

Земледелие и мелиорация

УДК 631.1/004.048

DOI 10.31857/S2500262724060025 EDN RVEHXI

МОДЕЛИРОВАНИЕ ПРОДУКТИВНОСТИ СЕВООБОРОТОВ С ИСПОЛЬЗОВАНИЕМ АДАПТИВНОЙ НЕЙРО-НЕЧЕТКОЙ СИСТЕМЫ ВЫВОДА© 2024 г. **В. К. Каличкин**, доктор сельскохозяйственных наук, **Д. С. Федоров**, **К. Ю. Максимович**, кандидат биологических наук*Сибирский федеральный научный центр агробиотехнологий Российской академии наук,
630501, Новосибирская обл., Новосибирский р-н, пос. Краснообск
E-mail: vk.kalichkin@gmail.com*

Исследование проводили с целью разработки модели и осуществления прогнозирования продуктивности севооборотов на основе адаптивного нейро-нечеткого вывода. В работе использовали материалы длительных полевых опытов (данные по 9 видам севооборотов, ориентированных на производство зерна), проведенных в Новосибирской области в 1999–2019 гг. В процессе работы применяли алгоритм обучения искусственной нейронной сети с использованием гибридного метода оптимизации, сочетающего метод наименьших квадратов и метод обратного распространения ошибки, для задания нечеткого правила с подходящими функциями принадлежности с учетом входных и выходных данных. На основе использования адаптивного нейро-нечеткого моделирования и среды разработки MATLAB создана модель продуктивности севооборотов ANFIS. Сформированные в процессе обучения ANFIS правила позволяют с достаточно высокой точностью детерминировать значимые комбинации факторов, определяющие продуктивность заданных севооборотов. При осуществлении прогнозного моделирования на примере трех видов севооборотов выявлено существенное влияние озимых культур и элементов плодосмена на устойчивость севооборотов к неблагоприятным условиям атмосферного увлажнения и эффективность применения агрохимических средств. Результаты комплексного анализа с использованием различных метрик точности (коэффициент детерминации – 0,78; корень из среднеквадратичной ошибки – 5,66; средняя абсолютная ошибка – 4,31; средняя абсолютная ошибка в процентах – 20,07 %) свидетельствуют о достаточно хорошей предиктивной способности модели. Разработанная модель ANFIS демонстрирует высокую способность учитывать сложные нелинейные взаимосвязи между признаками, влияющими на продуктивность севооборотов, и может быть использована в принятии производственных решений при краткосрочном и долгосрочном планировании.

MODELING CROP ROTATION PRODUCTIVITY USING AN ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM**V. K. Kalichkin, D. S. Fedorov, K. Yu. Maksimovich***Siberian Federal Research Center of Agricultural Biotechnology,
Russian Academy of Sciences,
630501, Novosibirskaya obl., Novosibirskii r-n, pos. Krasnoobsk
E-mail: vk.kalichkin@gmail.com*

The study was conducted with the goal of developing a model and forecasting crop rotation productivity using adaptive neuro-fuzzy inference. The work utilized data from long-term field experiments (data from 9 types of crop rotations focused on grain production) conducted by the Siberian Research Institute of Agriculture and Chemicalization of Agriculture (Siberian Federal Scientific Centre of Agro-BioTechnologies of the Russian Academy of Sciences) from 1999 to 2019. During the study, an artificial neural network (ANN) training algorithm was applied using a hybrid optimization method, combining the least squares method and backpropagation, to set up fuzzy rules with appropriate membership functions based on input and output data. Based on the use of adaptive neuro-fuzzy modeling and the MATLAB development environment, ANFIS crop rotation productivity model has been developed. The ANFIS rules formed during training allow for fairly accurate determination of significant factor combinations that influence the productivity of the given crop rotations. In predictive modeling of three types of crop rotations, the significant role of winter crops and crop rotation elements in enhancing crop rotation resilience to adverse atmospheric moisture conditions and improving the effectiveness of agrochemical application was revealed. A comprehensive analysis using various accuracy metrics (coefficient of determination – 0.78; root mean square error – 5.66; mean absolute error – 4.31; mean absolute percentage error – 20.07 %) indicates the model has good predictive ability. The developed ANFIS model demonstrates a strong ability to account for complex nonlinear relationships between the features influencing crop rotation productivity and can be used in production decision-making for short- and long-term planning.

Ключевые слова: севооборот, моделирование продуктивности, интеллектуальное земледелие, искусственный интеллект, машинное обучение, ANFIS.

Keywords: crop rotation, productivity modeling, intelligent farming, artificial intelligence, machine learning, ANFIS.

В современном земледелии в связи с возможными изменениями климата, необходимостью сокращения использования химических веществ, усиления комплексной борьбы с вредителями и болезнями сельскохозяйственных культур возродилась популярность севооборота как ключевой концепции реализации систем земледелия [1, 2]. В длительных полевых опытах установлено,

что бессистемное размещение сельскохозяйственных культур, повторное и бесменное возделывание большинства из них приводит к ухудшению плодородия зональных почв, повышению засоренности посевов и поражению растений вредителями и болезнями, что в конечном итоге вызывает снижение продуктивности сельскохозяйственных земель [3, 4].

В мировой науке развиваются две категории подходов к прогнозированию продуктивности и формированию севооборотов: теоретический, основанный на знаниях, и подход машинного обучения, основанный на данных. В качестве примера первого подхода можно привести программный инструмент ROTAT, который был разработан для обеспечения всех теоретически возможных севооборотов с конкретным набором культур и применяет фильтры для уменьшения общего количества севооборотов в соответствии с агрономическими критериями (правилами). Аналогичным образом основанная на правилах модель ROTOR генерирует севообороты с учетом заранее определенных процессов растениеводства с фиксированными датами посева и уборки урожая. Общее количество технически возможных севооборотов сокращается посредством набора критериев исключения, связанных с питанием растений, пораженностью сорняками и фитосанитарными последствиями. Еще одно программное обеспечение для линейного программирования представлено инструментом CropRota. В нем выводятся типичные, а не теоретические севообороты, подходящие для систем моделирования землепользования, путем интеграции агрономических правил и наблюдаемых данных о конкретном землепользовании [5, 6]. Предлагаются также многоцелевые модели смешанного линейного программирования с целочисленными и бинарными переменными решения задач планирования севооборота [7]. Основным недостатком этих методов – неспособность адаптироваться к меняющимся условиям, поскольку модели рассматриваются в качестве статической концепции.

В качестве примера подходов второй категории, основанных на применении искусственного интеллекта (ИИ), можно назвать AI4CROPR – метод определения матриц севооборота с использованием индексов вегетации (VI), полученных на основе дистанционного зондирования, кластеризации и ИИ [8]. Для прогнозирования индексов вегетации возделываемых культур применяется экстремальный градиентный бустинг (XGBoost) с использованием исторических данных об урожайности. Нормализованные значения VI в различных кластерах в дальнейшем применяются для создания матрицы севооборотов. Система поддержки принятия решений Fruchtfolge позволяет оптимизировать выбор культур в севообороте с использованием больших данных и пространственного моделирования [9]. Рекуррентные нейронные сети (RNN) в архитектуре Seq2Seq могут быть использованы для прогнозирования наиболее вероятных сценариев севооборотов в соответствии с историческими данными по возделыванию сельскохозяйственных культур [10]. Для прогнозирования наиболее вероятных культур в севообороте, возделываемых в $n+1$ году, могут быть использованы цепи Маркова [11].

Системы на основе ИИ, например искусственные нейронные сети (ИНС), используются для реализации сложных функций в различных областях. Однако ИНС выступают моделями «черного ящика», и поэтому сложно или невозможно объяснить результаты их работы. Чтобы сделать результаты интеллектуальных моделей более приближенными к ожидаемым результатам в типичных ситуациях, появилась концепция нечетких систем. Нечеткие системы – это системы или правила, основанные на знаниях, то есть действующие на основе опыта эксперта. Отправной точкой для построения нечеткой системы служит получение набора нечетких правил «если – то» из знаний эксперта или из данных в анализируемой предметной области. В поисках согласованной синергии между обучающей способностью

ИНС и возможностью представления проблем в более интерпретируемом виде были предложены модели, которые используют лучшее из обеих концепций для формирования гибридных систем [12]. Среди этих систем можно отметить адаптивную нейро-нечеткую инференционную систему (Adaptive neuro-fuzzy inference system – ANFIS), в русском переводе часто называемую адаптивной системой нейро-нечеткого вывода [13, 14, 15].

ANFIS с использованием набора входных-выходных данных создает систему нечеткого вывода и тем самым похожа на нейронные сети с переменной структурой. Это означает, что определение ее структуры выполняется в соответствии с данными. Настройка параметров ANFIS может быть выполнена посредством обратного распространения ошибки и/или иных алгоритмов [16]. Следующим шагом выступает объединение нечетких лингвистических правил в единую систему. Это важный аспект теории нечетких систем, который обеспечивает систематический процесс преобразования базы знаний в нелинейное отображение [17, 18].

В отечественном научном сообществе интерес к этой предметной области невелик. В качестве примера можно привести работу [19], в которой использовали ANFIS для классификации болезней растений. Входными данными системы служили текстурные признаки Харалика, извлеченные из изображений растений. Модель классификации болезней достигала 85 % точности.

Цель исследований – разработать модель и осуществить прогнозирование продуктивности севооборотов с использованием адаптивного нейро-нечеткого вывода на основе анализа данных длительных полевых опытов.

Методика. Нейро-нечеткое моделирование продуктивности севооборотов проводили с использованием материалов длительных полевых опытов, проведенных в лесостепи Приобья Новосибирской области Сибирским НИИ земледелия и химизации сельского хозяйства СФНЦА РАН в течение 1999–2019 гг. В опытах изучали 9 видов севооборотов, ориентированных на производство зерна: бессменная пшеница (А), пшеница – овес – пшеница – ячмень (В), вико – овес (на зерно) – пшеница – пшеница – ячмень (С), рапс – пшеница – пшеница – ячмень (D), пар – пшеница – пшеница – ячмень (E), пар – озимая рожь – пшеница – ячмень (F), донник – озимая рожь – пшеница – ячмень с подсевом донника (G), клевер – озимая рожь – пшеница – ячмень с подсевом клевера (H), вико – овес (на зеленую массу) – пшеница – пшеница – ячмень (I). Все севообороты реализованы во времени и пространстве в 3-кратной повторности на делянках размером 475 м², всего экспериментальных полей севооборотов 104. В расчетах использованы временные ряды продуктивности севооборотов, выраженные в зерн.ед./га с севооборотной площади. Использованы данные, полученные на 3 уровнях применения агрохимических средств (уровнях интенсификации): без удобрений и пестицидов (экстенсивный) (1), удобрения + гербициды (нормальный) (2), удобрения + фунгицид + гербицид + инсектициды (интенсивный) (3) [20]. Для оценки продуктивности севооборотов был проведен перерасчет фактической урожайности изучаемых культур в зерновые единицы (зерн.ед.) с использованием коэффициентов перевода продукции растениеводства (в соответствии с Приказом Минсельхоза России от 29.04.2022 N 273 Об утверждении Порядка отбора проектов мелиорации). Атмосферное увлажнение в годы проведения опытов учитывали посредством применения стандартизованного индекса осадков (Standardized Precipitation

Index – SPI), который позволяет представить в числовом виде степень увлажнения/засушливости территории. Возможность использования индекса SPI в качестве информативного показателя степени атмосферного увлажнения территории и эффективность его применения при оценке изменчивости и прогнозировании урожайности продемонстрирована ранее [21]. За основной SPI, участвующий в математических расчетах, принята средняя величина атмосферного увлажнения в период с мая по июль за 4 года ротации каждого из анализируемых севооборотов. Для расчетов SPI использованы временные ряды по данным поста метеонаблюдений г. Новосибирска (источником данных был web-ресурс <http://www.pogodaiklimat.ru>). Расчеты SPI выполнены в программном обеспечении Drought Indices Calculator (DrinC) с открытым исходным кодом (<https://drought-software.com>) [22]. Степень проявления увлажненности/засушливости территории оценивали по следующей шкале варьирования SPI: экстремально влажно – 2,0+; сильно влажно – от 1,5 до 1,99; умеренно влажно – от 1,0 до 1,49; норма – от –0,99 до +0,99; умеренно сухо – от –1,0 до –1,49; сильно сухо – от –1,5 до –1,99 и экстремально сухо – –2,0 и менее [23].

Разработанная модель ANFIS, реализованная в среде MATLAB, имеет три входные переменные:

уровень интенсификации – дискретная переменная (1, 2, 3), соответствующая трем уровням применения техногенных средств;

SPI – непрерывная переменная, характеризующая степень атмосферного увлажнения;

вид севооборота – дискретная переменная (от А до I, соответствующая различным видам севооборотов).

Модель ANFIS была обучена с использованием гибридного метода оптимизации, сочетающего метод наименьших квадратов и метод обратного распространения ошибки с использованием 80 % данных для обучения и 20 % для тестирования модели. Процесс обучения проводился в течение 150 эпох, что обеспечило достаточную сходимость модели. Выбор количества эпох основывался на анализе кривой обучения, которая показывает зависимость ошибки от числа итераций. Ошибка обучения стабилизируется примерно после 100 эпох, что подтверждает адекватность выбранного числа итераций.

Результаты и обсуждение. ANFIS объединяет концепции нечеткой логики и нейронных сетей, что позволяет системе обучаться на основе имеющихся данных и адаптировать параметры функций принадлежности и весовые коэффициенты правил для минимизации ошибки между расчетными и фактическими

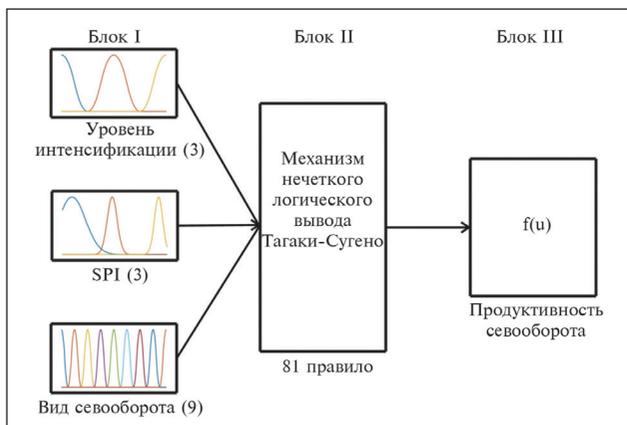


Рис. 1. Структура ANFIS в общем виде.

значениями выходной переменной. Нечеткие выходы, полученные в результате срабатывания правил, агрегируются и дефазифицируются для получения четкого выходного значения из результатов.

Структура разработанной модели ANFIS состоит из пяти последовательных слоев, объединенных в три основных блока (рис. 1).

Блок I состоит из входного слоя (Input layer) с тремя переменными и слоя фаззификации (Fuzzification layer). Каждая входная переменная характеризуется своими функциями принадлежности (ФП). В слое фаззификации происходит преобразование четких входных значений в степени принадлежности к нечетким множествам по формуле:

$$O_i^1 = \mu A_i(x), \quad (1)$$

где O_i^1 – выход i -го узла первого слоя, $\mu A_i(x)$ – функция принадлежности для нечеткого множества A_i , x – входное четкое значение, i – индекс узла в первом слое.

Блок II состоит из слоя нечетких правил (Neurologic rules) и слоя нормализации (Normalization layer). Этот блок реализует механизм нечеткого логического вывода Такаги – Сугено. Он включает в себя слой нечетких правил и слой нормализации. В слое нечетких правил каждый узел соответствует одному правилу. В этой модели использована база из 81 правила, что соответствует всем возможным комбинациям входных переменных ($3 \times 3 \times 9 = 81$). Каждое правило имеет вид «ЕСЛИ (входная переменная 1 есть А) И (входная переменная 2 есть В), И (входная переменная 3 есть С), ТО (выход есть Z)», где А, В, С – нечеткие множества, а Z – линейная функция входных переменных. Выход узла рассчитывается как произведение степеней принадлежности входов:

$$O_i^2 = w_i = \mu A_i(x) \cdot \mu B_i(y) \cdot \mu C_i(z), \quad (2)$$

где O_i^2 – выход i -го узла второго слоя, w_i – сила срабатывания i -го правила, $\mu A_i(x)$, $\mu B_i(y)$, $\mu C_i(z)$ – функции принадлежности для нечетких множеств A_i , B_i , C_i соответственно, x, y, z – входные четкие значения для трех входных переменных, i – индекс правила.

В слое нормализации происходит вычисление нормализованной силы срабатывания каждого правила:

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{i=0}^n w_i}, \quad (3)$$

где O_i^3 – выход i -го узла третьего слоя, \bar{w}_i – нормализованная сила срабатывания i -го правила, w_i – сила срабатывания i -го правила, $\sum_{i=0}^n w_i$ – сумма сил срабатывания всех правил.

Блок III состоит из выходного слоя (Output layer). Представлен одной выходной переменной $f(u)$, которая соответствует продуктивности севооборота, выраженной в зерн.ед./га. В этом слое происходит дефаззификация – преобразование нечетких выводов в четкое значение:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i z + s_i), \quad (4)$$

где O_i^4 – выход i -го узла четвертого слоя, \bar{w}_i – нормализованная сила срабатывания i -го правила, f_i – линейная функция входных переменных для i -го правила, p_i, q_i, r_i – коэффициенты при входных переменных x, y, z соответственно, s_i – свободный член в линейной функции, x, y, z – входные четкие значения.

Общий выход системы рассчитывается как:

$$f(u) = \frac{\sum_{i=0}^n \bar{w}_i f_i}{\sum_{i=0}^n \bar{w}_i}, \quad (5)$$

где $f(u)$ – окончательный выход системы (продуктивность севооборота), \bar{w}_i – нормализованная сила срабатывания i -го правила, f_i – линейная функция входных переменных для i -го правила.

Формулы и общая структура ANFIS основаны на работе J. S. Jang [24], а также подробно описаны в работе [25].

Для каждого входного значения в пределах соответствующего диапазона определяется степень принадлежности к каждому нечеткому множеству. Степень принадлежности может иметь значения от нуля до единицы. Для выходного параметра лингвистические термины присваиваются синглтонам (паттернам проектирования), что служит особой характеристикой для FIS Такаги – Сугено. В модели ANFIS определены ФП для каждой переменной, использованы следующие их типы: уровень интенсификации – три кусочно-линейные функции (а); SPI – три гауссовы функции (б); вид севооборота – девять кусочно-линейных функций (с) (рис. 2).

Выбор типов ФП обусловлен характером входных данных. Кусочно-линейные функции хорошо подходят для дискретных переменных, таких как уровень интенсификации и вид севооборота, так как они позволяют четко разграничить категории. Гауссовы функции выбраны для SPI, поскольку они обеспечивают плавный переход между категориями, что более адекватно отражает непрерывную природу этой переменной.

Сформированные в процессе обучения ANFIS правила отражают сложные взаимосвязи между входными переменными (уровень интенсификации, SPI и вид севооборота) и выходной переменной (продуктивность севооборота). Анализ правил позволяет выявить наиболее значимые комбинации факторов, влияющих на продуктивность. В качестве примера приведем несколько правил:

ЕСЛИ (уровень интенсификации I) И (SPI *низкий*), И (вид севооборота A) ТО (продуктивность *низкая*).

ЕСЛИ (уровень интенсификации I) И (SPI *низкий*), И (вид севооборота B) ТО (продуктивность *низкая*).

ЕСЛИ (уровень интенсификации I) И (SPI *средний*), И (вид севооборота C) ТО (продуктивность *средняя*).

ЕСЛИ (уровень интенсификации I) И (SPI *средний*), И (вид севооборота D) ТО (продуктивность *средняя*).

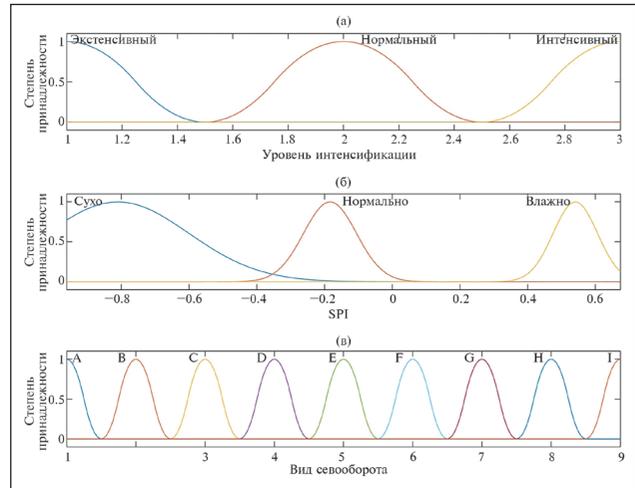


Рис. 2. Функции принадлежности ANFIS: а) уровень интенсификации; б) SPI; в) вид севооборота.

ЕСЛИ (уровень интенсификации I) И (SPI *высокий*), И (вид севооборота E) ТО (продуктивность *высокая*).

ЕСЛИ (уровень интенсификации I) И (SPI *высокий*), И (вид севооборота F) ТО (продуктивность *высокая*).

Для более наглядного представления зависимостей между входными и выходной переменными были построены поверхности отклика (рис. 3). Эти поверхности демонстрируют нелинейный характер взаимосвязей между входными переменными.

В частности, можно отметить, что при взаимодействии между SPI и уровнем интенсификации (рис. 3а) наблюдается тенденция к увеличению продуктивности севооборотов при повышении уровня применения технологий средств, особенно в благоприятных условиях увлажнения (высокие значения SPI). Эффективность повышения уровня интенсификации варьируется в зависимости от вида севооборота (рис. 3б), что указывает на необходимость дифференцированного подхода к управлению различными севооборотами. Различные виды севооборотов демонстрируют разную устойчивость к уменьшению атмосферного увлажнения вегетационного периода, что отражается в вариациях продуктивности при изменении SPI (рис. 3с).

Для оценки эффективности модели был проведен комплексный анализ с использованием различных метрик. Среднеквадратичная ошибка (RMSE) составила 5,66, а средняя абсолютная ошибка (MAE) – 4,31, что свидетельствует о достаточно хорошей точности

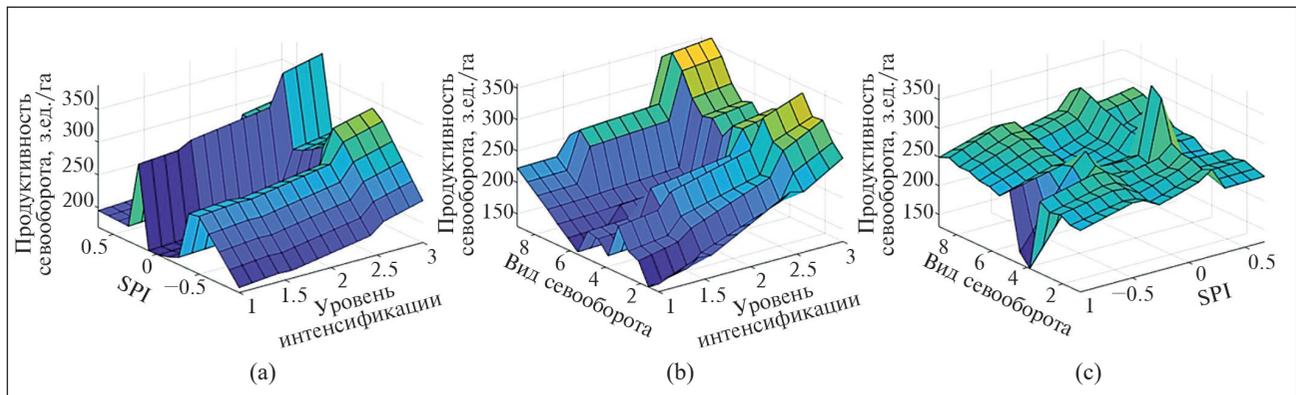


Рис. 3. Поверхности отклика ANFIS: а) зависимость продуктивности от SPI и уровня интенсификации; б) зависимость продуктивности от уровня интенсификации и вида севооборота; в) зависимость продуктивности от вида севооборота и SPI.

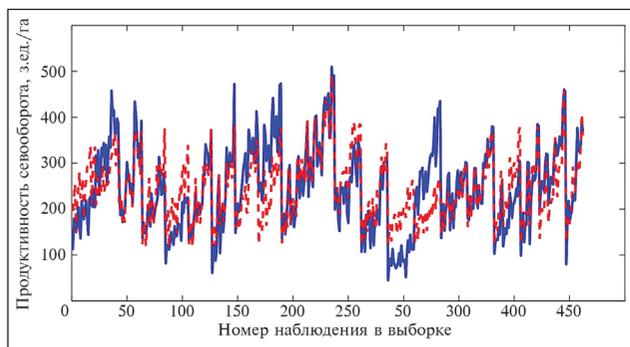


Рис. 4. Фактические и прогнозные значения продуктивности севооборотов.

прогнозов. Средняя абсолютная процентная ошибка (MAPE) в 20,07 % представляет оценку о том, что прогнозы в среднем отклоняются от фактических значений на одну пятую. Коэффициент корреляции Пирсона (r), равный 0,78, подтверждает сильную положительную связь между предсказанными и фактическими значениями. Медианная абсолютная ошибка (MedAE) и среднее абсолютное отклонение (MAD) достигают значений 3,21 и 7,43 соответственно.

Визуальный анализ фактических и прогнозных значений продуктивности севооборотов показывает, что модель в целом хорошо улавливает тенденции изменения продуктивности, хотя и присутствуют некоторые отклонения, особенно в экстремальных точках (рис. 4).

На основе разработанной модели ANFIS была проведена серия прогнозов (27 шт.) продуктивности севооборотов при различных входных параметрах (см. табл.).

В качестве примера прогностических возможностей модели ANFIS приведены три вида наиболее репрезентативных севооборотов в лесостепи Сибири. В севообороте с паром и яровыми культурами в засушливых условиях при всех уровнях интенсификации существенно снижается продуктивность, в сравнении с севооборотом с озимой рожью. Причем без примене-

Фрагмент базы прогнозов продуктивности севооборотов

Вид севооборота	Уровень интенсификации	SPI	Прогнозируемая продуктивность, зерн.ед./га
Пар – пшеница – пшеница – ячмень (E)	экстенсивный	-1,10	994
		0,27	1735
		1,35	1461
	нормальный	-1,05	1265
		0,17	2854
		1,15	2204
Пар – озимая рожь – пшеница – ячмень (F)	экстенсивный	-1,14	2415
		0,08	3024
		1,18	2869
	нормальный	-1,12	1792
		-0,01	1900
		1,38	1734
Клевер – озимая рожь – пшеница – ячмень с подсевом клевера (H)	нормальный	-1,13	2311
		-0,60	2542
		1,12	2152
	интенсивный	-1,15	2371
		-0,54	3178
		1,11	2919
Клевер – озимая рожь – пшеница – ячмень с подсевом клевера (H)	экстенсивный	-1,14	2071
		-0,33	3065
		1,16	2718
	нормальный	-1,05	2420
		-0,22	3233
		1,10	2866
	интенсивный	-1,12	3274
		0,12	4070
		1,09	3678

ния агрохимических средств ее снижение составляет 44,5 %. При использовании удобрений и гербицидов относительная разница в продуктивности севооборотов не уменьшается, несмотря на то, что в абсолютных величинах она в целом увеличивается. Продуктивность этих севооборотов в засушливых условиях выравнивается только при комплексном применении агрохимических средств (удобрения + фунгицид + гербицид + инсектицид).

В благоприятных условиях атмосферного увлажнения продуктивность этих севооборотов выравнивается и закономерно увеличивается с повышением уровня интенсификации. В условиях атмосферного переувлажнения продуктивность севооборота с яровыми культурами на экстенсивном уровне уменьшается на 16 %, в сравнении с севооборотом с озимой рожью. На нормальном и интенсивном уровне продуктивность этих севооборотов практически выравнивается.

Результаты этого моделирования подчеркивают значение озимых культур (в нашем случае озимой ржи) в повышении устойчивости севооборотов к неблагоприятным условиям (атмосферная засуха и переувлажнение) и стабилизации продуктивности в сравнении с севооборотом с яровыми культурами. Результаты моделирования также отражают значение агрохимических средств в повышении устойчивости севооборотов к неблагоприятным условиям атмосферного увлажнения и повышения их продуктивности.

Моделирование продуктивности севооборотов показало также важность включения элементов плодосмена в чередование культур. Так, зернотравяной севооборот (клевер – озимая рожь – пшеница – ячмень с подсевом клевера) более устойчив к засушливым условиям вегетационного периода и переувлажнению, особенно при увеличении применения агрохимических средств. В целом продуктивность этого севооборота в различных условиях атмосферного увлажнения была выше на экстенсивном уровне на 1220 зерн.ед./га зернопарового севооборота с зерновыми культурами и на 810 зерн.ед./га зернопарового севооборота с озимой рожью. На интенсивном уровне различие в продуктивности севооборотов уменьшалось в сравнении с зернопаровым севооборотом до 910 зерн.ед./га, а в сравнении с зернопаровым севооборотом с озимой рожью увеличивалось до 850 зерн.ед./га.

Выводы. Адаптивная нейро-нечеткая система вывода (ANFIS) может эффективно решать нелинейные задачи, представляя собой комбинацию ИНС и нечетких систем. Вследствие синергизма этих двух подходов она обладает преимуществами получения хороших результатов в ситуациях, когда данные неточны и противоречивы.

В модели ANFIS применяли алгоритм обучения ИНС с использованием гибридного метода оптимизации, сочетающего метод наименьших квадратов и метод обратного распространения ошибки, для задания нечеткого правила с подходящими функциями принадлежности с учетом входных и выходных данных. Для уровня интенсификации и вида севооборота использовали кусочно-линейные функции принадлежности, а для индекса увлажнения/засушливости (SPI) – гауссовы функции.

Среднеквадратичная ошибка (RMSE) составила 5,66, а средняя абсолютная ошибка (MAE) – 4,31, что свидетельствует о достаточно хорошей точности прогнозов. В целом показатели точности модели демонстрируют хороший баланс между точностью и обобщающей способностью, делая ее пригодной для практического применения. Однако наличие ошибок также указывает на потенциал для дальнейшей опти-

мизации, возможно, путем включения дополнительных признаков или увеличения объема обучающей выборки.

Прогнозное моделирование на примере трех видов севооборотов продемонстрировало правдоподобные закономерности изменения их продуктивности. Это позволило выявить существенное влияние озимых культур и элементов плодосмена на устойчивость севооборотов к неблагоприятным условиям атмосферного увлажнения и эффективность применения агрохимических средств.

Разработанная модель ANFIS демонстрирует способность учитывать сложные нелинейные взаимосвязи между признаками, влияющими на продуктивность севооборотов. Адаптивное нейро-нечеткое моделирование продуктивности севооборотов открывает возможности по принятию обоснованных решений по плану посевов и севообороту. Поскольку это динамичный процесс, его можно включить в последовательность разработки других плановых и адаптивных решений, принимаемых на годовом и долгосрочном уровнях.

ФИНАНСИРОВАНИЕ РАБОТЫ.

Исследования выполнены согласно Государственному заданию Министерства науки и высшего образования РФ в рамках НИР по теме No FNUU-2022–0001.

СОБЛЮДЕНИЕ ЭТИЧЕСКИХ СТАНДАРТОВ.

В работе отсутствуют исследования человека или животных.

КОНФЛИКТ ИНТЕРЕСОВ.

Авторы работы заявляют, что у них нет конфликта интересов.

Литература.

1. Schöning J., Wachter P., Trautz D. Crop rotation and management tools for every farmer?: The current status on crop rotation and management tools for enabling sustainable agriculture worldwide // *Smart Agricultural Technology*. 2023. Vol. 3. P. 100086. URL: <https://www.sciencedirect.com/science/article/pii/S277237552200051X> (дата обращения: 01.08.2024).
2. Review on the contribution of farming practices and technologies towards climate-smart agricultural outcomes in a European context / K. T. Erekaloa, S. M. Pedersena, T. Christensena, et al. // *Smart Agricultural Technology*. 2024. Vol. 7. P. 100413. URL: <https://www.sciencedirect.com/science/article/pii/S2772375524000182> (дата обращения: 01.08.2024).
3. Юшкевич Л. В., Чибис В. В. Особенности формирования полевых севооборотов в условиях лесостепи Западной Сибири // *Вестник Красноярского государственного аграрного университета*. 2021. № 9 (174). С. 3–9. doi: 10.36718/1819-4036-2021-9-3-9.
4. Фитосанитарное состояние и урожайность озимой пшеницы в севооборотах лесостепной зоны Поволжья / А. Л. Тойгильдин, М. И. Подсевалов, И. А. Тойгильдина и др. // *Аграрная наука*. 2022. Т. 354. № 11–12. С. 82–87. doi: 10.32634/0869-8155-2021-354-11-12-82-87.
5. Model-based design of crop diversification through new field arrangements in spatially heterogeneous landscapes. A review / I. M. Hernández-Ochoa, T. Gaiser, K.-C. Kersebaum, et al. // *Agronomy for Sustainable Development*. 2022. Vol. 42. No. 4. P. 74. URL: <https://link.springer.com/article/10.1007/s13593-022-00805-4> (дата обращения: 04.08.2024).
6. AI-and data-driven crop rotation planning / S. Fenz, T. Neubauer, J. K. Friedel, et al. // *Computers and Electronics in Agriculture*. 2023. Vol. 212. P. 108160. URL: <https://www.sciencedirect.com/science/article/pii/S0168169923005483> (дата обращения: 01.08.2024).
7. Multi-objective models for crop rotation planning problems / R. D. S. G. Pontes, D. N. Brandão, F. L. Usberti, et al. // *Agricultural Systems*. 2024. Vol. 219. P. 104050. URL: <https://www.sciencedirect.com/science/article/pii/S0308521X24002002> (дата обращения: 19.08.2024).
8. AI-and data-driven pre-crop values and crop rotation matrices / S. Fenz, T. Neubauer, J. Heurix, et al. // *European Journal of Agronomy*. 2023. Vol. 150. P. 126949. URL: <https://www.sciencedirect.com/science/article/pii/S1161030123002174> (дата обращения: 07.07.2024).
9. Pahlmeyer C., Kuhn T., Britz W. «Fruchtfolge»: A crop rotation decision support system for optimizing cropping choices with big data and spatially explicit modeling // *Computers and Electronics in Agriculture*. 2021. Vol. 181. P. 105948. URL: <https://www.sciencedirect.com/science/article/pii/S0168169920331537> (дата обращения: 07.07.2024).
10. Dupuis A., Dadouchi C., Agard B. Methodology for multi-temporal prediction of crop rotations using recurrent neural networks // *Smart Agricultural Technology*. 2023. Vol. 4. P. 100152. URL: <https://www.sciencedirect.com/science/article/pii/S2772375522001162> (дата обращения: 07.06.2024).
11. Dupuis A., Dadouchi C., Agard B. Predicting crop rotations using process mining techniques and Markov principals // *Computers and Electronics in Agriculture*. 2022. Vol. 194. P. 106686. URL: <https://www.sciencedirect.com/science/article/pii/S0168169922000035> (дата обращения: 09.07.2024).
12. de Campos Souza P. V. Fuzzy neural networks and neuro-fuzzy networks: A review the main techniques and applications used in the literature // *Applied soft computing*. 2020. Vol. 92. P. 106275. URL: <https://www.sciencedirect.com/science/article/pii/S1568494620302155> (дата обращения: 12.08.2024).
13. Remya S., Sasikala R. Performance evaluation of optimized and adaptive neuro fuzzy inference system for predictive modeling in agriculture // *Computers & Electrical Engineering*. – 2020. Vol. 86. P. 106718. URL: <https://www.sciencedirect.com/science/article/pii/S0045790620305735> (дата обращения: 05.08.2024).
14. Rathnayake N., Dang T. L., Hoshino Y. A novel optimization algorithm: Cascaded adaptive neuro-fuzzy inference system // *International Journal of Fuzzy Systems*. 2021. Vol. 23. No. 7. P. 1955–1971. doi: 10.1007/s40815-021-01076-z.
15. Remya S. An adaptive neuro-fuzzy inference system to monitor and manage the soil quality to improve sustainable farming in agriculture // *Soft Computing*. 2022. Vol. 26. № 23. P. 13119–13132. doi: 10.1007/s00500-022-06832-3.
16. Modeling and simulation of a multi-parametric fuzzy expert system for variable rate nitrogen application / A. Heiß, D. S. Paraforos, G. M. Sharipov, et al. // *Computers and Electronics in Agriculture*. 2021. Vol. 182. P. 106008. URL: <https://www.sciencedirect.com/science/article/pii/S0168169921000260> (дата обращения: 10.08.2024).
17. An Insight into Fuzzy Logic Computation Technology and Its Applications in Agriculture and Meteorology / S. Sowmiyaa, S. Moghana Lavanya, K. Mahendran, et al. // *Oriental Journal of Computer Science and Technology*. 2021. Vol. 13. No. 2, 3. P. 97–101. doi: 10.13005/ojcs13.0203.06.
18. Sensitivity analysis of Takagi-Sugeno fuzzy neural network / J. Wang, Q. Chang, T. Gao, et al. // *Information*

- Sciences*. 2022. Vol. 582. P. 725–749. doi: 10.1016/j.ins.2021.10.037.
19. Классификация состояния растений с использованием адаптивной нейро-нечеткой инференционной системы (ANFIS) / В. В. Брыкин, М. Я. Брагинский, Д. В. Тараканов и др. // *Вестник кибернетики*. 2024. Т. 23. № 2. С. 23–30. doi: 10.35266/1999-7604-2024-2-3.
 20. Урожайность зерновых культур в звеньях севооборотов лесостепи Приобья / А. Н. Власенко, В. Н. Шоба, Г. М. Захаров и др. // *Земледелие*. 2016. № 5. С. 12–14.
 21. Органическое земледелие в лесостепи Западной Сибири: связь урожайности яровой пшеницы и влагообеспеченности территории / К. Ю. Максимович, Д. С. Федоров, В. К. Каличкин и др. // *Аграрный вестник Северного Кавказа*. 2022. № . 2 (46). С. 32–38. doi: 10.31279/2222-9345-2022-11-46-32-38.
 22. Tigkas D., Vangelis H., Tsakiris G. *DrinC: a software for drought analysis based on drought indices* // *Earth Science Informatics*. 2015. Vol. 8. P. 697–709. doi: 10.1007/s12145-014-0178-y.
 23. Руководство для пользователей стандартизированного индекса осадков // ВМО-№ 1090. 2012. 26 с. URL: https://www.droughtmanagement.info/literature/WMO_standardized_precipitation_index_user_guide_ru_2012.pdf (дата обращения: 10.08.2024).
 24. Jang J. S. *ANFIS: adaptive-network-based fuzzy inference system* // *IEEE transactions on systems, man, and cybernetics*. 1993. Vol. 23. No. 3. P. 665–685. doi: 10.1109/21.256541.
 25. Karaboga D., Kaya E. *Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey* // *Artificial Intelligence Review*. 2019. Vol. 52. No. 4. P. 2263–2293. doi: 10.1007/s10462-017-9610-2.

Поступила в редакцию 13.09.2024
После доработки 31.10.2024
Принята к публикации 19.11.2024