



DOI: 10.26794/3033-7097-2025-1-4-76-85  
УДК 330.47:004.67(045)

# Прогнозирование урожайности в регионах юга России с использованием инструментов искусственного интеллекта

С.В. Шайтура<sup>а</sup>, Н.П. Семичевская<sup>б</sup>, Н.С. Шайтура<sup>с</sup>

<sup>а</sup> Технологический университет им. дважды Героя Советского Союза, летчика-космонавта А.А. Леонова, Московская область, г. Королев, Российская Федерация;

<sup>б</sup> Московский государственный университет технологий и управления им. К.Г. Разумовского (ПКУ), Москва, Российская Федерация;

<sup>с</sup> Российский государственный аграрный университет – МСХА им. К.А. Тимирязева, Москва, Российская Федерация

## АННОТАЦИЯ

**В статье рассматриваются** современные подходы к прогнозированию урожайности сельскохозяйственных культур в аграрных регионах юга России с использованием технологий искусственного интеллекта (нейронных сетей). Актуальность темы обусловлена высокой значимостью южных регионов (Краснодарский и Ставропольский края, Ростовская область и др.) в продовольственной безопасности России и необходимостью оперативного и точного прогнозирования урожая. **Цель данной работы** – разработать, применить и сделать оценку моделей прогнозирования урожайности сельскохозяйственных культур на юге России с использованием методов искусственного интеллекта, основанных на нейронных сетях различного типа. Рассмотрены методология и инструментарий применения нейросетевых алгоритмов (LSTM, CNN, MLP) для прогнозирования урожайности на основе данных 2020–2025 гг., включая статистические показатели урожайности, метеорологические данные и индексы растительности (NDVI). **Представлены результаты** моделирования, демонстрирующие преимущество LSTM-модели по точности прогноза по сравнению с другими моделями. Приведены графики и таблицы, иллюстрирующие фактическую и прогнозируемую урожайность, а также сравнительный анализ ошибок моделей. Проведена оценка результатов – сравнительная точность и ошибки прогнозов различных моделей. Рассмотрены ограничения проведенного исследования, к которым относятся непредставительность контрольных выборок, а также несовершенство системы сбора статистической информации. В связи с этим предложены направления дальнейших исследований, таких как расширение объема данных, обработка и подготовка данных к анализу, использование гибридных моделей, улучшение интерпретируемости моделей. **Ключевые слова:** урожайность сельскохозяйственных культур; прогнозирование урожайности; нелинейная регрессионная модель; полиномиальная регрессионная модель; нейронная сеть; многослойный перцептрон; сверточная нейронная сеть; карта нормализованного вегетационного индекса; рекуррентная нейронная сеть

**Для цитирования:** Шайтура С.В., Семичевская Н.П., Шайтура Н.С. Прогнозирование урожайности в регионах юга России с использованием инструментов искусственного интеллекта. *Цифровые решения и технологии искусственного интеллекта*. 2025;1(4):76-85. DOI: 10.26794/3033-7097-2025-1-4-76-85

ORIGINAL PAPER

## Predicting Crop Yields in the Southern Regions of Russia with Artificial Intelligence Tools

S.V. Shaitura<sup>а</sup>, N.P. Semichevskaya<sup>б</sup>, N.S. Shaitura<sup>с</sup>

<sup>а</sup> Leonov University of Technology, Korolev, Moscow Region, Russian Federation;

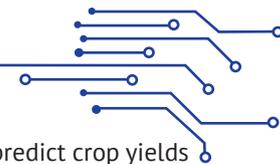
<sup>б</sup> K.G. Razumovsky Moscow State University of Technologies and Management, Moscow, Russian Federation;

<sup>с</sup> Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russian Federation

## ABSTRACT

**The article discusses** modern approaches to predicting crop yields in the agricultural regions of southern Russia using artificial intelligence technologies (neural networks). The relevance of this topic is due to the high importance of the southern regions (Krasnodar Territory, Stavropol Territory, Rostov Region, etc.) in Russia's food security, and the need for prompt and accurate crop forecasting. **The purpose of this work** is to develop, apply and evaluate models for predicting crop yields in southern Russia using artificial intelligence methods based on various types of neural networks.

© Шайтура С.В., Семичевская Н.П., Шайтура Н.С., 2025



Methodology and tools of neural network algorithms application (LSTM, CNN, MLP) are considered to predict crop yields based on data from 2020 to 2025, including statistical indicators of crop yields, meteorological data, and vegetation indices (NDVI). **The article presents the results** of modeling, which demonstrate the advantage of the LSTM model in terms of prediction accuracy compared to other models. The results section includes graphs and tables that illustrate the actual and predicted crop yields, as well as a comparative analysis of the model errors.

**Keywords:** crop yield; yield prediction; nonlinear regression model; polynomial regression model; neural network; multilayer perceptron; convolutional neural network; normalized vegetation index map; recurrent neural network

**For citation:** Shaitura S.V., Semichevskaya N.P., Shaitura N.S. Predicting crop yields in the southern regions of Russia with artificial intelligence tools. *Digital Solutions and Artificial Intelligence Technologies*. 2025;1(4):76-85. DOI: 10.26794/3033-7097-2025-1-4-76-85

## ВВЕДЕНИЕ

Прогнозирование урожайности сельскохозяйственных культур является одной из ключевых задач аграрного сектора, особенно для регионов с интенсивным земледелием, таких как юг России.

Ростовская область, Краснодарский и Ставропольский края традиционно занимают лидирующие позиции по производству зерновых культур (пшеница, рожь, ячмень, овес) и являются важнейшей компонентой продовольственной безопасности страны. От точности прогнозов урожая в этих регионах зависит планирование продовольственных ресурсов, экспортного потенциала и ценовой стабильности.

Решение задачи прогнозирования урожайности культур может потенциально повысить саму урожайность за счет выполнения следующих мероприятий в сельскохозяйственных регионах:

- определение состояния растений, которое визуально незаметно, применяя аппаратные методы визуализации;
- выделение проблемных участков уже на ранних этапах вегетации путем применения методов компьютерного зрения и аэрофотосъемки;
- планирование методов обработки посевов (пересева, дополнительной подпитки);
- контроль появления сорных растений сразу после проведения посева, так как сорняки активнее набирают массу и хорошо отображаются в спектре;
- установление растений, которые возделывались в данном месте в предыдущие периоды и какие растут сейчас;
- точечное применение фосфорных, калийных и азотных удобрений на основе определения проблемных зон посредством индексов вегетации и последующего забора почвы на анализ;
- своевременная идентификация болезней и вредителей в период, когда повреждения еще не заметны визуально, путем применения методов распознавания и компьютерной идентификации.

Актуальность применения искусственного интеллекта и нейросетевых технологий для решения задачи прогнозирования урожайности обусловлена несколькими факторами. Во-первых, традиционные

методы прогнозирования (агрометеорологические и статистические модели) не всегда обеспечивают требуемую точность и оперативность. Математические модели, построенные на нейросетевых алгоритмах, способны выявлять скрытые нелинейные зависимости между урожайностью и множеством влияющих факторов (погодные условия, агротехнологии, состояние посевов и др.), что повышает точность прогнозов [1–3]. Во-вторых, последние годы характеризуются бурным развитием цифровых технологий в сельском хозяйстве — от спутникового мониторинга полей до систем точного земледелия, что обеспечивает приток высокочастотных и детализированных пространственных данных [4–6].

**Цель данной работы** заключается в разработке модели прогнозирования урожайности сельскохозяйственных культур на юге России с использованием методов искусственного интеллекта, основанных на нейронных сетях различного типа. Для достижения цели решены задачи: сбор и подготовка данных по урожайности в регионах юга России за 2020–2025 гг.; разработка моделей (MLP, CNN, LSTM); обучение и тестирование на актуальных, фактических данных; сравнение точности и ошибок; анализ преимуществ и ограничений подходов; формулировка рекомендаций.

## МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ИССЛЕДОВАНИИ ПРОГНОЗИРОВАНИЯ УРОЖАЙНОСТИ

В данном исследовании применялся комплекс методов искусственного интеллекта, главным образом различные архитектуры искусственных нейронных сетей.

1. Многослойный перцептрон (MLP) — это класс искусственных нейронных сетей прямого распространения. В исследовании на нейронной сети построена модель, имитирующая зависимость урожайности от набора признаков. MLP как минимум состоит из трех слоев. Конфигурация сети MLP: два скрытых слоя по 32 нейрона, ReLU, выход с линейной активацией; оптимизация — Adam; функция потерь — MSE. Модель обучалась на исторических данных 2020–2024 гг. и служила базовым нейросе-

тевым бенчмарком. Многослойный перцептрон является популярным инструментом анализа данных и входит в платформы для бизнес-аналитики [13].

2. Сверточная нейронная сеть (CNN) — специализированный тип глубоких нейронных сетей, предназначенных для эффективного распознавания образов, данная сеть входит в технологию глубокого обучения. Сеть CNN в исследовании применена для анализа пространственных данных, а именно данных на картах нормализованного вегетационного индекса (NDVI). Архитектура сети CNN: несколько сверточных слоев (ядро  $3 \times 3$ ) с пулингом, затем полносвязный блок для регрессии урожайности. CNN обучалась на парах «спутниковое изображение участка — фактическая урожайность» [3–7].

3. Рекуррентная сеть LSTM — специализированный тип рекуррентной нейронной сети RNN, используемой для запоминания и обработки долгосрочных зависимостей в последовательностях данных временной динамики. В исследовании рекуррентная сеть LSTM использовалась для анализа временной динамики по последовательности NDVI и собранных данных по метеопоказателям в течение сезона [5]. Архитектура сети LSTM: два LSTM-слоя (50 и 20 ячеек) и выходной плотный слой; оптимизатор — Adam; функция потерь — MSE. LSTM использует механизмы памяти для выделения существенных межфазовых закономерностей роста сельскохозяйственной культуры [7–10].

В качестве дополнительных сравнительных методов для анализа прогнозных значений использовалась полиномиальная регрессионная модель, для построения которой были собраны статистические данные из официальных статистических источников.

Для предотвращения переобучения применялись кросс-валидация по годам, регуляризация (dropout 0,2; L2), ранняя остановка. Качество оценивали по RMSE, MAPE и  $R^2$ . Предварительная нормализация и отбор признаков выполнены на основе анализа корреляций и важности (в том числе SHAP для MLP).

## ОБЛАСТЬ ИССЛЕДОВАНИЯ

Областью исследования являются аграрные регионы юга Российской Федерации: Республики Адыгея, Калмыкия, Крым, Краснодарский край, Астраханская, Волгоградская и Ростовская области и город Севастополь. Для проведения анализа урожайности были выбраны южные регионы (Краснодарский и Ставропольский края, Ростовская область). Для этих регионов характерен умеренно континентальный климат с мягкой зимой и теплым продолжительным летом; при годовых осадках 400–700 мм доминируют весенне-летние.

Почвенно-ландшафтный фонд представлен высокоплодородными черноземами, что определяет высокий потенциальный уровень урожайности. Структура посевов включала озимую пшеницу (как индикаторную культуру), ячмень, кукурузу, подсолнечник, сахарную свеклу. Период анализа 2020–2025 гг. охватывает годы с различными погодными режимами, что важно для устойчивого обучения моделей и получения прогнозных значений на 2025 г. [3–6].

## СБОР ДАННЫХ ОБ УРОЖАЙНОСТИ КУЛЬТУР

Опишем систему сбора и обработки данных об урожайности культур, так как от нее зависит качество всей системы прогнозирования урожайности в южных регионах Российской Федерации. Структура Южного федерального округа представлена тремя республиками, тремя областями, одним краем и одним городом федерального значения. Для исследования урожайности сельскохозяйственных культур выбирались данные по трем объектам: Краснодарский край, Ставропольский край, Ростовская область.

Инструментальными средствами сбора статистических данных послужили статистические данные по урожайности сельскохозяйственных культур в сельскохозяйственных организациях Южного федерального округа по указанным объектам.

По данным сформированы следующие группы данных (выборки).

- Статистические показатели урожайности культур по регионам за 2020–2024 гг. (ц/га), предварительные данные за 2025 г. прогнозировались методом полиномиальной регрессии (рис. 1); валовые сборы использовались для контроля. Эти данные выступали целевыми переменными.

- Метеорологические данные: месячные и сезонные суммы осадков, средние температуры, сумма активных температур ( $>+10$  °C), индикаторы экстремальных явлений. Агрегация по региону.

- Дистанционное зондирование: индексы NDVI (и доп. EVI/VHI) по данным Sentinel-2/MODIS; рассчитаны среднемесячные ряды и интегральные показатели (максимум NDVI за сезон, площадь под кривой NDVI). Использовались готовые продукты и расчеты в специализированных сервисах спутникового мониторинга («ВЕГА» и др.) [1, 4, 5, 10–12].

- Агротехнические факторы: индикаторы орошения, приблизительные оценки применения удобрений, доли элитных семян, предшественники (на региональном уровне — укрупненно) [13–15].

Для расширения выборки применено синтетическое моделирование сценариев погодных комбина-



ций с эмпирическим откликом урожайности; затем дообучение на фактических данных 2020–2024 гг. Все количественные признаки нормированы; категориальные (регионы) закодированы.

Результаты прогноза урожайности культур на 2025 г. по регрессионной модели представлены на *рис. 1*.

## ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ И ИНСТРУМЕНТЫ

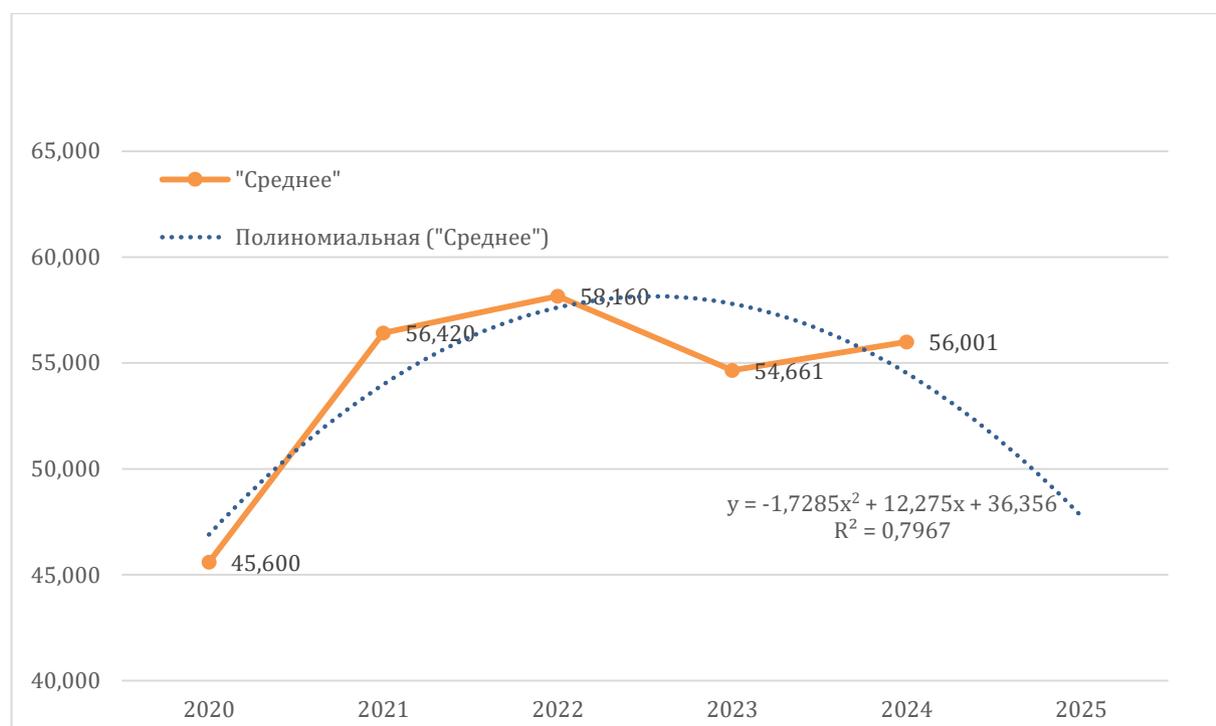
Для реализации исследования использовалось специальное программное обеспечение и комплекс технических средств.

Индекс NDVI (Normalized Difference Vegetation Index) — нормализованный относительный индекс растительности, он определяется как количественный показатель фотосинтетически активной биомассы на участке поверхности Земли. Индекс рассчитывается на основе данных спутниковых фотоснимков или аэрофотоснимков, полученных с беспилотных аппаратов [1, 2, 4, 5].

Карта NDVI может быть получена с помощью следующих видео- и фотооборудования: фотоаппарат, БВС «Альбатрос М», геодезическое GNSS оборудование, мультиспектральная камера для получения нормализованного вегетационного индекса NDVI. В результате имеем визуальную карту местности, карту с индексом NDVI и детальный

ортофотоплан полей, что позволяет дать качественный прогноз с диапазоном отклонений от фактических данных от 4 до 20%. Показатели предоставляются с географической точечной привязкой, выполненной в формате KMZ, geoTIF или в других форматах SHP, JPG. Методика расчетов индекса NDVI позволяет определить состояние посевов на местности со сложным рельефом и присутствием объектов природного и неприродного происхождения, причем четко определяются искусственные материалы (асфальт, бетон), а также естественные водные источники, участки со снежным покровом, разряженных растений и незасеянные почвенные участки. Используются программы по распознаванию объектов на фотоснимках. Пример полученных и обработанных изображений с визуализацией засеянных полей представлен на *рис. 2*.

Используются библиотеки на языке программирования Python: NumPy — библиотека для работы с массивами большой размерности, с помощью этой библиотеки обрабатываются статистические данные по урожайности культур; Pandas — программная библиотека для обработки и анализа структурированных наборов данных (панельных данных), сформированных как многомерные массивы; Matplotlib — библиотека для работы с графикой, подключение которой позволяет визуализировать анализ данных; geodata-стек для обработки гео-

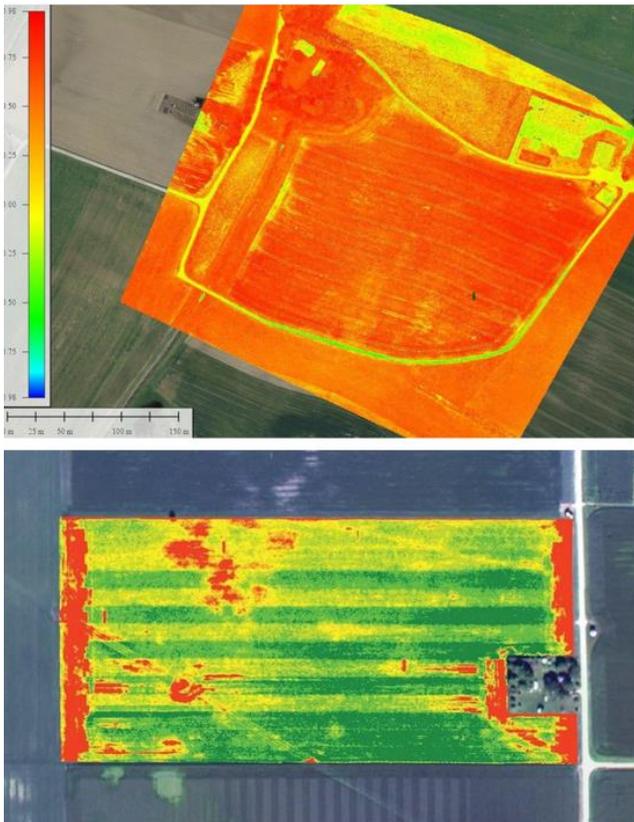


*Рис. 1 / Fig. 1. Фактическая и прогнозируемая урожайность культур (2020–2024 гг.), ц/га / Actual and Predicted Crop Yields of Agricultural Culture (2020–2024 гг.)*

*Источник / Source:* составлено авторами / Compiled by the authors.

данных (rasterio/GDAL — инструмент для создания нейросетей, для геопространственной обработки данных, GeoPandas — библиотека для работы с пространственными данными); фреймворки глубокого обучения Tensor Flow/Keras предоставляют мощные инструменты для создания и обучения нейронных сетей, выполнения различных задач машинного обучения и PyTorch — фреймворк для глубокого обучения, при котором используются многослойные обучаемые модели и нейронные сети. При проведении эксперимента использованы random\_state — генератор случайных чисел в алгоритмах машинного обучения и MLflow — платформа для управления жизненным циклом машинного обучения, которая регистрирует параметры, метрики и артефакты проводимого эксперимента, включая random\_state.

Программная реализация нейронных сетей выполнена на языке Python с использованием следующих библиотек и инструментов NumPy, Pandas, Matplotlib, geodata-стек (rasterio/GDAL, GeoPandas),



**Рис. 2 / Fig. 2. Графическая интерпретация данных об урожайности культур на картах NDVI / Graphical Interpretation of Agricultural Culture Crop Yields Data on NDVI Maps**

Источник / Source: карты NDVI. 000 «Альбатрос». / NDVI Maps. Albatros. URL: <https://www.alb.aero/services/karta-ndvi/>

фреймворки глубокого обучения TensorFlow/Keras и PyTorch. Для репликации экспериментов использованы фиксированные random\_state и MLflow для логирования метрик и артефактов. Спутниковые данные агрегировались через Earth Engine и профильные отечественные сервисы («ВЕГА»). Дополнительно для сравнительного анализа классических моделей временных рядов использовался пакет R (пакет forecast).

### УЧЕТ ФАКТОРОВ, ВЛИЯЮЩИХ НА РЕЗУЛЬТАТЫ

В модель включены агрометеорологические показатели (осадки и температура по месяцам/сезонно), дистанционные индексы (максимальный NDVI, интегральный NDVI, фенологические характеристики), региональные эффекты (категориальный признак), ориентиры агротехники (уровень внесения удобрений, орошение). Анализ точности алгоритмов проводился алгоритмом машинного обучения Random Forest и SHAP для MLP, что показало доминирование NDVI (пик и интеграл), суммы осадков июня–июля, средней температуры июня и индикатора сдвига фенологий (ранняя/поздняя весна). Для частичной интерпретируемости модели LSTM визуализирован вклад временных шагов: максимальная чувствительность к NDVI мая–июня и к осадкам в июне. Признаки масштабированы, высоко коррелирующие агрегированы. Учтены риски аномалий (град, вспышки болезней) — частично отражаются в динамике NDVI, но требуют дальнейшей интеграции фитосанитарных данных [7–12].

### РЕЗУЛЬТАТЫ ПРОГНОЗИРОВАНИЯ

Сравнение фактической и прогнозной урожайности культур по регионам показало, что все нейросетевые модели улавливают межгодовую динамику, но с варьируемой точностью. Наиболее точные оценки продемонстрировала модель LSTM, особенно при раннем прогнозировании (за 1,5–2 месяца до уборки ошибка возрастала лишь умеренно). Графическое сопоставление (рис. 3) иллюстрирует, что модель LSTM лучше воспроизводит экстремумы (низкая урожайность 2020 г., высокий уровень 2021 г.), тогда как перцептрон MLP склонен к сглаживанию.

Для оценки точности прогноза использовались такие показатели, как: RMSE — среднеквадратическая ошибка, MAPE — средняя абсолютная процентная ошибка между предсказанными и фактическими значениями и коэффициент детерминации  $R^2$  — статистическая мера соответствия регрессионной модели фактическим данным. Анализ позволяет

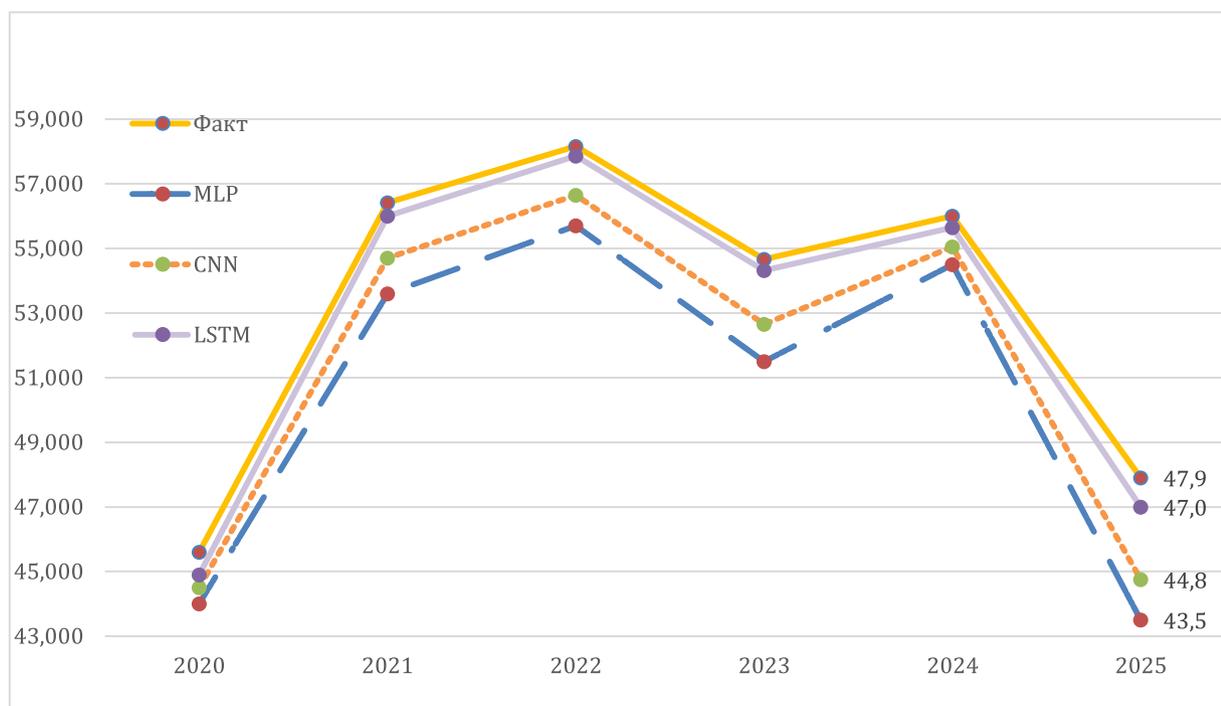


Рис. 3 / Fig. 3. Фактическая и прогнозируемая урожайность культур (2020–2024 гг.) на моделях нейросетей MLP, CNN, LSTM, ц/га / Actual and Predicted Agricultural Culture (2020–2024) Based on Neural Network Models MLP, CNN, LSTM, c/ha

Источник / Source: составлено авторами / Compiled by authors.

установить статистическую значимость математических моделей искусственного интеллекта.

Количественные метрики приведены в таблице:

- модель LSTM показала  $RMSE \approx 2,5$  ц/га,  $MAPE \approx 5,5\%$ ,  $R^2 \approx 0,92$ ;
- модель CNN —  $RMSE \approx 3,0$  ц/га,  $MAPE \approx 6\%$ ,  $R^2 \approx 0,89$ ;
- модель MLP —  $RMSE \approx 3,5$  ц/га,  $MAPE \approx 7,5\%$ ,  $R^2 \approx 0,85$ ;
- для линейной регрессии  $RMSE \approx 5$  ц/га,  $MAPE \approx 10,5\%$ ,  $R^2 \approx 0,75$ ;
- для полиномиальной регрессионной модели  $RMSE \approx 4,5$  ц/га,  $MAPE \approx 10,0\%$ ,  $R^2 \approx 0,79$ .

Это соответствует представлениям о превосходстве рекуррентных архитектур в задачах временных рядов, т.е. рекуррентная сеть LSTM, используемая как модель для запоминания и обработки долгосрочных зависимостей в последовательностях данных временной динамики по последовательности NDVI и собранных данных по метеорологическим показателям в течение сезона, показала наиболее точный прогноз урожайности культур [7–9].

#### Ключевые аналитические выводы:

1) индекс NDVI в период выхода в трубку — колосшение зерна является сильнейшим индикатором будущей урожайности культур;

2) сумма осадков в июне–июле критически влияет на налив зерна;

3) существуют значимые региональные эффекты (при прочих равных по Краснодарскому краю прогнозы выше, чем в Ростовской области, что отражает различия в почвенно-агротехнической базе);

4) по индексу NDVI выделяются проблемные участки уже на ранних этапах вегетации в южных регионах;

5) прогнозирование неурожайных ситуаций возможно уже по состоянию на конец мая при резком отставании NDVI от многолетней нормы.

Сравнительные метрики моделей полиномиальной регрессии и нейросетей MLP, CNN, LSTM показаны в таблице.

Полученные количественные метрики отражают в большей степени точность прогнозирования урожайности культур и никак не показывают ключевые особенности каждой построенной модели нейронных сетей, не дают точную оценку по архитектуре нейронной сети. Полиномиальная регрессионная модель была построена на основе статистических данных об урожайности за период 2020–2024 гг. в трех южных регионах России (Краснодарский край, Ставропольский край, Ростовская область). При построении моделей нейронных сетей использовался многофакторный анализ данных по следующим показателям: урожайность в регионах, метеорологические показатели, полученные индексы NDVI путем дистанционного зондирования.

**Сравнение качества прогноза по моделям (точность на тестовой выборке) / Comparison of Model Prediction Quality (Accuracy on the Test Set)**

Модель / Model	RMSE, ц/га	MAPE, %	R <sup>2</sup>
Полиномиальная регрессия	4,50	10,00	0,79
MLP (Перцептрон)	3,50	7,50	0,85
CNN (Сверточная сеть)	3,00	6,00	0,89
LSTM (Рекуррентная сеть)	2,5	5,50	0,92

Источник / Source: составлено авторами / Compiled by authors.

ния и индикаторы по агротехническим факторам, влияющим на урожайность (индикаторы орошения, оценки применения удобрений, доли элитных семян, предшественники). Применение аппарата нейронных сетей позволило увеличить точность прогнозных моделей и выделить лучшую из трех моделей нейронных сетей.

### ОБСУЖДЕНИЕ ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

При получении результатов были учтены основные ограничения: 1) умеренный объем данных по урожайности сельскохозяйственных культур (2020–2025 гг., три региона) и частичная неоднородность источников; 2) неполный учет биотических факторов (болезни, вредители); 3) локальность моделей (адаптация под юг России); 4) ограниченная интерпретируемость. Можно выделить следующие направления развития: расширение временных рядов, т.е. увеличение временных диапазонов исследования урожайности культур; увеличение зон исследования и пространственного охвата; применение в дальнейшем гибридных нейросетевых архитектур (Conv LSTM, трансформеры), ансамблирование нейросетевых моделей CNN (перцептрон) и LSTM (сверточная сеть); интеграция в модели данных фитосанитарного мониторинга; внедрение оценок неопределенности

за счет построения статистических моделей (байесовские сети); использование пилотных облачных сервисов для хозяйств с регулярным обновлением прогноза.

Экономический эффект от внедрения автоматизированных систем прогнозирования на базе ИИ проявляется через оптимизацию процессов планирования, снижение рисков и повышение эффективности использования ресурсов в сельскохозяйственной деятельности [3–6, 13–15].

### ВЫВОДЫ

Сравнительный анализ показателей оценочных метрик качества прогнозных моделей выявил статистически значимое преимущество модели LSTM над MLP (по критерию Вилкоксона сдвиг показателей одной модели более интенсивный, чем в другой модели, по парным ошибкам  $p < 0,05$ ) и умеренное преимущество CNN над MLP. Интерпретируемость нейросетей обеспечивается частично (SHAP, анализ временных вкладов), однако для производственного внедрения предпочтительна интеграция модулей ХАИ. Стабильность результатов подтверждена тестами на независимых годах (2024 г.). Практическая значимость ошибки порядка 5–6% оценивается как достаточная для управленческих решений по логистике и страхованию урожая, превосходящая точность классических подходов [1–3, 7–13].

### СПИСОК ИСТОЧНИКОВ

1. Лупян Е.А., Савин И.Ю., Баргалева С.А., Толпин В.А., Балашов И.В. и др. Спутниковый сервис мониторинга состояния растительности («ВЕГА»). *Современные проблемы дистанционного зондирования Земли из космоса*. 2011;8(1):190–198. URL: <https://elibrary.ru/nvwwbl>
2. Савин И.Ю., Баргалева С.А., Лупян Е.А., Толпин В.А. Прогнозирование урожайности сельскохозяйственных культур на основе спутниковых данных: возможности и перспективы. *Современные проблемы дистанционного зондирования Земли из космоса*. 2010;7(3):275–285. URL: <https://elibrary.ru/ncyazf>
3. Тарасов А.Н., Исаева О.В., Холодова М.А. Аграрный сектор юга России: современные тенденции и перспективы развития. Ростов-на-Дону: Азов-Принт; 2020. 112 с. DOI: 10.34924/FRARC.2020.45.18.001



4. Барталев С.А., Лупян Е.А., Савин И.Ю. Дистанционная оценка параметров сельскохозяйственных земель по данным MODIS. *Современные проблемы дистанционного зондирования Земли из космоса*. 2004;1(1):113–123. URL: <https://elibrary.ru/ndpntl>
5. Ерошенко Ф.В., Барталев С.А., Сторчак И.Г., Плотников Д.Е. Возможности дистанционной оценки урожайности озимой пшеницы на основе вегетационного индекса фотосинтетического потенциала. *Современные проблемы дистанционного зондирования Земли из космоса*. 2016;13(4):99–112. DOI: 10.21046/2070-7401-2016-13-23-99-112
6. Сторчак И.Г., Ерошенко Ф.В. Использование NDVI для оценки продуктивности озимой пшеницы в Ставропольском крае. *Земледелие*. 2014;7:12–15. URL: <http://jurzemledelie.ru/arkhiv-nomerov/7-2014/662-ispolzovanie-ndvi-dlya-otsenki-produktivnosti-ozimoy-pshenitsy-v-stavropolskom-krae>
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. DOI: 10.1162/neco.1997.9.8.1735
8. Gers F., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000;12(10):2451–2471. DOI: 10.1162/089976600300015015
9. Karim F., Majumdar S., Darabi H., Chen S. LSTM Fully Convolutional Networks for Time Series Classification. *IEEE Access*. 2018;6:1662–1669. DOI: 10.1109/ACCESS.2017.2779939
10. Денисов П.В., Иванов А.Б., Мишуров Н.П., Петухов Д.А., Подъяблонский П.А. и др. Прогнозирование урожайности озимой пшеницы с использованием технологий дистанционного зондирования Земли. *Управление рисками в АПК*. 2021;39:37–45. DOI: 10.53988/24136573-2021-01-03
11. Бондур В.Г., Гороховский К.Ю., Игнатъев В.Ю., Мурынин А.Б., Гапонова Е.В. Метод прогнозирования урожайности по космическим наблюдениям за динамикой развития вегетации. *Известия высших учебных заведений. Геодезия и аэрофотосъемка*. 2013;6:61–68. URL: <https://elibrary.ru/uiuicwn>
12. Лупян Е.А., Барталев С.А., Крашенинникова Ю.С., Плотников Д.Е., Толпин В.А. и др. Спутниковый сервис «ВЕГА»: методы и примеры использования в АПК. *Современные проблемы дистанционного зондирования Земли из космоса*. 2015;12(5):231–247. URL: <https://elibrary.ru/thxydn>
13. Шайтура С.В., Герасимов В.А. Методы проведения интеллектуального анализа данных. *Славянский форум*. 2022;4(38):421–429. URL: <https://elibrary.ru/xwuxwa>
14. Шайтура С.В., Семичевская Н.П., Белю Л.П. Анализ процессов цифровизации социально-экономических систем. *Вопросы региональной экономики*. 2024;4(61):197–212. URL: <https://elibrary.ru/jaeyhr>
15. Николаева С.Г., Семичевская Н.П., Кошкина Л.Ю. Анализ больших данных в экономике: применение и перспективы. *Экономика и управление: проблемы, решения*. 2025;11(3)(156):188–192. DOI: 10.36871/ek.up.p.r.2025.03.11.018

## REFERENCES

1. Lupyan E.A., Savin I. Yu., Bartalev S.A., Tolpin V.A., Balashov I.V., Plotnikov D.E. Satellite service for vegetation monitoring VEGA. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2011;8(1):190–198. URL: <https://elibrary.ru/nvwwbl> (In Russ.).
2. Savin I. Yu., Bartalev S.A., Lupyan E.A., Tolpin V.A. Crop yields forecasting based on satellite data: opportunities and prospects. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2010;7(3):275–285. URL: <https://elibrary.ru/ncyazf> (In Russ.).
3. Tarasov A.N., Isaeva O.V., Kholodova M.A. The agrarian sector of the south of Russia: current trends and development prospects. Rostov-on-Don: Azov-Print; 2020. 112 p. (In Russ.). DOI: 10.34924/FRARC.2020.45.18.001
4. Bartalev S.A., Lupyan E.A., Savin I. Yu. Remote Assessment of Agricultural Land Parameters Using MODIS Data. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2004;1(1):113–123. URL: <https://elibrary.ru/ndpntl> (In Russ.).
5. Eroshenko F.V., Bartalev S.A., Storchak I.G., Plotnikov D.E. The possibility of winter wheat yield estimation based on vegetation index of photosynthetic potential derived from remote sensing data. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2016;13(4):99–112. (In Russ.). DOI: 10.21046/2070-7401-2016-13-23-99-112
6. Storchak I.G., Eroshenko F.V. Using of NDVI for assessing productivity of winter wheat in Stavropol region. *Agriculture*. 2014;7:12–15. URL: <http://jurzemledelie.ru/arkhiv-nomerov/7-2014/662-ispolzovanie-ndvi-dlya-otsenki-produktivnosti-ozimoy-pshenitsy-v-stavropolskom-krae> (In Russ.).
7. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. DOI: 10.1162/neco.1997.9.8.1735



8. Gers F., Schmidhuber J., Cummins F. Learning to Forget: Continual Prediction with LSTM. *Neural Computation*. 2000;12(10):2451-2471. DOI: 10.1162/089976600300015015
9. Karim F., Majumdar S., Darabi H., Chen S. LSTM Fully Convolutional Networks for Time Series Classification. *IEEE Access*. 2018;6:1662-1669. DOI: 10.1109/ACCESS.2017.2779939
10. Denisov P.V., Ivanov A.B., Mishurov N.P., Petukhov D.A., Podyablonskiy P.A. et al. Forecasting the yield of winter wheat using remote sensing technologies. *Agricultural Risk Management*. 2021;39:37-45. (In Russ.). DOI: 10.53988/24136573-2021-01-03
11. Bondur V.G., Gorokhovskiy K. Yu., Ignatiev V. Yu., Murynin A.B., Gaponova E.V. Method of Yield Forecasting Based on Space Observations of Vegetation Dynamics. *Izvestia Vuzov. Geodesy and Aerophotosurveying*. 2013;6:61-68. URL: <https://elibrary.ru/uiycwn> (In Russ.).
12. Lupyan E.A., Bartalev S.A., Krashenninnikova Yu.S., Plotnikov D.E., Tolpin V.A. et al. VEGA satellite service applications in regional remote monitoring systems. *Sovremennye Problemy Distantionnogo Zondirovaniya Zemli iz Kosmosa* [Modern Problems of Earth Remote Sensing from Space]. 2015;12(5):231-247. URL: <https://elibrary.ru/thxydn> (In Russ.).
13. Shaitura S.V., Gerasimov V.A. Data Mining Methods. *Slavic Forum*. 2022;4(38):421-429. URL: <https://elibrary.ru/xwuxwa> (In Russ.).
14. Shaitura S.V., Semichevskaya N.P., Belyu L.P. Analysis of the Processes of Digitalization of Socio-Economic Systems. *Problems of Regional Economy*. 2024;4(61):197-212. URL: <https://elibrary.ru/jaeyhr> (In Russ.).
15. Nikolaeva S.G., Semichevskaya N.P., Koshkina L. Yu. Big data analysis in economy: application and prospects. *Economics and Management: Problems, Solutions*. 2025;11(3)(156):188-192. (In Russ.). DOI: 10.36871/ek.up.p.r.2025.03.11.018

### ИНФОРМАЦИЯ ОБ АВТОРАХ / ABOUT THE AUTHORS

**Сергей Владимирович Шайтура** — кандидат технических наук, доцент кафедры информационных технологий и управляющих систем, Технологический университет имени дважды Героя Советского Союза, летчика-космонавта А.А. Леонова, г. Королев, Московская область, Российская Федерация

**Sergey V. Shaitura** — Cand. Sci. (Tech.), Assoc. Prof. of the Department of Information Technologies and Control System, Leonov University of Technology, Korolev, Moscow Region, Russian Federation, Korolev, Moscow Region, Russian Federation

<https://orcid.org/0000-0002-5621-5460>

Автор для корреспонденции / Corresponding author:

[swshaytura@gmail.com](mailto:swshaytura@gmail.com)

**Наталья Петровна Семичевская** — кандидат технических наук, доцент, доцент кафедры информационных систем и цифровых технологий, Московский государственный университет технологий и управления имени К.Г. Разумовского (ПКУ), Москва, Российская Федерация

**Nataliya P. Semichevskaya** — Cand. Sci. (Tech.), Assoc. Prof., Assoc. Prof. of the Department of Information Systems and Digital Technologies, K.G. Razumovsky Moscow State University of Technologies and Management, Moscow, Russian Federation

<https://orcid.org/0009-0001-2577-3363>

[npsem@mail.ru](mailto:npsem@mail.ru)

**Наталья Сергеевна Шайтура** — кандидат физико-математических наук, старший преподаватель кафедры высшей математики, Российский государственный аграрный университет — МСХА имени К.А. Тимирязева, Москва, Российская Федерация

**Nataliya S. Shaitura** — Cand. Sci. (Phys.-Math.), Senior Lecturer of the Higher Mathematics Department, Russian State Agrarian University — Moscow Timiryazev Agricultural Academy, Moscow, Russian Federation

<https://orcid.org/0000-0002-9422-910X>

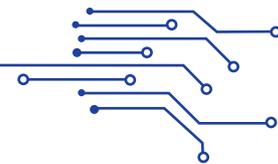
[tesh-s@yandex.ru](mailto:tesh-s@yandex.ru)

#### Заявленный вклад авторов:

**С.В. Шайтура** — разработка общей концепции статьи и технической части.

**Н.П. Семичевская** — описание общей теоретической части, проверка и описание математических моделей, выкладок и аналитической части.

**Н.С. Шайтура** — разработка алгоритмов, сбор и обработка данных, предоставление результатов и участие в обсуждениях и выводах.



**Authors declared contributions:**

**S.V. Shaitura** – development of the general concept of the article and the technical part.

**N.P. Semichevskaya** – description of the general theoretical part, verification of mathematical models, calculations, and the analytical part.

**N.S. Shaitura** – data collection and processing, reporting results, and participation in discussions and conclusions.

*Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.*

*Conflicts of Interest Statement: The authors have no conflicts of interest to declare.*

*Статья поступила в редакцию 13.10.2025; принята к публикации 24.11.2025.*

*Авторы прочитали и одобрили окончательный вариант рукописи.*

*The article was submitted on 13.10.2025; accepted for publication on 24.11.2025.*

*The authors read and approved the final version of the manuscript.*