



## Прогнозирование временных рядов технологических параметров оборудования на основе рекуррентных нейронных сетей LSTM

Ильнур Ильдарович Хасанов<sup>1</sup>,

кандидат технических наук, доцент,

e-mail: iikhasanov@fa.ru;

Дмитрий Олегович Хорт<sup>2</sup>,

доктор технических наук, главный научный сотрудник,

e-mail: dmitriyhort@mail.ru;

Никита Васильевич Бережанский<sup>1</sup>,

старший преподаватель,

e-mail: nvberezhanskij@fa.ru

<sup>1</sup>Финансовый университет при Правительстве Российской Федерации, Москва, Российская Федерация;

<sup>2</sup>Федеральный научный агроинженерный центр ВИМ, Москва, Российская Федерация

**Реферат.** В условиях цифровизации агропромышленного комплекса и роста объемов данных, формируемых при эксплуатации сельскохозяйственных машин и технологического оборудования, возрастает потребность в интеллектуальных методах анализа, способных учитывать нелинейную динамику и адаптироваться к изменяющимся режимам работы оборудования. Особый интерес представляют методы прогнозирования временных рядов технологических параметров, обеспечивающие повышение точности мониторинга и переход к предиктивным стратегиям управления и обслуживания. *(Цель исследования)* Изучение возможностей рекуррентных нейронных сетей типа LSTM для краткосрочного прогнозирования временных рядов технологических параметров сельскохозяйственных машин и оборудования с учетом длительных временных зависимостей и нестационарного характера данных. *(Материалы и методы)* В качестве исходных данных использовались телеметрические временные ряды, полученные в процессе эксплуатации промышленного оборудования. Применен подход к формированию обучающих последовательностей, ориентированный на сохранение временного контекста. Для моделирования использовалась рекуррентная нейронная сеть архитектуры LSTM, обеспечивающая учет долгосрочных зависимостей. Качество прогнозирования оценивалось с использованием показателей MAE, MSE и RMSE. Для сравнения применялись модели ARIMA и полносвязная нейронная сеть. *(Результаты и обсуждение)* Разработанная LSTM-модель продемонстрировала высокую точность прогнозирования, эффективно воспроизводя как стационарные, так и переходные участки временных рядов. В ходе эксперимента получены значения MAE = 0,0094, MSE = 0,00014 и RMSE = 0,0119, превосходящие результаты моделей сравнения. *(Выводы)* Подтверждены эффективность применения LSTM-моделей для анализа и прогнозирования технологических процессов, а также перспективность их использования в системах промышленного мониторинга и предиктивного управления.

**Ключевые слова:** прогнозирование, временные ряды, LSTM, глубокое обучение, промышленная аналитика, интеллектуальные системы, технологические процессы.

**Для цитирования:** Хасанов И.И., Хорт Д.О., Бережанский Н.В. Прогнозирование временных рядов технологических параметров оборудования на основе рекуррентных нейронных сетей LSTM // *Сельскохозяйственные машины и технологии*. 2026. Т. 20. №2. С. 52-58. DOI: 10.22314/2073-7599-2026-20-2-52-58. EDN: YALNVH.

Scientific article

## Forecasting Time Series of Technological Parameters of Equipment Using LSTM Recurrent Neural Networks

Ильнур И. Хасанов<sup>1</sup>,

Ph.D.(Eng.), associate professor,

e-mail: iikhasanov@fa.ru;

Дмитрий О. Хорт<sup>2</sup>,

Dr.Sc.(Eng.), chief researcher,

e-mail: dmitriyhort@mail.ru;

Никита В. Бережанский<sup>1</sup>,

senior lecturer,

e-mail: nvberezhanskij@fa.ru

<sup>1</sup>Financial University under the Government of the Russian Federation, Moscow, Russian Federation;

<sup>2</sup>Federal Scientific Agroengineering Center VIM, Moscow, Russian Federation

**Abstract.** The digitalization of the agro-industrial sector and the growing volume of data generated by agricultural machinery and technological equipment create a demand for intelligent analytical methods capable of capturing nonlinear dynamics and adapting to changing operating modes. Time-series forecasting methods for technological parameters are of particular interest, as they can improve monitoring accuracy and enable the transition to predictive control and maintenance strategies. (*Research purpose*) The study aims to assess the potential of Long Short-Term Memory (LSTM) recurrent neural networks for short-term forecasting time series of technological parameters in agricultural machinery and equipment, taking into account long-term temporal dependencies and the non-stationary nature of the data. (*Materials and methods*) The study used telemetric time series obtained during the operation of industrial equipment as the initial data. Training sequences were developed to preserve the temporal context of the observations. Modelling was performed using a recurrent neural network based on the LSTM architecture, which allows long-term dependencies in the data to be captured. Forecasting performance was evaluated using the MAE, MSE, and RMSE metrics. ARIMA models and a fully connected neural network were employed as baseline methods for comparison. (*Results and discussion*) The developed LSTM model demonstrated high forecasting accuracy, effectively reproducing both stationary segments and transition periods of the time series. The experimental results yielded MAE = 0.0094, MSE = 0.00014, and RMSE = 0.0119, indicating that the proposed LSTM model outperformed the benchmark models. (*Conclusions*) The results confirm the effectiveness of LSTM-based models for the analysis and forecasting of technological processes and indicate their strong potential for application in industrial monitoring and predictive control systems.

**Keywords:** forecasting, time series, LSTM, deep learning, industrial analytics, intelligent systems, technological processes.

■ **For citation:** Khasanov I.I., Khort D.O., Berezhansky N.V. Forecasting time series of technological parameters of equipment using LSTM recurrent neural networks. *Agricultural Machinery and Technologies*. 2026. Vol. 20. N2. 52-58 (In Russian). DOI: 10.22314/2073-7599-2026-20-2-52-58. EDN: YALNVH.

Современные предприятия агропромышленного комплекса функционируют в условиях высокой степени автоматизации и цифровизации технологических процессов, в том числе эксплуатации сельскохозяйственных машин, машинно-тракторных агрегатов и технологического оборудования. Огромный массив данных требует качественного и быстрого анализа. Для этих целей существуют технологии, такие как *BigData* и алгоритмы искусственного интеллекта [1]. В результате систематического сбора измерительной информации формируются большие массивы временных рядов, отражающих поведение оборудования и протекание производственных процессов [2]. Анализ таких данных позволяет выявлять закономерности функционирования систем, прогнозировать изменение технологических параметров и обеспечивать переход от реактивных к превентивным стратегиям технического обслуживания [3, 4].

В последние годы значительное развитие получили методы интеллектуального анализа данных, основанные на алгоритмах глубокого обучения. Рекуррентные нейронные сети, в частности архитектуры типа *LSTM* (*Long Short – Term Memory*), продемонстрировали высокую эффективность при прогнозировании сложных, нелинейных и нестационарных временных рядов [5, 6]. Эти модели способны учитывать длительные временные зависимости, что делает их перспективными для решения задач анализа промышленных процессов [7].

Несмотря на достижения в данной области, сохраняется ряд нерешенных вопросов, связанных с выбором оптимальных методов предобработки дан-

ных, определением длины обучающих последовательностей и обеспечением устойчивости моделей к изменениям режимов работы (Воронина В.В., Михеев А.В., Ярушкина Н.Г., Святов К.В. Теория и практика машинного обучения. Ульяновск: УлГТУ. 2017. 290 с.).

**Цель исследования** – разработка и экспериментальная проверка алгоритма прогнозирования временных рядов технологических параметров на основе архитектуры *LSTM*, включающего этапы подготовки данных, обучения модели и анализа ее прогностических свойств на примере реальных производственных данных.

**Материалы и методы.** Интеллектуальные методы анализа данных позволяют решать задачи прогнозирования технологических процессов на основе больших объемов телеметрических данных. В условиях цифровизации производства особое значение приобретает использование моделей глубокого обучения, способных учитывать временные зависимости и нелинейные связи между параметрами. Одним из наиболее результативных подходов является применение рекуррентных нейронных сетей типа *LSTM*, которые сохраняют контекст последовательности и обеспечивают устойчивое обучение даже при больших временных интервалах [8, 9].

В рамках данного исследования сформирована модульная архитектура решения, предназначенная для прогнозирования временных рядов технологических параметров на основе *LSTM*-модели (представлено исследованиями по архитектурам рекуррентных моделей [8], *рис. 1*).




Рис. 1. Архитектура модуля прогнозирования технологических параметров

Fig. 1. Architecture of the technological-parameter forecasting module

Архитектура включает подсистемы импорта и преобработки данных, формирования обучающих последовательностей, обучения и прогнозирования, а также модули визуализации и аналитической оценки качества. Такая организация обеспечивает гибкость и возможность интеграции в промышленные аналитические платформы.

Архитектура модуля прогнозирования технологических параметров построена в виде двух функциональных контуров: контура обучения и контура прогнозирования. Контур обучения включает входной блок подготовки данных, в котором выполняются импорт, контроль качества и предварительная обработка временных рядов, а также блок формирования временных последовательностей и признаков, предназначенных для обучения модели. Центральным компонентом контура обучения является нейросетевая модель на основе архитектуры *LSTM*, обеспечивающая выявление и моделирование временных зависимостей в технологических данных. Результаты обучения и параметры модели сохраняются для последующего использования.

Контур прогнозирования включает входной блок обработки текущих измерений, в котором реализуются те же процедуры предварительной обработки и формирования временных последовательностей, что и в контуре обучения. Сформированные данные поступают в сервис прогнозирования, использующий обученную модель для вычисления прогнозных значений. Выходной блок выполняет последующую обработку результатов и формирование итоговых прогнозов, обеспечивая их передачу и интеграцию в аналитическую среду (Brownlee J. Deep learning for time series forecasting: predict the future with MLPs, CNNs and LSTMs in Python. Machine Learning Mastery. 2018. 42-52).

Математическая постановка задачи основана на анализе последовательности измерений технологического параметра ( $X$ ):

$$X = \{x_1, x_2, x_3, \dots, x_T\}, x_T \in R, \quad (1)$$

где  $x_1, \dots, x_T$  – значение параметра в момент времени  $t$ ;  $T$  – общая длина имеющейся последовательности наблюдений;  $R$  – множество действительных чисел.

Для формирования обучающей выборки исходный ряд разбивается на перекрывающиеся подпоследовательности фиксированной длины ( $L$ ). Каждая обучающая последовательность ( $S_i$ ) имеет вид:

$$S_i = \{x_1, x_{i+1}, \dots, x_{i+L-1}\}, y_i = x_{i+L}, \quad (2)$$

где  $y_i$  – целевое значение (выход переменной), соответствующее обучающей последовательности.

Обучающая выборка представляется множеством пар ( $D$ ):

$$D = \{(S_i, y_i)\}_{i=1}^{T-L}.$$

Для моделирования временной структуры данных используется рекуррентная нейронная сеть типа *LSTM*. Каждая *LSTM*-ячейка принимает на вход текущее значение временного ряда  $x_t$ , скрытое состояние предыдущего шага  $h_{t-1}$  и внутреннее состояние памяти  $c_{t-1}$ . Работа *LSTM*-ячейки описывается системой уравнений:

$$\begin{aligned} f_t &= \sigma(W_{if}x_t + b_{if} + W_{hf}h_{(t-1)} + b_{hf}); \\ i_t &= \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{(t-1)} + b_{hi}); \\ g_t &= \tan h(W_{ig}x_t + b_{ig} + W_{hg}h_{(t-1)} + b_{hg}); \\ c_t &= f_t c_{(t-1)} + i_t g_t; \\ o_t &= \sigma(W_{io} \cdot x_t + b_{io} + W_{ho} \cdot h_{(t-1)} + b_{ho}); \\ h_t &= o_t \cdot \tan h(c_t), \end{aligned}$$

где  $\sigma$  – сигмоидальная функция активации;  $W, U, b$  – параметры модели;  $x_t$  – входное значение в момент времени  $t$  (элемент временного ряда);  $h_{t-1}$  – скрытое состояние *LSTM*-ячейки на предыдущем шаге;  $c_{t-1}$  – состояние ячейки на предыдущем шаге;  $h_t$  – новое скрытое состояние;  $c_t$  – обновленное состояние памяти;  $f_t, i_t, o_t$  – соответственно забывающий, входной и выходной элементы (*gate*);  $g_t$  – вектор обновления состояния ячейки, вычисляемый на основе текущего входа и предыдущего скрытого состояния с применением функции активации.

Для обучения модели используется функция потерь – среднеквадратичная ошибка:

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (3)$$

где  $L$  – итоговое значение функции потерь, характеризующее средний уровень ошибки модели;  $N$  – общее количество наблюдений в выборке;  $y_i$  – фактическое (истинное) значение параметра для  $i$ ;  $\hat{y}_i$  – предсказанное (оцененное) значение выходной переменной, полученное моделью для  $i$ -го наблюдения.

Основные параметры используемой *LSTM*-модели приведены в *таблице 1*.

В исследовании использовались данные промышленного программируемого логического контроллера, применяемого для мониторинга вибрационных характеристик узлов сельскохозяйственной машины в режиме реальной эксплуатации (*рис. 2*).

Параметр	Значение	Описание
Длина входной последовательности	50	Количество временных шагов во входе
Размер скрытого слоя	64	Число нейронов в LSTM-ячейке
Функция потерь	MSE	Среднеквадратичная ошибка
Оптимизатор	Adam	Метод адаптивной оптимизации
Количество эпох	30	Циклы обучения
Размер батча	64	Количество примеров за итерацию

Дата	Метка времени	Значение	Статус
2025.02.18	00:00:02	0,34	Достоверно
2025.02.18	00:00:02	0,33	Достоверно
2025.02.18	00:00:03	0,35	Достоверно
2025.02.18	00:00:03	0,33	Достоверно
2025.02.18	00:00:05	0,32	Достоверно



Рис. 2. Объект мониторинга вибрационных характеристик узлов системы ирригации агропромышленного предприятия  
Fig. 2. Monitored object for assessing the vibration characteristics of irrigation system components at an agro-industrial enterprise

Датасет представляет собой последовательность временных меток, измеренных значений и статусов достоверности записей; фрагмент исходных данных приведен в таблице 2. Учитывая нерегулярную дискретизацию и наличие дублирующихся измерений, данные были предварительно приведены к стандартизированному виду и использованы для формирования обучающих последовательностей, применяемых на этапе обучения модели LSTM [10, 11].

Завершая анализ структуры исходных данных, необходимо отметить, что их формат и динамические особенности определяют необходимость тщательной предобработки, направленной на обеспечение однородности временной шкалы и стабильности входных последовательностей [11]. После выполнения всех процедур подготовки данные становятся пригодными для корректного обучения LSTM-модели и объективной оценки ее прогностических характеристик.

**Результаты и обсуждение.** Результаты вычислительных экспериментов показали, что разработанная модель эффективно воспроизводит динамику технологического параметра и корректно отража-

ет как стационарные участки временного ряда, так и переходные режимы [12]. На рисунке 3 представлено сравнение обучающих данных, прогнозных значений и фактической траектории параметра.




Рис. 3. Сравнение обучающих, прогнозных и фактических значений временного ряда: 1 – обучающие данные; 2 – конец обучающего периода; 3 – предсказанные значения; 4 – реальные данные после периода обучения  
Fig. 3. Comparison of the training, predicted, and actual time-series values: 1 – training data; 2 – end of the training period; 3 – predicted values; 4 – actual values after the training period

Количественный анализ демонстрирует высокую точность полученных прогнозов. Для оценки качества прогнозирования использовались следующие метрики (табл. 3):

- MAE (Mean Absolute Error) – метрика, характеризующая среднее абсолютное отклонение прогнозируемых значений от фактических;
- MSE (Mean Squared Error) – метрика, определяющая среднее значение квадратов отклонений прогнозов от истинных значений;
- RMSE (Root Mean Squared Error) – квадратный корень из среднеквадратичной ошибки, отражающий среднюю величину ошибки в исходных единицах измерения.

Для сопоставления были реализованы классическая модель ARIMA и полносвязная нейронная сеть (Dense NN). Таким образом, использование рекуррентной архитектуры LSTM позволило снизить среднеквадратичную ошибку прогноза в среднем на 34-40%, обеспечив устойчивость модели к шумовым компонентам и изменениям режимов работы системы [13].

Анализ результатов прогнозирования показывает, что модель демонстрирует особенно высокую

СРАВНЕНИЕ ТОЧНОСТИ МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ COMPARATIVE ACCURACY OF THE FORECASTING MODELS			
Модель	MAE	MSE	RMSE
LSTM	0,0094	0,00014	0,0119
ARIMA	–	–	0,0270
Полносвязная нейронная сеть	–	–	0,0180

точность на участках устойчивой работы технологического процесса [14]. Здесь наблюдения имеют слабую вариативность, что обеспечивает полную согласованность прогнозных значений с фактическими. LSTM-архитектура эффективно запоминает продолжительные временные зависимости, что особенно заметно в фазах медленного изменения параметра.

На переходных участках, характеризующихся быстрыми изменениями амплитуды, качество прогноза несколько снижается. Это связано с тем, что резкие пики редко представлены в обучающих данных и имеют высокую локальную динамику. Тем не менее, модель удовлетворительно воспроизводит общую форму переходных процессов. В частности, она корректно определяет моменты начала роста параметра, относительную высоту пиков и моменты возвращения к стабильному режиму, что подтверждает способность модели захватывать нелинейные структуры временного ряда.

Как видно из *рисунка 3*, в области резкого роста значений временного ряда прогноз модели демонстрирует сглаживание пиковых значений, что проявляется в занижении амплитуды локальных экстремумов по сравнению с фактическими данными. Данное поведение является типичным для LSTM и обусловлено внутренними механизмами рекуррентной фильтрации, уменьшающими чувствительность к шумовым колебаниям.

Несмотря на высокое качество прогнозов, предложенный подход имеет ряд ограничений. Во-первых, модель учитывает только одномерный временной ряд, тогда как реальный технологический процесс может быть многопараметрическим и зависеть от ряда факторов. Во-вторых, прогноз выполняется в условиях фиксированной длины обучающего окна, что потенциально ограничивает способность модели адаптироваться к редким или долгосрочным режимам работы. В-третьих, модель обучена в стационарных условиях и не учитывает возможных структурных сдвигов или деградации оборудования.

С учетом указанных ограничений при разработке программной реализации особое внимание уделено удобству эксплуатации модуля и наглядному представлению результатов прогнозирования (*рис. 4*). Разработанный модуль прогнозирования интегри-

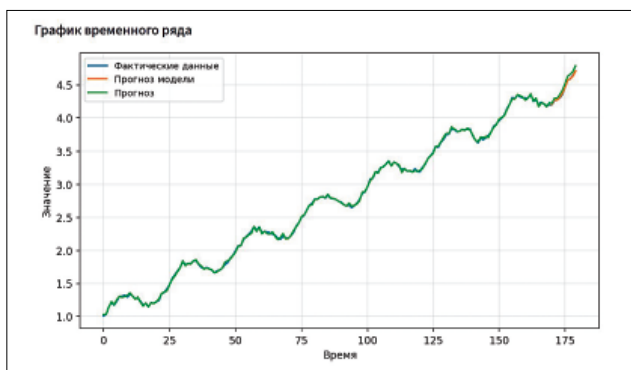


Рис. 4. Интерфейс модуля прогнозирования временных рядов на основе LSTM с окном загрузки данных: 1 – фактические данные; 2 – прогноз; 3 – прогноз модели

Fig. 4. Interface of the LSTM-based time-series forecasting module with the data upload window: 1 – actual data; 2 – forecast values; 3 – model-generated forecast

рован с простым пользовательским интерфейсом, ориентированным на эксплуатационный персонал. Интерфейс включает панели загрузки данных, настройки параметров модели (длина входной последовательности, количество эпох обучения, размер батча) и отображения результатов. Визуальный модуль позволяет сравнивать фактические и прогнозные значения временного ряда, а также выводить значения основных метрик качества (MAE, RMSE). Такая организация обеспечивает возможность использования предложенного решения в составе промышленных аналитических панелей без участия специалистов по машинному обучению.

Перспективы дальнейших исследований включают расширение модели до многомерных входных данных, применение архитектур с механизмом внимания (*Attention*) для повышения чувствительности к локальным изменениям, а также использование гибридных моделей, объединяющих LSTM с методами спектрального или вероятностного анализа [13, 15]. Дополнительно представляется перспективным внедрение механизмов онлайн-обучения для адаптации модели к изменяющимся режимам работы и интеграция прогностического модуля в состав интеллектуальных и роботизированных агротехнологических комплексов, выполняющих сбор и обработку данных в режиме реального времени, как показано в работе [16]. Также перспективным направлением является интеграция прогностического модуля в системы цифровых двойников технологических процессов.

**Выводы.** Разработан и экспериментально обоснован метод прогнозирования временных рядов технологических параметров на основе рекуррентных нейронных сетей LSTM. Предложенная архитектура обеспечивает существенно более высокую точность по сравнению с классическими методами, включая ARIMA и полносвязные нейронные се-

ти: снижение значения *RMSE* в среднем на 34-40 подтверждает ее эффективность для моделирования нелинейной и нестационарной динамики технологических процессов.

*LSTM*-модель корректно воспроизводит как стационарные режимы, так и переходные участки, демонстрируя устойчивость к шумовым искажениям данных. Несмотря на тенденцию к сглаживанию локальных экстремумов, модель успешно выявляет ключевые структурные особенности временно-го ряда, что делает ее применимой для задач прогнозирования технического состояния сельскохо-

зяйственной техники в условиях реальной эксплуатации.

Возможность использования разработанного модуля в системах мониторинга и предиктивного обслуживания способствует повышению надежности сельскохозяйственных машин, снижению простоев и реализации энерго- и ресурсосберегающих технологий. Полученные результаты создают основу для дальнейшего развития подхода, включая расширение модели на многомерные данные, применение механизмов внимания и разработку адаптивных схем онлайн-обучения.

### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Костомахин М.Н., Пестряков Е.В. Программный комплекс для дистанционного контроля узлов и агрегатов // *Сельскохозяйственные машины и технологии*. 2022. Т. 16. N4. С. 19-25. DOI: 10.22314/2073-7599-2022-16-4-19-25.
2. Pashshoev B., Petrusovich D.A. Neural network analysis in time series forecasting. *Russ. Technol. J.* 2024;12(4):106–116. DOI: 10.32362/2500-316X-2024-12-4-106-116.
3. Qin S.J. Process data analytics in the era of big data. *AICChE Journal*. 2020. Vol. 66. Iss. 4. e16865. DOI:10.1002/aic.14523.
4. Napoleone A., Macchi M., Pozzetti A. A review on the characteristics of cyber-physical systems for the future smart factories. *Journal of Manufacturing Systems*. 2020. 54. 305-335. DOI: 10.1016/j.jmsy.2020.01.007.
5. Gao Y., Wang R., Zhou E. Stock prediction based on optimized LSTM and GRU models. *Wireless Communications and Mobile Computing*. 2021. 4055281. DOI: 10.1155/2021/4055281.
6. Mathonsi T., van Zyl T. L. A statistics and deep learning hybrid method for multivariate time series forecasting and mortality modeling. *Forecasting*. 2022. Vol. 4. N1. 1-25. DOI: 10.48550/arXiv.2112.08618.
7. Zhang C., Sjarif N.N.A., Ibrahim R. Deep learning models for price forecasting of financial time series: *A review of recent advancements: 2020-2022*. 2023. DOI: 10.1002/widm.1519.
8. Smyl S., Dudek G., Pelka P. ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. *2112.02663 [cs.LG]*. 2021. DOI: 10.48550/arXiv.2112.02663.
9. Саввин Н.В. Прогнозирование временных рядов: улучшение LSTM-моделей с помощью векторно-временного кодирования // *Инженерные системы и сооружения*. 2025. N2 (60). С. 148-154. DOI: 10.36622/2074-188X.2025.54.65.015.
10. Zhang G., Ren T., Yang Y. A new unified deep learning approach with decomposition-reconstruction-ensemble framework for time series forecasting. *2002.09695 [stat.ML]*. 2020. DOI: 10.48550/arXiv.2002.09695.
11. Erichson N.B., Lim S.H., Mahoney M.W. Gated recurrent neural networks with weighted time-delay feedback. *2212.00228 [cs.LG]*. 2022. DOI: 10.48550/arXiv.2212.00228.
12. Пашшоев Б.А., Петрусевич Д.А. Анализ нейросетевых моделей для прогнозирования временных рядов. *Russian Technological Journal*. 2024. Т. 12. N4. С. 106-116. DOI: 10.32362/2500-316X-2024-12-4-106-116.
13. Nurhaida I., Noprisson H., Ayumi V. et al. Implementation of deep learning predictor (LSTM) algorithm for human mobility prediction. 2020. *International Journal of Interactive Mobile Technologies*. 2020. Vol. 14. N18. 132-144. DOI: 10.3991/ijim.v14i18.16867.
14. Рапаков Г.Г., Горбунов В.А., Дианов С.В., Елизарова Л.В. Исследование LSTM-нейросетевого подхода при моделировании временных рядов // *Вестник Череповецкого государственного университета*. 2023. N3 (114). С. 47-54. DOI: 10.23859/1994-0637-2023-3-114-4.
15. Wang Q., Chen L., Zhao J., Wang W. A deep granular network with adaptive unequal-length granulation strategy for long-term time series forecasting and its industrial applications. *Artificial Intelligence Review*. 2020. Vol. 53. N7. 5353-5381. DOI: 10.1007/s10462-020-09822-9.
16. Смирнов И.Г., Хорт Д.О., Кутырев А.И. Интеллектуальные технологии и роботизированные машины для возделывания садовых культур // *Сельскохозяйственные машины и технологии*. 2021. Т. 15. N4. С. 35-41. DOI: 10.22314/2073-7599-2021-15-4-35-41.

### REFERENCES

1. Kostomakhin M.N., Pestryakov E.V. Software package for remote diagnostics of agricultural machinery condition. *Agricultural Machinery and Technologies*. 2022. Vol. 16. N4. 19-25 (In Russian). DOI: 10.22314/2073-7599-2022-16-4-19-25.
2. Pashshoev B., Petrusovich D.A. Neural network analysis in time series forecasting. *Russ. Technol. J.* 2024;12(4):106–116. DOI: 10.32362/2500-316X-2024-12-4-106-116.
3. Qin S.J. Process data analytics in the era of big data. *AICChE Journal*. 2020. Vol. 66. Iss. 4. e16865. DOI:10.1002/aic.14523.

4. Napoleone A., Macchi M., Pozzetti A. A review on the characteristics of cyber-physical systems for future smart factories. *Journal of Manufacturing Systems*. 2020. Vol. 54. 305-335. DOI: 10.1016/j.jmsy.2020.01.007.
5. Gao Y., Wang R., Zhou E. Stock prediction based on optimized LSTM and GRU models. *Wireless Communications and Mobile Computing*. 2021. 4055281. DOI: 10.1155/2021/4055281.
6. Mathonsi T., van Zyl T.L. A statistics and deep learning hybrid method for multivariate time series forecasting and mortality modeling. *Forecasting*. 2022. Vol. 4. N1. 1-25. DOI: 10.48550/arXiv.2112.08618.
7. Zhang C., Sjarif N.N.A., Ibrahim R. Deep learning models for price forecasting of financial time series: *A review of recent advancements: 2020-2022*. 2023. DOI: 10.1002/widm.1519.
8. Smyl S., Dudek G., Pelka P. ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. *2112.02663 [cs.LG]*. 2021. DOI: 10.48550/arXiv.2112.02663.
9. Savvin N.V. Time series forecasting: improving LSTM models using vector-time encoding. *Engineering Systems and Structures*. 2025. N2 (60). 148-154 (In Russian). DOI: 10.36622/2074-188X.2025.54.65.015.
10. Zhang G., Ren T., Yang Y. A new unified deep learning approach with decomposition-reconstruction-ensemble framework for time series forecasting. *2002.09695 [stat.ML]*. 2020. DOI: 10.48550/arXiv.2002.09695.
11. Erichson N.B., Lim S.H., Mahoney M. W. Gated recurrent neural networks with weighted time-delay feedback. *2212.00228 [cs.LG]*. 2022. DOI: 10.48550/arXiv.2212.00228.
12. Pashshoev B.A., Petrushevich D.A. Analysis of neural network models for time series forecasting. *Russian Technological Journal*. 2024. Vol. 12. N4. 106-116. (In Russian). DOI: 10.32362/2500-316X-2024-12-4-106-116.
13. Nurhaida I., Noprisson H., Ayumi V. et al. Implementation of deep learning predictor (LSTM) algorithm for human mobility prediction. 2020. *International Journal of Interactive Mobile Technologies*. 2020. Vol. 14. N18. 132-144. DOI: 10.3991/ijim.v14i18.16867.
14. Rapakov G.G., Gorbunov V.A., Dianov S.V., Elizarova L.V. Study of LSTM neural network approach in time series modeling. *Bulletin of Cherepovets State University*. 2023. N3 (114). 47-54 (In Russian). DOI: 10.23859/1994-0637-2023-3-114-4.
15. Wang Q., Chen L., Zhao J., Wang W. A deep granular network with adaptive unequal-length granulation strategy for long-term time series forecasting and its industrial applications. *Artificial Intelligence Review*. 2020. Vol. 53. N7. 5353-5381. DOI: 10.1007/s10462-020-09822-9.
16. Smirnov I.G., Khort D.O., Kutyrev A.I. Intelligent technologies and robotic machines for garden crops cultivation. *Agricultural Machinery and Technologies*. 2021. Vol. 15. N4. 35-41 (In Russian). DOI: 10.22314/2073-7599-2021-15-4-35-41.

### Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

### Заявленный вклад соавторов:

- Хасанов И.И. – разработка математической постановки задачи и алгоритма прогнозирования временных рядов, выбор и обоснование параметров нейросетевой модели, сравнение с классическими методами прогнозирования, формирование выводов;
- Хорт Д.О. – формулирование цели и задач исследования, разработка архитектуры модели прогнозирования на основе LSTM, подготовка и предобработка экспериментальных данных, проведение вычислительных экспериментов, анализ и интерпретация результатов;
- Бережанский Н.В. – научное руководство исследованием, обоснование актуальности и практической значимости работы, постановка проблемы и утверждение текста статьи.

*Авторы прочитали и одобрили окончательный вариант рукописи.*

### Conflict of interest

The authors declare no conflict of interest.

### Coauthors' contribution:

- Khasanov I.I. – mathematical formulation of the problem, development of the time-series forecasting algorithm, selection and justification of neural network model parameters, comparison with classical forecasting methods; formulation of the conclusions;
- Khort D.O. – formulation of the research purpose and objectives, development of the LSTM-based forecasting model architecture, preparation and preprocessing of experimental data, computational experiments, analysis and interpretation of the results;
- Berezhansky N.V. – scientific supervision, justification of the relevance and practical significance of the study, problem statement, approval of the manuscript.

*The authors read and approved the final manuscript.*

Статья поступила в редакцию  
Статья принята к публикации

The paper was submitted to the Editorial Office on  
The paper was accepted for publication on

03.04.2026  
05.05.2026