. S. Kramareva^{1,2},
A. V. Boroditskaya^{1,2}, S. P. Korolev¹

¹ Computing Center FEB RAS, Khabarovsk 680000, Russia
E-mail: sergey.malkovsky@ccfebras.ru

² Far Eastern Center of SRC “Planeta”, Khabarovsk 680000, Russia
E-mail: v.bleshchinsky@dvrccpdr.ru

The paper presents an algorithm for nowcasting cloud motion in the Asia-Pacific region using infrared satellite imagery from the geostationary Himawari-8/9 satellites. The algorithm is based on the HybridCloudCast hybrid neural network model, developed by the authors, which combines the advantages of deterministic and statistical approaches in short-term forecasting. The deterministic component ensures accurate prediction of cloud evolution through the use of a physically grounded model, while the statistical component, implemented via a diffusion neural network, enhances the detail and visual quality of forecasted images. HybridCloudCast uses input images containing brightness temperature values from channel 14 of the AHI instrument. In addition to satellite imagery, the neural network model incorporates a cloud-free composite to improve forecast accuracy by accounting for the brightness characteristics of the underlying surface. The developed HybridCloudCast model generates short-term forecasts with a temporal resolution of 10 minutes and a spatial resolution of 2 km. Validation results show that the proposed algorithm is comparable in accuracy to existing methods, while offering higher temporal resolution. The model is capable of producing forecast images over a three-hour forecast horizon with a Root Mean Squared Error (RMSE) not exceeding 12 K and a correlation coefficient of at least 0.84.

Keywords: nowcasting, cloudiness, neural network, Himawari, HybridCloudCast

Accepted: 29.09.2025
DOI: 10.21046/2070-7401-2025-22-6-52-65

References

1. Kuchma M. O., Malkovsky S. I., Andreev A. I., Bleshchinskiy V. D., Neural network approaches to precipitation nowcasting: A review and test of existing methods, *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2023, V. 20, No. 6, pp. 35–48, DOI: 10.21046/2070-7401-2023-20-6-35-48.
2. Baker S., Matthews I., Lucas–Kanade 20 years on: A unifying framework, *Intern. J. Computer Vision*, 2004, V. 56, pp. 221–255, DOI: 10.1023/B:VISI.0000011205.11775.fd.

3. Chen T., On the importance of noise scheduling for diffusion models, <https://arxiv.org/>, arXiv:2301.10972, 2023, 12 p., DOI: 10.48550/arXiv.2301.10972.
4. Chen H., Shi X., Nie X. et al., Tropical aviation turbulence induced by the interaction between a jet stream and deep convection, *J. Geophysical Research: Atmospheres*, 2024, V. 129, Iss. 18, Article e2024JD04076, DOI: 10.1029/2024JD040763.
5. Chen H., Zhong X., Zhai Q. et al., Skillful nowcasting of convective clouds with a cascade diffusion model, <https://arxiv.org/>, arXiv:2502.10957, 2025, 15 p., DOI: 10.48550/arXiv.2502.10957.
6. Chen L., Zhong X., Li H. et al., A machine learning model that outperforms conventional global subseasonal forecast models, *Nature Communications*, 2024, V. 15, Article 6425, DOI: 10.1038/s41467-024-50714-1.
7. Ehsani M. R., Zarei A., Gupta H. V. et al., NowCasting-nets: Representation learning to mitigate latency gap of satellite precipitation products using convolutional and recurrent neural networks, *IEEE Trans. Geoscience and Remote Sensing*, 2022, V. 60, Article 4706021, 21 p., DOI: 10.1109/TGRS.2022.3158888.
8. 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, *Proc. 41st Intern. Conf. on Machine Learning*, 2024, Article 633, pp. 15809–15822.
9. Guo Y., Zhong M., Chen X. et al., A thunderstorm gale forecast method based on the objective classification and continuous probability, *Atmosphere*, 2022, V. 13, No. 8, Article 1308, DOI: 10.3390/atmos13081308.
10. Heusel M., Ramsauer H., Unterthiner T. et al., GANs trained by a two time-scale update rule converge to a local Nash equilibrium, <https://arxiv.org/>, arXiv:1706.08500, 2018, 38 p., DOI: 10.48550/arXiv.1706.08500.
11. Kingma D. P., Ba J. L., Adam: A method for stochastic optimization, <https://arxiv.org/>, arXiv:1412.6980v9, 2017, 15 p., DOI: 10.48550/arXiv.1412.6980.
12. Leinonen J., Hamann U., Nerini D. et al., Latent diffusion models for generative precipitation nowcasting with accurate uncertainty quantification, <https://arxiv.org/>, arXiv:2304.12891, 2023, 18 p., DOI: 10.48550/arXiv.2304.12891.
13. Nai C., Pan B., Chen X. et al., Reliable precipitation nowcasting using probabilistic diffusion models, *Environmental Research Letters*, 2024, V. 19, No. 3, Article 034039, DOI: 10.1088/1748-9326/ad2891.
14. Peebles W., Xie S., Scalable diffusion models with transformers, *IEEE/CVF Intern. Conf. on Computer Vision (ICCV)*, Paris, France, 2023, pp. 4195–4205, DOI: 10.1109/ICCV51070.2023.00387.
15. Prudden R., Adams S., Kangin D. et al., A review of radar-based nowcasting of precipitation and applicable machine learning techniques, <https://arxiv.org/>, arXiv:2005.04988, 2020, 17 p., DOI: 10.48550/arXiv.2005.04988.
16. Shi X., Chen Z., Wang H., Yeung D., Wong W., Woo W., Convolutional LSTM Network: A machine learning approach for precipitation nowcasting, *Proc. 29th Intern. Conf. on Neural Information Processing Systems*, 2015, V. 1, pp. 802–810.
17. Smith J., Birch C., Marsham J. et al., Evaluating pySTEPS optical flow algorithms for convection nowcasting over the Maritime Continent using satellite data, *Natural Hazards and Earth System Sciences*, 2024, V. 24, pp. 567–582, DOI: 10.5194/nhess-24-567-2024.
18. Tran Q.-K., Song S.-k., Computer vision in precipitation nowcasting: Applying image quality assessment metrics for training deep neural networks, *Atmosphere*, 2019, V. 10, No. 5, Article 244, DOI: 10.3390/atmos10050244.
19. Wang R., Su L., Wong W.K. et al., Skillful radar-based heavy rainfall nowcasting using task-segmented generative adversarial network, *IEEE Trans. Geoscience and Remote Sensing*, 2023, V. 61, Article 4103613, 13 p., DOI: 10.1109/TGRS.2023.3295211.
20. Wang Y., Wu H., Zhang J. et al., PredRNN: A Recurrent Neural Network for Spatiotemporal Predictive Learning, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2023, V. 45, No. 2, pp. 2208–2225, DOI: 10.1109/TPAMI.2022.3165153.
21. Wei X., Zhang F., Zhang R. et al., DaYu: Data-driven model for geostationary satellite observed cloud images forecasting, <https://arxiv.org/>, arXiv:2411.10144, 2024, 12 p., DOI: 10.48550/arXiv.2411.10144.
22. Wen P., He M., Filippi P., DuoCast: Duo-probabilistic diffusion for precipitation nowcasting, <https://arxiv.org/>, arXiv:2412.01091, 2025, 9 p., DOI: 10.48550/arXiv.2412.01091.
23. Wood-Bradley P., Zapata J., Pye J., Cloud tracking with optical flow for short-term solar forecasting, *Proc. 50th Annual AuSES Conf. (Solar 2012)*, Australian Solar Energy Soc., 2012, 6 p.
24. Zhang Y., Long M., Chen K. et al., Skilful nowcasting of extreme precipitation with NowcastNet, *Nature*, 2023, V. 619, pp. 526–532, DOI: 10.1038/s41586-023-06184-4.
25. Zhuk S., Tchrakian T., Akhriev A. et al., Where computer vision can aid physics: dynamic cloud motion forecasting from satellite images, <https://arxiv.org/>, arXiv:1710.00194, 2017, 17 p., DOI: 10.48550/arXiv.1710.00194.