

МЕХАНИЗАЦИЯ, ЭЛЕКТРИФИКАЦИЯ, АВТОМАТИЗАЦИЯ / MECHANIZATION, ELECTRIFICATION, AUTOMATION

<https://doi.org/10.30766/2072-9081.2026.27.1.219-229>



УДК 631.171:004.3:004.932

Разработка нейросетевой модели на Python для прогнозирования урожайности картофеля в условиях ограниченного объема данных

© 2026. Д. А. Москвичев

ФГБОУ ВО «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева», г. Москва, Российская Федерация

Научная работа посвящена разработке нейросетевой модели на языке программирования Python для решения технологической задачи прогнозирования урожайности картофеля в условиях ограниченного объема агроклиматических данных. Разработанная программа рассматривается как элемент цифровой трансформации технологических процессов в растениеводстве, ориентированный на оптимизацию использования сельскохозяйственной техники и материальных ресурсов в агропромышленном комплексе. В исследовании использованы данные за 2022–2024 гг. о климатических условиях, типах почв и фактической урожайности картофеля по агропредприятиям Ульяновской области. Для обеспечения качества исходной информации проведена комплексная предобработка данных, включающая устранение пропущенных значений, фильтрацию статистических выбросов и нормализацию числовых параметров. Создана модель нейронной сети с использованием библиотек TensorFlow и Keras с архитектурой, включающей входной слой, два скрытых слоя по 64 нейрона и выходной слой. Особенностью исследования является работа с ограниченным объемом данных (15 наблюдений за 3 года), в связи с чем для предотвращения переобучения были применены методы регуляризации (L2, Dropout) и аугментации данных. Архитектура оптимизирована методом подбора гиперпараметров, а для оценки надежности модели применено перекрестное проверочное разделение данных. Валидация модели на тестовой выборке показала, что разработанная нейронная сеть обеспечивает среднюю абсолютную ошибку (MAE) 0,32 т/га и коэффициент детерминации (R^2) 0,87. Модель превзошла по качеству прогноза множественную линейную регрессию (MAE = 0,45 т/га, R^2 = 0,75) и случайный лес (MAE = 0,38 т/га, R^2 = 0,81). Полученные результаты демонстрируют потенциал разработанного программного обеспечения для повышения эффективности планирования агротехнологических операций. Рекомендуется внедрение модели в качестве программного модуля систем поддержки принятия решений при управлении технологическими процессами в картофелеводстве.

Ключевые слова: агропромышленный комплекс, цифровые технологии, программное обеспечение, нейронные сети, оптимизация ресурсов, картофелеводство, технологические процессы

Благодарности: работа выполнена без финансового обеспечения в рамках инициативной тематики.

Автор благодарит рецензентов за их вклад в экспертную оценку этой работы.

Конфликт интересов: автор заявил об отсутствии конфликта интересов.

Для цитирования: Москвичев Д. А. Разработка нейросетевой модели на Python для прогнозирования урожайности картофеля в условиях ограниченного объема данных. Аграрная наука Евро-Северо-Востока. 2026;27(1):219–229.

DOI: <https://doi.org/10.30766/2072-9081.2026.27.1.219-229>

Поступила: 19.05.2025

Принята к публикации: 26.01.2026

Опубликована онлайн: 27.02.2026

Developing a Python neural network model for potato yield forecasting with limited data

© 2026. Dmitry A. Moskvichev

Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Moscow, Russian Federation

This research focuses on developing a neural network model in the Python programming language to solve the technological problem of forecasting potato yields with limited agroclimatic data. The developed program is considered as an element of the digital transformation of technological processes in crop production, aimed at optimizing the use of agricultural machinery and material resources in the agro-industrial complex. The study used data for 2022–2024 on climatic conditions, soil types, and actual potato yields at agricultural enterprises in the Ulyanovsk region. To ensure the quality of the initial information, comprehensive data preprocessing was performed, including the elimination of missing values, filtering of statistical outliers, and normalization of numerical parameters. A neural network model was created using the TensorFlow and Keras libraries with an architecture including an input layer, two hidden layers of 64 neurons each, and an output layer. A distinctive feature of the study is that it works with a limited amount of data (15 observations over 3 years). Therefore, regularization (L2, Dropout)

and data augmentation methods were used to prevent overfitting. The architecture was optimized using hyperparameter selection, and a cross-validation split of the data was used to evaluate the reliability of the model. Validation of the model on a test set showed that the developed neural network provides a mean absolute error (MAE) of 0.32 t/ha and a determination coefficient (R^2) of 0.87. The model outperformed multiple linear regression (MAE = 0.45 t/ha, $R^2 = 0.75$) and random forest (MAE = 0.38 t/ha, $R^2 = 0.81$) in forecast quality. The obtained results demonstrate the potential of the developed software for improving the efficiency of planning agricultural operations. It is recommended to implement the model as a software module for decision support systems in the management of technological processes in potato growing.

Keywords: agro-industrial complex, digital technologies, software, neural networks, resource optimization, potato farming, technological processes.

Acknowledgements: the work was completed without financial support within the framework of the initiative topic.

The author thanks the reviewers for their contribution to the peer review of this work.

Conflict of interest: the author stated that there was no conflict of interest.

For citations: Moskvichev D. A. Developing a Python neural network model for potato yield forecasting with limited data. *Agrarnaya nauka Evro-Severo-Vostoka* = Agricultural Science Euro-North-East. 2026;27(1):219–229. (In Russ.). DOI: <https://doi.org/10.30766/2072-9081.2026.27.1.219-229>

Received: 19.05.2025

Accepted for publication: 26.01.2026

Published online: 27.02.2026

Современный агропромышленный комплекс переживает этап активной цифровой трансформации, где ключевым направлением развития являются «Технологии, машины и оборудование сельскохозяйственного назначения» [1]. В рамках этого направления особую актуальность приобретает создание интеллектуальных программных комплексов для управления технологическими процессами в растениеводстве. Одной из наиболее важных технологических задач, непосредственно влияющих на эффективность использования машинно-тракторного парка и материальных ресурсов, является точное прогнозирование урожайности сельскохозяйственных культур [2]. Картофель как одна из ключевых продовольственных культур требует особого подхода к планированию технологических операций – от подготовки почвы до уборки и хранения [3]. Традиционные методы оценки урожайности, основанные на эмпирическом опыте и статистических данных, часто не учитывают комплексное влияние множества технологических параметров, что приводит к значительным погрешностям в планировании производственных процессов¹. Разработка специализированного программного обеспечения с применением нейронных сетей представляет собой перспективное направление решения данной технологической задачи [4].

Нейросетевые модели способны анализировать многомерные данные технологического цикла и выявлять сложные нелинейные зависимости между агротехническими параметрами и конечной урожайностью².

Цель исследования – разработка нейросетевой программы на высокоуровневом языке программирования Python для прогнозирования урожайности картофеля, ориентированной на интеграцию в технологические процессы агропромышленного комплекса.

Особое внимание уделено особенностям реализации программного обеспечения, обеспечивающим его практическое применение в условиях современного сельскохозяйственного производства [5].

Основные задачи исследования:

- адаптация методов машинного обучения для решения технологической задачи прогнозирования урожайности картофеля [6];
- разработка архитектуры нейронной сети, учитывающей специфику технологических параметров картофелеводства;
- реализация программного модуля с возможностью интеграции в системы управления технологическими процессами;
- верификация эффективности разработанного решения на реальных производственных данных [7].

¹Чашинский А. В., Рогозина Е. В., Козлов В. А., Башко Д. В. Изучение межвидовых гибридов картофеля селекции отдела генетических ресурсов картофеля ВИР в условиях Республики Беларусь. V Вавиловская международная конференция: к 135-летию со дня рождения Н. И. Вавилова: тез. докл. Санкт-Петербург, 21–25 ноября 2022 года. Санкт-Петербург: ФИЦ Всероссийский институт генетических ресурсов растений им. Н. И. Вавилова, 2022. С. 161–162. URL: <https://www.elibrary.ru/item.asp?id=50259275&pff=1> EDN: SYZASX

²Середкин Е. И., Иванько Я. М. Проектирование информационной системы прогнозирования урожая с использованием спутниковой информации. Значение научных студенческих кружков в инновационном развитии агропромышленного комплекса региона: сб. научн. тез. студ. п. Молодежный, 07–08 ноября 2024 года. п. Молодежный: Иркутский ГАУ им. А. А. Ежовского, 2024. С. 456–457. URL: <https://www.elibrary.ru/item.asp?id=80478476&pff=1> EDN: STXDPI

Преимущества использования нейронных сетей:

- с их помощью можно эффективно обрабатывать и анализировать большие массивы данных, что позволяет учитывать множество факторов, влияющих на урожайность [8];

- способны находить сложные нелинейные зависимости, которые могут быть неочевидны при использовании традиционных методов анализа [9];

- полученные модели можно адаптировать и улучшить по мере поступления новых данных, что позволит поддерживать их актуальность [10].

Научная новизна – заключается в адаптации и верификации архитектуры нейронной сети для задач прогнозирования урожайности картофеля в условиях малого объема агроклиматических данных, характерных для регионального уровня, а также в разработке специализированного программного обеспечения, сочетающего методы машинного обучения с требованиями технологических процессов в картофелеводстве, что позволяет оптимизировать

использование сельскохозяйственной техники и материальных ресурсов.

Практическая значимость определяется возможностью внедрения разработанной программы в качестве программного модуля систем поддержки принятия технологических решений, обеспечивающего повышение эффективности планирования производственных операций в картофелеводстве.

Материал и методы. Для разработки модели были собраны данные о климате, почве и урожайности за несколько лет из различных источников, включая метеорологические станции и агрономические исследования. Данные включали такие параметры, как температура, осадки, тип почвы и предыдущие урожаи [11]. Создание программы на Python для прогнозирования урожайности картофеля с использованием нейронных сетей – это задача, которая требует сбора данных, их обработки и построения модели [12]. В данном случае работа программы ЭВМ представлена в виде алгоритма (рис. 1).



Рис. 1. Алгоритм работы программы ЭВМ на Python для прогнозирования урожайности картофеля с использованием нейронных сетей /

Fig. 1. An algorithm for a Python computer program for predicting potato yields using neural networks

Далее переходим к описанию программы, включая необходимые шаги и код. Этапы разработки программы [13]:

Сбор данных об урожайности различных культур в зависимости от факторов, таких как температура, осадки, тип почвы, используемые удобрения, площадь посева. Данные могут быть получены из открытых источников – государственные статистические службы или специализированные агрономические исследования.

Предварительная обработка данных:

- очистка: удаление пропусков, аномалий и некорректных значений;
- нормализация: приведение всех параметров к одному масштабу для улучшения работы нейронной сети;
- разделение на обучающую и тестовую выборки.

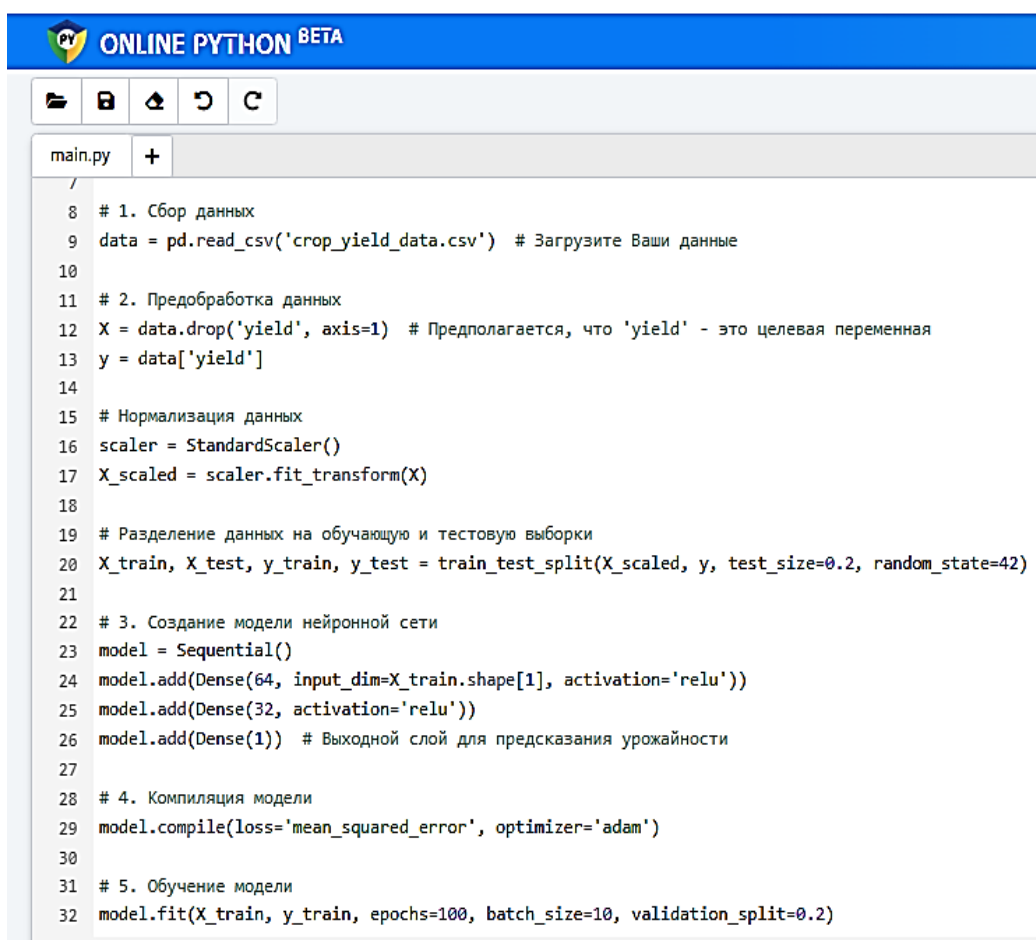
Создание модели нейронной сети – использование библиотеки TensorFlow или Keras для разработки и обучения модели.

Определение архитектуры нейронной сети. Входной слой: количество нейронов соответствует количеству факторов. Скрытые слои: один или несколько слоев с функцией активации ReLU. Выходной слой: один нейрон для прогнозирования урожайности.

Обучение модели на обучающей выборке с использованием функции потерь (например, среднеквадратичная ошибка) и оптимизатора (например, Adam). Мониторинг процесса обучения с использованием валидационной выборки для предотвращения переобучения.

Оценка производительности модели на тестовой выборке с использованием метрик, таких как MAE (средняя абсолютная ошибка) и RMSE (корень из средней квадратичной ошибки).

Фрагмент кода программы ЭВМ на Python для прогнозирования урожайности сельскохозяйственных культур с использованием нейронных сетей представлен на рисунке 2.



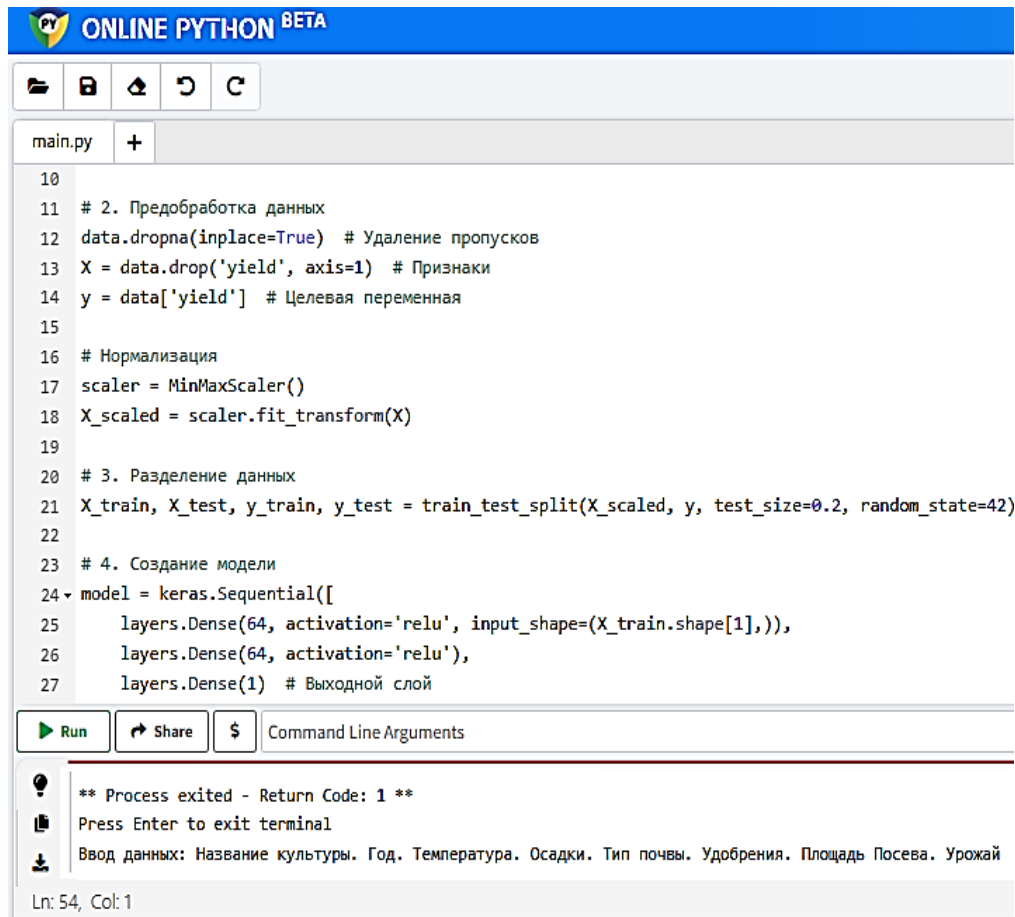
```
ONLINE PYTHON БЕТА
main.py +
/
8 # 1. Сбор данных
9 data = pd.read_csv('crop_yield_data.csv') # Загрузите Ваши данные
10
11 # 2. Предобработка данных
12 X = data.drop('yield', axis=1) # Предполагается, что 'yield' - это целевая переменная
13 y = data['yield']
14
15 # Нормализация данных
16 scaler = StandardScaler()
17 X_scaled = scaler.fit_transform(X)
18
19 # Разделение данных на обучающую и тестовую выборки
20 X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.2, random_state=42)
21
22 # 3. Создание модели нейронной сети
23 model = Sequential()
24 model.add(Dense(64, input_dim=X_train.shape[1], activation='relu'))
25 model.add(Dense(32, activation='relu'))
26 model.add(Dense(1)) # Выходной слой для предсказания урожайности
27
28 # 4. Компиляция модели
29 model.compile(loss='mean_squared_error', optimizer='adam')
30
31 # 5. Обучение модели
32 model.fit(X_train, y_train, epochs=100, batch_size=10, validation_split=0.2)
```

Рис. 2. Фрагмент программы ЭВМ на Python для прогнозирования урожайности картофеля с использованием нейронных сетей /

Fig. 2. A fragment of a Python computer program for predicting potato yields using neural networks

Визуализация результатов прогнозирования с помощью табличных значений. Программная реализация представляет собой модуль, который принимает на вход значения параметров (факторов) и возвращает прогнози-

руемую урожайность. Создание простого графического интерфейса или командной строки для взаимодействия с пользователем представлено на рисунке 3.



```
ONLINE PYTHON БЕТА
main.py +
10
11 # 2. Предобработка данных
12 data.dropna(inplace=True) # Удаление пропусков
13 X = data.drop('yield', axis=1) # Признаки
14 y = data['yield'] # Целевая переменная
15
16 # Нормализация
17 scaler = MinMaxScaler()
18 X_scaled = scaler.fit_transform(X)
19
20 # 3. Разделение данных
21 X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.2, random_state=42)
22
23 # 4. Создание модели
24 model = keras.Sequential([
25     layers.Dense(64, activation='relu', input_shape=(X_train.shape[1],)),
26     layers.Dense(64, activation='relu'),
27     layers.Dense(1) # Выходной слой
28 ])
Run Share $ Command Line Arguments
** Process exited - Return Code: 1 **
Press Enter to exit terminal
Ввод данных: Название культуры. Год. Температура. Осадки. Тип почвы. Удобрения. Площадь Посева. Урожай
Ln: 54, Col: 1
```

Рис. 3. Фрагмент визуализации ввода данных программы ЭВМ / Fig. 3. Fragment of visualization of data input of a computer program

Для обучения и валидации модели использовали данные за 3-летний период (2022–2024 гг.) по агропредприятиям Ульяновской области. Общий объем исходной выборки составил 15 наблюдений (по 5 хозяйствам ежегодно).

Источники данных:

- метеорологические – среднесуточная температура за вегетационный период, сумма осадков (ФГБУ «Ульяновский ЦГМС»³);

- по почвенному составу и агротехническим параметрам – тип почвы, виды удобрений, площадь посева (операционная отчетность сельхозпредприятий);

- фактическая урожайность: уборочные ведомости хозяйств.

Проблема малого объема выборки и методы ее компенсации. Учитывая объем данных, для предотвращения переобучения модели были применены: L2-регуляризация с коэффициентом 0,001 в скрытых слоях нейронной сети; dropout-слои с вероятностью 0,2 после каждого скрытого слоя; ранняя остановка (early stopping) при мониторинге loss на валидационной выборке с patience = 15 эпох; аугментация данных путем добавления гауссова шума к числовым признакам в пределах 5 % от стандартного отклонения. Помимо указанных параметров, в модель были включены следующие производные признаки: скользящие средние температуры за ключевые периоды вегетации; накопленная сумма осадков; бинарные признаки для каждого типа почвы

³Метеоинфо – сайт. [Электронный ресурс]. URL: <https://meteoinfo.ru/> (дата обращения: 01.05.2025).

и удобрений; произведения признаков (взаимодействия), такие как "температура x осадки".

Для объективной оценки эффективности разработанной нейросетевой модели проведено сравнение с тремя традиционными методами машинного обучения: множественная линейная регрессия (Linear Regression); случайный лес (Random Forest) со 100 деревьями; метод опорных векторов (Support Vector Regression) с RBF-ядром.

Все сравнительные модели реализованы с использованием библиотеки scikit-learn (v.1.3) с оптимизацией гиперпараметров методом GridSearchCV.

Для оценки надежности прогноза использована 5-кратная перекрестная валидация (5-fold cross-validation) со стратифицированным разделением по годам. Исходная выборка разделена на 5 блоков (folds) с сохранением

пропорций по годам. В каждом эксперименте 4 блока использовали для обучения, 1 – для тестирования. Процедура повторена 5 раз с ротацией тестового блока. Итоговые метрики рассчитаны как среднее по всем итерациям. Гиперпараметры нейронной сети:

1. Алгоритм оптимизации Adam (learning rate = 0,001).
2. Размер мини-батча – 8 наблюдений.
3. Количество эпох – 200 (с ранней остановкой).
4. Функция потерь – MSE (Mean Squared Error).

Результаты и их обсуждение. Программа прошла проверку опытным путем. В качестве экспериментальной части рассмотрена урожайность картофеля сорта Коломбо. Данные по урожайности взяты по агропредприятиям Ульяновской области за 2022, 2023, 2024 гг. и представлены в таблице 1.

Таблица 1 – Экспериментальные данные по урожайности картофеля сорта Коломбо в агропредприятиях Ульяновской области за 2022, 2023, 2024 гг. /

Table 1 – Experimental data on the yield of 'Colombo' potatoes at agricultural enterprises in the Ulyanovsk region for 2022, 2023, 2024

<i>Среднесуточная температура воздуха, °C / Average daily air temperature, °C</i>	<i>Сумма осадков, мм / Total precipitation, mm</i>	<i>Тип почвы / Soil type</i>	<i>Удобрения / Fertilizers</i>	<i>Площадь посева, га / Sown area, ha</i>	<i>Урожайность, т/га / Productivity, t/ha</i>
1	2	3	4	5	6
2022 г.					
20	300	Чернозем / Chernozem	Азотные, калийные / Nitrogen, potassium	10	25
22	250	Чернозем / Chernozem	Азотные, фосфорные / Nitrogen, phosphorus	15	28
18	350	Серая лесная / Gray forest soil	Комплексные / Complex	20	22
21	280	Чернозем / Chernozem	Азотные / Nitrogen	12	27
19	320	Дерново-подзолистая / Sod-podzolic	Фосфорные / Phosphorus	18	24
2023 г.					
21	290	Чернозем / Chernozem	Азотные, калийные / Nitrogen, potassium	12	26
23	260	Чернозем / Chernozem	Азотные, фосфорные / Nitrogen, potassium	16	30
19	340	Серая лесная / Gray forest soil	Комплексные / Complex	22	24
20	275	Чернозем / Chernozem	Азотные / Nitrogen	14	28
22	310	Дерново-подзолистая / Sod-podzolic	Фосфорные / Phosphorus	20	25

Продолжение табл. 1

1	2	3	4	5	6
2024 г.					
22	295	Чернозем / Chernozem	Азотные, калийные / Nitrogen, potassium	11	27
24	240	Серая лесная / Gray forest soil	Азотные, фосфорные / Nitrogen, phosphorus	14	29
20	360	Дерново-подзолистая / Sod-podzolic	Комплексные / Complex	21	23
19	280	Тяжёлый суглинок* / Heavy loam	Азотные / Nitrogen	16	25
23	310	Чернозем / Chernozem	Фосфорные / Phosphorus	19	30

Примечания: Агроклиматические параметры представлены за период вегетации картофеля.

*В модель в качестве признака включен гранулометрический состав тяжелосуглинистых и глинистых почв / Notes: Agroclimatic parameters are presented for the potato growing season.

*The model includes the particle size distribution of heavy loamy and clayey soils as a feature.

После использования разработанной программы ЭВМ были получены результаты прогноза урожайности на 2025 г. (табл. 2). Прогнозируемая температура для 2025 г. варьирует от 20 до 23 °С. Эти значения находятся в пределах оптимального диапазона для большинства сельскохозяйственных культур, что свидетельствует о потенциально благоприятных условиях для роста и развития. Осадки изменяются от 260 до 340 мм. Это также является важным фактором, так как достаточное количество осадков способствует лучшему увлажнению почвы и, следовательно, более высоким урожаям. Однако обильные осадки (например, 340 мм) могут привести к затоплению и другим

проблемам. Среди различных типов почв чернозем, как наиболее плодородный, демонстрирует наивысшую прогнозируемую урожайность (27 и 29 т/га). Прибавка урожая картофеля от оптимизации фосфорного питания на подобных почвах может достигать 30–50 %. В условиях Ульяновской области при интенсивной технологии возделывания (орошение, сбалансированные подкормки) потенциальная урожайность картофеля на окультуренных дерново-подзолистых почвах также может превышать 25–30 т/га. Таким образом, модель отразила не абсолютное плодородие типа почвы, а реальный агротехнический потенциал конкретного поля при оптимальном управлении.

Таблица 2 – Результаты прогноза урожайности картофеля сорта Коломбо, полученные с помощью программы ЭВМ на 2025 год /

Table 2 – Results of the ‘Colombo’ potato cultivar yield forecast obtained using a computer program for 2025

Среднесуточная температура воздуха, °C / Average daily air temperature, °C	Сумма осадков, мм / Total precipitation, mm	Тип почвы / Soil type	Удобрения / Fertilizers	Площадь посева, га / Sown area, ha	Урожайность, т/га / Productivity, t/ha
2025 г.					
21	300	Чернозем / Chernozem	Азотные, калийные / Nitrogen, potassium	12	27
23	260	Чернозем / Chernozem	Азотные, фосфорные / Nitrogen, phosphorus	16	29
20	340	Серая лесная / Gray forest	Комплексные / Complex	22	24
20	280	Тяжёлый суглинок* / Heavy loam	Азотные / Nitrogen	14	26
22	310	Дерново-подзолистая / Sod-podzolic	Фосфорные / Phosphorus	20	28

*См. табл. 1 / Refer to table 1

Использование различных видов удобрений также влияет на прогнозируемые урожаи, что подтверждает необходимость правильного выбора удобрений для достижения максимальной урожайности. Прогнозируемая моделью более высокая урожайность на черноземах при внесении азотно-фосфорных удобрений (29 т/га) против азотно-калийных (27 т/га) не противоречит агрономическим принципам, а отражает специфику условий. Черноземы Ульяновской области характеризуются высокой естественной обеспеченностью калием, поэтому его дополнительное внесение может не давать значимой прибавки, тогда как фосфор, часто находящийся в труднодоступной форме, становится лимитирующим фактором. Модель, учитывая комплекс данных (исходный почвенный баланс, прогноз погоды), выявила эту неочевидную зависимость, демонстрируя, что на хорошо окультуренных черноземах приоритет в программе удобрений может смещаться в сторону фосфора для реализации потенциала урожайности, что согласуется с принципом региональной адаптации агротехнологий.

Площадь посева варьирует от 12 до 22 га. Большая площадь посева может привести к более высокому общему урожаю, однако важно учитывать, что эффективность исполь-

зования ресурсов также зависит от других факторов, таких как тип почвы и удобрения. В практике хозяйствования площади под картофель на таких землях часто сознательно ограничивают, ориентируясь на участки с более легким гранулометрическим составом, что и согласуется с логикой данных, заложенных в модель. Этот технологический нюанс подтверждает, что модель корректно отражает не только биоклиматические, но и организационно-агротехнические взаимосвязи.

После завершения обучения модели были получены результаты прогноза урожайности картофеля. Процедура 5-кратной перекрестной валидации показала следующую производительность разработанной нейросетевой модели на тестовых блоках (фолдах): средние метрики по всем итерациям кросс-валидации; средняя абсолютная ошибка (MAE) – 3,2 ц/га; корень из среднеквадратичной ошибки (RMSE) – 3,9 ц/га; коэффициент детерминации (R^2) – 0,87.

Для объективной оценки эффективности проведено сравнение метрик с альтернативными алгоритмами машинного обучения, обученными и протестированными на тех же данных с использованием идентичной процедуры кросс-валидации, представленное в таблице 3.

Таблица 3 – Сравнительные метрики моделей прогнозирования урожайности картофеля сорта Коломбо / Table 3 – Comparative metrics of yield forecasting models for the ‘Colombo’ potato cultivar

<i>Модель / Model</i>	<i>Средняя абсолютная ошибка (MAE), ц/га / Mean absolute error (MAE), c/ha</i>	<i>Корень из среднеквадратичной ошибки (RMSE), ц/га / Root mean square error (RMSE), c/ha</i>	<i>Коэффициент детерминации (R^2) / Coefficient of determination (R^2)</i>
Нейронная сеть (наша модель) / Neural network (our model)	3,2	3,9	0,87
Случайный лес (Random Forest) / Random Forest (RF)	3,8	4,7	0,81
Множественная линейная регрессия / Multiple linear regression (MLR)	4,5	5,4	0,75
Метод опорных векторов (SVR) / Support vector regression (SVR)	4,1	5,1	0,78

Для проверки значимости превосходства нейросетевой модели над лучшим из традиционных методов (Случайный лес) был проведен парный t-тест по результатам MAE на 5 фолдах кросс-валидации. Результат показал p -value < 0,05, что статистически подтверждает – улучшение качества прогноза не является случайным. Модель продемонстрировала значительное

улучшение по сравнению с традиционными методами, такими как линейная регрессия.

Анализ результатов показал, что наибольшее влияние на урожайность оказывают климатические условия – температура и количество осадков. Однако также были выявлены важные корреляции с характеристиками почвы и предыдущими урожаями.

Реализация включает этапы сбора и пред-обработки данных, нормализации и обучения нейронной сети с использованием библиотек TensorFlow или Keras, а также графический пользовательский интерфейс, облегчающий взаимодействие пользователя с системой. Таким образом, созданная модель демонстрирует преимущества нейронных сетей в обработке данных и выявлении сложных зависимостей, что позволяет повысить качество прогноза урожайности картофеля. Полученные результаты указывают на потенциальные возможности для аграриев в планировании и управлении сельскохозяйственным производством, повышая его эффективность и обеспечивая более стабильные урожаи в условиях изменяющегося климата. Модель в её текущем состоянии показывает высокую эффективность на имеющейся выборке, но требует дальнейшей проверки и дообучения на более обширных и репрезентативных массивах данных из разных регионов, прежде чем может быть рекомендована для широкого практического применения. Таким образом, настоящее исследование служит доказательством концепции, а его основная практическая ценность заключается в демонстрации методики, которая может быть масштабирована после накопления дополнительных данных. В целом работа показывает перспек-

тивы внедрения современных технологий машинного обучения в агропромышленный комплекс и их важную роль в повышении продовольственной безопасности.

Заключение. Разработка программы ЭВМ на Python с применением нейронных сетей для прогнозирования урожайности картофеля продемонстрировала свою эффективность. Использование машинного обучения в данном исследовании позволило повысить надежность прогнозирования по сравнению с традиционными методами, что подтверждается снижением MAE на 1,3 ц/га. Программа прошла успешную проверку экспериментальным путем. В ходе кросс-валидации на данных по урожайности картофеля сорта Коломбо (Ульяновская область, 2022–2024 гг.) модель продемонстрировала стабильную эффективность: средняя абсолютная ошибка (MAE) составила $3,2 \pm 0,4$ ц/га, коэффициент детерминации (R^2) – 0,87.

В настоящее время подана заявка на получение государственной регистрации программы ЭВМ. Дальнейшие исследования могут быть направлены на улучшение модели и ее адаптацию к различным регионам и культурам, что позволит агрономам принимать более обоснованные решения и улучшить продовольственную безопасность.

Список литературы

1. Беленков А. И., Мазиров М. А., Зеленев А. В. Взаимосвязь урожайности зерновых культур и слагаемых параметров, влияющих на нее. Инновационные технологии в селекции, семеноводстве и возделывании зерновых культур: проблемы, достижения и перспективы: сб. научн. ст. Международ. научн. конф., посвящ. 300-летию Российской академии наук. В 2-х томах. Москва, 04–05 апреля 2024 года. М.: ФГБНУ «ФИЦ «Немчиновка», 2024. С. 85–90.
2. Ёров Ш. Ф. Оценка применения органических удобрений на развитие и урожайность картофеля раннего. Фундаментальные и прикладные научные исследования: актуальные вопросы современной науки, достижения и инновации: сб. научн. ст. по мат-лам XIII Международ. научн.-практ. конф. Уфа, 15 декабря 2023 года. Уфа: ООО «Научно-издательский центр «Вестник науки», 2023. С. 222–227.
Режим доступа: <https://www.elibrary.ru/item.asp?id=59762917> EDN: RZFFZE
3. Москвичев Д. А. Совершенствование системы мониторинга сельскохозяйственной техники. Мат-лы Международной научной конференции молодых учёных и специалистов, посвящённой 150-летию со дня рождения А. Я. Миловича. Москва, 03–05 июня 2024 года. М.: РГАУ – МСХА имени К. А. Тимирязева, 2024. С. 535–539. Режим доступа: <https://www.elibrary.ru/item.asp?edn=PZSLBK&ysclid=mkmhq06fyo360918561> EDN: PZSLBK
4. Шарый П. А., Шарая Л. С., Рухович О. В., Шкуркин С. И. Методы моделирования урожайности сельскохозяйственных культур: обзор. Проблемы агрохимии и экологии. 2023;(2):62–70.
DOI: <https://doi.org/10.26178/AE.2023.42.74.010> EDN: TBRORS
5. Москвичев Д. А., Хакимов Р. Т. Особенности разработки компьютерной программы для систем управления тракторами сельскохозяйственного назначения на основе искусственного интеллекта. АгроЭко-Инженерия. 2024;(4(121)):29–37. DOI: <https://doi.org/10.24412/2713-2641-2024-4121-29-37> EDN: OAPAPS
6. Боженко П. П., Стативко Р. У. Краткая характеристика нейронных сетей. Реализация расширяемой нейронной сети. Вестник молодёжной науки России. 2019;(5):1.
Режим доступа: <https://www.elibrary.ru/item.asp?id=44496710> EDN: SDFVWR

7. Нарушевич А. Л., Болдырь Д. В., Демчук Е. В. Анализ систем глобального позиционирования в АПК. Научное и техническое обеспечение АПК, состояние и перспективы развития: сб. VII Международ. научн.-практ. конф. Омск, 14 апреля 2022 года. Омск: Омский ГАУ имени П. А. Столыпина, 2022. С. 98–103. Режим доступа: <https://www.elibrary.ru/item.asp?id=48697040> EDN: AJGGFA
8. Демина М. И. Прогнозирование урожайности картофеля. Вестник Российского государственного аграрного заочного университета. 2008;(5(10)):47–48.
9. Evgrafov A., Guzalov A., Moskvichev D. Experimental studies of temperature-dynamic properties of peat soils in agricultural lands. E3S Web of Conferences: XI International Conference on Advanced Agritechnologies, Environmental Engineering and Sustainable Development, Termez, Uzbekistan, October 31 – November 02, 2024. Termez, Uzbekistan: EDP Sciences, 2025. Vol. 613. No. 05003. DOI: <https://doi.org/10.1051/e3sconf/202561305003> EDN: KQAYOQ
10. Vinogradov O. V., Moskvichev D. A., Didmanidze O. N., Parlyuk E. P. Methods of analyzing the structure of the modular car park and the intensity of its operation. Indo American Journal of Pharmaceutical Sciences. 2019;6(3):5289–5292. DOI: <https://doi.org/10.5281/zenodo.2592821> EDN: XKYYBC
11. Lykhovyd P., Vozhehova R., Zaiets S., Piliarska O. Selecting the best target function to Predict crop yields using their water use through regression analysis. Grail of Science. 2023;(26):185–192. DOI: <https://doi.org/10.36074/grail-of-science.14.04.2023.033> EDN: VWUCFC
12. Van Klompenburg T., Kassahun A., Catal C. Crop yield prediction using machine learning: A systematic literature review. Computers and Electronics in Agriculture. 2020;177:105709. DOI: <https://doi.org/10.1016/j.compag.2020.105709>
13. Chlingaryan A., Sukkarieh S., Whelan B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. Computers and Electronics in Agriculture. 2018;151:61–69. DOI: <https://doi.org/10.1016/j.compag.2018.05.012>

References

1. Belenkov A. I., Mazirov M. A., Zelenev A. V. The relationship between the yield of grain crops and the components of the parameters that affect it. Innovative technologies in breeding, seed production and cultivation of grain crops: problems, achievements and prospects: collection of scientific articles of the International scientific conference, dedicated to the 300th anniversary of the Russian Academy of Sciences. In 2 vol. Moscow, April 04-05, 2024. Moscow: FGBNU «FITs «Nemchinovka», 2024. pp. 85–90.
2. Yorov Sh. F. Assessment of the use of organic fertilizers on the development and yield of early potatoes. Fundamental and applied scientific research: current issues of modern science, achievements and innovations: collection of scientific articles on the materials of the XIII International scientific-practical conference Ufa, December 15, 2023. Ufa: OOO «Nauchno-izdatelskiy tsentr «Vestnik nauki», 2023. pp. 222–227. URL: <https://www.elibrary.ru/item.asp?id=59762917>
3. Moskvichev D. A. Improvement of the monitoring system of agricultural machinery. Proceedings of the International Scientific Conference of Young Scientists and Specialists dedicated to the 150th anniversary of the birth of A. J. Milovich. Moscow, June 03-05, 2024. Moscow: RGAU – MSKHA imeni K. A. Timiryazeva, 2024. pp. 535–539. URL: <https://www.elibrary.ru/item.asp?edn=PZSLBK&ysclid=mkmhq06fyo360918561>
4. Shary P. A., Sharaya L. S., Rukhovich O. V., Shkurkin S. I. Methods of crop production modeling: a review. *Problemy agrokhimii i ekologii*. 2023;(2):62–70. (In Russ.). DOI: <https://doi.org/10.26178/AE.2023.42.74.010>
5. Moskvichev D. A., Khakimov R. T. Specific aspects of designing ai-based computer programs for control systems of agricultural tractors. *Agro-EkoInzheneriya = AgroEcoEngineering*. 2024;(4(121)):29–37. (In Russ.). DOI: <https://doi.org/10.24412/2713-2641-2024-4121-29-37>
6. Bozhenko P. P., Stativko R. U. Brief characteristics of neural networks. realization of the expandable neural network. *Vestnik molodëzhnoy nauki Rossii*. 2019;(5):1. (In Russ.). URL: <https://www.elibrary.ru/item.asp?id=44496710>
7. Narushevich A. L., Boldyr' D. V., Demchuk Ye. V. Analiz sistem global'nogo pozitsionirovaniya v APK. Scientific and technical support of the agro-industrial complex, state and prospects of development: collection of the VII International scientific- practical conference. Омск, April 14, 2022. Омск: Омский ГАУ имени П. А. Столыпина, 2022. pp. 98–103. URL: <https://www.elibrary.ru/item.asp?id=48697040>
8. Demina M. I. Potato yield forecasting. *Vestnik Rossiyskogo gosudarstvennogo agrarnogo zaochnogo universiteta = Bulletin of Michurinsk State Agrarian University*. 2008;(5(10)):47–48. (In Russ.).
9. Evgrafov A., Guzalov A., Moskvichev D. Experimental studies of temperature-dynamic properties of peat soils in agricultural lands. E3S Web of Conferences: XI International Conference on Advanced Agritechnologies, Environmental Engineering and Sustainable Development, Termez, Uzbekistan, October 31 – November 02, 2024. Termez, Uzbekistan: EDP Sciences, 2025. Vol. 613. No. 05003. DOI: <https://doi.org/10.1051/e3sconf/202561305003> EDN: KQAYOQ

10. Vinogradov O. V., Moskvichev D. A., Didmanidze O. N., Parlyuk E. P. Methods of analyzing the structure of the modular car park and the intensity of its operation. Indo American Journal of Pharmaceutical Sciences. 2019;6(3):5289–5292. DOI: <https://doi.org/10.5281/zenodo.2592821> EDN: XKYYBC

11. Lykhovyd P., Vozhehova R., Zaiets S., Piliarska O. Selecting the best target function to Predict crop yields using their water use through regression analysis. Grail of Science. 2023;(26):185–192. DOI: <https://doi.org/10.36074/grail-of-science.14.04.2023.033> EDN: VWUCFC

12. Van Klompenburg T., Kassahun A., Catal C. Crop yield prediction using machine learning: A systematic literature review. Computers and Electronics in Agriculture. 2020;177:105709. DOI: <https://doi.org/10.1016/j.compag.2020.105709>

13. Chlingaryan A., Sukkarieh S., Whelan B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. Computers and Electronics in Agriculture. 2018;151:61–69. DOI: <https://doi.org/10.1016/j.compag.2018.05.012>

Сведения об авторе

✉ **Москвичев Дмитрий Александрович**, кандидат техн. наук, старший преподаватель кафедры тракторов и автомобилей, ФГБОУ ВО «Российский государственный аграрный университет – МСХА имени К. А. Тимирязева», ул. Тимирязевская, д. 49, г. Москва, Российская Федерация, 127434, e-mail: rector@rgau-msha.ru, ORCID: <https://orcid.org/0009-0002-7082-4876>, e-mail: moskvichev@rgau-msha.ru

Information about the author

✉ **Dmitry A. Moskvichev**, PhD in Engineering, Senior Lecturer, the Department of Tractors and Automobiles, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, Timiryazevskaya st., 49, Moscow, Russian Federation, 127434, e-mail: rector@rgau-msha.ru, ORCID: <https://orcid.org/0009-0002-7082-4876>, e-mail: moskvichev@rgau-msha.ru

✉ – Для контактов / Corresponding author