



Научная статья

УДК 632.111.51+632.111.52+004.852

doi: 10.55186/25876740_2025_68_7_958

ДОЛГОСРОЧНОЕ ПРОГНОЗИРОВАНИЕ ЗАМОРОЗКОВ С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В СИСТЕМЕ ТОЧНОГО ЗЕМЛЕДЕЛИЯ

**А.Е. Молин, О.А. Митрофанова, В.М. Буре,
Е.П. Митрофанов**

Санкт-Петербургский государственный университет,
Санкт-Петербург, Россия

Аннотация. Целью исследования являлось обучение и сравнительный анализ моделей машинного обучения (МО) и глубокого обучения (ГО) для долгосрочного прогнозирования минимальных суточных температур (заморозков) — ключевого агрометеорологического риска, влияющего на продуктивность сельскохозяйственных культур. Исследование выполнено на основе данных метеостанций Санкт-Петербурга и Ленинградской области. Для прогнозирования на год вперед, что соответствует потребностям оперативного агропроизводственного планирования (сроки сева, уборки, защитных мероприятий), использовались 8 методов: ForecasterAutoreg, Random Forest, Support Vector Regression (SVR), XGBoost, сверточная нейронная сеть (CNN), SimpleRNN, Gated Recurrent Unit (GRU) и Long Short-Term Memory (LSTM). Анализ проводился на двух датасетах: за периоды 1936-2024 и 1881-1995 годы. Качество моделей оценивалось по метрикам MAE, MSE, RMSE, R2 и скорректированному R2. Наиболее точные результаты на основном датасете (1936-2024) показала модель LSTM: MAE 2,9, MSE 14,661, R2 0,789. На архивных данных (1881-1995) лучшие метрики продемонстрировал метод SVR (MAE 3,461, R2 0,775). Установлено, что модели ГО (LSTM, GRU, CNN) в целом превосходят классические методы МО на современных данных. Метод LSTM признан наиболее эффективным для интеграции в системы точного земледелия и агромониторинга региона для заблаговременного планирования агротехнологических мероприятий по защите посевов от заморозков, оптимизации севооборотов и минимизации рисков потери урожая.

Ключевые слова: долгосрочное агрометеорологическое прогнозирование, заморозки, методы машинного обучения, методы глубокого обучения, точное земледелие, управление агропроизводством, принятие решений в растениеводстве

Благодарности: исследование выполнено за счёт гранта Российского научного фонда № 24-21-00231, <http://rscf.ru/project/24-21-00231>.

Original article

LONG-TERM FROST FORECASTING USING MACHINE LEARNING METHODS IN A PRECISION FARMING SYSTEM

**А.Е. Molin, О.А. Mitrofanova, В.М. Bure,
Е.П. Mitrofanov**

Saint Petersburg State University, St. Petersburg, Russia

Abstract. The purpose of the study was to train and compare machine learning (ML) and deep learning (DL) models for long-term forecasting of minimum daily temperatures (frosts) — a key agrometeorological risk affecting crop productivity. The study was based on data from weather stations in St. Petersburg and the Leningrad region. To predict the year ahead, which aligns with the needs of operational agricultural production planning (sowing dates, harvest timing, protective measures), 8 methods were used: ForecasterAutoreg, Random Forest, Support Vector Regression (SVR), XGBoost, Convolutional Neural Network (CNN), SimpleRNN, Gated Recurrent Unit (GRU) and Long Short-Term Memory (LSTM). The analysis was carried out on two datasets: for the periods 1936-2024 and 1881-1995. The quality of the models was assessed using the metrics MAE, MSE, RMSE, R2 and adjusted R2. The LSTM model showed the most accurate results on the main dataset (1936-2024): MAE 2.9, MSE 14.661, R2 0.789. The SVR method (MAE 3.461, R2 0.775) demonstrated the best metrics based on archived data (1881-1995). It has been established that DL models (LSTM, GRU, CNN) generally outperform classical ML methods based on modern data. The LSTM method is recognized as the most effective for integration into precision farming systems and agricultural monitoring in the region for the advance planning of agrotechnological measures to protect crops from frost, optimization of crop rotation systems, and minimization of crop loss risks.

Keywords: long-term agrometeorological forecasting, freezing, machine learning methods, deep learning methods, precision farming, agricultural management, decision-making in crop production

Acknowledgments: the study was supported by the Russian Science Foundation grant No. 24-21-00231, <https://rscf.ru/en/project/24-21-00231>.

Введение. В современных условиях долгосрочное прогнозирование метеорологических рисков приобретает растущую значимость для оптимизации планирования и принятия управлений решений в точном земледелии. Данная тенденция связана с наблюдаемым ростом среднесуточных температур глобального характера, а также с учащением экстремальных погодных явлений [1]. В рамках настоящего исследования в качестве одного из ключевых метеорисков рассматриваются заморозки (минимальные суточные температуры). Примечательно, что, несмотря на общую тенденцию к потеплению, риск возникновения заморозков не нивелируется, а напротив, возрастает. В частности, исследование [2] демонстрирует

установленную корреляцию между глобальным изменением климата и потерями урожайности, обусловленными весенними заморозками. Для сельского хозяйства Северо-Западного региона России весенние и осенние заморозки представляют собой один из наиболее существенных агроклиматических рисков. Воздействие отрицательных температур на сельскохозяйственные культуры в критические фазы вегетации (такие как цветение, формирование завязи) может приводить к значительному снижению урожайности и прямым экономическим потерям.

Долгосрочный прогноз агрометеорисков позволяет аграриям оптимизировать сроки проведения полевых работ, такие как посев яровых культур и уборка урожая, а также заблаговре-

менно планировать меры активной защиты растений от заморозков, планировать севооборот и т.п. Интеграция точных прогнозов в системы поддержки принятия решений (СППР) для сельского хозяйства способствует минимизации потерь урожая, рациональному использованию ресурсов и в конечном счете повышению производительности агропромышленного комплекса.

Помимо традиционных и хорошо изученных методов прогнозирования временных рядов [3], в научных исследованиях получают распространение технологии искусственного интеллекта. Они успешно применяются, в том числе в задачах мониторинга заморозков [4]. Параллельно возрастает востребованность ГИС-систем, оснащенных функционалом прогнозирования [5].



Если подходы на основе глубокого обучения уже продемонстрировали высокую эффективность в задачах краткосрочного прогнозирования метеорологических параметров [6], то долгосрочное прогнозирование, остающееся крайне актуальным для точного земледелия, продолжает активно развиваться. Значительная часть исследований в данной области опирается на классические методы машинного обучения, такие как ARIMA и SARIMA [7, 8]. В последние годы для долгосрочного прогнозирования погодных условий также активно разрабатываются подходы с применением технологий XGBoost [7], LSTM [9, 10], Transfer [11] и других.

Целью настоящего исследования являлось обучение и сравнительный анализ нескольких моделей машинного обучения для решения задачи долгосрочного агрометеорологического прогнозирования — предсказания минимальных температур (заморозков). Разработка моделей направлена на их последующую интеграцию в систему точного земледелия на примере региона Санкт-Петербурга для заблаговременного планирования агротехнических мероприятий, таких как определение оптимальных сроков сева яровых и уборки урожая, регулирование фенологических фаз развития растений, управление рисками потери урожая, обусловленными воздействием низких температур на сельскохозяйственные культуры.

Объекты и методы. Агрометеорологическим объектом исследования выступают минимальные суточные температуры воздуха в приземном слое, прямо определяющие риск возникновения заморозков — одного из наиболее опасных для растениеводства агрометеорологических явлений. Для сельского хозяйства Северо-Западного региона заморозки представляют особую угрозу в периоды весенней вегетации (май-начало июня) и осеннего созревания урожая (сентябрь), так как воздействие отрицательных температур на сельскохозяйственные культуры в критические фенофазы (такие как цветение, формирование завязи, налив зерна) может приводить к значительному снижению урожайности и прямым экономическим потерям.

Для решения задачи долгосрочного прогнозирования заморозков на горизонте одного года, что соответствует потребностям оперативного планирования в сельскохозяйственном предприятии (например, для выбора морозустойчивых сортов, планирования севооборота и составления агротехнологических карт), были сформированы два датасета:

- С измерениями за период с 1 января 1936 года по 8 августа 2024 года, полученные с использованием сервиса организации NOAA (National Oceanic and Atmospheric Administration). Датасет разделен на три части: для обучения (с 1 января 1936 по 31 декабря 2021), для верификации (с 1 января 2023 по 8 августа 2024) и для тестирования (с 1 января 2022 по 31 декабря 2022).
- С измерениями за период с 1 января 1881 года по 31 декабря 1995 года, полученные на архивном ресурсе. Датасет также разделен на три части: для обучения (с 1 января 1881 по 31 декабря 1993), для верификации (с 1 января 1995 по 31 декабря 1995) и для тестирования (с 1 января 1994 по 31 декабря 1994).

Пропущенные даты в обучающей части обоих датасетов были удалены, анализируемый регион метеостанций — Санкт-Петербург, что

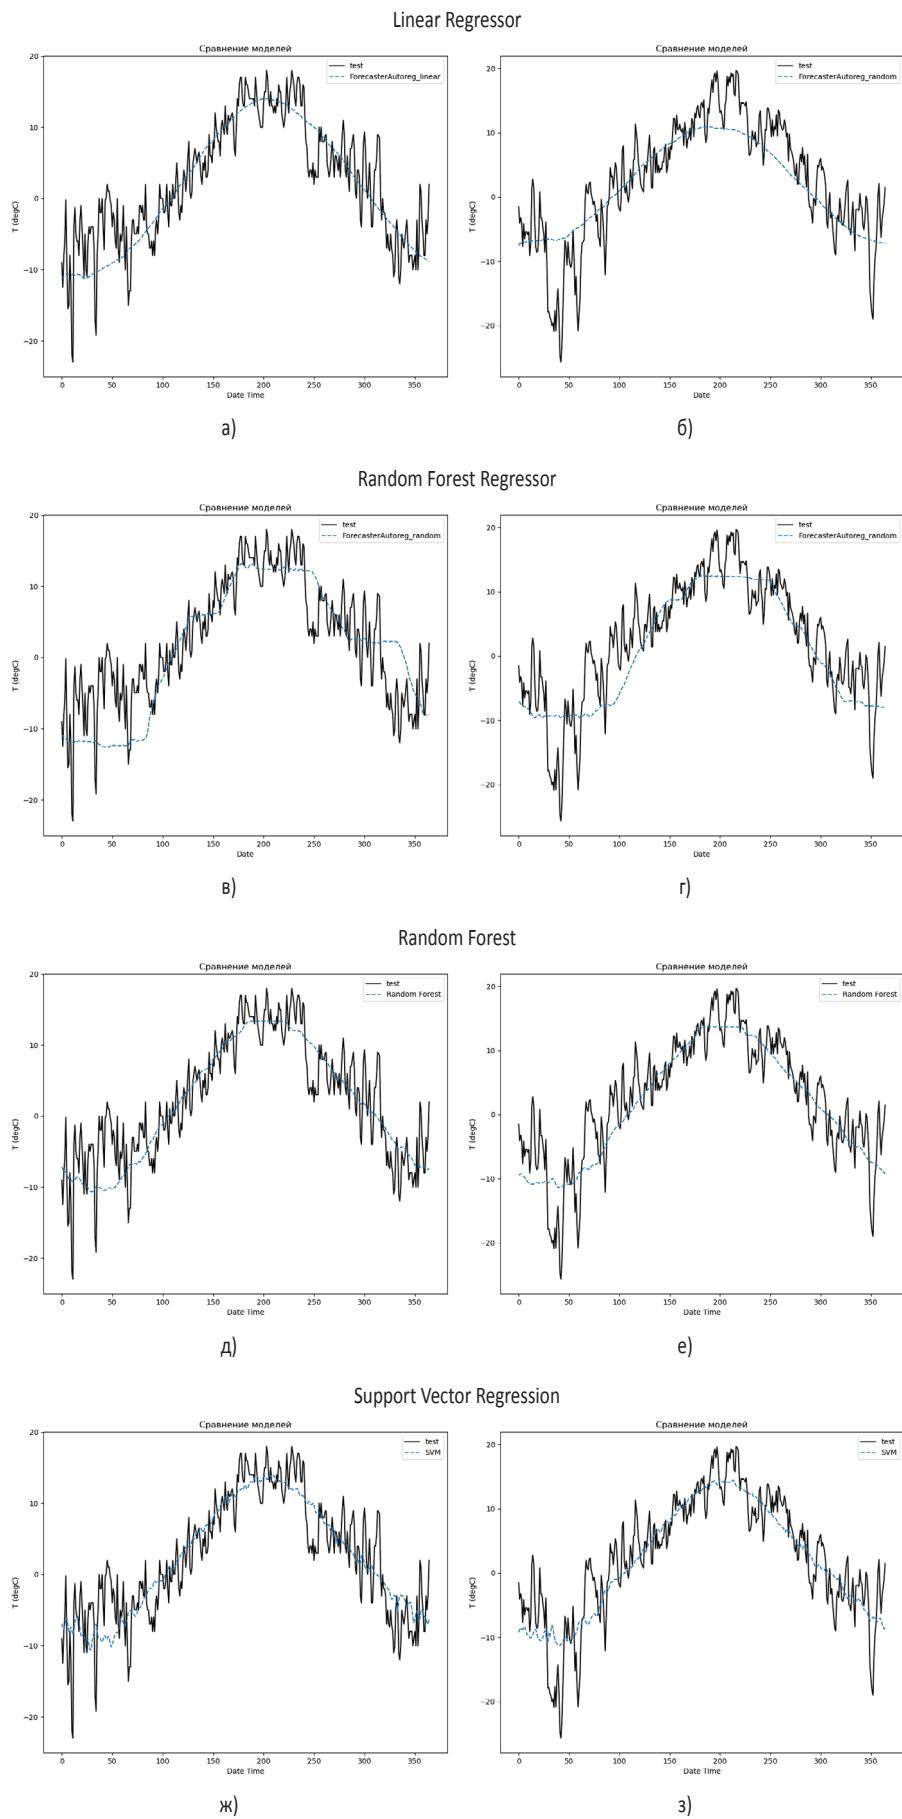


Рисунок 1. Сравнение предсказанной минимальной температуры на 1 год с реальной:
 а), в), д), ж) — для первого датасета (за период с 1936 до 2024 г.);
 б), г), е), 3) — для второго датасета (за период с 1881 до 1995 г.)

Figure 1. Comparison of the predicted minimum temperature for 1 year with the real one:
 а), с), е), г) — for the first dataset (for the period from 1936 to 2024);
 б), д), ф), 3) — for the second dataset (for the period from 1881 to 1995)



репрезентативно для агроклиматических условий Ленинградской области.

Для построения моделей прогнозирования были использованы 4 метода машинного обучения: ForecasterAutoreg, Random Forest, Support Vector Regression, XGBoost; а также 4 метода глубокого обучения: Convolutional Neural Network, SimpleRNN, GRU и LSTM. При обучении нейросетей использовался оптимизатор SGD и функция потерь MSE. Начальная скорость обучения была установлена равной 0,1. Были использованы методы аддитивного обучения и ранней остановки, чтобы уменьшить ошибки и избежать переобучения. В случае, если при проверке на выборке верификации после каждой эпохи результат функции потерь четыре раза подряд не уменьшался, скорость обучения умножалась на 0,25. Максимальное количество эпох было установлено на 100, но после пятикратного изменения скорости обучения обучение нейросетей прекращалось.

Для анализа точности полученных прогнозов были использованы следующие метрики:

- Средняя абсолютная ошибка (Mean Absolute Error) показывает, насколько в среднем прогнозы модели отклоняются от реальных значений по модулю

$$MAE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|,$$

где y_i — значения наблюдаемой переменной; $\hat{y}_i = f(x_1, x_2, \dots, x_k)$ — модельные значения, построенные по оцененным параметрам; N — количество наблюдений.

- Среднеквадратичная ошибка (Mean Squared Error)

$$MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2.$$

- Корень из среднеквадратичной ошибки (Root Mean Squared Error)

$$RMSE(y, \hat{y}) = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}.$$

- Коэффициент детерминации R^2 показывает, какая доля дисперсии целевых значений объясняется моделью:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2},$$

где \bar{y}_i — среднее значение по экспериментальным (наблюдаемым) данным. В отличие от предыдущих метрик, в данном случае более высокое значение метрики говорит о лучшем качестве модели.

- Скорректированный коэффициент детерминации (R^2 adj) — коэффициент детерминации, скорректированный на число факторов, и не чувствительный к числу регрессоров, рассчитывается по формуле

$$R^2 \text{adj} = 1 - (1 - R^2) \frac{N-1}{N-k},$$

где k — количество факторов, включенных в модель.

Результаты и их обсуждение. Для каждого из двух сформированных наборов метеоданных были обучены 9 моделей прогнозирования (на основе методов ForecasterAutoreg, Random Forest, Support Vector Regression, XGBoost, Convolutional Neural Network, SimpleRNN, GRU и LSTM). Для авторегрессионных подходов использовалась библиотека Skforecast (язык программирования Python), позволяющая применять любой регрессор для рекурсивного многошагового прогноза. В настоящем исследовании за основу брались линейный регрессор и случайный лес: Linear Regressor и Random Forest Regressor.

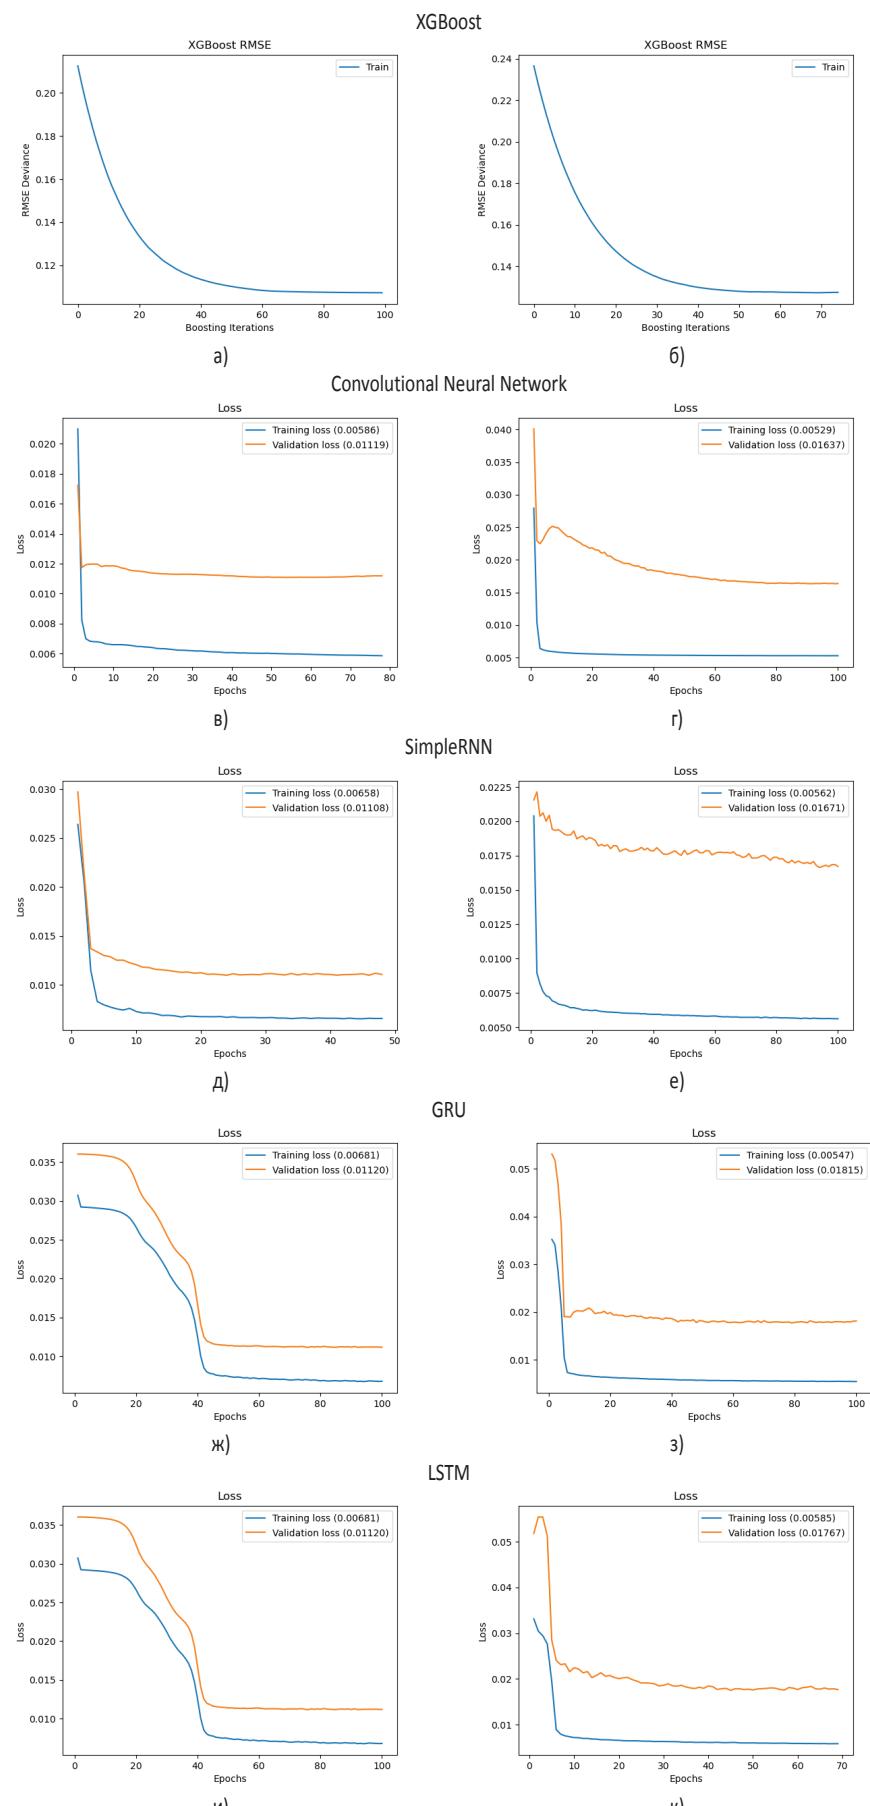


Рисунок 2. Функции потерь при обучении моделей прогнозирования на основе пяти методов:

а), в), д), ж), и) — для первого датасета (за период с 1936 до 2024 гг.);

б), г), е), з), к) — для второго датасета (за период с 1881 до 1995 гг.)

Figure 2. Loss functions for training forecasting models based on five methods:

а), с), е), г), и) — for the first dataset (for the period from 1936 to 2024);

б), д), ф), г), к) — for the second dataset (for the period from 1881 to 1995)



Таблица 1. Динамика объемов импорта
Table 1. Dynamics of import volumes

Метод	Метрики				
	MAE	MSE	RMSE	R ²	R ² adj
Датасет 1 (с 1936 до 2024 гг.)					
Forecaster Linear Regressor	3,164	17,08	4,133	0,754	0,754
Forecaster Random Regressor	4,116	28,568	5,345	0,589	0,588
Random Forest	3,165	17,041	4,128	0,755	0,754
SVM	3,117	16,589	4,073	0,762	0,761
XGBoost	3,149	16,119	4,015	0,768	0,768
Convolutional Neural Network	2,936	14,886	3,858	0,786	0,785
SimpleRNN	2,925	14,724	3,837	0,788	0,788
GRU	2,932	14,662	3,829	0,789	0,789
LSTM	2,9	14,661	3,829	0,789	0,789
Датасет 2 (с 1881 до 1995 гг.)					
Forecaster Linear Regressor	3,947	26,647	5,162	0,703	0,702
Forecaster Random Regressor	4,094	27,06	5,202	0,699	0,698
Random Forest	3,624	21,549	4,642	0,76	0,759
SVM	3,461	20,234	4,498	0,775	0,775
XGBoost	3,729	22,417	4,735	0,75	0,75
Convolutional Neural Network	3,447	20,657	4,545	0,77	0,769
SimpleRNN	3,447	22,278	4,72	0,752	0,751
GRU	3,416	21,185	4,603	0,764	0,763
LSTM	3,413	22,024	4,693	0,755	0,754

Для четырех моделей прогнозирования (на основе методов Linear Regressor, Random Forest Regressor, Random Forest, Support Vector Regression) использовались только две выборки из каждого датасета: для обучения и для тестиирования. На рис. 1 представлены результаты сравнения предсказанной минимальной температуры с реальной, графики приводятся для всех четырех моделей для каждого набора метеоданных, прогнозируемый период — 1 год.

Для остальных пяти моделей прогнозирования (на основе методов XGBoost, Convolutional Neural Network, SimpleRNN, GRU и LSTM) использовались все три выборки каждого набора метеоданных: для обучения, верификации и тестиирования. Помимо сравнения прогнозных и реальных значений также были проанализированы функции потерь во время обучения для каждой модели для обоих датасетов (рис. 2). Как видно на графиках, для второго датасета, состоящего из архивной информации, функции потерь имеют больше расхождений, что может быть связано с несколькими факторами: долгосрочность прогноза, нестационарность исходного параметра, пропуски в данных.

С целью проверки качества полученных результатов для каждой обученной модели были рассчитаны основные метрики: Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), коэффициент детерминации R², Скорректированный коэффициент детерминации R²adj (табл. 1).

Как видно из рисунков и таблицы, для второго архивного набора данных результаты оказались более неравномерны. Несмотря на то, что по метрикам наилучшей оказалась модель прогнозирования, построенная на основе метода SVM, преждевременно рекомендовать ее для использования в задачах долгосрочного про-

гнозирования агрометеорисков. При этом результаты, полученные на первом датасете, более достоверны. Методы глубокого обучения оказались более эффективными в сравнении с методами машинного обучения, наилучшей оказалась модель, обученная на основе метода LSTM.

Проведенный сравнительный анализ выявил ряд важных закономерностей, значимых для задач долгосрочного прогнозирования в точном земледелии:

1. *Преимущество моделей глубокого обучения.* Превосходство архитектур LSTM и GRU, а также сверточной нейронной сети на основном датасете (1936–2024 гг.) ожидаемо и согласуется с современными исследованиями [8, 9]. Эти модели представляются перспективными для работы с последовательностями и эффективно выявляют сложные нелинейные и долгосрочные временные зависимости в данных, что критически важно для прогнозирования погодных параметров, характеризующихся выраженной нестационарностью и сезонностью. Способность LSTM-сетей запоминать долгосрочные контексты позволяет им точнее моделировать годовые циклы температур и экстремальные явления, такие как заморозки.

2. *Влияние качества и объема данных на результат.* Существенное расхождение в результатах между двумя датасетами требует отдельного обсуждения. Более высокие ошибки и меньшая стабильность метрик для архивного набора (1881–1995 гг.) могут быть обусловлены несколькими факторами: 1) пропуски в данных; 2) исторические данные могли собираться различными инструментами и по отличным от современных методикам, что вносит дополнительную зашумленность в данные; 3) в рассмотренный период могли попасть различные климатические эпохи, что может приводить

к ухудшению обобщающей способности на длительных горизонтах прогноза.

3. *Эффективность «классических» методов.* Стоит отметить, что такие методы, как Support Vector Regression (SVM) и Random Forest, продемонстрировали конкурентоспособные, а в случае архивных данных даже лучшие результаты. Это указывает на то, что для конкретных задач, особенно при работе с зашумленными или неполными историческими данными, сложные модели глубокого обучения не всегда имеют безоговорочное преимущество. Высокая производительность SVM на втором датасете может объясняться ее устойчивостью к переобучению в условиях малого объема данных и способностью эффективно работать в высокомерных пространствах признаков.

4. *Практическое значение для точного земледелия.* С точки зрения внедрения в систему точного земледелия, наилучшие результаты, показанные LSTM-моделью на современных данных (набор 1), являются наиболее релевантными. Низкие значения MAE (~2.9°C) и высокий R² (~0.79) для годичного прогноза минимальных температур свидетельствуют о практической применимости модели для заблаговременного планирования агротехнических мероприятий. Полученный прогноз позволяет агрономам-технологам и фермерам более эффективно управлять рисками, связанными с весенними и осенними заморозками. На практике это выражается в оптимизации сроков посева яровых культур и уборочной компании, заблаговременном планировании мер активной защиты растений, а также в обоснованном выборе морозоустойчивых культур и сортов, что в конечном счете способствует экономии ресурсов и повышению рентабельности агробизнеса.

Заключение. Проведенное исследование демонстрирует высокий потенциал применения методов машинного и глубокого обучения для решения актуальной задачи долгосрочного прогнозирования заморозков в системе точного земледелия. Сравнительный анализ восьми различных моделей на двух независимых временных рядах метеоданных выявил устойчивое преимущество архитектур глубокого обучения, в частности модели LSTM, при работе с современными данными. Это позволяет рекомендовать именно данный подход для интеграции в системы агрометеорологического мониторинга и поддержки принятия управленческих решений.

Ключевым практическим результатом работы является подтверждение возможности построения эффективной модели прогнозирования минимальных температур на годичном горизонте. Несмотря на то, что абсолютная ошибка прогноза сохраняется на уровне 2.9–3.8°C, модель обеспечивает высокую объясняющую способность (R² = 0.79), что является ценным инструментом для заблаговременного планирования сельскохозяйственных работ и минимизации рисков потери урожая.

Перспективы дальнейших исследований видаются в развитии двух основных направлений. Во-первых, это обогащение модели дополнительными климатическими предикторами и агрономическими данными. Во-вторых, разработка ансамблевых моделей, сочетающих сильные стороны разных алгоритмов, что позволит нивелировать их индивидуальные недостатки и повысить общую надежность и точность долгосрочного прогноза агрометеорологических рисков.



**Список источников / References**

1. IPCC, 2012: Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change [Field, C.B., V. Barros, T.F. Stocker, D. Qin, D.J. Dokken, K.L. Ebi, M.D. Mastrandrea, K.J. Mach, G.-K. Plattner, S.K. Allen, M. Tignor, and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, UK, and New York, NY, USA, 582 pp.
2. Li X., Jiang D., Liu F. Winter soil warming exacerbates the impacts of Spring Low temperature stress on wheat // Journal of Agronomy and Crop Science. 2016. V. 202, no. 6. P. 554-563.
3. Mitrofanova O., Mitrofanov E., Blekanov I., Bure V., Molin A. Approach for long-term forecasting of frosts and droughts in smart agriculture // Agriculture Digitalization and Organic Production. ADOP 2024. Smart Innovation, Systems and Technologies, Springer, Singapore. 2024. V. 397. P. 35-46.
4. Hua W., Heinemann P., He L. Frost management in agriculture with advanced sensing, modeling, and artificial intelligent technologies: A review // Computers and Electronics in Agriculture. 2025. V. 231. Article 110027.
5. Eitzinger J., Daneu V., Kubu G., Thaler S., Trnka M., Schaumberger A., Schneider S., Tran T.M.A. Grid based monitoring and forecasting system of cropping conditions and risks by agrometeorological indicators in Austria — Agricultural Risk Information System ARIS // Climate Services. 2024. V. 34. Article 100478.
6. Harilal G.T., Dixit A., Quattrone G. Establishing hybrid deep learning models for regional daily rainfall time series forecasting in the United Kingdom // Engineering Applications of Artificial Intelligence. 2024. V. 133. Article 108581.
7. Guhan V., Raju A.D., Krishna R., Nagaratna K. Evaluating weather trends and forecasting with machine learning: Insights from maximum temperature, minimum temperature, and rainfall data in India // Dynamics of Atmospheres and Oceans. 2025. V. 110. Article 101562.
8. Hossain M.A., Rahman Md M., Hasan S.S., Mahmud A., Bai L. Analysis and forecasting of meteorological drought using PROPHET and SARIMA models deploying machine learning technique for southwestern region of Bangladesh // Environment and Sustainability Indicators. 2025. V. 27. Article 100761.
9. Hsu C.-C., Lin Y.-P. Incorporating long-term numerical weather forecast to quantify dynamic vulnerability of irrigation supply system: A case study of Shihmen Reservoir in Taiwan // Agricultural Water Management. 2024. V. 306. Article 109178.
10. Chen L., Liu X., Zeng C., He X., Chen F., Zhu B. Temperature prediction of seasonal frozen subgrades based on CEEMDAN-LSTM hybrid model // Sensors. 2022. V. 22. Article 5742.
11. Zhang D., Ma Y., Jiang A., Ren Y., Lin J., Peng Q., Jin T. Long-term water temperature forecasting in fish spawning grounds downstream of hydropower stations using machine learning // Sustainability. 2025. V. 17. Article 4514.

Информация об авторах:

Молин Александр Евгеньевич, кандидат технических наук, младший научный сотрудник, Санкт-Петербургский государственный университет, ORCID: <http://orcid.org/0009-0007-0833-7029>, a.molin@spbu.ru

Митрофанова Ольга Александровна, кандидат технических наук, доцент кафедры технологии программирования, старший научный сотрудник, Санкт-Петербургский государственный университет, ORCID: <https://orcid.org/0000-0002-7059-4727>, o.a.mitrofanova@spbu.ru

Буре Владимир Мансурович, доктор технических наук, профессор, профессор кафедры математической теории игр и статистических решений, ведущий научный сотрудник, Санкт-Петербургский государственный университет, ORCID: <http://orcid.org/0000-0001-7018-4667>, v.bure@spbu.ru

Митрофанов Евгений Павлович, кандидат технических наук, доцент кафедры технологии программирования, старший научный сотрудник, Санкт-Петербургский государственный университет, ORCID: <http://orcid.org/0000-0002-1967-5126>, e.mitrofanov@spbu.ru

Information about the authors:

Aleksandr E. Molin, candidate of technical sciences, junior researcher, Saint Petersburg State University, ORCID: <http://orcid.org/0009-0007-0833-7029>, a.molin@spbu.ru

Olga A. Mitrofanova, candidate of technical sciences, associate professor of department of programming technologies, senior researcher, Saint Petersburg State University, ORCID: <https://orcid.org/0000-0002-7059-4727>, o.a.mitrofanova@spbu.ru

Vladimir M. Bure, doctor of technical sciences, professor, professor of department of programming technologies, leading researcher, Saint Petersburg State University, ORCID: <http://orcid.org/0000-0001-7018-4667>, v.bure@spbu.ru

Eugenii P. Mitrofanov, candidate of technical sciences, associate professor of department of programming technologies, senior researcher, Saint Petersburg State University, ORCID: <http://orcid.org/0000-0002-1967-5126>, e.mitrofanov@spbu.ru

 o.a.mitrofanova@spbu.ru

Издательство «Электронная наука» выпускает научные журналы на русском и английском языках.

Нам доверяют авторы по всему миру. Количество наших читателей, в том числе и в Интернете, более **55 тысяч** человек ежемесячно.

ЖУРНАЛЫ ИЗДАТЕЛЬСТВА «ЭЛЕКТРОННАЯ НАУКА»

Международный журнал прикладных наук и технологий «INTEGRAL» издается 6 раз в год.

- Стратегический научный партнер журнала **«Государственный университет по землеустройству»**.
- **INTEGRAL** цитируется в РИНЦ, Google Scholar, КиберЛенинке.
- Научным публикациям присваивается международный цифровой индикатор DOI.
- Журнал участник программы **открытого доступа** к научным публикациям.

Контакты: <https://e-integral.ru>, e-integral@ya.ru