

DOI: <https://doi.org/10.37162/2618-9631-2025-3-132-145>

УДК 631.559:004.032.26:551.501.86

## **Оценка ожидаемой средней районной урожайности озимой пшеницы с использованием полносвязной нейронной сети**

*А.Д. Клещенко, О.В. Савицкая, Я.А. Вдовина*

*Всероссийский научно-исследовательский институт  
сельскохозяйственной метеорологии, г. Обнинск, Россия  
cxm-dir@obninsk.ru*

Показана возможность использования глубоких нейронных сетей для оценки ожидаемой средней районной урожайности озимой пшеницы для территории Северо-Кавказского УГМС. Обучение нейронной сети выполнялось на наборе данных, включающих спутниковые индексы, метеорологические данные, а также временные ряды средней районной урожайности за период с 2012 по 2023 год. Проведен экспериментальный поиск оптимальных гиперпараметров нейронной сети, который позволил достичь баланса между точностью и обобщенностью модели. Проведен сравнительный анализ точности расчётов ожидаемой урожайности, полученных на основе нейронной сети, статистических регрессионных моделей и алгоритмов машинного обучения (дерево решений, случайный лес, линейная регрессия). Результаты анализа показали, что максимальная сходимость между фактической и рассчитанной урожайностями озимой пшеницы достигается с использованием нейронной сети. Полученные результаты демонстрируют перспективность нейросетевого подхода для оценки ожидаемой урожайности озимой пшеницы на основе комплексирования наземных и спутниковых данных.

*Ключевые слова:* урожайность, метеорологическая информация, индексы NDVI, VCI, VCNI, регрессия, нейронная сеть

## **Estimation of average regional expected winter wheat yield using a fully connected neural network**

*A.D. Kleshchenko, O.V. Savitskaya, Ya.A. Vdovina*

*All-Russian Research Institute of Agricultural Meteorology, Obninsk, Russia  
cxm-dir@obninsk.ru*

The possibility of using deep neural networks to estimate the winter wheat expected average district-level yield for the territory of the North Caucasus Hydrometeorological Service is shown. The neural network was trained on a dataset that included satellite indices and meteorological data, and historical series of average regional yields for the period from 2012 to 2023. An experimental search for optimal neural network hyperparameters was conducted which let achieve the balance between the model's accuracy and generalizability. A comparative analysis of the expected yield was conducted using a neural network, statistical regression models and machine learning algorithms (decision tree, random forest, linear regression). The results of the analysis showed that a more accurate convergence between actual and calculated winter wheat yields is achieved when using the neural network. The best results were obtained when using the neural network approach, ground-based and

satellite data integration. The obtained results demonstrate the potential of the neural network approach for assessing the expected yield of winter crops based on the integration of ground-based and satellite data.

*Ключевые слова:* crop yield, meteorological information, NDVI, VCI, VCNI, regression, neural network

## Введение

В современном мире наблюдается стремительное развитие и широкое применение инструментов машинного обучения в самых разнообразных областях. Принципы, лежащие в основе наиболее передовых и эффективных моделей машинного обучения, были разработаны еще в середине прошлого века. Активное развитие машинного обучения началось примерно 10 лет назад. Это связано с накоплением значительных объемов информации за последние годы и с существенным повышением вычислительных мощностей, необходимых для обучения моделей.

Отличительной особенностью нейронной сети является ее способность к обучению на наблюдаемых примерах, с определением в процессе обучения вида функциональной зависимости. В 2006 году [12] была предложена концепция глубокого обучения, которая представляет собой процесс машинного обучения, направленный на формирование глубокой сетевой структуры. В основе глубоких нейронных сетей лежит концепция многослойности [7]. По мере углубления сети извлекаются более сложные характеристики, которые способствуют повышению точности результатов. Глубокое обучение находит свое применение в решении сложных и комплексных задач, и одним из ключевых условий успешного моделирования является наличие достаточно длинной выборки данных, включающей в себя тысячи наблюдений.

В последнее время методы машинного обучения, включая искусственные нейронные сети (НС), находят все большее применение при решении гидрометеорологических задач, в том числе агрометеорологических, в частности при прогнозировании урожайности сельскохозяйственных культур [14, 15]. Это связано с тем, что способность НС выявлять сложные многомерные нелинейные связи, особенно важна при анализе метеорологических данных, обусловленных разнообразием физических процессов в атмосфере и их сложным распределением в пространстве и во времени.

Цель настоящего исследования состояла в реализации нейросетевого подхода и анализе его применимости при оценке ожидаемой урожайности озимой пшеницы на основе интеграции наземной и спутниковой информации.

## Подбор предикторов и подготовка обучающей выборки

Подготовка обучающей выборки НС является важным этапом создания модели. От качества подготовленных данных во многом зависит точность и эффективность разработанной НС. Основная задача этапа состоит

в формировании массива метеорологических и спутниковых параметров, влияющих на моделируемую переменную (урожайность).

В качестве спутниковой информации использовались данные со спектрорадиометра MODIS спутника Terra с пространственным разрешением 250 м, которые доступны на сервисе Vega-PRO (<http://pro-vega.ru>, ИКИ РАН). С помощью этого сервиса были получены в разрезе районов следующие спутниковые индексы: NDVI, VCI, VCNI. Эти спутниковые индексы доступны на сайте с учетом маски озимых и яровых культур. Наиболее широкое применение получил индекс NDVI, представляющий собой отношение разности сигналов в ближнем инфракрасном и красном диапазонах к их сумме. Индекс состояния растительности (VCI) [13] вычисляется на основе NDVI следующим образом:

$$VCI_j = \frac{NDVI_j - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}} \cdot 100\%, \quad (1)$$

где  $NDVI_j$  – значение NDVI для даты  $j$ ;  $NDVI_{\max}$  – значения максимальных NDVI внутри всего набора данных;  $NDVI_{\min}$  – значение минимальных NDVI внутри всего набора данных

Индекс VCNI позволяет выявлять аномальные изменения в развитии сельскохозяйственных культур [2, 5] и рассчитывается по следующей формуле:

$$VCNI_j = \frac{NDVI_j - NDVI_{\text{сред.}}}{NDVI_{\text{сред.}}}, \quad (2)$$

где  $VCNI_j$  – значение индекса для даты  $j$ ;  $NDVI_j$  – значение NDVI для даты  $j$ ;  $NDVI_{\text{сред.}}$  – среднее значение NDVI внутри всего набора данных.

В качестве наземной метеорологической информации использовались следующие параметры, полученные по данным наблюдений на гидрометеорологических станциях Росгидромета: средняя декадная температура воздуха ( $T$ ), сумма осадков за декаду ( $P$ ), среднедекадный дефицит влажности воздуха ( $D$ ). Следует отметить, что неблагоприятные погодные условия особенно опасны при продолжительном воздействии на посевы, поэтому наряду с ежедекадными данными использовались следующие параметры, полученные за три декады: средняя температура воздуха за 3 декады ( $T_3$ ), сумма осадков за 3 декады ( $P_3$ ), средний дефицит влажности воздуха за 3 декады ( $D_3$ ). Кроме того, использовался гидротермический коэффициент Селянинова (ГТК), характеризующий соотношение тепла и влаги:

$$ГТК_i = \frac{\sum R_{[i+(i-1)+(i-2)]}}{0,1 \cdot \sum T_{10^\circ C[i+(i-1)+(i-2)]}}, \quad (3)$$

где  $i$  – номер оцениваемой декады;  $i-1$  – номер декады, предшествующей на одну декаду от оцениваемой;  $i-2$  – номер декады, предшествующей на две декады от оцениваемой;  $\sum R$  – сумма осадков, мм;  $\sum T_{10^{\circ}\text{C}}$  – сумма температур воздуха  $10^{\circ}\text{C}$  и выше.

В качестве статистической информации использовались исторические ряды средних районных значений урожайности за период с 2012 по 2023 год. Для всех районов ряды урожайности доступны на сайте Федеральной службы государственной статистики в базе данных показателей муниципальных образований.

В ходе предварительного анализа данных было выявлено, что количество муниципальных районов существенно превышает количество гидрометеорологических станций в субъекте. В результате на уровне многих районов отмечается отсутствие метеорологических наблюдений. При этом предполагалось, что значения метеорологических параметров для местности, где расположена станция, отражают погодные условия в этом районе. Таким образом, возникла необходимость получения метеорологической информации для районов, где отсутствуют станции. Для этого использовался метод обратных взвешенных квадратов расстояний [4]. Идея метода заключается в том, что в процессе интерполяции более значимые веса присваиваются ближайшим точкам, при этом влияние каждой точки обратно пропорционально ее расстоянию. После того, как для всех районов была получена метеорологическая информация, осуществлялось формирование обучающей выборки для НС.

Для успешного обучения НС требуется обширная и репрезентативная выборка. При этом выборка должна охватывать самые разные «ситуации». Чем больше будет при обучении различных «ситуаций», в нашем случае состояний агрометеорологических условий, тем выше качество работы НС. Поэтому для увеличения объема выборки районы в пределах субъекта объединялись в один массив данных, также производилось объединение субъектов, входящих в состав Управления по гидрометеорологии и мониторингу окружающей среды (УГМС), тем более что их агроклиматические условия достаточно близки. В процесс интеграции данных также были включены периоды наблюдений, охватывающие временной интервал с первой декады мая по первую декаду июня и учитывающий основные фазы развития пшеницы. Таким образом, был сформирован весьма длинный ряд данных, включающий более 5 тыс. наблюдений для Северо-Кавказского УГМС. Для обеспечения способности нейронной сети распознавать временные периоды (месяцы, декады) были введены дополнительные категориальные переменные. Напрямую категориальные переменные не могут быть использованы в нейронных сетях, поскольку НС работает с данными в числовом формате. Поэтому было выполнено преобразование категориальных переменных в числовой формат с помощью метода one-hot encoding (однократное кодирование).

Поскольку различные признаки имеют разные единицы измерения и диапазоны значений, для более стабильной и эффективной работы НС данные были приведены к одному масштабу. Для этого была выполнена

предварительная нормализация данных с использованием математического ожидания и среднеквадратичного отклонения, которая позволяет масштабировать числовые значения в указанном диапазоне. Этот процесс заключается в делении разницы между исходными данными и математическим ожиданием на величину среднеквадратичного отклонения по следующим формулам:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i, \quad (4)$$

$$x = \frac{x_i - \mu}{\sigma}, \quad (5)$$

где  $\mu$  – математическое ожидание;  $\sigma$  – среднеквадратичное отклонение;  $x_i$  –  $i$ -е значение показателя;  $x$  – новое нормализованное значение показателя.

В процессе анализа исключались параметры, характеризующиеся наличием мультиколлинеарности. Данная операция осуществлялась посредством предварительного расчета парных коэффициентов корреляции Пирсона между исследуемыми переменными. После выявления сильно коррелирующих пар признаков оставались те, которые имели большую корреляцию с урожайностью.

### Структура и принцип работы полносвязных нейронных сетей

Полносвязная нейронная сеть представляет собой сеть, которая имеет несколько слоев, связанных между собой таким образом, что каждый нейрон слоя связан со всеми нейронами следующего слоя. Эти связи являются весовыми коэффициентами и настраиваются в процессе обучения. Сигнал передается от входного слоя к выходному без формирования обратных связей. На вход нейрону подается массив входных сигналов – это значения спутниковых и метеорологических параметров (в случае нейронов первого скрытого слоя) или выходные сигналы нейронов предыдущего слоя. Сигнал меняет свое значение в соответствии с весом.

$$z_h = \sum_{i=1}^n \omega_{ih} \cdot x_i, \quad (6)$$

где  $z_h$  – взвешенная линейная комбинация входных сигналов;  $n$  – число входных сигналов;  $\omega_{ih}$  – веса для нейрона  $h$ ;  $x_i$  – входной сигнал;

В нейроне происходит расчет взвешенной суммы входных сигналов с учетом смещения  $b$  (bias). Затем к полученному результату применяется функция активации, которая вычисляет выходной сигнал нейрона для его последующей передачи на следующий слой:

$$y_h = f(z_h + b_h), \quad (7)$$

где  $y_h$  – выходной сигнал нейрона  $h$ ;  $f()$  – функция активации;  $b_h$  – смещение.

Поскольку на основе спутниковых и метеорологических данных нужно спрогнозировать одно значение (урожайность), поэтому для реализации текущей задачи выходной слой содержит один нейрон, в котором не прибавляется смещение и не применяется функция активации.

Такая структура и принципы вычислений в НС способны моделировать сложные нелинейные связи между входными данными (спутниковые, метеорологические параметры) и целевой переменной (урожайность), что представляет собой основное преимущество НС.

### Результаты исследования

При проектировании нейронной сети важным этапом является подбор оптимальных гиперпараметров. Гиперпараметры нейронной сети представляют собой настройки модели, которые устанавливаются до начала процесса обучения и определяют общую структуру модели и способ ее обучения. Гиперпараметры влияют на производительность и эффективность работы НС. Подбор оптимальных гиперпараметров позволяет минимизировать эффект переобучения и одновременно увеличить обобщающую способность модели на ранее неизвестных данных. Переобучение происходит, когда модель слишком сложна по сравнению с объемом доступных обучающих данных. Такая избыточная сложность способна приводить к эффекту запоминания моделью конкретных примеров из обучающей выборки, а не к формированию обобщенных закономерностей. Это, в свою очередь, ведет к высокой точности работы модели на обучающем наборе данных, однако существенно снижает ее эффективность при обработке новых, ранее неизвестных данных. Наоборот, недообучение происходит, когда во время обучения не удается установить достаточно точные взаимосвязи между предикторами и целевой переменной, и НС демонстрирует низкую точность предсказания даже на обучающем наборе данных [7].

Нейронные сети имеют несколько важных гиперпараметров, которые необходимо настроить: количество скрытых слоев, количество нейронов в каждом слое, функции активации, количество эпох, скорость обучения.

Скрытые слои являются промежуточными между входным и выходным слоями, и обрабатывают данные, применяя к ним нелинейные функции. Большее количество скрытых слоев и нейронов может улавливать более сложные взаимосвязи, но также увеличивает риск переобучения. Функция активации нейронов вносит нелинейность в модель. В качестве функции активации обычно используются различные нелинейные функции. В данном исследовании для поиска оптимальной функции активации использовались: гиперболический тангенс, логистическая функция и ReLU (Rectified Linear Unit) [7]. Количество эпох определяет, сколько раз алгоритм обучения будет обрабатывать весь набор обучающих данных. Каждая эпоха обучения формирует новое состояние весовых коэффициентов. С увеличением количества эпох, весовые коэффициенты НС изменяются

все большее количество раз. С каждым разом НС лучше адаптируется к данным. Однако при увеличении количества эпох, также возрастает риск переобучения. Скорость обучения является одним из важнейших гиперпараметров в процессе оптимизации НС. Она определяет величину каждого шага при поиске минимума ошибки.

На текущий день существует несколько популярных подходов к автоматизации подбора гиперпараметров: поиск по решетке [11], случайный поиск [9] и на основе байесовской оптимизации. В поиске по решетке выполняется полный перебор всех возможных комбинаций гиперпараметров из заданного диапазона. Однако этот поиск очень медленный, поскольку нужно перебрать все комбинации всех параметров, более того, перебор будет продолжаться даже в случае заведомо неудачных сочетаний. При случайном поиске параметры выбираются произвольно из набора данных. Этот подход работает быстрее, чем поиск по решетке, но не всегда обеспечивает нахождение оптимального решения и не защищает от перебора заведомо неудачных сочетаний.

В рамках данного научного исследования для автоматизации поиска наилучшей комбинации гиперпараметров использовался алгоритм Tree-structured Parzen Estimator (ТРЕ) [8]. Алгоритм ТРЕ разработан на основе байесовской оптимизации. ТРЕ интеллектуально исследует пространство поиска гиперпараметров и способен учиться на истории испытаний и направлять поиск в наиболее перспективные области пространства гиперпараметров, что приводит к более быстрой сходимости и повышению эффективности. Для оптимизации гиперпараметров использовалась библиотека с открытым исходным кодом Optuna [8], реализованная на языке Python. Поскольку конечной целью разработки нейронной сети является прогнозирование на основе новых входных данных, для подбора гиперпараметров выборка разделяется на обучающую и независимую тестовую. Нейронная сеть обучается на примерах обучающей выборки, после этого вычисляется критерий качества работы НС по тестовой выборке. Качество модели оценивалось на основе среднеквадратичной ошибки (MSE) между прогнозируемыми и фактическими значениями, которая применялась в качестве функции потерь:

$$\text{MSE} = \frac{1}{n} \cdot \sum_{i=1}^n (y_i - \bar{y}_i)^2, \quad (8)$$


где  $n$  – количество наблюдений;  $y_i$  – фактическое значение переменной;  $\bar{y}_i$  – значение переменной, предсказанное моделью.

Таким образом, по итогам автоматизированного поиска были подобраны оптимальные гиперпараметры, которые обеспечивают наилучший баланс между точностью прогнозирования и обобщенностью модели. Для примера в табл. 1 представлены оптимальные гиперпараметры, подобранные для районов Северо-Кавказского УГМС.

**Таблица 1.** Оптимальные гиперпараметры нейронной сети, подобранные для районов Северо-Кавказского УГМС**Table 1.** Optimal neural network hyperparameters selected for the districts of the North Caucasus Department of Hydrometeorological Service


Гиперпараметр	Значения
Количество скрытых слоев	3
Количество нейронов в каждом скрытом слое	145, 145, 109
Функция активации для скрытых слоев	ReLU, ReLU, ReLU
Скорость обучения	0,0075
Количество эпох	600

Также при обучении НС подбирались различные оптимизаторы, предназначенные для минимизации функции потерь, что способствует повышению точности прогнозирования модели [3]. Существует большое количество оптимизаторов, наиболее эффективными при обучении НС показали себя следующие оптимизаторы: Adam (adaptive momentum), RMSprop (running mean square), Nadam (Nesterov-accelerated adaptive momentum), SGD (Stochastic gradient descent), AdaDelta (adaptive learning rate). На рис. 1 показана диаграмма изменения функции потерь в зависимости от указанных выше оптимизаторов и процентного соотношения обучающей и тестовой выборки для районов Северо-Кавказского УГМС.

**Рис. 1.** Изменения функции потерь в зависимости от различных оптимизаторов и процентного соотношения обучающей и тестовой выборки для районов Северо-Кавказского УГМС.**Fig. 1.** Changes in the loss function depending on different optimizers and the percentage ratio of training and test samples for the districts of the North Caucasus Department of Hydrometeorological Service.

Из рис. 1 видно, что наименьшая среднеквадратичная ошибка наблюдается при использовании оптимизатора Adam и при разделении выборки в соотношении 80 % для обучения и 20 % для тестирования.


Таким образом, была реализована глубокая нейронная сеть на Python с использованием библиотеки программного обеспечения с открытым исходным кодом PyTorch. На рис. 2 представлена схема полносвязной нейронной сети, которая была получена в рамках данного научного исследования. Формулы и обозначения представлены выше в разделе при описании структуры полносвязной нейронной сети.



**Рис. 2.** Схема полносвязной нейронной сети.

**Fig. 2.** Fully connected neural network diagram.

С помощью разработанной нейронной сети рассчитывается ожидаемая средняя районная урожайность озимой пшеницы. На рис. 3 представлены графики плотности вероятности фактической и рассчитанной урожайностей озимой пшеницы для районов Северо-Кавказского УГМС.

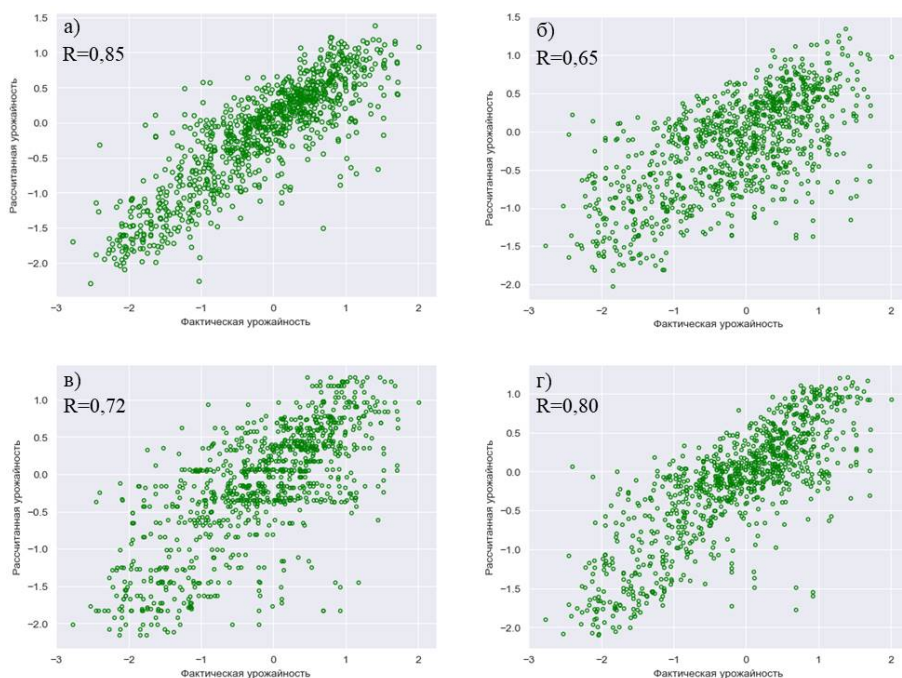


**Рис. 3.** Плотность вероятности фактической (а) и рассчитанной (б) урожайностей озимой пшеницы для районов Северо-Кавказского УГМС.

**Fig. 3.** Probability density of actual (a) and calculated (b) yields of winter wheat for the districts of the North Caucasus Department of Hydrometeorological Service.

Из графиков видно, что модель НС может достаточно достоверно сохранить распределительные свойства урожайности. Однако дисперсия рассчитанной урожайности меньше, что указывает на то, что расчет по модели НС более центрирован около среднего значения. При прогнозировании крайне важно учитывать экстремальные значения, которые определяют допустимые пределы урожайности. Как видно из графиков, НС удастся прогнозировать граничные значения, хотя и с меньшей частотой.

Было проведено сравнение рассчитанных значений урожайности, полученных с помощью разработанной нейронной сети и моделей машинного обучения на основе следующих алгоритмов: линейная регрессия (Linear Regression), дерево решений (Decision Tree [7]) и случайный лес (Random Forest [10, 7]). Примеры диаграмм рассеяния на тестовой выборке для районов Северо-Кавказского УГМС показаны на рис. 4.



**Рис. 4.** Результаты моделирования урожайности озимой пшеницы для районов Северо-Кавказского УГМС на основе методов машинного обучения: нейронная сеть (а), линейная регрессия (б), дерево решений (в), случайный лес (г).

**Fig. 4.** Results of modeling winter wheat yield for the districts of the North Caucasus Department of Hydrometeorological Service based on machine learning methods: neural network (a), linear regression (б), decision tree (в), random forest (г).

Из рис. 4 видно, что наилучшая сходимость между рассчитанными и фактическими значениями урожайности озимой пшеницы наблюдается при использовании нейронной сети, коэффициент корреляции составляет 0,85.

Следует отметить, что в последние годы во ВНИИСХМ был разработан метод оценки ожидаемой урожайности по административным районам юга России с использованием регрессионных моделей [1]. Регрессионные уравнения были построены для каждой определенной группы районов, расположенной в пределах субъекта, при этом указанные модели формировались отдельно и для каждой временной декады исследуемого периода. Районы объединялись в группы на основе агроклиматического районирования территории, разработанной Д.И. Шашко [6]. По Шашко, при агроклиматическом районировании территорию разделяют по показателям обеспеченности вегетационного периода теплом и влагой. Таким образом, при разработке регрессионных уравнений учитывались комплексно агроклиматические условия территории и временная динамика хода развития сельскохозяйственных культур. Представляется целесообразным провести сравнительный анализ точности расчетов ожидаемой урожайности, полученной на основе регрессионных моделей и с использованием нейронной сети. Для примера в табл. 2 показана относительная ошибка между фактическими и рассчитанными урожайностями озимой пшеницы для районов Краснодарского края, Ростовской и Волгоградской областей за 2021, 2022 и 2023 гг., полученными на основе регрессионных моделей и с использованием нейронной сети.

**Таблица 2.** Относительная ошибка между рассчитанными и фактическими урожайностями озимой пшеницы для районов Краснодарского края, Ростовской и Волгоградской областей за 2021, 2022 и 2023 гг.

**Table 2.** Relative error between winter wheat calculated and actual yields for the districts of Krasnodar, Rostov and Volgograd regions for 2021, 2022 and 2023


Месяц	Декада	Относительная ошибка, %					
		2021		2022		2023	
		R	AI	R	AI	R	AI
<b>Краснодарский край</b>							
Май	1	4,7	3,7	8,0	5,4	12,0	5,7
	2	4,5	3,6	7,3	4,7	8,2	3,8
	3	6,1	3,3	6,5	3,4	8,7	4,2
Июнь	1	5,7	3,5	11,0	2,6	7,1	3,8
<b>Волгоградская область</b>							
Май	1	16,8	10,9	8,1	6,5	11,3	7,0
	2	12,9	8,8	7,8	7,9	13,5	6,5
	3	12,3	9,2	9,8	7,1	14,8	7,3
Июнь	1	18,3	13,9	15,5	7,8	19,2	6,6
<b>Ростовская область</b>							
Май	1	9,9	3,1	5,6	3,6	6,3	4,6
	2	4,3	3,2	4,8	3,5	13,2	3,8
	3	5,9	4,8	3,9	2,5	14,1	5,0
Июнь	1	8,8	3,4	10,2	3,1	14,1	6,2

*Примечание.* R – регрессия, AI – нейронная сеть.

Как следует из табл. 2, практически во всех случаях относительная ошибка расчетов при использовании нейронной сети ниже по сравнению с регрессионными моделями. Аналогичные результаты получены при расчетах для всех районов рассматриваемых субъектов.

Для наглядности на рис. 5 представлено сравнение картосхем фактической и ожидаемой урожайности озимой пшеницы по территории Ростовской области с первой декады мая по первую декаду июня 2023 года с использованием регрессионных моделей и нейронной сети.

На основе анализа картосхем, представленных на рис. 5, можно сделать вывод, что более точная сходимость между фактической и рассчитанной урожайностями озимой пшеницы достигается посредством применения нейронной сети.



**Рис. 5.** Картосхемы ожидаемой урожайности озимой пшеницы по территории Ростовской области с первой декады мая по первую декаду июня 2023 г. с использованием регрессионных моделей (а–г) и нейронной сети (е–и); картосхема фактической урожайности (д).

**Fig. 5.** Maps of actual and expected yields of winter wheat in the Rostov region from the first ten days of May to the first ten days of June for 2023 using regression models (a–г) and a neural network (e–и); map of actual yield (д).

## Заключение

Представленные результаты исследований подтвердили возможность и эффективность применения глубокой нейронной сети для оценки ожидаемой средней районной урожайности озимой пшеницы для территории Северо-Кавказского УГМС. Разработанная модель нейронной сети, интегрирующая спутниковые индексы и метеорологические параметры, продемонстрировала более высокую точность расчетов по сравнению с традиционными регрессионными моделями и алгоритмами машинного обучения. Для использования полученных результатов в системе оперативного мониторинга оценки состояния и ожидаемой урожайности сельскохозяйственных культур, необходимо провести производственные испытания, а также продолжить исследования по разработке методов оценки ожидаемой средней районной урожайности с применением глубокой нейронной сети для других регионов и культур.

## Список литературы

1. Клещенко А.Д., Савицкая О.В., Косякин С.А. Оценка средней районной урожайности озимой пшеницы по спутниковой и наземной метеорологической информации // Гидрометеорологические исследования и прогнозы. 2020. № 3 (377). С. 103-121.
2. Луян Е.А., Барталев С.А., Толпин В.А., Крашенинникова Ю.С. Возможности использования пространственно-временных вегетационных индексов на примере анализа аномальных условий развития озимых культур на Европейской части России в 2016 году // Сборник тезисов докладов четырнадцатой всероссийской открытой конференции «Современные проблемы дистанционного зондирования земли из космоса». 2016. С. 361.
3. Пойнтер Я. Программируем с PyTorch: Создание приложений глубокого обучения. СПб.: Питер, 2020. 256 с.
4. Ткачева Ю.В. Методика интерполяции кусочно-линейных данных об эмиссиях автотранспорта на регулярную модельную сетку // Труды Гидрометцентра России. 2018. Вып. 368. С. 170-180.
5. Толпин В.А., Луян Е.А., Барталев С.А., Плотников Д.Е., Матвеев А.М. Возможности анализа состояния сельскохозяйственной растительности с использованием спутникового сервиса «ВЕГА» // Оптика атмосферы и океана. 2014. Том 27, № 7 (306). С. 581-586.
6. Шашко Д.И. Агроклиматическое районирование СССР. М.: Колос, 1967. 336 с.
7. Шолле Ф. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.
8. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A next-generation hyperparameter optimization framework. In International Conference on Knowledge Discovery and Data Mining. 2019. P. 2623-2631.
9. Bergstra J., Bengio Y. Random search for hyper-parameter optimization // Journal of machine learning research. 2012. P. 281-305.
10. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. P. 5-32.
11. Hutter F., Kotthoff L., Vanschoren J. Automated Machine Learning // Hyperparameter Optimization. Springer, 2019. P. 3-33.
12. Hinton G.E., Osindero S., Teh Y.W. A fast learning algorithm for deep belief nets // Neural Comput. 2006. Vol. 18. P. 1527-1554. DOI: 0.1162/neco.2006.18.7.1527
13. Kogan F. N. NOAA / AVHRR Satellite Data-Based Indices for Monitoring Agricultural Droughts // Monitoring and Predicting Agricultural Drought. Oxford: University Press, 2005. P. 79-89.
14. Khaki S., Wang L. Crop Yield Prediction Using Deep Neural Networks // Frontiers in Plant Science. 2019. Vol. 10. DOI: 10.3389/fpls.2019.00621.
15. Kumar S., Kumar V., Sharma R. K. Sugarcane yield forecasting using artificial neural network models // International Journal of Artificial Intelligence and Applications. 2015. Vol. 6, no. 5. P. 51-68.

## References

1. Kleshchenko A.D., Savitskaya O.V., Kosyakin S.A. Estimation of average regional yield of winter wheat using satellite and ground-based meteorological information. *Gidrometeorologicheskie issledovaniya i prognozy [Hydrometeorological research and forecasts]*, 2020, vol. 377, no. 3, pp. 103-121 [in Russ.].
2. Lupyán E.A., Bartalev S.A., Tolpin V.A., Krashenimnikova Yu.S. Vozmozhnosti ispol'zovaniya prostranstvenno-vremennykh vegetatsionnykh indeksov na primere analiza anomal'nykh uslovii razvitiya ozimyykh kul'tur na Evropeiskoi chasti Rossii v 2016 godu [Possibilities of using spatiotemporal vegetation indices on the example of analysis of abnormal conditions for the development of winter crops in the European part of Russia in 2016]. *Collection of abstracts of reports of the fourteenth all-Russian open conference "Modern problems of remote sensing of the earth from space"*. Moscow, 2016, 361 p. [in Russ.].
3. Pointer Ya. Programmiruem s PyTorch: Sozdanie prilozhenii glubokogo obucheniya. [Programming with PyTorch: Creating Deep Learning Applications.]. Saint Petersburg: Piter Publ., 2020, 256 p. [in Russ.].
4. Tkacheva Yu.V. Methodology for interpolating piecewise linear data on vehicle emissions onto a regular model grid. *Trudy Gidromettsentra Rossii [Proceedings of the Hydrometeorological Center of Russia]*, 2018, vol. 368. pp. 170-180 [in Russ.].
5. Tolpin V.A., Lupyán E.A., Bartalev S.A., Plotnikov D.E., Matveev A.M. Vozmozhnosti analiza sostoyaniya sel'skokhozyaistvennoi rastitel'nosti s ispol'zovaniem sputnikovogo servisa «VEGA» [Possibilities of analyzing the state of agricultural vegetation using the VEGA satellite service]. *Optika atmosfery i okeana [Optics of the atmosphere and ocean]*, 2014, vol. 27, no. 7 (306), pp. 581-586 [in Russ.].
6. Shashko D.I. Agroklimaticheskoe raionirovanie SSSR [Agroclimatic zoning of the USSR], Moscow, Kolos Publ., 1967, 336 p. [in Russ.].
7. Sholle F. Glubokoe obuchenie na Python [Deep Learning in Python]. Saint Petersburg, Piter Publ., 2018, 400 p. [in Russ.].
8. Akiba T., Sano S., Yanase T., Ohta T., Koyama M. Optuna: A next-generation hyperparameter optimization framework. *In International Conference on Knowledge Discovery and Data Mining*, 2019, pp. 2623-2631.
9. Bergstra J., Bengio Y. Random search for hyper-parameter optimization. *Journal of machine learning research*, 2012, pp. 281-305.
10. Breiman L. Random Forests. *Machine Learning*, 2001, vol. 45, pp. 5-32.
11. Hutter F., Kotthoff L., Vanschoren J. Automated Machine Learning. *Hyperparameter Optimization*, Springer, 2019, pp. 3-33.
12. Hinton G.E., Osindero S., Teh Y.W. A fast learning algorithm for deep belief nets. *Neural Comput*, 2006, vol. 18, pp. 1527-1554. DOI: 0.1162/neco.2006.18.7.1527.
13. Kogan F.N. NOAA / AVHRR Satellite Data-Based Indices for Monitoring Agricultural Droughts. *Monitoring and Predicting Agricultural Drought*. Oxford: University Press. 2005, pp. 79-89.
14. Khaki S., Wang L. Crop Yield Prediction Using Deep Neural Networks. *Frontiers in Plant Science*, 2019, vol. 10. DOI: 10.3389/fpls.2019.00621.
15. Kumar S., Kumar V., Sharma R.K. Sugarcane yield forecasting using artificial neural network models. *International Journal of Artificial Intelligence and Applications*, 2015, vol. 6, no. 5, pp. 51-68.

Поступила 26.06.2025; одобрена после рецензирования 01.10.2025;  
принята в печать 15.10.2025.

Submitted 26.06.2025; approved after reviewing 01.10.2025;  
accepted for publication 15.10.2025.