

Нейросетевые методы наукастинга осадков: обзор и апробация существующих решений

М. О. Кучма^{1,2}, С. И. Мальковский¹, А. И. Андреев^{1,2}, В. Д. Блощинский^{1,2}

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

² *Дальневосточный центр НИЦ «Планета», Хабаровск, 680000, Россия*

В последние годы среди исследователей и метеорологических агентств разных стран отмечается рост интереса в области прогноза текущей погоды с использованием наземных и спутниковых систем наблюдений. В связи с этим в настоящей работе представлен обзор последних достижений в этой области. В частности, рассмотрены современные нейросетевые методы наукастинга для решения задачи экстраполяции последовательности цифровых матриц, содержащих информацию об интенсивности осадков за предыдущие сроки наблюдений. При этом особое внимание уделяется возможности прогнозирования осадков, где в качестве основного источника информации используются данные геостационарных космических аппаратов, что обусловлено большим территориальным покрытием, в том числе для отдалённых территорий. Используя общедоступный набор данных SEVIR (*англ.* Storm EVent ImagRy), объединяющий наземные и спутниковые наблюдения за осадками и опасными явлениями погоды, авторы провели апробацию отдельных архитектур нейронных сетей для решения задачи наукастинга. Сделаны выводы о возможности применения рассматриваемых решений для прогноза текущей погоды в Дальневосточном регионе России.

Ключевые слова: наукастинг, текущий прогноз погоды, осадки, искусственный интеллект, машинное обучение, нейронные сети, гидрометеорология

Одобрена к печати: 18.10.2023

DOI: 10.21046/2070-7401-2023-20-6-35-48

Введение

Прогноз текущей погоды, или наукастинг, — одна из активно развивающихся областей гидрометеорологии, призванная повысить детализацию прогнозов и их точность. Появление этого направления во многом связано с совершенствованием систем наземного и спутникового наблюдения, а также развитием вычислительной техники и алгоритмов обработки поступающего в непрерывном режиме потока инструментальной информации. В соответствии с действующим определением Всемирной метеорологической организации (ВМО, *англ.* World Meteorological Organization — WMO), приведённом в Наставлении по глобальной системе обработки данных и прогнозирования (<https://meteoinfo.ru>), временная граница диапазона наукастинга составляет до 2 ч. При этом наукастинг подразумевает высокое пространственное разрешение.

Востребованность данного типа прогнозов обусловлена климатическими изменениями (Кузнецова, 2020; <https://www.weforum.org>), порождающими экстремальные явления погоды (ливни, ураганы, тайфуны), приводящие к человеческим жертвам и большому экономическому ущербу. Отметим также, что подобные прогнозы играют важную роль во многих сферах человеческой деятельности: в сельском хозяйстве, энергетике, транспорте и др.

Основным источником данных для наукастинга выступают измерения наземных доплеровских метеорологических радиолокаторов (ДМРЛ). Их пространственное и временное разрешение позволяют с достаточно высокой степенью точности отслеживать осадки и опасные погодные явления, однако их существенным недостатком является относительно небольшой радиус сканирования, не превышающий 250 км. Ввиду этого радиолокационные измерения становятся наиболее эффективными при использовании сети равноудалённых локаторов, что требует создания мощной и дорогостоящей инфраструктуры и не всегда осуществимо для удалённых и труднодоступных регионов. Эта проблема ярко выражена для территории

Дальнего Востока России, где количество таких наземных средств наблюдений невелико. По указанной выше причине на первый план выходит использование возможностей спутникового мониторинга, основанного на применении данных с геостационарных и полярно-орбитальных космических аппаратов.

В работе решение задачи наукастинга осадков рассматривается в рамках двух её аспектов: перемещения областей осадков и прогноза значений мгновенной интенсивности. И в том и в другом случае, опираясь на мировой опыт, зачастую используют либо алгоритмы оптического потока (Liu et al., 2015; Pulkkinen et al., 2019), либо алгоритмы, основанные на применении нейронных сетей (Gao et al., 2021; Moskolai et al., 2021). Алгоритмы оптического потока основаны только на анализе изменения положения пикселей на двух соседних по времени изображениях без учёта изменения формы облака и яркости его пикселей, что накладывает серьёзные ограничения на анализ ситуаций с быстроразвивающимися процессами (конвективный шторм, взрывная конвекция и т. д.). Ввиду того что анализ проводится только для пары изображений, прогноз перемещения облачности является линейным, а его точность стремительно падает с увеличением заблаговременности. С другой стороны, использование нейронных сетей позволяет формулировать задачу прогноза как вероятностную, благодаря чему можно взглянуть на неё под другим углом. Нейронные сети являются универсальными нелинейными аппроксиматорами непрерывных функций многих переменных. Они достаточно гибки к формату представления входных и выходных данных, и для их обучения не требуется прямого задания физических законов. Вместо этого нейронные сети извлекают всю необходимую информацию непосредственно из обучающих данных. Указанные преимущества говорят о наличии большого потенциала нейронных сетей для разработки алгоритмов наукастинга нового поколения. Обзору и апробации таких решений посвящена представленная работа.

Обзор распространённых архитектур нейронных сетей

Решение задачи наукастинга осадков, как правило, сводится к прогнозированию следующего кадра видеопоследовательности, а входными данными становится серия из более чем двух последовательных изображений, что позволяет более точно моделировать нелинейные перемещения (Gao et al., 2021) рассматриваемых объектов по сравнению с классическими методами на основе оптического потока.

В рамках решения задачи наукастинга осадков наибольшее распространение среди специалистов ввиду открытости исходного кода моделей и заявленной высокой прогностической способности получили следующие архитектуры нейронных сетей: модели семейств ConvLSTM (*англ.* Convolutional Long Short-Term Memory) и TrajGRU (*англ.* Trajectory Gated Recurrent Units) (Shi et al., 2015, 2017), PredRNN (*англ.* Predictive Recurrent Neural Network) (Wang et al., 2017, 2018, 2022), PrecipLSTM (*англ.* precipitation Long Short Term Memory) (Ma et al., 2022), MoDeRNN (Yao et al., 2023), MIM (*англ.* Memory In Memory) (Wang et al., 2019). Рассмотрим их особенности.

Модель ConvLSTM (Shi et al., 2015) — одна из первых архитектур, предназначенных для решения задачи наукастинга нейросетевым методом. В данной архитектуре были впервые объединены преимущества применявшихся ранее в этой области свёрточных CNN (*англ.* Convolutional Neural Network) (Lecun, Bengio, 1995) и классических рекуррентных нейронных сетей RNN (*англ.* Recurrent Neural Network) (Recurrent..., 1999). В качестве рекуррентного блока здесь используются ячейки с элементами краткосрочной памяти LSTM (*англ.* Long Short-Term Memory) (Hochreiter, Schmidhuber, 1997), что позволяет преодолеть проблему потери информации из начальных элементов входной последовательности за счёт специальной реализации механизма памяти и передачи контекстной информации между входными элементами на различных временных масштабах. Модель ConvLSTM превзошла традиционные методы прогнозирования осадков, основанные на алгоритмах оптического потока, в среднем на ~16 % по RMSE (*англ.* Root Mean Square Error, величина среднеквадратичной ошибки) (Shi et al., 2015) и послужила отправной точкой для дальнейших усовершенствований данного ме-

тогда прогнозирования. Однако её недостатком оказался тот факт, что отклик сигнала сети на выходе свёрточных слоёв слабо зависит от местоположения наблюдаемого явления на изображении. Это может приводить к неточностям, например при моделировании вращения циклона, росте облачных конвективных ячеек и в ряде других ситуаций (Shi et al., 2017).

Усовершенствованная архитектура модели ConvLSTM, получившая название TrajGRU (Shi et al., 2017), основана на рекуррентных ячейках GRU (*англ.* Gated Recurrent Unit) (Cho et al., 2014), которые, в свою очередь, представляются дальнейшим развитием идей LSTM. Архитектура TrajGRU имеет ряд преимуществ. Первое из них заключается в использовании более эффективного механизма памяти, требующего меньше вычислительных ресурсов. Второе — улучшение точности прогноза за счёт внедрения механизма передачи дополнительной контекстной информации о местоположении локальных объектов на изображениях.

Другое семейство архитектур, часто используемых для решения задачи прогнозирования, берёт своё начало с модели PredRNN (Wang et al., 2017). Данная модель основана на принципе запоминания характерных пространственно-временных паттернов поведения движущихся объектов в процессе обучения. Механизм памяти здесь, в отличие от LSTM, реализуется не только отдельно внутри каждой рекуррентной ячейки, но и в соединениях между ними. Рекуррентный принцип построения архитектуры предполагает, что каждая ячейка LSTM отвечает за определённый кадр входной последовательности и состоит из четырёх последовательных нейронных слоёв, определяющих уровень абстракции признаков, извлекаемых из изображения. Промежуточная информация на выходе последнего слоя предыдущей ячейки передаётся на первый слой следующей ячейки LSTM. Как отмечают авторы работы (Wang et al., 2017), это ограничивает возможность запоминания мелких деталей движущихся объектов. В качестве решения данной проблемы исследователи предлагают передавать промежуточную контекстную информацию между всеми слоями соседних ячеек. Таким образом обеспечивается запоминание временных (траектория движения) и пространственных (изменение формы объектов) вариаций за счёт передачи контекстной информации на различных уровнях абстракции.

Основным недостатком модели PredRNN стала проблема затухания градиента, заключающаяся в неспособности нейронной сети обучаться из-за слишком большой её глубины, а именно большого количества ячеек и слоёв. Обучаемая рекуррентная нейронная сеть в этом случае фокусирует своё внимание только на ближайших кадрах, а информация, получаемая из кадров более высокого порядка, теряется. Для решения этой проблемы в работе (Wang et al., 2018) был предложен усовершенствованный вариант архитектуры, названный PredRNN++. Во-первых, был доработан механизм пространственно-временной памяти, передающий информацию, полученную на предыдущем кадре в слое, расположенном на более низком уровне абстракции. Во-вторых, разработан вспомогательный блок GHU (*англ.* Gradient Highway Unit), передающий информацию о контексте сразу через все ячейки. Всё это в совокупности позволяет существенно уменьшить проблему затухания градиентов и повысить точность прогнозирования для достаточно длинных входных последовательностей кадров.

Наконец, модель PredRNN-V2 представляет собой улучшенный вариант исходной архитектуры PredRNN по трём направлениям. Во-первых, авторами работы (Wang et al., 2022) предложена новая функция минимизации при обучении нейронной сети. Во-вторых, изменения коснулись самой процедуры обучения, при которой случайным образом маскируется часть пикселей последовательности на каждой обучающей итерации. В-третьих, сама структура нейронной сети также была доработана с целью улучшения способности архитектуры к моделированию среды, в которой происходит движение объектов.

Сеть PrecipLSTM (Ma et al., 2022) представляет собой ещё один модернизированный вариант архитектуры PredRNN. Ключевой особенностью новой архитектуры стало использование двух отдельных модулей, один из которых предназначен для запоминания пространственных признаков, а другой — признаков, зависящих от времени. При этом в архитектуру внедрён механизм локального внимания (Luong et al., 2015), позволяющий модели фокусироваться на определённых участках изображения.

Сеть ModeRNN основана на использовании механизма внимания. Однако данная архитектура принципиально отличается от остальных за счёт идеи использования так называемой концепции слотов (Locatello et al., 2020), т. е. специальных ячеек состояний, запоминающих определённые паттерны поведения наблюдаемой динамической системы. По мнению авторов исследования (Yao et al., 2023), подобный подход должен помочь предотвратить возможное переобучение нейронной сети для конкретных примеров физических процессов в обучающей выборке, когда с одним и тем же процессом могут быть связаны различные паттерны поведения наблюдаемого объекта. Для этого в процессе обучения формируется домен возможных состояний наблюдаемого физического процесса, а выбор того или иного паттерна поведения этого процесса осуществляется за счёт применения обучаемых весовых коэффициентов нейронной сети.

Природные процессы могут характеризоваться высокой степенью нестационарности: от низкоуровневой, соответствующей пространственно-временным корреляциям локальных значений пикселей, до высокоуровневой, связанной, например, с рассеянием эхо-сигналов метеорологических радиолокаторов. Примером таких процессов могут служить вертикальное развитие кучево-дождевого облака и линейное горизонтальное перемещение всей облачной системы в целом. При этом большинство архитектур рекуррентных сетей, по заверению авторов работы (Wang et al., 2019), недостаточно эффективны в подобных ситуациях. Предложенная ими архитектура MIM призвана восполнить этот недостаток. Ключевой идеей здесь выступает использование встроенных в ячейку PredRNN двух модулей, предназначенных для запоминания и передачи контекстной информации отдельно для стационарных и нестационарных процессов.

Таблица 1. Сравнение архитектур нейронных сетей для задачи прогноза видеопоследовательностей

Архитектура	Год	Количество параметров, млн	Наборы обучающих данных						
			Moving MNIST		TaxiBJ		KTH	Набор радарных данных	
			SSIM	MAE	MSE	SSIM	PSNR	CSI	HSS
ConvLSTM	2015	1,77	0,863	109,190	0,278	23,58	0,712	0,407	0,560
TrajGRU	2017	2,11	—	—	0,282	26,97	0,790	0,309	—
PredRNN	2017	3,59	0,884	94,431	0,273	27,55	0,839	0,427	0,580
PredRNN++	2018	5,61	0,892	89,307	0,294	28,47	0,865	—	—
MIM	2019	7,36	0,884	93,637	0,280	—	—	0,427	0,579
PredRNN-V2	2022	3,60	0,884	94,793	—	28,37	0,838	0,462	—
PrecipLSTM	2022	7,04	0,885	93,544	—	—	—	0,435	0,588
MoDeRNN	2023	5,86	—	—	0,283	—	—	—	—

Примечание: MNIST — *англ.* Modified National Institute of Standards and Technology; SSIM — *англ.* Structure Similarity; MAE — *англ.* Mean Absolute Error; TaxiBJ — *англ.* Taxi Beijing; KTH — *швед.* Kungliga Tekniska Högskolan, *англ.* Royal Institute of Technology; PSNR — *англ.* Peak Signal-to-Noise Ratio; CSI — *англ.* Critical Success Index; HSS — *англ.* Heidke Skill Score.

Одной из серьёзных проблем, с которой сталкиваются исследователи, оказывается необходимость использования большого объёма дорогостоящих вычислительных ресурсов при работе со многими вышеуказанными архитектурами. Решение этой проблемы предложено в работе (Ma et al., 2023), в которой авторы оптимизировали приведённые выше модели с использованием общей структуры под названием Multi-Scale. Основная идея данного подхода заключается в использовании пространственных признаков предыдущего кадра последовательности в следующем на различных масштабах, причём контекстная информация передаётся от нижних слоёв LSTM-ячеек к верхним от первого до последнего кадра через всю

входную последовательность. Сокращение объёма вычислений достигается за счёт перегруппировки свёрточных слоёв с одинаковым набором параметров. Кроме того, для уменьшения объёма занимаемой оперативной памяти применяется операция подвыборки (субдискретизации, *англ.* pooling). Полученные таким образом модели нейронных сетей превосходят по точности исходные модели, поэтому указанный подход использовался в настоящей работе при обучении представленных выше архитектур.

Сводные характеристики рассматриваемых моделей, включающие приблизительные показатели точности для различных наборов обучающих данных, приведены в *табл. 1*.

Таким образом, в основе современных моделей для прогнозирования осадков лежат идеи, впервые представленные в работах, посвящённых исследованию рекуррентных структур нейронных сетей (Hochreiter, Schmidhuber, 1997; Recurrent..., 1999; Shi et al., 2015). Авторами каждой из описанных выше архитектур предлагаются собственные подходы к решению проблемы увеличения точности и продолжительности прогнозов. При этом можно выделить два основных направления для решения этой проблемы: установление вспомогательных связей между различными слоями и рекуррентными ячейками нейронной сети (модели PredRNN, PredRNN++), а также совершенствование самих рекуррентных ячеек (TrajGRU, MoDeRNN, MIM). Какое из этих направлений даёт наилучшее качество прогнозов осадков при прочих равных условиях — вопрос, на который предстоит ответить в настоящей работе.

Данные для обучения нейронных сетей

В качестве данных для обучения нейронных сетей используются наборы спутниковых изображений, самостоятельно подготовленные специалистами для определённых территорий, которым свойственны те или иные природные процессы, влияющие на образование осадков.

В открытом доступе можно найти множество проектов с наборами данных, поддерживаемых международными метеорологическими агентствами. Так, набор данных НКО-7 (*англ.* The Hong Kong Observatory) (Shi et al., 2017) содержит данные ДМРЛ в центре Гонконга за шестилетний период. Королевский нидерландский метеорологический институт (*нидерл.* Koninklijk Nederlands Meteorologisch Instituut, *англ.* The Royal Netherlands Meteorological Institute) представил выборку (Overeem, Imhoff, 2020), которая содержит данные об отражательной способности за десятилетний период с двух радаров. Данные TAASRAD19 (*англ.* Trentino-Alto Adige/Sudtiroi Radar 2019) (Franch et al., 2020) хранят в себе информацию об отражательной способности ДМРЛ за девять лет на территории Альпийского региона. SEVIR (*англ.* Storm Event Imagery) (Veillette et al., 2020) содержит спутниковые данные и данные ДМРЛ (160 радаров сети NEXRAD (*англ.* The Next Generation Weather Radar)) по территории США за двухлетний период, сгруппированные по случайным осадкам и осадкам категории «опасные явления погоды» (ОЯП) (Ansari et al., 2018). Немецкая метеорологическая служба представила набор RADOLAN (*англ.* Radar Online Adjustment) (Ramsauer et al., 2018), который содержит данные об отражательной способности и осадках с 18 ДМРЛ за три года на территории Германии.

Во избежание ошибок при формировании обучающей выборки, которые в том числе связаны со сложностью расчёта интенсивности осадков для территорий, не покрытых сетью доплеровских метеорологических радиолокаторов (ДМРЛ), в работе решено было использовать общедоступный и универсальный набор данных, обычно применяемый для решения подобных задач. В настоящей работе для апробации архитектур нейронных сетей авторами был использован набор общедоступных данных SEVIR, содержащий как осадки низкой и средней интенсивности, так и осадки категории ОЯП.

SEVIR представляет собой набор приведённых к единому пространственному и временному разрешению последовательностей изображений, на которых представлены различные погодные явления на территории США по данным спутника GOES-16 (*англ.* Geostationary Operational Environmental Satellite) и наземной радиолокационной сети NEXRAD с 2017 по 2019 г. Данный набор содержит пять типов изображений: видимый спутниковый канал

GOES-16 0,6 мкм (*англ.* visible — VIS), инфракрасные (*англ.* infrared — IR) каналы 6,9 и 10,7 мкм (IR069, IR107), радиолокационные изображения вертикально интегрированной влаги (*англ.* Vertically Integrated Liquid — VIL), которая фактически представляет собой оценку общей массы осадков в облаках, а также данные о молниевых разрядах, полученные по данным прибора GLM (*англ.* Geostationary Lightning Mapper), установленного на космическом аппарате (КА) GOES-16.

Каждая последовательность в наборе данных SEVIR состоит из четырёхчасовой серии изображений, размер которых составляет 384×384 пикселей, с пространственным разрешением 1 км и временной дискретностью 5 мин. Как было упомянуто ранее, набор данных SEVIR сгруппирован на осадки малой и средней интенсивности, а также в категорию ОЯП. Отметим также, что в указанном наборе данных географические координаты изображений выбраны случайным образом по всей территории США с учётом наличия измерений VIL. При формировании выборки в первую очередь рассматривались пиксели с наибольшей интенсивностью поля VIL, что позволяет минимизировать вероятность наличия случаев без осадков.

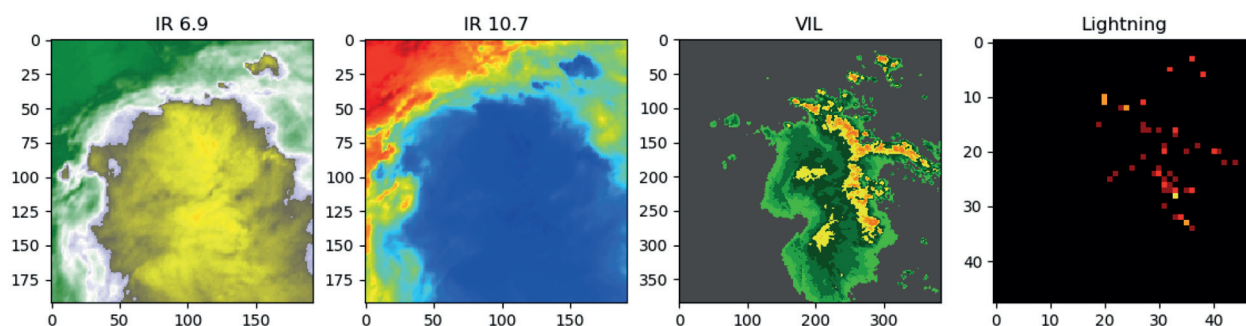


Рис. 1. Пример визуализации одного события из набора данных SEVIR

В методе группировки на основе штормовых событий использовалась база данных о штормовых явлениях Национального центра экологической информации (*англ.* National Centers for Environmental Information — NCEI, <https://www.ncdc.noaa.gov/stormevents/>) для определения зарегистрированных случаев ОЯП. Указанная база данных содержит временной интервал, местоположение, тип ОЯП, а также краткое описание каждого события. Для SEVIR были выбраны записи в базе данных о штормовых явлениях за период с 2017 по 2019 г., соответствующие категориям наводнения, града, ливневого дождя, молнии, грозового ветра или торнадо. Эти события были также сгруппированы по времени, широте и долготе с использованием иерархического алгоритма кластеризации. Центральная точка в каждом идентифицированном кластере использовалась для выбора времени и положения события SEVIR. На рис. 1 (Veillette et al., 2020) приведён пример визуализации одного события из выборки SEVIR.

Методы и технологии апробации алгоритмов

Отобранные авторами алгоритмы наукастинга (см. разд. «Обзор распространённых архитектур нейронных сетей») относятся к рекуррентным архитектурам (Recurrent..., 1999). Их работа организована следующим образом. На вход сети подаётся временная последовательность из N кадров с одинаковым шагом по времени, а её выходом служит либо прогнозируемая карта на один определённый срок вперёд, либо последовательность кадров с той же дискретностью, что и на входе. Это обусловлено тем, что нейронная сеть использует в качестве входных данных в процессе обучения и прогнозирования кадры, сгенерированные на предыдущих итерациях.

Для обучения нейронных сетей был задействован сервер с восемью графическими ускорителями NVIDIA A5000, каждый из которых оснащён 24 Гб видеопамяти, а программная реализация архитектур нейронных сетей и обучающего кода осуществлялась с использованием библиотеки PyTorch 1.12.1 на языке программирования Python.

Для оценки точности результатов прогнозирования использовались следующие метрики: CSI (Schaefer, 1990), HSS (Forecast..., 2012), PSNR (Huynh-Thu, Ghanbari, 2008) и SSIM (Wang et al., 2004), формулы расчёта которых приведены ниже:

$$CSI = \frac{TP}{TP + FN + FP}, \quad HSS = \frac{2((TP + FN) - (FP + FN))}{(TP + FN) \cdot (FN + TN) + (TP + FP) \cdot (FP + TN)},$$

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) = 20 \log_{10} \left(\frac{MAX_I}{\sqrt{MSE}} \right), \quad SSIM(x, y) = \frac{(2\mu_x \mu_y + c_1) \cdot (2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1) \cdot (\sigma_x^2 + \sigma_y^2 + c_2)},$$

где TP (*англ.* true positive) — истинно положительное событие; FP (*англ.* false positive) — ложное положительное событие; FN (*англ.* false negative) — ложное отрицательное событие; TN (*англ.* true negative) — истинно отрицательное событие; x — прогнозируемое значение; y — истинное значение; μ_x — среднее x ; μ_y — среднее y ; μ_x^2 — дисперсия x ; μ_y^2 — дисперсия y ; σ_{xy} — ковариация x и y ; $c_1 = (0,01L)^2$, $c_2 = (0,03L)^2$, где L — динамический диапазон яркости пикселей (0–255); MAXI — это максимальное значение, принимаемое пикселем изображения (равное 255).

В качестве входных данных для обучения нейронных сетей в настоящей работе используются поля осадков и значения интенсивности, полученные из исходного набора данных VII. Для формирования выборки использовались все имеющиеся в наборе данных SEVIR события категории ОЯП — 3,9 тыс. последовательностей, а также осадки малой и средней интенсивности в количестве 4 тыс. последовательностей. Для задачи наукастинга полей осадков обучающая выборка формировалась исходя из условия, при котором все значения поля VII меньше 5 или равные 255 (Veillette et al., 2020) приравниваются к 0, а все остальные — к 1. Для наукастинга значений интенсивности измерения VII нормировались в диапазоне [0, 1].

Так как исходный размер изображений составляет 384×384 пикселей, выполнялось их сжатие бикубическим методом интерполяции, чтобы все тестируемые модели нейронных сетей помещались в оперативную память. При уменьшении разрешения на пиксель сохраняется окружающий контекст вокруг изображений и тестируемые модели ставятся в одинаковые условия.

Для выбора метода прогнозирования последовательности кадров был проведён эксперимент, в котором рассматривались два основных метода прогноза. В качестве архитектуры используется модель нейронной сети PredRNN, которая в целом показывает высокие результаты в работах многих авторов (Ma et al., 2022; Wang et al., 2017, 2018).

Пусть имеется входная последовательность кадров F_{t-n}, \dots, F_t, F_t , где F — кадр полей осадков в определённый момент времени t ; n — общая длина входной последовательности. Выходной последовательностью также является серия кадров F_{t+1}, \dots, F_{t+m} , где m — количество выходных кадров.

Первый метод прогноза заключается в использовании входной последовательности для получения одного нового кадра на заранее определённый фиксированный момент времени F_{t+m} , для которого обучается отдельная модель M нейронной сети:

$$F_{t+1} = M_1(F_{t-n}, \dots, F_{t-1}, F_t), \quad F_{t+2} = M_2(F_{t-n}, \dots, F_{t-1}, F_t), \quad F_{t+m} = M_m(F_{t-n}, \dots, F_{t-1}, F_t).$$

Другой вариант предполагает прогноз кадра F_{t+1} , который затем добавляется в конец исходной последовательности, после чего делается прогноз следующего кадра F_{t+2} :

$$F_{t+1} = M(F_{t-n}, \dots, F_{t-1}, F_t), \quad F_{t+2} = M(F_{t-n+1}, \dots, F_{t-1}, F_t, F_{t+1}), \quad F_{t+m} = M(F_{t-n+m}, \dots, F_{t+m-1}).$$

Входной информацией для нейронной сети является последовательность из шести кадров бинарного поля осадков размером 192×192 пикселей с временной дискретностью 10 мин,

обусловленной минимальным временным шагом между изображениями КА Himawari-8, -9 и их пространственным разрешением 2 км (исходное разрешение данных SEVIR — 1 км), для которого в дальнейшем планируется разработка алгоритма прогноза осадков применительно к территории Дальнего Востока России. Для первого метода прогноза в качестве выходных данных использовались шесть последующих сроков с 10-минутным интервалом, для второго — один последующий срок заблаговременностью 1 ч. Полученные результаты представлены в *табл. 2*. Поскольку в этом эксперименте прогнозируется только маска полей осадков, то в качестве метрик используются CSI и HSS.

Таблица 2. Оценка точности прогноза полей осадков

Вид прогноза	CSI	HSS
Прогноз одного кадра на 1 ч	0,586	0,588
Прогноз 10-минутных кадров на 1 ч	0,663	0,673

Дополнительно был проведён подобный эксперимент для наукастинга интенсивности осадков. Для этого в работе также использовались изображения поля VIJ, значения которого нормализованы в пределах [0, 1]. Формирование обучающей выборки полностью аналогично вышеупомянутому методу. Полученные результаты представлены в *табл. 3*. Поскольку в этом эксперименте прогнозируются значения интенсивности осадков, то в качестве метрик используются PSNR и SSIM.

Таблица 3. Оценка точности прогноза интенсивности осадков

Вид прогноза	PSNR	SSIM
Прогноз одного кадра на 1 ч	23,474	0,602
Прогноз 10-минутных кадров на 1 ч	23,729	0,625

Анализируя информацию из *табл. 2* и *3*, можно сделать вывод, что для наукастинга как полей осадков, так и значений интенсивности использование стратегии обучения с прогнозом только одного кадра на большой период заблаговременности (порядка 1 ч) имеет погрешность существенно большую, чем при прогнозе серии кадров с минимальным шагом по времени (10 мин в рассматриваемом случае). С учётом этих результатов последний вариант использовался в качестве метода прогноза в дальнейших экспериментах.

Прогноз полей осадков

Задача прогноза осадков может быть решена двумя способами: путём прогноза перемещения бинарных полей (например, отдельно для малой, средней и высокой интенсивности) либо прогноза непрерывной величины интенсивности осадков. Для начала рассмотрим первый вариант.

Используя входную последовательность из шести 10-минутных кадров и выходную — из двенадцати 10-минутных кадров (прогноз заблаговременностью 2 ч), авторы производили обучение вышеупомянутых нейронных сетей. Результаты тестирования обученных моделей для прогнозирования полей осадков представлены в *табл. 4*, а на *рис. 2* приведены примеры прогнозирования для каждой модели.

Из представленных в *табл. 4* результатов можно сделать вывод, что высокие значения метрик при прогнозе заблаговременностью 2 ч показали модели PredRNN-V2 (CSI = 0,584, HSS = 0,582) и MIM (CSI = 0,593, HSS = 0,580), а низкие значения метрик — модели PrecipLSTM (CSI = 0,568, HSS = 0,558) и MoDeRNN (CSI = 0,555, HSS = 0,552). Однако, ана-

лизируя информацию из *рис. 2*, где продемонстрированы примеры прогноза полей осадков для моделей MIM и MoDeRNN, можно визуально наблюдать лишь незначительные различия между ними.

Таблица 4. Метрики моделей для наукастинга полей осадков

Модель	CSI				HSS			
	+0,5 ч	+1,0 ч	+1,5 ч	+2,0 ч	+0,5 ч	+1,0 ч	+1,5 ч	+2,0 ч
ConvLSTM	0,780	0,700	0,638	0,587	0,798	0,708	0,635	0,572
TrajGRU	0,778	0,700	0,640	0,590	0,795	0,708	0,635	0,573
PredRNN	0,784	0,703	0,641	0,589	0,802	0,713	0,639	0,576
PredRNN++	0,785	0,701	0,638	0,584	0,804	0,715	0,643	0,580
PredRNN-V2	0,779	0,698	0,637	0,584	0,799	0,712	0,643	0,582
PrecipLSTM	0,784	0,696	0,625	0,568	0,804	0,710	0,626	0,558
MoDeRNN	0,778	0,691	0,616	0,555	0,800	0,707	0,621	0,552
MIM	0,786	0,707	0,645	0,593	0,804	0,716	0,643	0,580

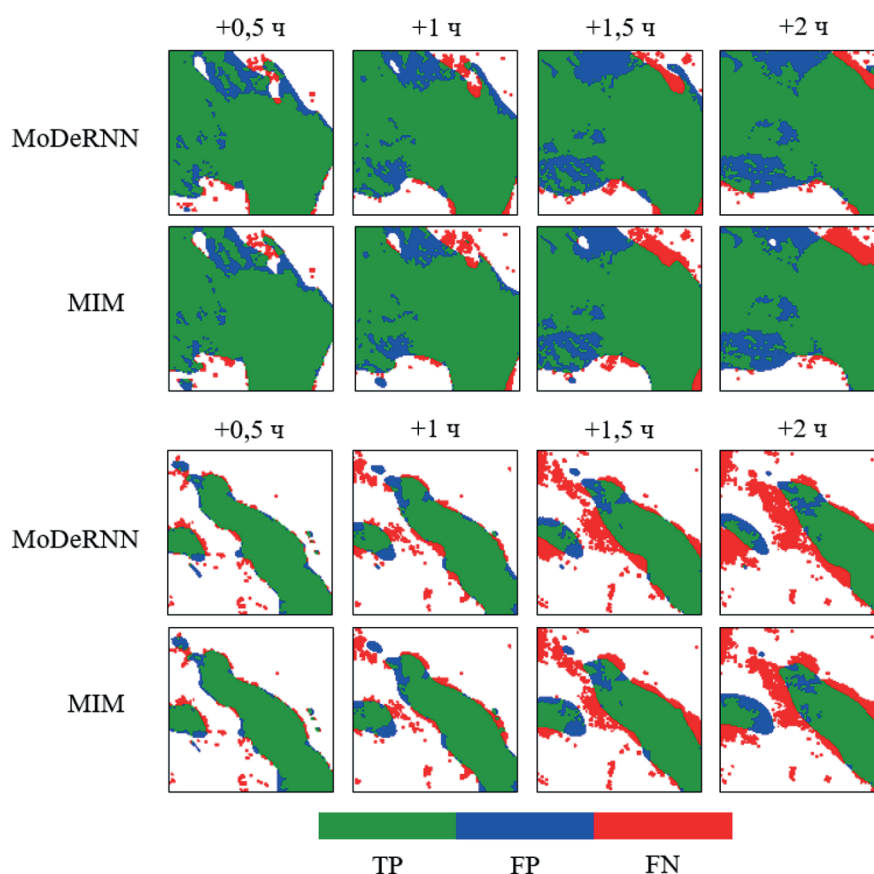


Рис. 2. Визуализация наукастинга полей осадков для архитектур MIM и MoDeRNN: TP — совпадения прогнозируемого и фактического поля; FP — ложный прогноз фактически отсутствующих осадков; FN — отсутствие осадков по модели при их наличии по фактическим данным

Прогноз интенсивности осадков

Задача прогноза мгновенных интенсивностей осадков является более сложной, поскольку в этом случае необходимо моделировать не только положение полей (т.е. вероятность нали-

чия осадков в каждом конкретном пикселе), но и непосредственно сами значения каждого пикселя.

В табл. 5 представлены результаты оценки точности для тестируемых моделей, а на рис. 3 — примеры эталонной последовательности интенсивности осадков по данным поля VII набора SEVIR (верхняя строка) и прогнозов из тестовой выборки для четырёх моделей, показавших наилучшие результаты. Поскольку в данном случае прогнозируется поле непрерывных значений, то в качестве метрик используются PSNR и SSIM.

Таблица 5. Метрики моделей для наукастинга интенсивности осадков

Модель	PSNR				SSIM			
	+0,5 ч	+1,0 ч	+1,5 ч	+2,0 ч	+0,5 ч	+1,0 ч	+1,5 ч	+2,0 ч
ConvLSTM	24,769	22,482	24,769	22,482	0,650	0,546	0,506	0,488
TrajGRU	24,682	22,293	24,682	22,293	0,652	0,549	0,507	0,488
PredRNN	26,175	23,729	26,175	23,729	0,725	0,625	0,571	0,536
PredRNN++	26,389	23,842	26,389	23,842	0,737	0,629	0,566	0,520
PredRNN-V2	25,795	23,614	25,795	23,614	0,704	0,601	0,533	0,484
PrecipLSTM	26,382	23,922	26,382	23,922	0,737	0,642	0,596	0,569
MoDeRNN	26,619	23,911	26,619	23,911	0,742	0,622	0,544	0,486
MIM	26,472	24,032	26,472	24,032	0,739	0,632	0,577	0,542

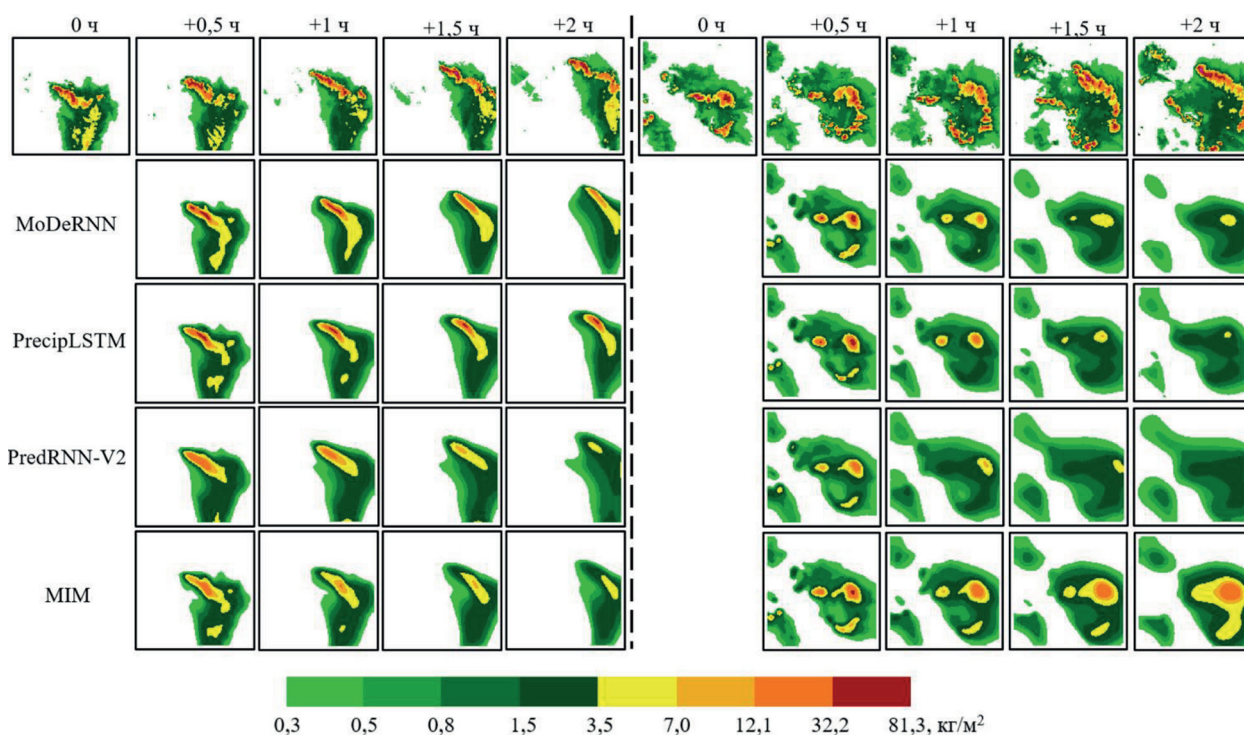


Рис. 3. Визуализация наукастинга интенсивности осадков для четырёх архитектур, показавших наилучшую точность по результатам тестирования

Как можно видеть из рис. 3, все представленные модели плохо прогнозируют высокие значения интенсивности на срок 1 ч и более. Одной из причин этого, по мнению авторов, является следующее: поскольку каждый вновь спрогнозированный кадр используется при прогнозе следующего, то происходит лавинообразное накопление ошибки. С другой стороны, как показал ранее проведённый эксперимент, прогноз одного кадра с большой заблаговре-

менностью также неэффективен, при том что в данном случае результаты прогноза не поступают на вход нейронных сетей. Предположительно, ошибку прогноза можно снизить за счёт использования ансамблевого подхода из нескольких моделей нейронных сетей, объединяя их результаты, например, применением обобщающей нейронной сети.

Сопоставляя точность для каждой модели из *табл. 5* с информацией из *рис. 3*, можно сделать вывод, что к наиболее оптимальным моделям для прогнозирования на срок более 1 ч можно отнести MoDeRNN и MIM.

Несмотря на обозначенные исследователями в своих работах попытки по улучшению механизма памяти для кадров дальнего порядка, информация из начала последовательности достаточно быстро теряется, поскольку модель рекуррентной сети излишне фокусируется на последней информации, что выражается в размытии кадров. Для решения этой проблемы, вероятно, требуется разработка иных структур моделей, сохраняющих детализацию прогноза на более поздних сроках.

Заключение

В настоящей работе представлен обзор существующих методов наукастинга осадков. Проведена апробация восьми различных архитектур нейронных сетей для решения задачи прогноза полей осадков и их интенсивности. По результатам проведённых экспериментальных расчётов выявлено, что поля осадков прогнозируются всеми моделями с приблизительно схожей точностью, в том числе и при визуальном анализе изображений. В то же время в задаче наукастинга интенсивности осадков лучшие результаты показали модели MoDeRNN и MIM.

Стоит отметить, что представленные алгоритмы несовершенные, что особенно ярко проявляется при прогнозе высоких значений интенсивности. При этом именно такие случаи представляют наибольший интерес у метеорологов. Исходя из результатов апробации, наиболее перспективным направлением для улучшения алгоритмов прогноза представляется разработка вспомогательных рекуррентных ячеек, позволяющих выборочно запоминать локальные явления на серии изображений. Подобное улучшение позволит использовать их, например, для территории Дальнего Востока России, где преобладает климат муссонного характера с высокой интенсивностью осадков в тёплый период года.

Исследование выполнено при финансовой поддержке гранта Российского научного фонда № 23-77-00011, <https://rscf.ru/project/23-77-00011/>.

Литература

1. Кузнецова В. П. Опасные гидрометеорологические явления северных регионов в условиях наблюдаемого изменения климата // Геоморфология и физ. география Сибири в XXI в. 2020. С. 104–108.
2. Ansari S., Greco S. D., Kearns E. et al. Unlocking the potential of NEXRAD data through NOAA's Big Data Partnership // Bull. American Meteorological Society. 2018. V. 99. No. 1. P. 189–204. DOI: 10.1175/BAMS-D-16-0021.1.
3. Cho K., Merrienboer B., Gulcehre C. et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation // arXiv preprint. arXiv:1406.1078. 2014. 15 p. DOI: 10.48550/arXiv.1406.1078.
4. Forecast verification: a practitioner's guide in atmospheric science / eds. I. T. Jolliffe, D. B. Stephenson. Chichester: John Wiley and Sons, 2012. 296 p.
5. Franch G., Maggio V., Coviello L. et al. TAASRAD19, a high-resolution weather radar reflectivity dataset for precipitation nowcasting // Scientific Data. 2020. V. 7. No. 1. Article 234. DOI: 10.1038/s41597-020-0574-8.
6. Gao Z., Shi X., Wang H. et al. Deep learning and the weather forecasting problem: Precipitation nowcasting // Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences. 2021. P. 218–239. DOI: 10.1002/9781119646181.ch15.
7. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation. 1997. V. 9. No. 8. P. 1735–1780. DOI: 10.1162/neco.1997.9.8.1735.

8. *Huynh-Thu Q., Ghanbari M.* Scope of validity of PSNR in image/video quality assessment // *Electronics Letters*. 2008. V. 44. No. 13. P. 800–801. DOI: 10.1049/el:20080522.
9. *Lecun Y., Bengio Y.* Convolutional networks for images, speech, and time series // *The Handbook of Brain Theory and Neural Networks*. 1995. V. 3361. No. 10. 14 p.
10. *Liu Y., Xi D.-G., Li Z.-L. et al.* A new methodology for pixel-quantitative precipitation nowcasting using a pyramid Lucas Kanade optical flow approach // *J. Hydrology*. 2015. V. 529. P. 354–364. DOI: 10.1016/j.jhydrol.2015.07.042.
11. *Locatello F., Weissenborn D., Unterthiner T., Mahendran A., Heigold G., Uszkorei J., Dosovitskiy A., Kipf T.* Object-centric learning with slot attention // *Advances in Neural Information Processing Systems*. 2020. V. 33. P. 11525–11538.
12. *Luong M. T., Pham H., Manning C. D.* Effective approaches to attention-based neural machine translation // *arXiv preprint. arXiv:1508.04025*. 2015. 11 p. DOI: 10.48550/arXiv.1508.04025.
13. *Ma Z., Zhang H., Liu J.* MS-RNN: A flexible multi-scale framework for spatiotemporal predictive learning // *arXiv preprint. arXiv:2206.03010*. 2022. 16 p. DOI: 10.48550/arXiv.2206.03010.
14. *Ma Z., Wang G., Yao J. et al.* An Improved U-Net Model Based on Multi-Scale Input and Attention Mechanism: Application for Recognition of Chinese Cabbage and Weed // *Sustainability*. 2023. V. 15. No. 7. Article 5764. DOI: 10.3390/su15075764.
15. *Moskolai W. R., Abdou W., Dipanda A. et al.* Application of deep learning architectures for satellite image time series prediction: A review // *Remote Sensing*. 2021. V. 13. No. 23. Article 4822. DOI: 10.3390/rs13234822.
16. *Pulkkinen S., Nerini D., Perez Hortal A. A. et al.* Pysteps: An open-source Python library for probabilistic precipitation nowcasting (v1.0) // *Geoscientific Model Development*. 2019. V. 12. No. 10. P. 4185–4219. DOI: 10.5194/gmd-12-4185-2019.
17. *Ramsauer T., Weiß T., Marzahn P.* Comparison of the GPM IMERG final precipitation product to RADOLAN weather radar data over the topographically and climatically diverse Germany // *Remote Sensing*. 2018. V. 10. No. 12. Article 2029. DOI: 10.3390/rs10122029.
18. *Recurrent neural networks: design and applications* / eds. L. Medsker, L. C. Jain. Boca Raton: CRC press, 1999. 416 p. <https://doi.org/10.1201/9781003040620>.
19. *Schaefer J. T.* The critical success index as an indicator of warning skill // *Weather and Forecasting*. 1990. V. 5. No. 4. P. 570–575. DOI: 10.1175/1520-0434(1990)005<0570:TCSIAA>2.0.CO;2.
20. *Shi X., Chen Z., Wang H., Yeung D. Y., Wong W. K., Woo W. C.* Convolutional LSTM network: A machine learning approach for precipitation nowcasting // *Advances in Neural Information Processing Systems*. 2015. V. 28. 9 p.
21. *Shi X., Gao Z., Lausen L., Wang H., Yeung D. Y., Wong W. K., Woo W. C.* Deep learning for precipitation nowcasting: A benchmark and a new model // *Advances in Neural Information Processing Systems*. 2017. V. 30. 9 p.
22. *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*. 2020. V. 33. P. 22009–22019.
23. *Wang Y., Long M., Wang J., Gao Z., Yu P. S.* Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms // *Advances in Neural Information Processing Systems*. 2017. V. 30. 9 p.
24. *Wang Y., Gao Z., Long M., Wang J., Yu P. S.* Predrnn++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning // *Intern. Conf. Machine Learning*. 2018. P. 5123–5132.
25. *Wang Y., Zhang J., Zhu H. et al.* Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics // *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition*. 2019. P. 9154–9162. DOI: 10.1109/CVPR.2019.00937.
26. *Wang Y., Wu H., Zhang J. et al.* Predrnn: A recurrent neural network for spatiotemporal predictive learning // *IEEE Trans. Pattern Analysis and Machine Intelligence*. 2022. V. 45. No. 2. P. 2208–2225. DOI: 10.1109/TPAMI.2022.3165153.
27. *Wang Z., Bovik A. C., Sheikh H. R. et al.* Image quality assessment: from error visibility to structural similarity // *IEEE Trans. Image Processing*. 2004. V. 13. No. 4. P. 600–612. DOI: 10.1109/TIP.2003.819861.
28. *Yao Z., Wang Y., Wu H. et al.* ModeRNN: Harnessing spatiotemporal mode collapse in unsupervised predictive learning // *IEEE Trans. Pattern Analysis and Machine Intelligence*. 2023. P. 1–16. DOI: 10.1109/TPAMI.2023.3293145.

Neural network approaches to precipitation nowcasting: A review and test of existing methods

M. O. Kuchma^{1,2}, S. I. Malkovsky¹, A. I. Andreev^{1,2}, V. D. Bloshchinsky^{1,2}

¹ *Computing Center FEB RAS, Khabarovsk 680000, Russia*
E-mail: a.andreev@dvrpod.ru

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

In recent years, there has been a growing interest among researchers and meteorological agencies in different countries in the field of accurate current weather forecasting using ground-based and satellite observation systems. In this regard, this paper provides an overview of recent advances in the field of current weather forecasting. In particular, modern neural network nowcasting methods are considered to solve the problem of extrapolating a sequence of digital matrices containing information about precipitation rate from previous observation dates. In this case, special attention is paid to the possibility of forecasting precipitation where data from geostationary spacecraft is used as the main source of information, which is due to the large territorial coverage, especially for remote areas. Using the publicly available SEVIR dataset, which combines ground-based and satellite observations of precipitation and hazardous weather events, the authors tested selected neural network architectures to solve the nowcasting problem. Conclusions are drawn about the possibility of using this neural network models for current weather forecasting in the Far Eastern region of Russia.

Keywords: nowcasting, current weather forecast, precipitation, artificial intelligence, machine learning, neural networks, hydrometeorology

Accepted: 18.10.2023

DOI: 10.21046/2070-7401-2023-20-6-35-48

References

1. Kuznetsova V. P., Dangerous hydrometeorological phenomena in the northern regions in the context of observed climate change, *Geomorfologiya i fizicheskaya geografiya Sibiri v XXI veke* (Geomorphology and physical geography of Siberia in the 21st century), 2020, pp. 104–108 (in Russian).
2. Ansari S., Greco S. D., Kearns E. et al., Unlocking the potential of NEXRAD data through NOAA's Big Data Partnership, *Bull. American Meteorological Society*, 2018, Vol. 99, No. 1, pp. 189–204, DOI: 10.1175/BAMS-D-16-0021.1.
3. Cho K., Merriënboer B., Gulcehre C. et al., Learning phrase representations using RNN encoder-decoder for statistical machine translation, *arXiv preprint, arXiv: 1406.1078*, 2014, 15 p., DOI: 10.48550/arXiv.1406.1078.
4. *Forecast verification: a practitioner's guide in atmospheric science*, I. T. Jolliffe, D. B. Stephenson (eds.), Chichester: John Wiley and Sons, 2012, 296 p.
5. Franch G., Maggio V., Coviello L. et al., TAASRAD19, a high-resolution weather radar reflectivity dataset for precipitation nowcasting, *Scientific Data*, 2020, Vol. 7, No. 1, Article 234, DOI: 10.1038/s41597-020-0574-8.
6. Gao Z., Shi X., Wang H. et al., Deep learning and the weather forecasting problem: Precipitation nowcasting, *Deep Learning for the Earth Sciences: A Comprehensive Approach to Remote Sensing, Climate Science, and Geosciences*, 2021, pp. 218–239, DOI: 10.1002/9781119646181.ch15.
7. Hochreiter S., Schmidhuber J., Long short-term memory, *Neural Computation*, 1997, Vol. 9, No. 8, pp. 1735–1780, DOI: 10.1162/neco.1997.9.8.1735.
8. Huynh-Thu Q., Ghanbari M., Scope of validity of PSNR in image/video quality assessment, *Electronics Letters*, 2008, Vol. 44, No. 13, pp. 800–801, DOI: 10.1049/el:20080522.
9. Lecun Y., Bengio Y., Convolutional networks for images, speech, and time series, *The Handbook of Brain Theory and Neural Networks*, 1995, Vol. 3361, No. 10, 14 p.
10. Liu Y., Xi D.-G., Li Z.-L. et al., A new methodology for pixel-quantitative precipitation nowcasting using a pyramid Lucas Kanade optical flow approach, *J. Hydrology*, 2015, Vol. 529, pp. 354–364, DOI: 10.1016/j.jhydrol.2015.07.042.
11. Locatello F., Weissenborn D., Unterthiner T., Mahendran A., Heigold G., Uszkorei J., Dosovitskiy A., Kipf T., Object-centric learning with slot attention, *Advances in Neural Information Processing Systems*, 2020, Vol. 33, pp. 11525–11538.

12. Luong M. T., Pham H., Manning C. D., Effective approaches to attention-based neural machine translation, *arXiv preprint, arXiv: 1508.04025*, 2015, 11 p., DOI: 10.48550/arXiv.1508.04025.
13. Ma Z., Zhang H., Liu J., MS-RNN: A flexible multi-scale framework for spatiotemporal predictive learning, *arXiv preprint, arXiv: 2206.03010*, 2022, 16 p., DOI: 10.48550/arXiv.2206.03010.
14. Ma Z., Wang G., Yao J. et al., An Improved U-Net Model Based on Multi-Scale Input and Attention Mechanism: Application for Recognition of Chinese Cabbage and Weed, *Sustainability*, 2023, Vol. 15, No. 7, Article 5764, DOI: 10.3390/su15075764.
15. Moskolai W. R., Abdou W., Dipanda A. et al., Application of deep learning architectures for satellite image time series prediction: A review, *Remote Sensing*, 2021, Vol. 13, No. 23, Article 4822, DOI: 10.3390/rs13234822.
16. Pulkkinen S., Nerini D., Perez Hortal A. A. et al., Pysteps: An open-source Python library for probabilistic precipitation nowcasting (v1. 0), *Geoscientific Model Development*, 2019, Vol. 12, No. 10, pp. 4185–4219, DOI: 10.5194/gmd-12-4185-2019.
17. Ramsauer T., Weiß T., Marzahn P., Comparison of the GPM IMERG final precipitation product to RADOLAN weather radar data over the topographically and climatically diverse Germany, *Remote Sensing*, 2018, Vol. 10, No. 12, Article 2029, DOI: 10.3390/rs10122029.
18. *Recurrent neural networks: design and applications*, L. Medsker, L. C. Jain (eds.), Boca Raton: CRC press, 1999, 416 p., <https://doi.org/10.1201/9781003040620>.
19. Schaefer J. T., The critical success index as an indicator of warning skill, *Weather and Forecasting*, 1990, Vol. 5, No. 4, pp. 570–575, DOI: 10.1175/1520-0434(1990)005<0570:TCSIAA>2.0.CO;2.
20. Shi X., Chen Z., Wang H., Yeung D. Y., Wong W. K., Woo W. C., Convolutional LSTM network: A machine learning approach for precipitation nowcasting, *Advances in Neural Information Processing Systems*, 2015, Vol. 28, 9 p.
21. Shi X., Gao Z., Lausen L., Wang H., Yeung D. Y., Wong W. K., Woo W. C., Deep learning for precipitation nowcasting: A benchmark and a new model, *Advances in Neural Information Processing Systems*, 2017, Vol. 30, 9 p.
22. 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*, 2020, Vol. 33, pp. 22009–22019.
23. Wang Y., Long M., Wang J., Gao Z., Yu P. S., Predrnn: Recurrent neural networks for predictive learning using spatiotemporal LSTMs, *Advances in Neural Information Processing Systems*, 2017, Vol. 30, 9 p.
24. Wang Y., Gao Z., Long M., Wang J., Yu P. S., Predrnn++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning, *Intern. Conf. Machine Learning*, 2018, pp. 5123–5132.
25. Wang Y., Zhang J., Zhu H. et al., Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics, *Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition*, 2019, pp. 9154–9162, DOI: 10.1109/CVPR.2019.00937.
26. Wang Y., Wu H., Zhang J. et al., Predrnn: A recurrent neural network for spatiotemporal predictive learning, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2022, Vol. 45, No. 2, pp. 2208–2225, DOI: 10.1109/TPAMI.2022.3165153.
27. Wang Z., Bovik A. C., Sheikh H. R. et al., Image quality assessment: from error visibility to structural similarity, *IEEE Trans. Image Processing*, 2004, Vol. 13, No. 4, pp. 600–612, DOI: 10.1109/TIP.2003.819861.
28. Yao Z., Wang Y., Wu H. et al., ModeRNN: Harnessing spatiotemporal mode collapse in unsupervised predictive learning, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2023, pp. 1–16, DOI: 10.1109/TPAMI.2023.3293145.