

## Обзор методов машинного обучения для автоматической идентификации и сопровождения конвективных ячеек по данным метеорадиолокации

В. А. Шаповалов<sup>1</sup>, А. А. Аджиева<sup>✉2</sup>, М. М. Ахматов<sup>2</sup>, А. Ж. Хитиева<sup>2</sup>

<sup>1</sup>Высокогорный геофизический институт  
360030, Россия, г. Нальчик, проспект Ленина, 2

<sup>2</sup>Кабардино-Балкарский государственный аграрный университет имени В. М. Кокова  
360030, Россия, г. Нальчик, проспект Ленина, 1в

**Аннотация.** Автоматическое выделение и сопровождение конвективных ячеек по радиолокационным данным – ключевая задача для краткосрочного прогноза опасных явлений погоды (наукастинга). Традиционные алгоритмы (пороговые и объект-ориентированные) широко применяются, но имеют ограничения по точности.

**Цель работы** – исследовать и сопоставить эффективность различных моделей машинного обучения в задаче обнаружения и отслеживания конвективных ячеек на изображениях радиолокационных обзоров.

**Результаты.** Проведен теоретический обзор современных подходов: классических алгоритмов (TITAN, SCIT), методов технического зрения (пороговая сегментация, кластеризация), а также методов машинного обучения – нечеткой логики, решающих деревьев, нейронных сетей (в т.ч. глубоких сверточных). Характеристики известных моделей машинного обучения сравнивались по показателям качества. Показано, что такие модели способны повысить вероятность обнаружения ячеек и снизить ложные срабатывания по сравнению с пороговыми методами.

**Выводы.** Алгоритмы на основе методов искусственного интеллекта превосходят традиционные по ряду метрик, позволяя более надежно идентифицировать опасные конвективные ячейки и прогнозировать их эволюцию. Практическое применение этих методов повысит точность наукастинга гроз и града, однако для их внедрения требуются правильно подготовленные большие обучающие выборки, учитывающие особенности локальных условий.

**Ключевые слова:** метеорологическая радиолокация, конвективные ячейки, обнаружение, сегментация, сопровождение, оптический поток, машинное обучение, глубокое обучение, нейронные сети, наукастинг, опасные явления погоды

Поступила 28.11.2025, одобрена после рецензирования 03.02.2026, принята к публикации 10.02.2026

**Для цитирования.** Шаповалов В. А., Аджиева А. А., Ахматов М. М., Хитиева А. Ж. Обзор методов машинного обучения для автоматической идентификации и сопровождения конвективных ячеек по данным метеорадиолокации // Известия Кабардино-Балкарского научного центра РАН. 2026. Т. 28. № 1. С. 90–101. DOI: 10.35330/1991-6639-2026-28-1-90-101

## Review on machine learning methods for convective cell identification and tracking using weather radar

V.A. Shapovalov<sup>1</sup>, A.A. Adzhieva<sup>✉2</sup>, M.M. Akhmatov<sup>2</sup>, A.Zh. Khitieva<sup>2</sup>

<sup>1</sup>High-Mountain Geophysical Institute  
2, Lenin avenue, Nalchik, 360004, Russia

<sup>2</sup>Kabardino-Balkarian State Agricultural University named after V.M. Kokov  
1v, Lenin avenue, Nalchik, 360030, Russia

**Abstract.** Automatic detection and tracking of convective cells using radar data is a crucial task for the nowcasting of severe weather events. Traditional algorithms, such as threshold-based and object-oriented methods, are widely employed but suffer from limitations in accuracy.

**Aim.** To investigate and compare the performance of various machine learning models in detecting and tracking convective cells in radar imagery.

**Results.** A theoretical review of state-of-the-art approaches was conducted, covering classical algorithms (TITAN, SCIT), computer vision methods (threshold segmentation, clustering), and machine learning techniques, including fuzzy logic, decision trees, and neural networks (specifically deep convolutional networks). The performance characteristics of established machine learning models were evaluated based on quality metrics. The results demonstrate that such models can increase the probability of detection and reduce false alarms compared to threshold-based methods.

**Conclusions.** AI-based algorithms outperform traditional approaches across several metrics, enabling more reliable identification of dangerous convective cells and forecasting of their evolution. The practical application of these methods will improve the accuracy of thunderstorm and hail nowcasting; however, their implementation requires large, properly prepared training datasets that account for specific local conditions.

**Keywords:** weather radar, convective cells, detection, segmentation, tracking, optical flow, machine learning, deep learning, neural networks, nowcasting, severe weather events

Submitted 28.11.2025,

approved after reviewing 03.02.2026,

accepted for publication 10.02.2026

**For citation.** Shapovalov V.A., Adzhieva A.A., Akhmatov M.M., Khitieva A.Zh. Review on machine learning methods for convective cell identification and tracking using weather radar. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2026. Vol. 28. No. 1. Pp. 90–101. DOI: 10.35330/1991-6639-2026-28-1-90-101

### ВВЕДЕНИЕ

В условиях климатических изменений, характеризующихся увеличением частоты и интенсивности экстремальных погодных явлений, задача точного и своевременного прогнозирования конвективных процессов, а также идентификации и сопровождения отдельных ячеек (конвективных облаков – потенциально ливневых, грозовых, градовых по данным радиолокации) приобретает критическое значение для обеспечения безопасности авиации, городской инфраструктуры, энергетики, транспорта и сельского хозяйства.

Конвективные облака, представляющие собой сложные термодинамические системы, являются источником целого спектра опасных метеорологических явлений (ОЯ): от катастрофических наводнений, вызванных интенсивными ливнями, и разрушительного крупного града до шквалов ураганной силы и вихрей (смерчей, тромбов-торнадо). Экономический ущерб от подобных событий исчисляется миллиардами, ежегодно затрагивая жизнь и безопасность людей и критически важные сектора экономики. Обеспечение безопасности



Content is available under license [Creative Commons Attribution 4.0 License](https://creativecommons.org/licenses/by/4.0/)

полетов, защита линий электропередачи от ветровых нагрузок и минимизация потерь урожая от градобития требуют наличия высокоточных систем мониторинга и прогнозирования ОЯ, связанных с конвективными процессами.

Особую сложность представляет задача текущего и сверхкраткосрочного прогнозирования, или наукастинга (nowcasting), охватывающая временной горизонт от 0 до 2–6 часов [1]. В отличие от синоптического прогноза, где доминирующую роль играют глобальные численные модели атмосферы (NWP – Numerical Weather Prediction), наукастинг работает с масштабами, где динамика процессов развивается быстрее, чем цикл обновления и расчета гидродинамических моделей. Численные модели часто страдают от проблемы инициализации («spin-up problem»), неспособности корректно воспроизвести микрофизику облаков на подсеточном масштабе и высокой вычислительной сложности и длительности. В этом контексте основным источником оперативной информации становятся данные дистанционного зондирования, прежде всего – метеорологические радиолокаторы (МРЛ), обеспечивающие высокое пространственное (сотни метров) и временное (минуты) разрешение.

Исторически автоматизация обработки радиолокационной информации развивалась по пути создания детерминированных алгоритмов, основанных на эвристических правилах и пороговых критериях. Пионерские разработки 1980–1990-х годов, такие как отечественные корреляционные алгоритмы, а также алгоритмы TITAN (Thunderstorm Identification, Tracking, Analysis and Nowcasting) и SCIT (Storm Cell Identification and Tracking), заложили фундамент современных оперативных систем предупреждения [2, 3, 4]. Эти методы базируются на концепции «зрелое облако как объект», где конвективная ячейка выделяется как связанная область превышения порога отражаемости, а ее движение экстраполируется линейно. Несмотря на свою надежность и интерпретируемость, данные подходы обладают фундаментальными ограничениями: они плохо справляются с нелинейной эволюцией, слиянием и разделением ячеек, а также чувствительны к выбору эмпирических порогов [5].

Последнее десятилетие ознаменовалось сдвигом парадигмы в сторону методов, «управляемых данными» (data-driven methods). Бурное развитие технологий искусственного интеллекта (ИИ), и в частности глубокого обучения (DL – Deep Learning), открыло новые горизонты в анализе геопространственных временных рядов [6]. Способность нейронных сетей автоматически извлекать иерархические признаки из многомерных массивов данных, моделировать сложные нелинейные зависимости и интегрировать разнородную информацию (радиолокация, спутниковые наблюдения, грозопеленгация, модели численного прогноза погоды) – все это позволяет преодолеть ограничения классических алгоритмов. Современные исследования демонстрируют, что применение сверточных нейронных сетей (CNN), рекуррентных архитектур (RNN, LSTM) и трансформеров (Transformers) позволяет значительно повысить точность идентификации опасных явлений и качество прогноза полей осадков.

**Целью настоящего обзора** является всесторонний анализ современного состояния методов машинного обучения (ML – Machine Learning), применяемых для автоматической идентификации, сопровождения и прогнозирования эволюции конвективных ячеек. В работе проводится детальное сравнение классических алгоритмов и новейших нейросетевых архитектур, обсуждаются физические принципы их работы, преимущества, ограничения и перспективы внедрения в оперативную практику.

#### ОБЪЕКТЫ И МЕТОДЫ ИССЛЕДОВАНИЙ

Для глубокого понимания проблем исследования необходимо рассмотреть физическую природу объекта исследования – конвективной ячейки – и инструмента наблюдения – метеорологического радиолокатора.

Современные доплеровские радиолокаторы с двойной поляризацией (ДМРЛ) измеряют комплекс параметров, характеризующих состояние атмосферы. Базовым параметром является радиолокационная отражаемость ( $Z$ ), измеряемая в логарифмических единицах ( $dBZ$ ). Отражаемость пропорциональна концентрации частиц и шестой степени их диаметра ( $Z \sim \sum D^6$ ), что делает радар чрезвычайно чувствительным к размеру гидrometeorов. Значения  $Z > 35-40 dBZ$  традиционно ассоциируются с конвективными ячейками, а значения  $> 55-60 dBZ$  уже указывают на наличие града.

Внедрение технологии двойной поляризации, позволяющей излучать и принимать волны с горизонтальной и вертикальной поляризацией, существенно расширило информативность данных. Ключевые поляриметрические переменные включают:

- дифференциальную отражаемость ( $Z_{DR}$ ) – разность отражаемости на горизонтальной и вертикальной поляризациях. Положительные значения  $Z_{DR}$  указывают на сплюснутые капли дождя, околонулевые – на хаотично ориентированный град, а специфические артефакты (« $Z_{DR}$  columns») выше уровня замерзания служат индикаторами мощных восходящих потоков, поднимающих переохлажденные капли на большие высоты;
- удельную дифференциальную фазу ( $K_{DP}$ ) – ее величина характеризует сдвиг фазы сигнала при прохождении через среду.  $K_{DP}$  чувствительна к концентрации жидкой воды и не зависит от наличия града, что позволяет разделять вклад дождя и льда в общий сигнал. Высокие значения  $K_{DP}$  в смешанной фазе (« $K_{DP}$  columns») также являются надежными предвестниками интенсификации конвективного процесса;
- коэффициент взаимной корреляции ( $\rho_{HV}$ ) – его величина показывает степень однородности частиц в объеме. Используется для фильтрации неметеорологического эха (птицы, насекомые) и даже детектирования «мусорного или обломочного облака» (debris ball) при торнадо.

В итоге полученные радиолокационные данные представляют собой сложные 3D-массивы в полярной системе координат (азимут, угол места, дальность). Для применения методов машинного обучения, особенно сверточных сетей, ориентированных на декартовы сетки изображений, требуется предварительная обработка: контроль качества для удаления шумов и артефактов – аномального радиоэха (отражения от земли – «местников», биологических объектов и пр.), интерполяция в регулярную сетку и нормализация значений.

Прежде чем перейти к анализу нейросетевых методов, необходимо все же рассмотреть классические алгоритмы, которые широко используются в оперативной практике. Их архитектура и ограничения определяют векторы развития современных ML-подходов.

Алгоритм TITAN, разработанный в Национальном центре атмосферных исследований США (NCAR) Диксоном и Винером (1993) [7], стал первой широко тиражируемой системой автоматического трекинга. Он базируется на определении конвективной ячейки как трехмерного непрерывного объекта. Основным критерием идентификации является превышение заданного порога отражаемости (обычно  $35-40 dBZ$ ) и порога минимального объема (например,  $50 \text{ км}^3$ ). Алгоритм сканирует объемные данные и объединяет все смежные воксели, удовлетворяющие критериям, в единую геометрическую сущность. Для каждого объекта рассчитываются свойства: центр масс (геометрический центр масс), объем, площадь проекции, максимальная отражаемость и параметры эллипса, аппроксимирующего форму шторма. Задача сопровождения (трекинга) в TITAN формулируется как задача комбинаторной оптимизации на двудольном графе. Для набора объектов, идентифицированных в момент времени  $t$  ( $N$  штормов) и  $t+\Delta t$  ( $M$  штормов), необходимо найти оптимальное соответствие. Алгоритм минимизирует функцию стоимости (cost function), которая штрафует нефизичные изменения траектории и свойств шторма. Функция стоимости  $C_{ij}$  для сопоставления ячейки  $i$  и ячейки  $j$  обычно имеет вид:

$$C_{ij} = w_1 \cdot \Delta d + w_2 \cdot \Delta V, \quad (1)$$

где  $\Delta d$  – расстояние между прогнозируемым положением центраида  $i$  и фактическим положением  $j$ ,  $\Delta V$  – изменение объема, а  $w_1, w_2$  – весовые коэффициенты. Такой подход позволяет ТИТАН отслеживать движение ячеек, даже если их форма меняется, однако он предполагает определенную инерционность свойств.

Несмотря на свою эффективность для изолированных ячеек, ТИТАН имеет ряд фундаментальных недостатков:

1. Проблема единственного порога (Single Threshold Problem) – когда использование одного уровня отсечения приводит к ошибкам в кластеризованных системах. Если несколько конвективных ядер соединены областью более слабых осадков, превышающих порог, ТИТАН объединяет их в один гигантский объект («False Merger»). Это искажает статистику и приводит к неверному расчету центраида, который может оказаться в зоне слабых осадков между ядрами.

2. Линейность предположений – то есть алгоритм предполагает, что штормы движутся по квазилинейным траекториям и меняют свои свойства плавно. В реальности конвекция часто развивается взрывообразно, а движение может быть нелинейным из-за размывания границ при взаимодействии с окружающей атмосферой (outflow boundaries).

3. Неустойчивость к разделению – то есть при распаде мультячейкового процесса на компоненты алгоритм может потерять историю развития отдельных ядер, присвоив им новые идентификаторы.

Алгоритм SCIT [8], разработанный для сети радаров WSR-88D (NEXRAD), представляет собой более сложную систему, направленную на решение проблем, присущих ТИТАН. Он использует иерархическую структуру идентификации – набор из семи порогов отражаемости (30, 35, 40, 45, 50, 55, 60 dBZ). Процесс идентификации происходит итеративно:

- 1D Сегменты. На каждом луче радара выделяются отрезки непрерывного превышения порогов.

- 2D Компоненты. Сегменты объединяются в плоские компоненты на каждом углу места по азимуту.

- 3D Ячейки. Компоненты на разных высотах ассоциируются в трехмерные структуры на основе вертикальной близости центраидов.

Такой подход позволяет SCIT видеть внутреннюю структуру ячейки («матрешку») и выделять более интенсивные уровни – ядра внутри обширных зон осадков. Это критически важно для обнаружения града и оценки потенциала ОЯ. Статистический анализ показывает, что SCIT корректно идентифицирует до 96 % ячеек с отражаемостью  $>50$  dBZ.

SCIT использует метод наименьших квадратов для линейной экстраполяции движения центраидов. Для каждого трека сохраняется история положений, на основе которой рассчитывается вектор скорости. Однако как и ТИТАН, SCIT страдает от проблем дискретности. Если ячейка быстро растет или затухает, ее центраид может сместиться слишком резко или исчезнуть, что приведет к разрыву трека. Более поздние модификации SCIT включают элементы вероятностной ассоциации данных (JPDA – Joint Probabilistic Data Association) для улучшения стабильности трекинга в условиях плотных кластеров.

Переходным этапом между объектными алгоритмами и глубоким обучением стало применение методов компьютерного зрения, основанных на представлении отражаемости как поля (field-based methods). В отличие от отслеживания дискретных объектов эти методы работают с полным полем изображения.

Алгоритмы оптического потока (Optical Flow), такие как Lucas-Kanade или ROVER (Real-time Optical flow by Variational method for Echoes of Radar), рассчитывают поле векторов скоростей для каждого пикселя изображения. Они решают уравнение переноса интенсивности:

$$dI/dt = \partial I/\partial t + V \cdot \nabla I = 0. \quad (2)$$

Это уравнение базируется на допущении Лагранжевой инерционности: интенсивность пикселя сохраняется при его движении вдоль траектории.

Методы оптического потока стали основой многих современных систем наукастинга осадков, например, открытой библиотеки Pysteps [9]. Алгоритм, такой как TREC (Tracking Radar Echoes by Correlation), разбивает радарное изображение на сетку узлов и находит вектор смещения для каждого, максимизируя коэффициент кросс-корреляции между последовательными кадрами. Эти методы обеспечивают плавную и визуально приятную экстраполяцию полей, превосходя объектные методы в прогнозе распределенных осадков. Однако для конвективных штормов допущение  $dI/dt = 0$  является физически некорректным. Конвективные ячейки характеризуются быстрым вертикальным развитием (рост) и последующим распадом (диссипация). Оптический поток способен предсказать перемещение существующего радиоэха – адвекцию, но не может предсказать зарождение новых ячеек или внезапное усиление существующих. Это приводит к систематическим ошибкам прогноза в ситуациях с активной динамикой развития.

Неспособность детерминированных алгоритмов учесть нелинейную природу атмосферных процессов вызвала постепенный отказ от эвристик в сторону применения методов машинного обучения. Эволюция ML в этой области прошла путь от простых классификаторов на основе признаков до глубоких генеративных моделей.

Первая волна внедрения ИИ заключалась в замене жестких правил ("если  $Z > 50$ , то град") на обучаемые классификаторы. В этом подходе объект сначала выделяется традиционным методом (сегментация SCIT/TITAN), затем для него рассчитывается вектор признаков (площадь, высота эхо, VIL, градиенты, температура верхушки по спутнику), который подается на вход модели.

Алгоритмы случайного леса (RF – Random Forest) и системы нечеткой логики (Fuzzy Logic) показали высокую эффективность в задачах классификации. В работе [10] Джунг и Ли (2015) предложили алгоритм трекинга на основе нечеткой логики, который оценивает степень принадлежности объекта к треку на основе множества факторов (расстояние, разница в размере, изменение формы). Это позволило сделать трекинг более устойчивым («робастным») к шуму и ошибкам сегментации по сравнению с жесткой логикой TITAN.

Другой пример – Йергенсен и др. (2020) [11]. Они использовали RF для классификации типа конвективной организации (суперячейка, линейная система, хаотичная конвекция). Модель обучалась на наборе морфологических признаков и данных об окружающей среде, достигая точности классификации  $\sim 77\%$ , что значительно превосходит возможности простых пороговых методов. Исследования показывают, что RF, обученный на комбинации радарных метрик и данных численных моделей, лучше разделяет градовые и неградовые ячейки, снижая количество ложных тревог.

Главным ограничением этого подхода остается зависимость от инженерии признаков (feature engineering). Качество модели ограничено тем, насколько удачно эксперт смог закодировать физику процесса в набор признаков. Модель не может «увидеть» паттерны, которые не были явно описаны, например, специфическую спиральную текстуру суперячейки.

Другой критической проблемой является дисбаланс классов. Конвективные ячейки, и тем более экстремальные явления (шквалы, торнадо, крупный град), встречаются крайне редко по сравнению с обычными осадками или ясным небом. В наборах данных, таких как зарубежные TorNet [12] или SEVIR, доля пикселей, соответствующих опасным явлениям, может составлять доли процента. Это создает риск того, что ML-модель обучится предсказывать «отсутствие явления», достигая формально высокой точности (Accuracy), но имея нулевую прогностическую ценность. Решение этой проблемы требует использования специализированных функций потерь и методов подготовки данных.

Революция глубокого обучения позволила перейти от анализа признаков к анализу сырых данных (representation learning). Сверточные нейронные сети (CNN), ставшие стандартом в компьютерном зрении, оказались идеально приспособлены для обработки радарных изображений.

#### РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Задача идентификации ячеек в терминах DL формулируется как задача семантической сегментации: каждому пикселю изображения необходимо присвоить метку класса («конвективная ячейка», «обложные осадки», «ясное небо»). Доминирующей архитектурой здесь стала U-Net, изначально разработанная для биомедицинских изображений.

U-Net имеет структуру энкодер-декодер:

– Энкодер – последовательность сверточных слоев и операций пулинга (pooling) уменьшает пространственную размерность изображения, одновременно увеличивая глубину признакового пространства. На этом этапе сеть «понимает» глобальный контекст (наличие крупномасштабной системы) и абстрактные паттерны [13].

– Декодер – последовательность операций передискретизации (upsampling) – восстанавливает исходное разрешение для попиксельного прогноза.

– Пропуск связей (Skip Connections) – ключевая особенность U-Net. Выходы слоев энкодера сопрягаются с соответствующими слоями декодера. Это позволяет передать информацию о мелких деталях и точных границах объектов (локализованную на первых слоях энкодера) напрямую на выход, минуя «бутылочное горлышко» сжатия. Это критически важно для точного оконтуривания мелких конвективных ячеек.

Применение CNN (в частности, архитектур RainNet [14], SegNet и U-Net) для детектирования конвекции демонстрирует качественный скачок в точности [15, 16]. В отличие от ТИТАН, аппроксимирующего штормы эллипсами, U-Net выделяет объекты произвольной формы (линии, дуги, сложные кластеры). CNN обучается распознавать не только превышение порога амплитуды, но и текстурные особенности (градиенты, неоднородности), что позволяет отличать конвекцию от артефактов (например, помех от земли или биологических отражателей). В сравнительных исследованиях [17] CNN-модели достигают вероятности обнаружения (POD)  $>0.9$  и индекса критического успеха (CSI)  $\approx 0.81$ , тогда как традиционные методы часто показывают  $CSI \approx 0.4-0.6$ .

Примером успешного применения CNN является алгоритм CITRA (Convective cell Identification and TRACKing), описанный в работе [18]. Авторы рассматривают задачу идентификации как задачу оптического распознавания символов (OCR), где формы штормов трактуются как «символы». Глубокая сверточная сеть обучается выделять границы ячеек даже в условиях сильного перекрытия (слияния), используя специальные функции потерь для разделения объектов. CITRA демонстрирует способность поддерживать целостность треков в ситуациях, где SCIT теряет ячейки из-за флуктуаций отражаемости. Помимо радиолокационных данных, исследователи успешно применяют аналогичные подходы и для спутниковых снимков [19] и мозаичных данных [20, 21].

Задача наукастинга требует моделирования эволюции системы во времени. Статические CNN не обладают памятью и не могут учесть инерцию движения или тренд развития.

Для работы с последовательностями обзоров (радарными данными во времени) было предложено использовать рекуррентные сверточные сети [22], в частности архитектуры:

– ConvLSTM (Convolutional LSTM). В классическом блоке LSTM (Long Short-Term Memory) операции матричного умножения заменены на операции свертки. Это позволяет скрытым состояниям сети ( $H_t, C_t$ ) сохранять пространственную структуру (быть 3D-тензорами). ConvLSTM способна моделировать нелинейную динамику: она «запоминает», что ячейка растет, и проецирует этот рост в будущее [22].

– TrajGRU (Trajectory GRU). Дальнейшее развитие ConvLSTM. Стандартные свертки имеют фиксированное рецептивное поле (смотрят в одну точку), что неэффективно для быстро движущихся объектов. TrajGRU использует механизм, позволяющий сети динамически обучаться траекториям движения информации (фактически встраивая аналог оптического потока внутрь рекуррентной ячейки). Это улучшает прогноз вращающихся и быстро смещающихся ячеек [23].

В последние годы (2022–2025) лидерство в задачах прогнозирования переходит к архитектурам на базе трансформеров (Transformers), использующих механизм внимания (Self-Attention). Модель Earthformer, разработанная Amazon и исследователями в области наук о Земле [24], решает проблему квадратичной сложности внимания ( $O(N^2)$ ) с помощью механизма «Cuboid Attention». Принцип заключается в следующем. Входной 3D-объем данных (пространство + время) разбивается на «кубоиды». Внимание рассчитывается внутри кубоидов (локально) и между ними (глобально). Это позволяет модели улавливать дальнедействующие связи. Например, зарождение конвекции в одной точке может быть спровоцировано оттоком холодного воздуха от облака (outflow boundary), находящегося за 50 км. Сверточные сети (с локальным окном) «видят» эту связь только через множество слоев, тогда как трансформер может связать эти события напрямую.

Эффективность: Earthformer демонстрирует State-of-the-Art (SOTA) результаты на бенчмарке SEVIR, превосходя ConvLSTM по способности предсказывать сложные сценарии развития погоды на горизонте до 2–3 часов.

В противовес сложным трансформерам развивается направление упрощенных моделей, таких как SimVP (Simpler yet Better Video Prediction). SimVP отказывается от рекурсии и сложного внимания в пользу полностью сверточной архитектуры с механизмом трансляции (Translator). Используя модули Group-Mix Attention, SimVP достигает сравнимой с трансформерами точности при значительно меньших вычислительных затратах и более высокой скорости, что критично для оперативных задач.

Также точность идентификации и прогноза значительно возрастает при использовании дополнительных источников информации.

Модель FURENet (Fusion and Reassignment Network) специально разработана для интеграции данных двойной поляризации ( $Z, Z_{DR}, K_{DP}$ ). FURENet использует архитектуру с несколькими ветвями энкодера и стратегию «позднего слияния» (late fusion). Блоки Squeeze-and-Excitation (SE) динамически перевзвешивают важность каналов. Например, если в данных присутствует сигнал  $K_{DP}$  выше уровня замерзания ( $K_{DP}$  column – признак мощного восходящего потока и образования града) [25], сеть придает этому каналу больший вес. Исследования показывают, что добавление поляриметрических переменных улучшает метрику CSI прогноза конвективной инициации на 13–17 %.

Модель CGsNet специализируется на прогнозе конвективных шквалов [26]. Обученная на сопоставлении радарных полей и данных наземных анемометров, она способна предсказывать поля ветра с разрешением 1 км, выявляя зоны риска нисходящих микропорывов (downbursts), что невозможно сделать с помощью стандартной экстраполяции.

Одной из главных проблем всех моделей, обучаемых на минимизацию среднеквадратичной ошибки (MSE Loss), является эффект размытия. Конвекция – стохастический процесс, то есть существует множество вероятных сценариев будущего. Модель, минимизирующая MSE, стремится предсказать «среднее» из всех сценариев. В результате прогноз получается гладким, теряются мелкие детали и, что самое опасное, занижаются пиковые значения интенсивности (экстремумы).

Для решения этой проблемы компания DeepMind предложила использовать генеративно-сопоставительные сети (GAN). Их модель DGMR (Deep Generative Model of Radar) [27],

в процессе ее обучения генератор создает прогноз, а два дискриминатора (пространственный и временной) пытаются отличить его от реальных радарных данных. Состязательное обучение (Adversarial Training) заставляет генератор создавать детализированные, реалистичные текстуры, сохраняя высокие и экстремальные значения  $dBZ$ . Субъективная оценка экспертами-метеорологами британского Met Office показала, что прогнозы DGMR признаются более реалистичными в 89 % случаев по сравнению с методами оптического потока и детерминированными DL-моделями, несмотря на то, что формальные метрики (CSI) могут быть ниже из-за стохастической природы прогноза (модель предсказывает правильную структуру, но может немного ошибиться в точном положении ячейки).

Перспективным направлением является и физически-информированный подход (PIML – Physics-Informed Machine Learning). Критика «чистых» нейросетей заключается в их физической несогласованности: сеть может сгенерировать появление массы воды «из ниоткуда» или нарушить законы сохранения. PID-GAN (Physics-Informed Discriminator GAN) интегрирует физические уравнения (например, уравнение неразрывности или сохранения влаги) непосредственно в функцию потерь при обучении. Дискриминатор проверяет не только визуальную схожесть прогноза с реальностью, но и его физическую корректность. Это позволяет существенно снизить количество нереалистичных артефактов и повысить надежность прогноза ОЯ.

#### ЗАКЛЮЧЕНИЕ

Анализ современного состояния исследований в области автоматической идентификации и сопровождения конвективных ячеек позволяет сделать однозначный вывод о смене технологической парадигмы. Традиционные алгоритмы, служившие верой и правдой в течение десятилетий в автоматизированных системах, достигли предела своих возможностей. Их жесткая логика и линейные допущения не позволяют адекватно описывать сложную нелинейную динамику атмосферной конвекции, что приводит к ошибкам в критических для прогноза ситуациях.

Методы машинного обучения, и в особенности глубокого обучения, демонстрируют неоспоримое преимущество в точности обнаружения (POD), качестве оконтуривания (сегментации) и надежности прогноза (CSI). Переход от инженерных признаков к обучению представлений (CNN, Transformers), использование пространственно-временного контекста (ConvLSTM, Earthformer) и борьба за реалистичность прогнозов (GAN) позволили создать системы, способные не просто экстраполировать движение, но и предсказывать эволюцию конвективных процессов.

Однако для полноценного оперативного внедрения этих технологий необходимо решить ряд вызовов: обеспечить интерпретируемость решений ИИ для синоптиков, преодолеть проблему дисбаланса данных о редких опасных явлениях и внедрить физические ограничения (PIML) для гарантии надежности. Таким образом, будущее систем штормового предупреждения лежит в гибридизации – синтезе физически обоснованных моделей и мощных алгоритмов глубокого обучения, работающих на мультимодальных данных.

#### СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. WMO-No. 1198. Guidelines for Nowcasting Techniques. Geneva, 2017. 184 p.
  2. Абшаев М. Т., Абшаев А. М., Малкарова А. М., Жарашуев М. В. Автоматизированная радиолокационная идентификация, измерение параметров и классификация конвективных ячеек для целей защиты от града и штормооповещения // Метеорология и гидрология. 2010. № 3. С. 36–45.
- Abshaev M.T., Abshaev A.M., Malkarova A.M., Zharashuev M.V. Automated radar identification, measurement of parameters and classification of convective cells for hail protection

and storm warning purposes. *Meteorologiya i gidrologiya* [Meteorology and Hydrology]. 2010. No. 3. Pp. 36–45. (In Russian)

3. Сарайкин А. А., Чайковский В. М. Применение нейронной сети в метеорологической радиолокации // Известия вузов. Поволжский регион. Технические науки. 2024. № 1(69). С. 83–90.

Saraykin A.A., Chaykovskiy V.M. Application of a neural network in meteorological radar. *Izvestiya vysshikh uchebnykh zavedeniy. Povolzhskiy region. Tekhnicheskiye nauki* [University News. Volga Region. Technical Sciences]. 2024. No. 1(69). Pp. 83–90. (In Russian)

4. Шановалов В. А., Тумгоева Х. А. Распознавание и сопровождение облачных конвективных ячеек с целью текущего прогноза опасных погодных явлений // Известия ЮФУ. Технические науки. 2018. № 3. С. 58–67. DOI: 10.23683/2311-3103-2018-3-58-67

Shapovalov V.A., Tumgoeva Kh.A. Recognition and tracking of cloud convective cells for nowcasting of hazardous weather phenomena. *Izvestiya YuFU. Tekhnicheskiye nauki* [Izvestiya SFedU. Engineering Sciences]. 2018. No. 3. Pp. 58–67. DOI: 10.23683/2311-3103-2018-3-58-67. (In Russian)

5. Bournas A., Baltas E. Development of a Storm-Tracking Algorithm for the Analysis of Radar Rainfall Patterns in Athens, Greece. *Water*. 2024. No. 16(20). P. 2905. DOI: 10.3390/w16202905

6. Lagerquist R., McGovern A., Gagne D. J. Deep Learning for Spatially Explicit Prediction of Synoptic-Scale Fronts. *Weather and Forecasting*. 2019. Vol. 34. No. 4. Pp. 1137–1160. DOI: 10.1175/WAF-D-18-0183.1

7. Dixon M., Wiener G. TITAN: Thunderstorm identification, tracking, analysis, and nowcasting – Radar-based methodology. *Journal of Atmospheric and Oceanic Technology*. 1993. Vol. 10. No. 6. Pp. 785–797. DOI: 10.1175/1520-0426(1993)010<0785:TTITAA>2.0.CO;2

8. Johnson J.T., MacKeen P.L., Witt A. et al. The storm cell identification and tracking algorithm: an enhanced WSR-88D Algorithm. *Weather and Forecasting*. 1998. Vol. 13. No. 2. Pp. 263–276. DOI: 10.1175/1520-0434(1998)013<0263: TSCIAT>2.0.CO;2

9. Pulkkinen S., Nerini D., Pérez Hortal A.A. et al. Pysteps: an open-source Python library for probabilistic precipitation nowcasting, including an ensemble of extrapolation, autoregressive and more advanced methods. *Geoscientific Model Development*. 2019. Vol. 12. Pp. 4185–4219. DOI: 10.5194/gmd-12-4185-2019

10. Jung S.-H., Lee G. Radar-based cell tracking with fuzzy logic approach. *Meteorological Applications*. 2015. Vol. 22. No. 4. Pp. 716–730. DOI: 10.1002/met.1509

11. Jergensen G.E., McGovern A., Lagerquist R., Smith T. Classifying convective storms using machine learning. *Weather and Forecasting*. 2020. Vol. 35, No. 2. Pp. 537–556.

12. Veillette M.S., Kurdzo J.M., Stepanian P.M. et al. A benchmark dataset for tornado detection and prediction using full-resolution polarimetric weather radar data (TorNet). *Artificial Intelligence for the Earth Systems*. 2024. Vol. 4. No. 1. DOI: 10.1175/AIES-D-24-0006.1

13. Nan G., Chen M., Qin R. et al. Identification, tracking and classification method of mesoscale convective system based on radar composite reflectivity mosaic and deep learning. *Acta Meteorologica Sinica*. 2021. Vol. 79(6). Pp. 1002–1021. DOI: 10.11676/qxxb2021.062

14. Ayzel G., Scheffer T., Heistermann M. RainNet v1.0: a convolutional neural network for radar-based precipitation nowcasting. *Geoscientific Model Development*. 2020. Vol. 13. No. 6. Pp. 2631–2644. DOI: 10.5194/gmd-13-2631-2020

15. Han L., Sun J., Zhang W. convolutional neural network for convective storm nowcasting using 3-d doppler weather radar data. *IEEE Transactions on Geoscience and Remote Sensing*. 2020. Vol. 58. No. 2. Pp. 1487–1495. DOI: 10.1109/TGRS.2019.2948070

16. Albu A.-I., Czibula G., Mihai A. et al. NeXtNow: A convolutional deep learning model for the prediction of weather radar data for nowcasting purposes. *Remote Sens*. 2022. No. 14. P. 3890. DOI: 10.3390/rs14163890

17. Ritvanen J., Pulkkinen S., Moisseev D., Nerini D. Cell-tracking-based framework for assessing nowcasting model skill in reproducing growth and decay of convective rainfall. *Geoscientific Model Development*. 2025. Vol. 18. Pp. 1851–1878. DOI: 10.5194/gmd-18-1851-2025
18. Ranganayakulu S.V., Subrahmanyam K.V., Niranjan A. A novel algorithm for convective cell identification and tracking based on optical character recognition neural network. *Journal of Electromagnetic Waves and Applications*. 2021. Vol. 35. No. 16. Pp. 2239–2255. DOI: 10.1080/09205071.2021.1941299
19. Liu J., Zhang Q. A novel algorithm for detecting convective cells based on h-maxima transformation using satellite images. *Atmosphere*. 2025. Vol. 16. No. 11. P. 1232. DOI: 10.3390/atmos16111232
20. Wang X., Liao R., Li J. et al. Thunderstorm identification algorithm research based on simulated airborne weather radar reflectivity data. *EURASIP Journal on Wireless Communications and Networking*. 2020. ID: 37. DOI: 10.1186/s13638-020-1651-6
21. Wang Y., Long M., Wang J. et al. PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs. *Advances in Neural Information Processing Systems*. 2017. Vol. 30. Pp. 1–10.
22. Shi X., Chen Z., Wang H. et al. Convolutional LSTM Network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems (NIPS)*. 2015. Vol. 28. Pp. 802–810.
23. Shi X., Gao Z., Lausen L. et al. Deep Learning for precipitation nowcasting: a benchmark and a new model. *Advances in Neural Information Processing Systems (NIPS)*. 2017. Vol. 30. Pp. 5617–5627.
24. Gao Z., Shi X., Wang H., et al. Earthformer: exploring space-time transformers for earth system forecasting. *Advances in Neural Information Processing Systems (NeurIPS)*. 2022. Vol. 35. Pp. 25390–25403. arXiv:2207.05833
25. Hu J., Rosenfeld D., Zrnić D. et al. Tracking and characterization of convective cells through their maturation into stratiform storm elements using polarimetric radar and lightning detection. *Atmospheric Research*. 2019. Vol. 226. Pp. 192–207.
26. Xiao H., Wang Y., Zheng Y. et al. Convective-gust nowcasting by a deep learning algorithm. *Geoscientific Model Development*. 2023. Vol. 16. Pp. 3611–3628. DOI: 10.5194/gmd-16-3611-2023
27. Ravuri S., Lenc K., Willson M. et al. Skilful precipitation nowcasting using deep generative models of radar. *Nature*. 2021. Vol. 597. Pp. 672–677. DOI: 10.1038/s41586-021-03854-z

**Вклад авторов:** все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

**Contribution of the authors:** the authors contributed equally to this article. The authors declare no conflict of interest.

**Финансирование.** Исследование проведено без спонсорской поддержки.

**Funding.** The study was performed without external funding.

### Информация об авторах

**Шаповалов Виталий Александрович**, д-р физ.-мат. наук, стар. науч. сотр., Высокогорный геофизический институт;

360030, Россия, г. Нальчик, проспект Ленина, 2;

vet555\_83@mail.ru, ORCID: <https://orcid.org/0000-0002-9701-6820>, SPIN-код: 6938-9800

**Аджиева Аида Анатольевна**, д-р физ.-мат. наук, профессор кафедры «Высшая математика и информатика», Кабардино-Балкарский государственный аграрный университет имени В. М. Кокова; 360030, Россия, г. Нальчик, проспект Ленина, 1в;

aida-adzhieva@mail.ru, ORCID: <https://orcid.org/0000-0002-1047-8417>, SPIN-код: 4128-9520

**Ахматов Мухадин Магомедович**, канд. физ.-мат. наук, доцент, доцент кафедры «Высшая математика и информатика», Кабардино-Балкарский государственный аграрный университет имени В. М. Кокова;

360030, Россия, г. Нальчик, проспект Ленина, 1в;

m\_ahmatov@mail.ru, ORCID: <https://orcid.org/0009-0003-2941-7459>, SPIN-код: 3620-2852

**Хитиева Аминат Жагафаровна**, канд. экон. наук, доцент, доцент кафедры «Высшая математика и информатика», Кабардино-Балкарский государственный аграрный университет имени В. М. Кокова; 360030, Россия, г. Нальчик, проспект Ленина, 1в;

aminkahitieva@mail.ru, ORCID: <https://orcid.org/0009-0004-6847-6328>, SPIN-код: 8085-7236

### Information about the authors

**Vitaliy A. Shapovalov**, Doctor of Physics and Mathematics, Senior Researcher, High-Mountain Geophysical Institute;

2, Lenin avenue, Nalchik, 360004, Russia;

vet555\_83@mail.ru, ORCID: <https://orcid.org/0000-0002-9701-6820>, SPIN-code: 6938-9800

**Aida A. Adzhieva**, Doctor of Physics and Mathematics, Professor, Department of Higher Mathematics and Informatics, Kabardino-Balkarian State Agricultural University named after V.M. Kokov;

1v, Lenin avenue, Nalchik, 360030, Russia;

aida-adzhieva@mail.ru, ORCID: <https://orcid.org/0000-0002-1047-8417>, SPIN-code: 4128-9520

**Mukhadin M. Akhmatov**, Candidate of Physical and Mathematical Sciences, Associate Professor, Associate Professor of the Department of Higher Mathematics, Kabardino-Balkarian State Agricultural University named after V.M. Kokov;

1v, Lenin avenue, Nalchik, 360030, Russia;

m\_ahmatov@mail.ru, ORCID: <https://orcid.org/0009-0003-2941-7459>, SPIN-code: 3620-2852

**Aminat Zh. Khitieva**, Candidate of Economic Sciences, Associate Professor, Associate Professor of the Department of Higher Mathematics and Informatics, Kabardino-Balkarian State Agricultural University named after V.M. Kokov;

1v, Lenin avenue, Nalchik, 360030, Russia;

aminkahitieva@mail.ru, ORCID: <https://orcid.org/0009-0004-6847-6328>, SPIN-code: 8085-7236