



**РЕСУРСОСБЕРЕГАЮЩИЕ ТЕХНОЛОГИИ  
В ЗЕМЛЕДЕЛИИ, АГРОХИМИИ, СЕЛЕКЦИИ  
И СЕМЕHOBOДСТВЕ**

**RESOURCE-SAVING TECHNOLOGIES IN  
AGRICULTURE, AGROCHEMISTRY, BREEDING  
AND SEED PRODUCTION**

УДК 631.432.2:519.2

DOI:10.31677/2311-0651-2024-46-4-91-102

**НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ ЗАПАСОВ ПРОДУКТИВНОЙ ВЛАГИ  
В ПОЧВЕ ПЕРЕД ПОСЕВОМ ЗЕРНОВЫХ КУЛЬТУР**

**Т.А. Кизимова**, младший научный сотрудник

**Н.В. Васильева**, кандидат биологических наук,  
старший научный сотрудник

**В.А. Шпак**, кандидат физико-математических наук, старший научный сотрудник

*Сибирский федеральный научный центр агробиотехнологий РАН*

E-mail: tanya.luzhnykh@mail.ru

**Ключевые слова:** почвенная влага, прогноз, нейронная сеть, зерновые культуры.

**Реферат.** Почвенные запасы влаги являются одним из основных факторов, влияющих на рост и развитие растений в период вегетации. Поэтому их предварительная оценка играет большую роль при планировании агротехнических мероприятий на весенний-летний период, что, в свою очередь, влияет на урожайность и в целом на эффективность сельскохозяйственного производства. В статье предложен метод прогнозирования запасов влаги в метровом слое почвы перед посевом зерновых культур, основанный на построении и обучении искусственной нейронной сети (ИНС). Для построения нейронной сети использовали данные многофакторного полевого опыта СибНИИЗиХ СФНЦА РАН (центральная лесостепь). Данные включают результаты исследований агрофизических и агрохимических показателей почвы в четырёхпольном зернопаровом севообороте с 1996 по 2018 г. Построенная нейросеть имеет архитектуру многослойного перцептрона, состоящего из входного, скрытого и выходного слоя. Входной слой принимает данные в виде предикторов, а именно: предшественник, способ обработки почвы, погодные условия, осенний запас продуктивной влаги предшествующего года, – т. е. факторы, влияющие на прогнозируемую переменную. В скрытом слое происходит преобразование и обработка входных данных, выходной слой генерирует прогноз модели. Разработанная нейронная сеть продемонстрировала достаточно высокую точность прогнозирования. Общий процент достоверно прогнозируемых наблюдений составил 80,6 %. ROC-анализ, проведенный для оценки предсказательной способности нейросети, показал, что площадь под кривой ROC для каждой категории была близкой к 1. Это свидетельствует о том, что нейронная сеть имеет высокую предсказательную силу и способна точно определять различные категории целевого показателя.

**NEURAL NETWORK FORECASTING OF PRODUCTIVE MOISTURE RESERVES  
IN SOIL BEFORE SOWING GRAIN CROPS**

**T.A. Kizimova**, Junior Researcher

**N.V. Vasilieva**, PhD in Biological Sciences, Senior Researcher

**V.A. Shpak**, PhD in Physical and Mathematical Sciences, Senior Researcher  
*Siberian Federal Scientific Center of Agrobiotechnologies RAS*

**Keywords:** soil moisture, prediction, neural network, grain crops.

**Abstracts.** *Soil moisture reserves are one of the main factors limiting the growth and development of plants during the vegetation period of agricultural crops, their preliminary assessment plays a major role in the planning of agrotechnical measures for the spring - summer period, which in turn affects the yield and efficiency of agricultural production. The article proposes a method of predicting moisture content in a meter layer of soil before sowing grain crops, based on the construction and training of an artificial neural network. To build an artificial neural network we used the data of multifactorial field experience of the Siberian Research Institute of Crop Production of SFNCA RAS (central forest-steppe). The data include the results of studies of agrophysical and agrochemical factors in a four-field grain-fallow crop rotation from 1996 to 2018. The constructed artificial neural network has the architecture of a multilayer perceptron consisting of an input, hidden and output layer. The input layer accepts data in the form of predictors, namely: predecessor, tillage method, weather conditions, autumn productive moisture reserve of the previous year, i. e. factors affecting the predicted variable. The hidden layer transforms and processes input data, while the output layer generates model predictions. The developed artificial neural network demonstrated a fairly high accuracy of forecasting. The total percentage of reliably predicted observations was 80.6 %. The ROC analysis performed to evaluate the predictive ability of the neural network showed that the area under the ROC curve for each category was close to 1. This indicates that the neural network has high predictive power and is able to accurately identify the different categories of the target indicator.*

Продуктивная влага в почве является важнейшим фактором, от которого зависит состояние и урожайность сельскохозяйственных культур. Все жизненные процессы в растениях протекают с участием воды, которую они потребляют непрерывно, с водой в растения поступают все необходимые питательные вещества. Запасы продуктивной влаги в почве в полевых условиях формируются в основном за счёт атмосферных осадков [1].

Зерновые культуры в критические фазы развития особенно чувствительны к недостатку влаги. При дефиците осадков в эти периоды растения для своей вегетации активно используют запасы продуктивной влаги почвы (ЗПВ). Из-за недостатка влаги нарушается развитие вегетативных и генеративных органов растений, что приводит к значительному снижению урожайности [2–7].

Оптимальный уровень влажности почвы, необходимый для нормального развития сельскохозяйственных культур, в частности зерновых, находится в пределах 60–80 % наименьшей влагоёмкости, ЗПВ выше 130–160 мм в метровом слое почвы соответствуют хорошим и очень хорошим запасам и обеспечивают формирование более высокой продуктивности. Эти показатели варьируют в зависимости от физических свойств почвы, её водоудерживающей способности [8].

Исследованиями СибНИИЗХим установлено, что в лесостепи Приобья на чернозёмах выщелоченных в условиях сильной засухи вегетационного периода при стартовом ЗПВ не более 100 мм в слое почвы 0–100 см (в зависимости от уровня интенсификации) можно рассчитывать на получение урожайности пшеницы не более 1,3 т/га; при запасах влаги 140 мм – от 2,0 до 2,4 т/га; при 180 мм – от 2,3 до 2,8 т/га [9]. Если в период вегетации яровой пшеницы выпадает среднемноголетняя норма осадков, то эти величины соответственно составляют: 2,1–2,5 т/га, 2,8–3,7 т/га и 2,9–4,0 т/га; при двух среднемноголетних нормах осадков: 3,0–3,6 т/га, 2,9–3,9 т/га и 3,5–4,4 т/га.

Данные о величине ЗПВ в метровом слое почвы позволяют планировать урожайность сельскохозяйственных культур, принимать эффективные управленческие решения при выборе агротехнических мероприятий (применение и корректировка доз удобрений, средств защиты растений, обработка почвы и др.), тем самым эффективно использовать ресурсы хозяйства. Поэтому заблаговременное определение ЗПВ в почве перед посевом сельскохозяйственных культур не теряет своей актуальности на современном этапе развития аграрных технологий.

В полевых условиях для оценки влажности почвы чаще всего используют термостатно-весовой метод, суть которого заключается в отборе почвенных проб по слоям почвы на глубину 100 см специальным буром и дальнейшей сушки почвенных образцов в лаборатории [10]. Однако этот процесс требует значительных временных и финансовых затрат, что делает этот метод не всегда применимым. Существует необходимость в разработке удобных в использовании инструментов, менее трудоемких, более экономичных, доступных для широкого применения в сельскохозяйственной практике. В связи с активным развитием цифровых технологий в сельском хозяйстве для оптимизации и автоматизации процесса оценки влажности почвы стали внедрять усовершенствованные методы. Они включают использование автоматизированных систем измерения, датчиков, сенсоров, спутниковых наблюдений (GPS, ГЛОНАСС), технологий ГИС, компьютерной техники, искусственного интеллекта, предиктивной аналитики [11–15].

Например, сенсоры, размещённые непосредственно в почве, могут в режиме реального времени передавать данные о её влажности, что позволяет аграриям принимать решения оперативно. Спутниковые системы и ГИС-технологии обеспечивают мониторинг состояния почвы на больших территориях. Использование искусственного интеллекта и предиктивной аналитики позволяет прогнозировать изменения влажности почвы с высокой точностью, что способствует оптимизации агротехнических мероприятий [16–21].

В настоящее время со стороны научного сообщества растёт интерес к технологиям искусственного интеллекта (ИИ), в том числе и в сельском хозяйстве. Методы ИИ, в частности – алгоритмы машинного обучения и искусственные нейронные сети (ИНС), позволяют извлекать полезную информацию из большого потока исторических данных и текущих параметров, поступающих из разных источников (датчики на полях, спутниковые снимки, дроны, метеостанции, почвенные анализаторы, мобильные устройства фермеров), выявлять в них скрытые закономерности и использовать эти знания для прогнозирования, моделирования условий и событий, происходящих в агроэкосистемах. В отличие от классических математических и физических моделей, ИНС обладают высокой способностью к нелинейному моделированию, могут одновременно учитывать большое количество входных данных разных типов, что позволяет моделям нейронных сетей быть более адаптивными и точными [22, 23]. Однако такие подходы в отечественной сельскохозяйственной практике находятся на ранней стадии развития и недостаточно интенсивно изучены [24].

Данная работа направлена на исследование возможностей и перспектив использования ИНС для прогнозирования почвенных запасов влаги.

Цель исследований – создать искусственную нейронную сеть (ИНС) для прогнозирования запасов продуктивной влаги в слое почвы 0–100 см перед посевом зерновых культур, оценить прогностические способности построенной ИНС.

В качестве объекта исследования выступали многолетние экспериментальные данные Сибирского научно-исследовательского института земледелия и химизации сельского хозяйства по изучению эффективности различных систем основной обработки почвы в зернопаровом 4-польном севообороте за 1996–2018 гг. Территория опытных участков относится к центральной лесостепи Приобья, почвенный покров представлен чернозёмом выщелоченным. С 1996 по 2006 г. схема севооборота имела вид: 1 – пар чистый, 2 – озимая рожь, 3 – яровая пшеница, 4 – яровая пшеница. С 2007 по 2018 г. набор культур в севообороте изменился: 1 – пар, 2 – яровая пшеница, 3 – яровая пшеница, 4 – яровая пшеница.

При построении ИНС использовалась выборка данных из 320 наблюдений. Зависимую переменную ЗПВ рассматривали как категориальную, разделив значения запасов влаги в слое почвы 0–100 см (к моменту посева зерновых культур) на 4 категории: 0 – очень хорошие запасы (выше 160 мм); 1 – хорошие запасы (130–160 мм); 2 – удовлетворительные запасы (90–130 мм); 3 – плохие запасы (менее 90 мм). На основании предварительного анализа данных

были определены предикторы модели – независимые переменные (факторы оказывающее непосредственное влияние на ЗПВ):

– варианты основной обработки почвы, 4 категории: 0 – нулевая обработка (без зяблевой обработки), 1 – минимальная обработка (плоскорезная обработка на глубину 10–12 см под все культуры ежегодно), 2 – безотвальная обработка (безотвальное рыхление стойками СиБИМЭ под 1-ю и 3-ю культуры на глубину 20–22 см и под 2-ю – на 25–27 см), 3 – вспашка (под 1-ю и 3-ю культуру – на 20–22 см, под 2-ю – на 25–27 см);

– поскольку в полевом опыте применялся четырёхпольный зернопаровой севооборот, то он характеризовался вектором из 4 показателей: предшественник 1 года (Пр1), предшественник 2 года (Пр2), предшественник 3 года (Пр3), предшественник 4 года (Пр4); каждый из предшественников описывается 5-тью категориями: 0 – чистый пар, 1 – первая пшеница, 2 – вторая пшеница, 3 – третья пшеница, 4 – озимая рожь;

– агроклиматические показатели: сумма активных температур  $> 0$  °С (больше нуля градусов Цельсия), сумма осадков (мм) за периоды сентябрь – февраль, март – апрель;

– осенний ЗПВ в слое 0–100 см почвы предшествующего года;

Исходный массив данных был поделён на три множества: обучающее, тестовое и контрольное в отношении 15 : 3 : 1. Для оценки запасов продуктивной влаги в метровом слое почвы применялась шкала, рекомендованная в отечественной почвоведческой практике [8].

Моделирование и обучение ИНС выполнялось с использованием аналитической платформы SPSS версии 26 [25].

При решении задач, где требуется прогнозировать значения целевой переменной, имеющей категориальный тип (принимая значения в виде градаций), приоритетно применение моделей нейронных сетей. Использование подходящих архитектур нейросетей позволяет получить оценки вероятности того, что целевая переменная относится к той или иной из определённых категорий. Для этого используются значения предикторов. В качестве конечной категории выбирается та, которая имеет наибольшую вероятность из множества возможных градаций ЗПВ [26].

Для решения рассматриваемой задачи прогноза запасов продуктивной влаги в настоящей работе применяется нейронная сеть с архитектурой многослойного персептрона (MLP). MLP – это нейронная сеть с прямой передачей сигнала. Она состоит из нескольких элементов:

- входные нейроны;
- один или несколько слоёв скрытых вычислительных нейронов;
- выходной слой нейронов.

По своей структуре MLP напоминает ориентированный граф, где вершины – это нейроны, а дуги – синаптические связи (веса) [26, 27].

Первый слой является входным, нейроны этого слоя воспринимают сигналы от предикторов (входных данных). Выходной слой сформирован из нейронов, воспринимающих результирующие выходные сигналы от предшествующих слоёв. Скрытые (вычислительные) слои преобразуют входящие сигналы в выходные с помощью подходящих активационных функций. Таким образом, исходные входные сигналы распространяются по сети в прямом направлении поочередно от слоя к слою.

Число скрытых слоёв и число нейронов подбирают экспериментально, путем оценки точности правильно классифицируемых наблюдений, получаемой на сетях различного размера, и выбора оптимальной по точности структуры. Вместе с выбором архитектуры сети необходимо определить функции активации нейронов скрытых и выходного слоёв. Типичными функциями активации являются функции  $\text{softmax}$  или гиперболического тангенса [26, 27].

Путем численных экспериментов и варьирования различных видов функций активации для выходного и промежуточных слоёв было построено несколько нейронных сетей с разным количеством скрытых слоёв. Лучшие результаты показала нейронная сеть с одним скры-

тым слоем, архитектура которой представлена на рисунке 1 (также для прогнозирования ЗПВ использовался метод мультиномиальной логистической регрессии, но полученная модель не имела адекватных результатов, точность прогнозов была очень низкой).

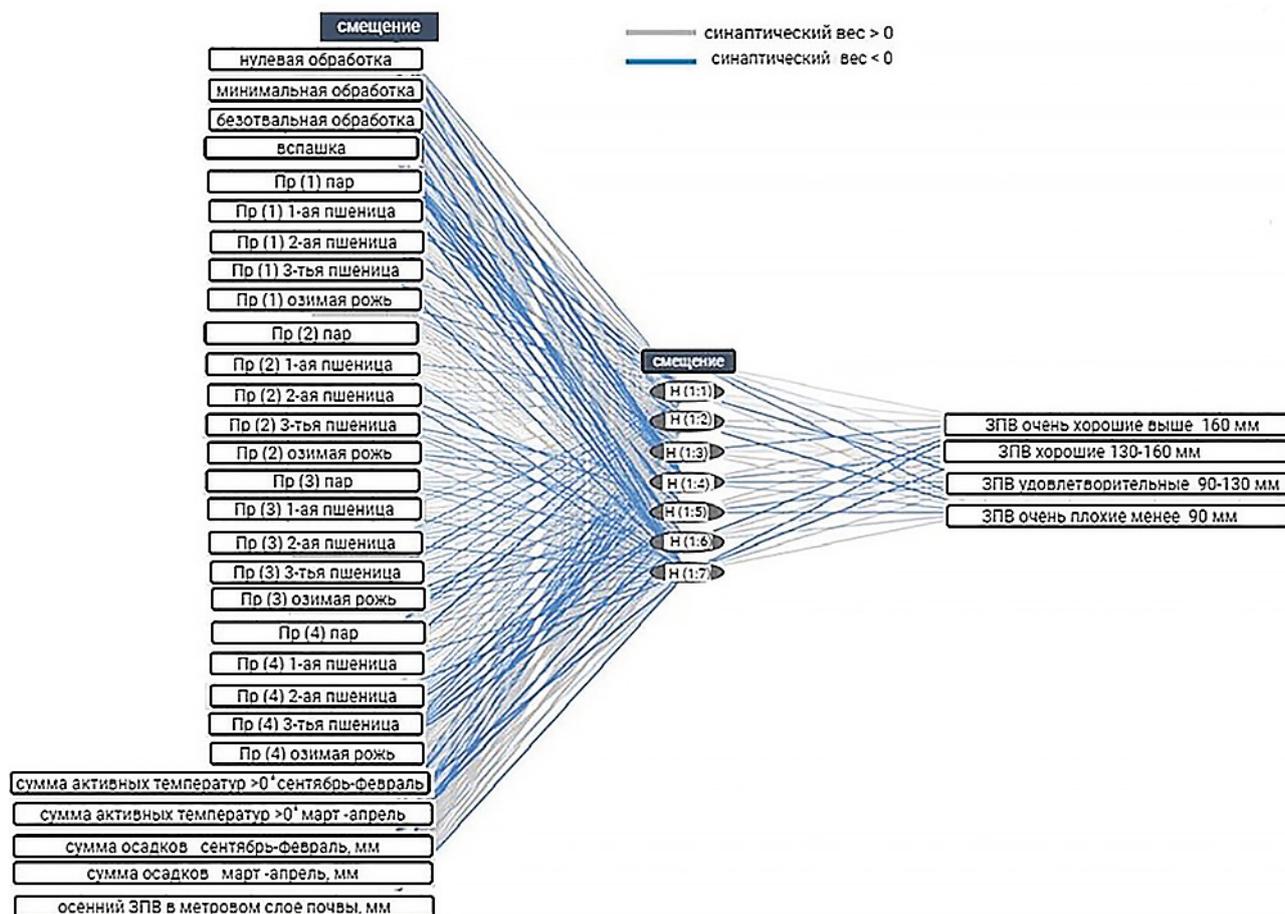


Рис. 1. Архитектура ИНС «многослойный персептрон»

Fig. 1. Architecture of the ANN «multilayer perceptron»

Как видно из рисунка 1, предложенная нейронная сеть имеет входной слой, состоящий из 29 нейронов, каждый из которых связан с соответствующим предиктором. Выходные сигналы от нейронов этого слоя передаются в следующий скрытый слой (состоит из 7 нейронов) как входные. В скрытом слое происходит обработка этих сигналов, и результаты этой обработки передаются в виде входных сигналов в 4 нейрона выходного слоя (возможные категории ЗПВ). В результате работы всего цикла генерируются значения вероятностей принадлежности для каждой возможной категории ЗПВ.

В скрытом слое в качестве функции активации применялся гиперболический тангенс, а в выходном слое – функция softmax [26, 27].

Для определения синаптических весов нейронной сети исходная выборка была разделена на три части: обучающую, тестовую и контрольную в соотношении 15 : 3 : 1 [26, 27].

Обучение нейронной сети происходило на обучающей выборке. На тестовых и контрольных выборках оценивалось качество построенной модели.

Синаптические веса и смещения определялись так, чтобы минимизировать ошибку обучения на выходе сети между фактическими и модельными значениями сигналов.

В таблице 1 приведены оценки качества прогнозов построенной ИНС. Для обучения модели использовалась выборка из 320 наблюдений. Число наблюдений распределено по ЗПВ в

метровом слое почвы следующим образом: очень хорошие запасы – 60, хорошие запасы – 96, удовлетворительные запасы – 120, плохие запасы – 44.

Таблица 1

**Классификационная таблица нейронной сети по предсказанию ЗПВ в метровом слое почвы перед посевом зерновых культур**  
**Classification table of neural network for predicting the PMR in a meter-thick soil layer before sowing grain crops**

Количество наблюдений	Предсказанные				Правильные прогнозы, %
	Очень хорошие запасы более 160 мм	Хорошие запасы от 130 до 160 мм	Удовлетворительные запасы от 90 до 30 мм	Плохие запасы менее 90 мм	
60 – очень хорошие запасы более 160 мм	49	9	0	2	81,7
96 – хорошие запасы от 130 до 160 мм	5	73	18	0	76,0
120 – удовлетворительные запасы от 90 до 130 мм	0	14	101	5	84,2
44 – плохие запасы менее 90 мм	0	2	7	35	79,5
Общая доля	-	-	-	-	80,6

Для первой градации «очень хорошие запасы более 160 мм» доля правильных прогнозов составила 81,7 %, точно спрогнозировано 49 наблюдений, ошибочными были 11 прогнозов, 9 из которых попали в градацию «хорошие запасы от 130 до 160 мм» и 2 в градацию «плохие запасы менее 90 мм». Для второй градации «хорошие запасы от 130 до 160 мм» из 96 наблюдений верно спрогнозировано 73, неверно – 23, доля верных прогнозов 76 %. Для третьей градации «удовлетворительные запасы от 90 до 130 мм» число достоверных прогнозов из 120 наблюдений составило 101, это 84,2 %, неправильно было классифицировано 19 наблюдений. Для четвертой градации «плохие запасы менее 90 мм» достоверно спрогнозировано 35 наблюдений, неверными были 9, доля правильных прогнозов соответствует 79,5 %.

Общее число правильно классифицируемых наблюдений достаточно высоко и составляет 80,6 %.

Приведем оценки прогностической способности построенной нейронной сети по ROC-кривым, которые описывают эффективность классификации по каждой категории целевой переменной. Построенные ROC-кривые для 4 градаций ЗПВ в метровом слое почвы перед посевом зерновых культур показаны на рисунке 2. Кривая с маркировкой 0 соответствует очень хорошим запасам продуктивной влаги в почве, 1 – хорошим запасам, 2 – удовлетворительным запасам, 3 – плохим запасам. Прямая линия по диагонали описывает чисто случайный классификатор.

Все ROC-кривые отклоняются от кривой случайного классификатора достаточно высоко, прижимаясь как можно ближе к левому верхнему углу, тем самым показывая, что классификатор работает правильно и достоверно. Если бы ROC-кривая проходила близко с диагональной

линией (или совпадала с ней), это свидетельствовало бы о низком качестве классификатора модели и, следовательно, о её непригодности.

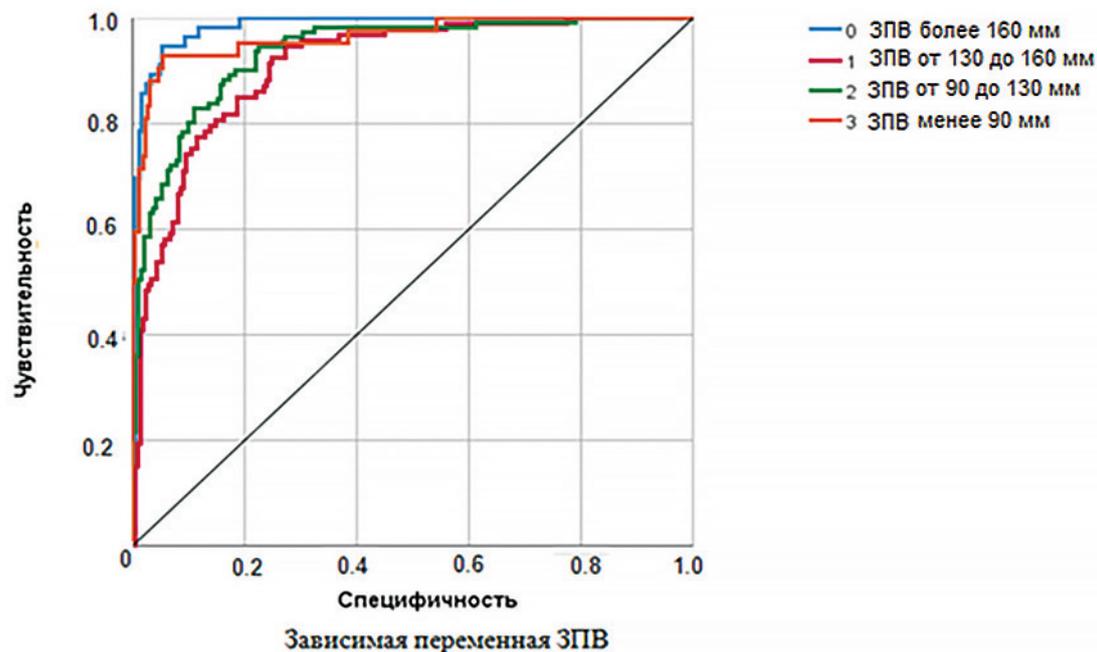


Рис. 2. График ROC-кривой ИНС

Fig. 2. ROC curve graph-ANN

На графике (рис. 2) чувствительность и специфичность являются ключевыми метриками, которые помогают оценить качество классификационной модели. Чувствительность для каждой категории ЗПВ (например, «хорошие запасы от 130 до 160 мм») показывает, насколько хорошо модель находит правильные прогнозы именно для данной градации. Специфичность для каждой категории демонстрирует, что модель не путает конкретную градацию с другими, что и приводит к высокой точности прогнозирования и минимальному числу неверных прогнозов.

Площади под ROC-кривыми, приведенные в таблице 2, позволяют также сравнивать классификаторы между собой.

Значение площади под рабочей характеристикой приёмника (ROC) для случайного классификатора равно 0,5. У более эффективных классификаторов этот показатель больше, например, он может приближаться к 1 [26, 27]. Площадь под ROC показывает, насколько хорошо классификатор отличает выборочное наблюдение конкретной категории от наблюдений других категорий.

Таблица 2

Значение площади под ROC-кривой  
Value of area under the ROC curve

Градации ЗПВ	Площадь под ROC-кривой
0 – Очень хорошие запасы более 160 мм	0,985
1 – Хорошие запасы от 130 до 160 мм	0,910
2 – Удовлетворительные запасы от 90 до 130 мм	0,935
3 – Плохие запасы менее 90 мм	0,965

Показатели площади под ROC-кривыми свидетельствуют о высоком качестве классификаторов для каждой категории ЗПВ. Это подтверждает, что построенная нейронная сеть подходит для решения поставленной задачи прогнозирования.

Анализ того, как предикторы модели влияют на прогнозы целевого показателя – ЗПВ в рамках рассматриваемой ИНС, приведен на рисунке 3. Для этого используется разделение исходной выборки на обучающую и тестовую части. На основе этого разделения создается диаграмма, которая показывает нормализованную важность предикторов в модели. Нормализованная важность – это важность предиктора, выраженная относительно наивысшего значения важности среди всех предикторов. Обычно нормализованная важность представляется в процентах, где 100 % соответствует наиболее важному предиктору, а все остальные предикторы получают значения, пропорциональные их важности по сравнению с наивысшим значением. Это позволяет легко интерпретировать относительный вклад каждого предиктора [27].

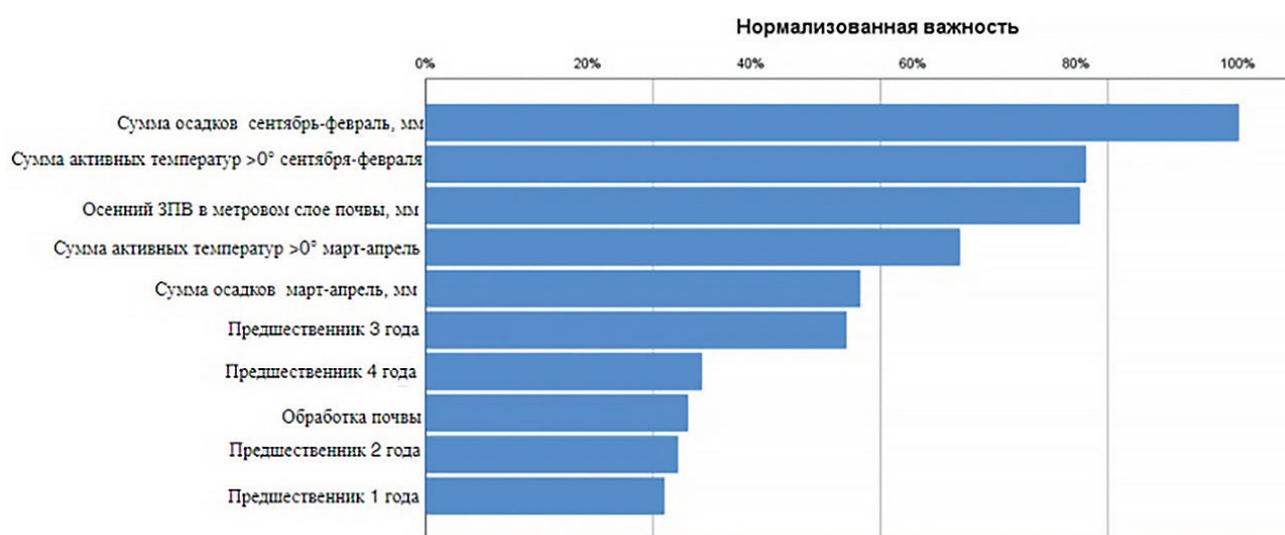


Рис.3. Важность влияния факторов на ЗПВ в почве

Fig. 3. Importance of the influence of factors on the PMR

Из данных, приведенных на рисунке 3, видно, что более существенное влияние на ЗПВ в слое почвы 0–100 см перед посевом зерновых культур оказывают: метеорологические условия в период сентябрь – февраль; запас продуктивной влаги в метровом слое почвы осенью предшествующего года; затем погодные условия в период март – апрель; и в меньшей мере – предшественник и обработка почвы.

Проанализируем, как прогнозируемые уровни ЗПВ в почве можно использовать для оценки потенциальной урожайности яровой пшеницы в зависимости от предшественника, системы обработки почвы, уровня интенсификации, погодных условий на предстоящий полевой сезон.

Если взять среднюю урожайность пшеницы по севообороту пар – пшеница – пшеница – пшеница на экстенсивном и интенсивном фоне за 2007–2018 гг., то лучше всего она коррелирует с весенними запасами продуктивной влаги в 0–100 см, а также с гидротермическим коэффициентом (ГТК Селянинова) за июнь – июль ( $r = 0,68 \pm 0,17$ ).

На рисунке 4 продемонстрирована чёткая связь между запасами продуктивной влаги (ЗПВ) и урожайностью яровой пшеницы.

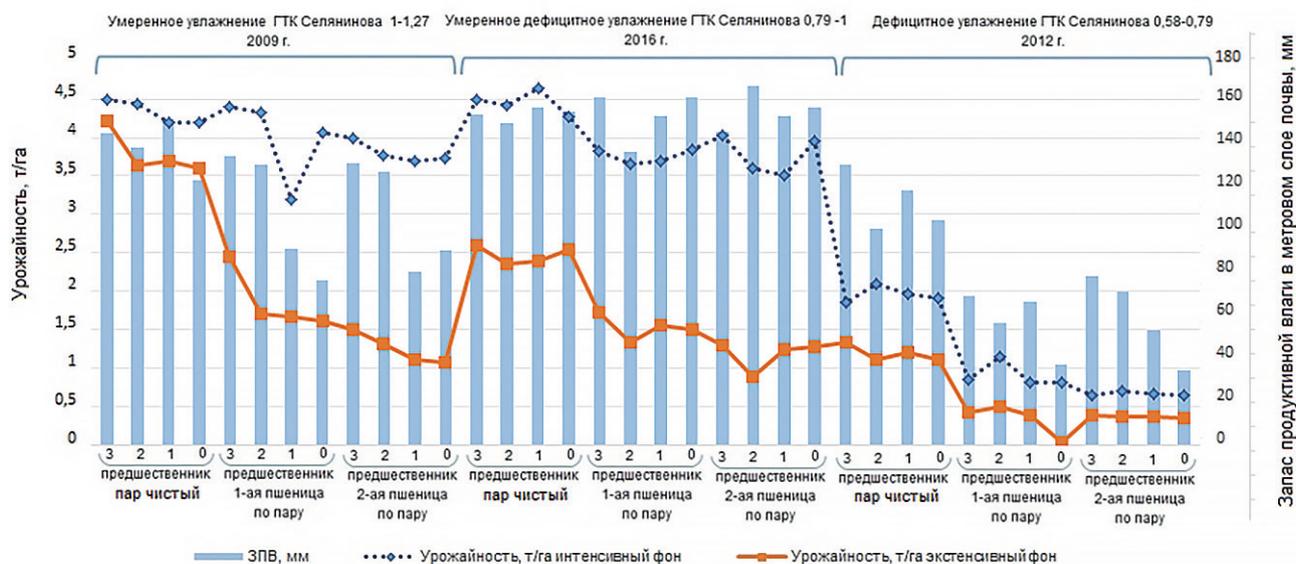


Рис. 4. Урожайность пшеницы в различные годы в зависимости от ЗПВ в почве, предшественника, системы основной обработки почвы и погодных условий (цифрами по оси x обозначена основная обработка почвы: 3 – вспашка, 2 – безотвальная обработка, 1 – минимальная обработка, 0 – нулевая обработка)

Fig. 4. Wheat yield in different years depending on soil productive moisture reserves (PMR), predecessor, primary tillage system, and weather conditions (3 – plowing, 2 – chisel plowing, 1 – minimum tillage, 0 – no-till)

Так как урожайность зерновых культур имеет большую амплитуду колебаний изменчивости по годам в зависимости от погодных условий, для сравнения на графике представлены года с разными значениями ГТК (по данным метеостанции Огурцово, Новосибирская область).

Анализ сценариев на основе данного графика позволяет видеть, как разные комбинации факторов влияют на урожайность, помогает оценить возможные риски снижения урожайности и разрабатывать стратегии для их минимизации.

Предположим, ИНС прогнозирует хорошие запасы продуктивной влаги (от 130 до 160 мм) к началу полевого сезона на рабочем участке, где предшественником был пар, в качестве основной обработки почвы проводилась вспашка и ожидается (прогнозируется) умеренное увлажнение вегетационного периода ГТК 1–1,2 как это наблюдалось например, в 2009 г. При таком сценарии может формироваться более высокая урожайность пшеницы  $\approx 4,3$  т/га на экстенсивном фоне. На графике также можно проследить, какую дополнительную прибавку урожайности можно получить за счёт применения средств защиты растений и удобрений (интенсивный фон). Если при тех же стартовых ЗПВ в почве ожидается умеренно дефицитное увлажнение вегетационного периода, Ку 0,79–1, например, как в 2016 г., то зерновая продуктивность по экстенсивному фону будет формироваться на уровне  $\approx 2,5$  т/га, дополнительная прибавка урожайности от средств химизации составит  $\approx +2$  т/га.

Если прогнозируются очень плохие ЗПВ менее 90 мм и ожидается дефицитный год по осадкам, как, например, в 2012 г., то при таком сценарии следует ожидать резкого снижения урожайности. В таких условиях нецелесообразно применение удобрений, так как при дефиците влаги они действуют очень слабо или не действуют совсем, можно планировать увеличение площади посева культур, более устойчивых к дефициту влаги.

Таким образом, проведённое исследование позволяет сделать следующие заключения.

1. На основе данных о погодных условиях, методах обработки почвы, предшествующих культурах и осенних запасах продуктивной влаги в почве была разработана искусственная нейронная сеть с архитектурой «многослойный перцептрон», которая позволила с точностью 80,6 % прогнозировать ЗПВ в метровом слое почвы перед посевом зерновых культур.

Предложенная модель прогнозирования, в отличие от классического метода определения запасов продуктивной влаги в почве, который требует выезда на поля, отбора проб и лабораторного анализа почвы, позволяет оперативно в реальном времени предоставлять результаты (значения ЗПВ) без полевых исследований, что позволяет экономить время и ресурсы хозяйства.

2. Полученные прогнозы могут быть использованы для:

– планирования структуры посевных площадей, что помогает выбрать культуры, лучше адаптированные к агроклиматическим условиям предстоящего сезона (например, при ожидаемом низком уровне запасов влаги можно заранее планировать посев более засухоустойчивых сортов и культур);

– оценки потенциальной урожайности и прибавки урожая от применения средств интенсификации (удобрений, средств защиты растений), при более благоприятных условиях увлажнения можно планировать получения более высокой урожайности, при этом корректировать дозы удобрений в основном внесении и подкормке;

– анализа эффективности агротехнических мероприятий прошлых сезонов, что позволяет определить, какие методы обработки почвы и предшественники способствовали лучшему накоплению и сохранению влаги в почве, а также скорректировать стратегии их применения в будущем.

Дальнейшие исследования будут направлены на улучшение точности прогнозов за счет включения дополнительных предикторов, таких как агрофизические свойства почвы (структура, плотность, водопроницаемость почвы) и интеграции новых источников данных (возможность включения в процесс прогнозирования спутниковых снимков, данных дистанционного зондирования).

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Вериго С. А., Разумова С. А.* Почвенная влага и ее значение в сельскохозяйственном производстве. – Л.: Гидрометеиздат, 1963. – 292 с.
2. *Влияние* продуктивной влаги на урожайность сельскохозяйственных культур в засушливых условиях Оренбургской области / Д. В. Митрофанов, Н. А. Максютов, В. Ю. Скороходов [и др.] // Животноводство и кормопроизводство. – 2017. – № 4 (100). – С. 225–233.
3. *Шарков И. Н., Колбин С. А.* Влияние погодных условий вегетационного периода на урожайность яровой пшеницы и эффективность азотного удобрения в лесостепи Приобья // Вестник Новосибирский государственный аграрный университет. – 2020. – № 1 (54). – С. 33–41. [\\_DOI: 10.31677/2072-6724-2020-54-1-33-41](https://doi.org/10.31677/2072-6724-2020-54-1-33-41).
4. *Чурзин В. Н., Серебряков А. А.* Роль атмосферных осадков и почвенной влаги в зависимости от способов основной обработки черного пара при выращивании озимой пшеницы на светло-каштановых почвах Волгоградской области // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. – 2014. – № 3 (35). – С. 83–88.
5. *Мухитов Л. А.* Влияние условий водообеспеченности на формирование листовой поверхности разных экотипов яровой пшеницы в лесостепи Оренбургского Предуралья // Известия Оренбургского государственного аграрного университета. – 2010. – № 4 (28–1). – С. 35–37.
6. *Серебряков В. Ф.* Роль весенних запасов продуктивной влаги и атмосферных осадков в формировании урожая озимой пшеницы // Известия Нижневолжского агроуниверситетского комплекса: наука и высшее профессиональное образование. – 2013. – № 4 (32). – С. 63–67.
7. *Запасы* продуктивной влаги по природно-почвенным зонам Алтайского края и их влияние на урожайность яровой пшеницы / Н. Б. Максимова, С. Б. Тарасова, Г. Г. Морковкин, Д. В. Арнаут // Вестник Алтайского государственного аграрного университета. – 2018. – № 4 (162). – С. 87–92.
8. *Вадюнина А. Ф., Корчагина З. А.* Методы исследования физических свойств почв. – М.: Агропромиздат, 1986. – 415 с.
9. *Адаптивно-ландшафтные* системы земледелия Новосибирской области / Кирюшин В. И., Власенко А. Н., Каличкин В. К. [и др.]. – Новосибирск: СибНИИЗиХ сельского хозяйства, 2000. – 388 с.

10. Федоровский Д. В. Определение водных и физических свойств почвы при проведении полевых и вегетационных опытов // Агрохимические методы исследований почв. – М.: Наука, 1975. – 333 с.
11. Неверов А. А. Прогнозирование почвенных влагозапасов на основе статистического моделирования природных процессов // Известия Оренбургского государственного аграрного университета. – 2020. – № 2 (82). – С. 14–18.
12. Тарасова Л. Л. Долгосрочный прогноз градаций увлажнения метрового слоя почвы весной // Агрофизика. – 2021. – № 1. – С. 33–38.
13. Медведева Е. С., Атоян Т. В., Киримова К. В. Исследование методов измерения влажности почвы // Молодой ученый. – 2020. – № 51 (341). – С. 449–452.
14. Антонова О. С., Неврюев А. М., Шлапак П. А. Использование данных ДЗЗ для анализа влагообеспеченности сельскохозяйственных угодий (на примере Саратовского Заволжья) // Геоинформационное картографирование в регионах России: материалы XI Всерос. науч.-практ. конф. Воронеж, 23–24 ноября 2020 г. – Воронеж: Цифровая полиграфия, 2020. – С. 22–27.
15. Kashyap B., Kumar R. Sensing Methodologies in Agriculture for Soil Moisture and Nutrient Monitoring // IEEE Access. – 2021. – Vol. 9. – P. 14095–14121.
16. Prediction of Soil Moisture Content from Sentinel-2 Images Using Convolutional Neural Network CNN / E. Hegazi, A. Samak, Ya. Lingbo, R. Huang // Agronomy. – 2023. – № 13 (3). – P. 656–674. – DOI: 10.3390/agronomy13030656.
17. Метод мониторинга влажности почвы, покрытой растительным покровом, с использованием нейронной сети, радарных и мультиспектральных оптических данных Sentinel-1, 2 / А. М. Зейлигер, К. В. Музалевский, Е. В. Зинченко, О. С. Ермолаева // Журнал радиоэлектроники. – 2023. – № 1. – С. 1–17.
18. Chatterjee S., Dey N., Sen S. Soil Moisture Quantity Prediction using Optimized Neural Supported model for sustainable agricultural applications // Sustainable Computing: Informatics and Systems. – 2018. – Vol. 28. – P. 100279. – DOI: <https://doi.org/10.1016/j.suscom.2018.09.002>.
19. Голов В. А., Быков Ф. Л. Моделирование запасов продуктивной влаги в верхних слоях почвы методом нейронных дифференциальных уравнений // Гидрометеорологические исследования и прогнозы. – 2022. – № 3 (385). – С. 144–160. – DOI: 10.37162/2618-9631-2022-3-144-160.
20. Soil Moisture Prediction with Attention-Enhanced Models: A Deep Learning Approach / V. Grubišić, D. Vasić, H. Ljubić [et al.] // Authorea Preprints. – 2024. – DOI: 10.36227/techrxiv.170792419.92585917/v1.
21. Sankhadeep C., Nilanjan D., Soumya S. Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications // Sustainable Computing: Informatics and Systems. – 2020. – Vol. 28, article 10027. – DOI: <https://doi.org/10.1016/j.suscom.2018.09.002>
22. Свищёв А. В., Гейкер А. М. Применение больших объемов данных и машинного обучения в сельском хозяйстве // E-Scio. – 2021. – № 11 (62). – С. 283–291.
23. Применение технологий искусственного интеллекта в сельском хозяйстве / Е. А. Скворцов, В. И. Набоков, К. В. Некрасов [и др.] // Аграрный вестник Урала. – 2019. – № 8 (187). – С. 91–98.
24. Каличкин В. К., Корякин Р. А., Куценогий П. К. Интеллектуальные системы в сельском хозяйстве (теоретический анализ возможного приложения): монография. – Новосибирск: СФНЦА РАН, 2020. – 296 с.
25. Бююль А., Цеффель П. SPSS: искусство обработки информации. – СПб.: Диа-СофтЮП, 2005. – 608 с.
26. Николенко С. И., Кадурин А. А., Архангельская Е. В. Глубокое обучение. – СПб.: Питер, 2018. – 480 с.
27. Khaikin S. Neural networks: full course / М.: Williams, 2016. – 1104 p.

## REFERENCES

1. Verigo S.A., Razumova S.A. *Pochvennaya vlaga i ee znachenie v sel'skoxozyajstvennom proizvodstve* (Soil moisture and its importance in agricultural production), Leningrad: Gidrometeoizdat, 1963, 292 p.
2. Mitrofanov D.V., Maksyutov N.A., Skorokhodov V.Yu. [i dr.], *Zhivotnovodstvo i kormoproizvodstvo*, 2017, No. 4 (100), pp. 225–233. (In Russ.)
3. Sharkov I. N., Kolbin S. A. *Vestnik NGAU*, 2020, No. 1 (54), pp. 33–41, DOI: 10.31677/2072-6724-2020-54-1-33-41. (In Russ.)
4. Churzin V.N., Serebryakov A.A., *Izvestiya Nizhnevolzhskogo agrouniversitetskogo kompleksa: nauka i vysshее professional'noe obrazovanie*, 2014, No. 3 (35), pp. 83–88. (In Russ.)

5. Muxitov L.A. *Izvestiya Orenburgskogo gosudarstvennogo agrarnogo universiteta*, 2010, No. 4 (28-1), pp. 35–37. (In Russ.)
6. Serebryakov V.F. *Izvestiya Nizhnevolzhskogo agrouniversitetskogo kompleksa: Nauka i vy'sshee professional'noe obrazovanie*. – 2013. – № 4 (32). – S. 63–67. (In Russ.)
7. Maksimova N.B., Tarasova S.B., Morkovkin G.G., Arnaut D.V., *Vestnik Altajskogo gosudarstvennogo agrarnogo universiteta*, 2018, No. 4 (162), pp. 87–92. (In Russ.)
8. Vadyunina A.F., Korchagina Z.A. *Metody` issledovaniya fizicheskix svoystv pochv* (Methods of research of physical properties of soils), Moscow: Agropromizdat, 1986, 415 p.
9. Adaptivno-landshaftny`e sistemy` zemledeliya Novosibirskoj oblasti / Kiryushin V. I., Vlasenko A. N., Kalichkin V. K. [i dr.]. – Novosibirsk: Sibirskij NII zemledeliya i ximizacii sel'skogo xozyajstva, 2000. – 388 s.
10. Fedorovskij D.V. *Agroximicheskie metody` issledovaniy pochv* (Agrochemical methods of soil research), Moscow: Nauka, 1975, 333 p.
11. Neverov A.A. *Izvestiya Orenburgskogo gosudarstvennogo agrarnogo universiteta*, 2020, No. 2 (82), pp. 14–18. (In Russ.)
12. Tarasova L.L. *Agrofizika*, 2021, No. 1, pp. 33–38. (In Russ.)
13. Medvedeva E.S., Atoyan T.V., Kirimova K.V., *Molodoj ucheny`j*, 2020, No. 51 (341), pp. 449–452. (In Russ.)
14. Antonova O.S., Nevryuev A.M., Shlapak P.A., *Geoinformacionnoe kartografirovanie v regionax Rossii* (Geoinformation mapping in the regions of Russia), Proceedings of the XI All-Russian Scientific and Practical Conference, Voronezh, November 23-24, 2020, Voronezh: Cifrovaya poligrafija, 2020, pp. 22–27. (In Russ.)
15. Kashyap B., Kumar R. Sensing Methodologies in Agriculture for Soil Moisture and Nutrient Monitoring, *IEEE Access*, 2021, Vol. 9, P. 14095–14121.
16. Hegazi E., Samak A., Lingbo Ya., Huang R., Prediction of Soil Moisture Content from Sentinel-2 Images Using Convolutional Neural Network CNN, *Agronomy*, 2023, No. 13 (3), P. 656–674, DOI: 10.3390/agronomy13030656.
17. Zejliger A.M., Muzalevskij K.V., Zinchenko E.V., Ermolaeva O.S., *Zhurnal radioe`lektroniki*, 2023, No. 1, pp. 1–17. (In Russ.)
18. Chatterjee S., Dey N., Sen S., *Sustainable Computing: Informatics and Systems*, 2018, Vol. 28, P. 100279, DOI: <https://doi.org/10.1016/j.suscom.2018.09.002>.
19. Golov V.A., By`kov F.L., *Gidrometeorologicheskie issledovaniya i prognozy`*, 2022, No. 3 (385), pp. 144–160, DOI: 10.37162/2618-9631-2022-3-144-160. (In Russ.)
20. Grubiic V., Vasic D., Ljubic H. [et al.], Soil Moisture Prediction with Attention-Enhanced Models: A Deep Learning Approach, *Authorea Preprints*, 2024, DOI: 10.36227/techrxiv.170792419.92585917/v1.
21. Sankhadeep C., Nilanjan D., Soumya S., Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications, *Sustainable Computing: Informatics and Systems*, 2020, Vol. 28, article 10027, DOI: <https://doi.org/10.1016/j.suscom.2018.09.002>
22. Svishhyov A.V., Gejker A.M., *E-Scio*, 2021, No. 11 (62), pp. 283–291.
23. Skvorcov E.A., Nabokov V.I., Nekrasov K.V. [i dr.], *Agrarny`j vestnik Urala*, 2019, No. 8 (187), pp. 91–98. (In Russ.)
24. Kalichkin V.K., Koryakin R.A., Kucenogij P.K. *Intellektual`ny`e sistemy` v sel'skom xozyajstve* (Intelligent systems in agriculture), Novosibirsk: SFNCZA RAN, 2020, 296 p.
25. Byuyul` A., Ceffel` P. *SPSS: iskusstvo obrabotki informacii* (SPSS: the art of information processing), Saint Petersburg: Dia-SoftYuP, 2005, 608 p.
26. Nikolenko S.I., Kadurin A.A., Arxangel'skaya E.V. *Glubokoe obuchenie* (Deep learning), Saint Petersburg: Piter, 2018, 480 p.
27. Khaikin S. *Neural networks: full course*, Moscow: Williams, 2016, 1104 p.