



О необходимости трансформации парадигмы научных исследований по земледелию (сообщение второе)

✉ **Каличкин В.К.**

Сибирский федеральный научный центр агробиотехнологий Российской академии наук

Новосибирская область, р.п. Краснообск, Россия

✉ e-mail: vk.kalichkin@gmail.com

Представлен анализ направлений научных исследований по земледелию, связанных с преобладающей современной парадигмой и четвертой сельскохозяйственной революцией. Следующим этапом развития цифровизации сельского хозяйства становится интеллектуальное земледелие, которое подразумевает использование различных технологических инноваций, включая машинное обучение, компьютерное зрение, дистанционное зондирование, геоинформационное моделирование, Интернет вещей. Рассмотрены особенности использования цифровых технологий и методов искусственного интеллекта по блокам систем земледелия, которые целесообразно применять в планировании научных исследований и анализе полученных результатов. Формирование севооборотов осуществляется моделированием их продуктивности с использованием различных подходов искусственного интеллекта на основе временных рядов урожайности культур и данных дистанционного зондирования. Выбор системы основной обработки почвы возможен с помощью предиктивных моделей урожайности возделываемых культур и других базовых параметров ее эффективности с помощью машинного обучения. Разработку рекомендаций по срокам, дозам и способам внесения удобрений осуществляют с помощью моделей на основе искусственного интеллекта. Синхронизацию внесения удобрений со свойствами почв, погодными условиями и возделываемыми культурами регулируют с помощью различных подходов к цифровому управлению. Защиту посевов сельскохозяйственных культур от вредных организмов реализуют в системе прогнозирования их развития на основании данных о погоде, управляющих воздействиях и других типов данных. Предиктивные модели урожайности сельскохозяйственных культур в научных исследованиях по земледелию должны решать задачи имитации урожая и управляющих воздействий в камеральных условиях. На основании результатов виртуальных моделей разрабатывают программы и планы полевых исследований с целью валидации этих моделей. Выбор и сопровождение агротехнологий реализуют в системе учета и анализа взаимодействия широкого спектра условий и факторов с помощью проксимального и дистанционного зондирования (мониторинга) с последующим моделированием процессов и объектов для создания системы поддержки принятия решений в виде ЦСУЗ. В целях масштабирования и адаптации инноваций целесообразно использовать возможности гражданской науки и сетевых Web-платформ.

Ключевые слова: парадигма, системы земледелия, машинное обучение, прогнозирование, масштабирование, севооборот, обработка почвы, удобрения, защита растений, агротехнологии

On the need for a paradigm shift in agricultural research (message two)

✉ **Kalichkin V.K.**

Siberian Federal Scientific Centre of AgroBioTechnologies of the Russian Academy of Sciences

Krasnoobsk, Novosibirsk region, Russia

✉ e-mail: vk.kalichkin@gmail.com

Analysis of the agricultural research directions related to the prevailing modern paradigm and the fourth agricultural revolution is presented. The next stage in the development of digitalization of agriculture is smart farming, which involves the use of various technological innovations, including

machine learning, computer vision, remote sensing, geo-information modeling, and the Internet of Things. The peculiarities of using digital technologies and methods of artificial intelligence on farming systems blocks are considered, which are expedient to apply in planning scientific research and analyzing the obtained results. Formation of crop rotations is carried out by modeling their productivity using various artificial intelligence approaches based on time series of crop yields and remote sensing data. Selection of the main tillage system is possible with the help of predictive models of cultivated crop yields and other basic parameters of its efficiency with the help of machine learning. The development of recommendations on timing, doses and methods of fertilizer application is carried out with the help of artificial intelligence-based models. Synchronization of fertilizer application with soil properties, weather conditions and cultivated crops is regulated through various digital management approaches. Protection of crops from pests is realized in the system of forecasting their development on the basis of weather data, control actions and other types of data. Predictive models of crop yields in agricultural research should solve the problems of crop simulation and control actions under office-compiled conditions. Based on the results of virtual models, programs and field study plans are developed to validate these models. Selection and support of agro-technologies are implemented in the system of registration and analysis of the interaction of a wide range of conditions and factors by means of proximal and remote sensing (monitoring) with subsequent modeling of the processes and objects for the creation of a decision support system in the form of DFMS (digital farming management system). In order to scale and adapt the innovations, it is advisable to utilize the capabilities of citizen science and Web-based networking platforms.

Keywords: paradigm, farming systems, machine learning, forecasting, scaling, crop rotation, tillage, fertilizers, plant protection, agricultural technologies

Для цитирования: Каличкин В.К. О необходимости трансформации парадигмы научных исследований по земледелию (сообщение второе) // Сибирский вестник сельскохозяйственной науки. 2024. Т. 54. № 9. С. 102–115. <https://doi.org/10.26898/0370-8799-2024-9-11>

For citation: Kalichkin V.K. On the need for a paradigm shift in agricultural research (message two). *Sibirskii vestnik sel'skokhozyaistvennoi nauki* = *Siberian Herald of Agricultural Science*, 2024, vol. 54, no. 9, pp. 102–115. <https://doi.org/10.26898/0370-8799-2024-9-11>

Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.

Conflict of interest

The author declares no conflict of interest.

В мировой науке в рамках «четвертой сельскохозяйственной революции» фокус исследований по системам земледелия все более отчетливо смещается в сторону применения методов искусственного интеллекта и цифровых технологий для оценки устойчивого развития, стабильного обеспечения продовольствием, адаптации к возможному изменению климата с учетом возникающих технологических, социально-экономических и демографических проблем. Следующим этапом развития цифровизации сельского хозяйства (после «точного земледелия») становится «интеллектуальное земледелие» (Smart farming). В интеллектуальном земледелии приоритет принадлежит анализу информации с помощью машинного обучения (Machine learning), предиктивной аналитики

и формализации знаний (концептуализация, онтологизация, базы знаний), в том числе с использованием технологий точного земледелия с целью создания систем поддержки принятия решений (СППР) [1, 2].

По мнению некоторых авторов, интеллектуальное земледелие – это сельское хозяйство 5,0, называемое также цифровым сельским хозяйством. Интеграция искусственного интеллекта и других современных цифровых технологий в сельское хозяйство представляет собой значительный сдвиг парадигмы в этой отрасли. Трансформация парадигмы обусловлена конвергенцией различных технологических инноваций, включая машинное обучение, компьютерное зрение, дистанционное зондирование, геоинформационное моделирование, Интернет вещей, предиктив-

ную аналитику и др. Вместе эти технологии меняют методы ведения сельского хозяйства, обеспечивая более эффективное управление ресурсами, повышая производительность и внося вклад в устойчивое развитие [3, 4].

Считаем целесообразным рассмотреть некоторые аспекты применения методов искусственного интеллекта и современных цифровых технологий, используемых в мировой науке и практике, с целью трансформации парадигмы научных исследований по земледелию и включения их в программы научно-исследовательских работ, чтобы соответствовать мировому уровню.

Известно, что изменения типа культур, возделываемых на отдельном поле в течение нескольких последовательных вегетационных периодов, помогают мобилизовать питательные вещества в почве, прервать циклы болезней и ограничить распространение сорняков и вредителей. В связи с этим культурооборот предоставляет возможность снизить применение пестицидов, необходимых для защиты сельскохозяйственных культур от вредных организмов, а также удобрений для получения более высоких урожаев. Выбор возделываемых типов культур, сортов и их распределение по участкам на заданном горизонте планирования лежат в основе управления системой земледелия, и реализуются данные задачи через севообороты. В этих решениях сконцентрирована вся сложность, связанная с форматированием системы земледелия на уровне конкретного землепользования.

Поскольку в адаптивно-ландшафтном земледелии акцент делается на адаптацию к природным и производственным условиям землепользования, то и севообороты не должны

быть догматическими, с «застывшей» схемой реализации. В связи с этим севообороты целесообразно рассматривать, как минимум, в трех вариантах (альтернативах):

- циклическом с фиксированной длиной;
- циклическом с переменной длиной;
- менее структурированном циклическом с сильно варьируемой длиной.

Особенностью реализации этого подхода к севооборотам является возможность ежегодных корректировок плана посева сельскохозяйственных культур в зависимости от меняющегося контекста. Для разработки и последующего освоения гибких севооборотов целесообразно их моделировать с использованием различной математической формализации.

В настоящее время развиваются две категории подходов к моделированию севооборотов: теоретический подход, основанный на знаниях, и подход машинного обучения, основанный на данных. В первом подходе существуют методы, моделирующие севооборот как задачу оптимизации, решение которой можно найти с помощью линейного программирования¹, инструментом CropRota² или моделирования сетевых потоков³. Существуют также методы, основанные на агрономических правилах (знаниях), например ROTAT⁴ и ROTOR⁵. Основной недостаток этих методов – их неспособность адаптироваться к меняющимся условиям, поскольку для любого изменения в модели необходимо формулировать новые правила.

В качестве примеров, относящихся ко второй категории, можно привести несколько подходов. Например, инструмент AI4CROP, который определяет возможный потенциал урожайности культур перед посевом и фор-

¹Свиридов В.И. Методологические и методические аспекты проектирования оптимальной структуры посевных площадей в условиях перехода к адаптивно-ландшафтному земледелию // Вестник Курской государственной сельскохозяйственной академии. 2018. № 2. С. 4–10.

²Schönhart M., Schmid E., Schneider U.A. CropRota – A crop rotation model to support integrated land use assessments // European Journal of Agronomy. 2011. Vol. 34. N 4. P. 263–277. DOI: 10.1016/j.eja.2011.02.004.

³Detlefsen N.K., Jensen A.L. Modelling optimal crop sequences using network flows // Agricultural Systems. 2007. Vol. 94. N 2. P. 566–572. DOI: 10.1016/j.agsy.2007.02.002.

⁴Dogliotti S., Rossing W.A.H., van Ittersum M.K. ROTAT, a tool for systematically generating crop rotations // European Journal of Agronomy. 2003. Vol. 19. N 2. P. 239–250. DOI: 10.1016/S1161-0301(02)00047-3.

⁵Bachinger J., Zander P. ROTOR, a tool for generating and evaluating crop rotations for organic farming systems // European Journal of Agronomy. 2007. Vol. 26. N 2. P. 130–143. DOI: 10.1016/j.eja.2006.09.002.

мирует матрицы севооборотов с использованием прошлых данных нормализованного относительного индекса растительности (NDVI), полученных с помощью дистанционного зондирования, кластеризации и искусственного интеллекта [5]. Использование рекуррентной нейронной сети (RNN) в архитектуре Seq2Seq для прогнозирования наиболее вероятных сценариев севооборотов, которые будут использоваться на поле в последующие вегетационные периоды, в соответствии с историческими данными по возделыванию культур [6]. Система проектирования диверсифицированных севооборотов на основе набора показателей устойчивости, которая сочетает в себе модель генератора севооборота (ROTAT), инструменты для принятия решений на основе Парето и процесс формирования многокритериальных характеристик [7]. Оптимизация севооборотов с помощью парадокса Паррондо (парадокс используется в теории игр и характеризуется как комбинация проигрышных стратегий, которая выигрывает). В подходе используют разнообразие типов сельскохозяйственных культур и неопределенности окружающей среды для улучшения севооборотов. Рассчитывают оптимальные вероятности выращивания культур в рандомизированной последовательности и предлагают их детерминированное чередование в сочетании с применением удобрений [8]. Использование шестиступенчатой методологии на основе цепей Маркова, которая позволяет прогнозировать наиболее вероятные культуры, возделываемые в $n + 1$ году. Интеллектуальный анализ процессов и графики прямого отслеживания (DFG) помогают моделировать и визуализировать результаты [9]. Примеры можно продолжить, но ограничимся приведенными. Освоение перспективных подходов к моделированию севооборотов необходимо рассматривать в качестве базового элемента СППР и интегрировать с технологиями цифрового управления системами земледелия.

Основная обработка почвы – самый энергоемкий технологический прием. Обоснованное ее применение является наиболее существенным способом регулирования затрат техногенных средств. Длительные полевые исследования в различных почвенно-климатических условиях Западной Сибири показали, что оптимизация обработки почвы заключается в ее дифференцировании в зависимости от этих условий, в том числе изменчивости погоды и уровня интенсификации⁶. Так, на тяжелых по гранулометрическому составу и заплывающих почвах после уборки зерновых культур требуется осенняя обработка (вспашка, глубокое безотвальное рыхление). Мелкая обработка склоновых земель с уплотненной прослойкой нижней части пахотного слоя не обеспечивает противозерозионную устойчивость. Безотвальные и мелкие плоскорезные обработки снижают накопление в корнеобитаемом слое подвижных соединений азота, что является негативным эффектом по мере удаления культур от пара в севообороте. Глубокие обработки, особенно отвальная, в условиях дефицитного увлажнения приводят к большим потерям почвенной влаги. Черноземные почвы среднесуглинистого гранулометрического состава при нормальном увлажнении осенью имеют благоприятное сложение пахотного слоя и не требуют дополнительного глубокого рыхления⁷.

Изложенное выше представляет собой базовые положения по выбору и применению систем основной обработки почвы, однако с тех пор прошло более 20 лет. За это время изменились технологии возделывания сельскохозяйственных культур, орудия и агрегаты для обработки почвы и посева, появилось стремление к минимизации обработки почвы вплоть до прямого посева (технология No-Till). Отношение к No-Till трансформировалось от сомнений в ее целесообразности в сибирских условиях до полного одобрения. Так, по результатам полевых опытов, про-

⁶Экологизация обработки почвы в Западной Сибири / Власенко А.Н., Филимонов Ю.П., Каличкин В.К., Иодко Л.Н., Усолкин В.Т. / СО РАСХН. СибНИИЗХим. Новосибирск, 2003. 268 с.

⁷Власенко А.Н., Каличкин В.К., Филимонов Ю.П., Иодко Л.Н. Экологизация почвообработки и энергосбережение в условиях юга Западной Сибири // Сибирский вестник сельскохозяйственной науки. 2002. № 1-2. С. 3–11.

веденных в 2008–2013 гг. на черноземе выщелоченном среднесуглинистом в лесостепи Новосибирской области в трехпольных севооборотах, сделан вывод о полной конкурентоспособности No-Till в сравнении с обычной технологией обработки почвы (глубокое безотвальное рыхление), при этом урожайность яровой пшеницы была выше в среднем на 0,2 т/га⁸.

Однако считать, что проблема выбора альтернатив обработки почвы однозначно решена, по-видимому, преждевременно. Так, глобальный метаанализ 678 исследований с 6005 парными наблюдениями, представляющими 50 культур и 63 страны, показал, что урожайность при нулевой обработке почвы соответствовала урожайности при традиционной обработке только для масличных культур, хлопка и бобовых. Среди зерновых негативное воздействие нулевой обработки почвы было наименьшим для пшеницы (–2,6%), наибольшим – для риса (–7,5%) и кукурузы (–7,6%). Применение технологии No-Till давало положительный эффект в богарных условиях в засушливом климате, при этом урожайность культур часто была равной или превышала ее по традиционной обработке почвы. Урожайность в первые 1–2 года после внедрения нулевой обработки почвы снизилась для всех культур, кроме масличных и хлопка, но сравнялась с урожайностью при традиционной обработке почвы через 3–10 лет, за исключением кукурузы и пшеницы во влажном климате. В целом без внесения азотных удобрений урожайность при нулевой обработке почвы снизилась на 12%⁹.

В силу различных причин технология нулевой обработки почвы не распространена повсеместно. Например, в США применение этой технологии варьирует примерно от 70% площадей под соей до лишь 40% площадей под хлопчатником. Объясняется это тем, что переход от обычной обработки почвы к

No-Till приводит к распространению сорняков и последующей зависимости от гербицидов, так что экономия на топливе, времени и рабочей силе может быть нивелирована увеличением затрат на гербициды [10]. Кроме того, при реализации этой технологии, как правило, возникает дефицит минерального азота в почве, уплотнение почв, снижение водопроницаемости, усиление поверхностного стока на склонах.

Масштабные полевые исследования по системам основной обработки почвы в различных севооборотах в настоящее время вряд ли возможно реализовать в силу ограниченного кадрового и финансового обеспечения аграрной науки. В связи с этим необходимо использовать возможности искусственного интеллекта и цифровых технологий.

Научных работ по моделированию выбора системы обработки почвы практически нет. Исследования в основном касаются моделирования взаимодействия рабочих органов и почвы при ее обработке. Однако в качестве примера можно привести многоцелевую процедуру принятия решений на основе нечеткой логики FLoDSS. Эта программа принимает нечеткие входные данные и формирует выводы с целью помощи агрономам в планировании операций по обработке почвы¹⁰. По нашему мнению, моделировать выбор системы основной обработки почвы можно путем прогнозирования урожайности возделываемых культур с помощью машинного обучения, принимая обработку почвы за наиболее важный признак (предиктор). Возможна также интеграция предиктивных моделей урожайности культур с моделированием плотности почвы как одного из показателей ее агроэкологического состояния для выбора альтернатив обработки [11]. Кроме того, необходимо использовать временные ряды данных, накопленные в прошлых стационарных исследованиях, с помощью методов искус-

⁸Власенко А.Н., Власенко Н.Г. Возможности экологизации технологий в земледелии Сибири // Достижения науки и техники АПК. 2015. Т. 29. № 9. С. 21–24.

⁹Pittelkow C.M., Linquist B.A., Lundy M.E., Liang X., van Groenigen K.J., Lee J., van Gestel N., Six J., Venterea R.T., van Kessel C. When does no-till yield more? A global meta-analysis // Field crops research. 2015. Vol. 183. P. 156–168. DOI: 10.1016/j.fcr.2015.07.020.

¹⁰Thangavadevelu S., Colvin T.S. Fuzzy-logic-based decision support system for scheduling tillage operations // Engineering Applications of Artificial Intelligence. 1997. Vol. 10. N 5. P. 463–472. DOI: 10.1016/S0952-1976(97)00023-7.

ственного интеллекта создавать базы знаний и формировать логические правила по выбору приема основной обработки почвы.

Роль удобрений в повышении урожайности сельскохозяйственных культур и устойчивости производства растениеводческой продукции сложно переоценить. В основании подхода по управлению питательными веществами в системе почва – растения – атмосфера – управление лежит концепция 4R, которая означает использование необходимых форм удобрений в рациональной дозе, в нужное время и оптимальным способом. Синхронизация внесения удобрений со свойствами почв, погодными условиями и возделываемыми культурами может быть осуществлена с помощью различных подходов к моделированию и цифровому управлению [12].

В настоящее время модели рекомендаций по внесению удобрений делятся на три категории: математические; основанные на знаниях; основанные на методах искусственного интеллекта. Математические модели используют уравнения, которые оценивают дозу внесения удобрений на основе входных переменных, таких как планируемая урожайность, требуемое количество элементов питания и их потребление культурой, эффективность использования удобрений [13]. Однако получить входные переменные, необходимые для математических моделей, непросто, и их трудно применять в больших географических масштабах.

Модели, основанные на знаниях, являются еще одним распространенным типом и представляют репрезентативный метод. При использовании этих моделей агрохимические и другие знания компилируются в явные правила и сохраняются в базе данных. После сопоставления правил в базе данных в соответствии с входными данными рекомендуется соответствующий план внесения удобрений. Хотя данный метод объясняется довольно явно, однако эти правила не могут выражать некоторые неявные знания, что приводит к потере части информации. Кроме того, модели, основанные на знаниях, менее способны использовать большие объемы данных и не

позволяют автоматизированно построить модель знаний путем обобщения данных. В связи с этим получение и формализация знаний без помощи человека затруднены, что является их техническим «узким местом» [14].

В последние годы с повышением вычислительной мощности были разработаны модели на основе искусственного интеллекта. По сравнению с двумя другими методами эти модели оказались более эффективными, обеспечивая моделирование за счет ввода легкодоступной полевой информации. Однако многие интеллектуальные системы, связанные с рекомендациями по внесению удобрений, используют искусственные нейронные сети, что приводит к недостаточной прозрачности и объяснимости процесса разработки рекомендаций [15]. Для преодоления этих отрицательных черт моделирования в настоящее время развивается объяснимый искусственный интеллект. Одним из подходов последнего можно считать использование технологии графов знаний. В отличие от традиционной онтологии, граф знаний может создавать сложную семантическую информацию с тонкой детализацией и структурой. С точки зрения приложений, граф знаний представляет собой передовую технологию работы с гетерогенными и междоменными наборами данных для решения возникающих вопросов и может эффективно извлекать семантические знания [16].

Способность предвидеть развитие вредных организмов, оценить возможные риски потери урожайности и оперативно принять взвешенное решение является неотъемлемой частью интегрированной системы защиты растений. Для этих целей применяют различные подходы, в том числе машинное обучение. В частности, на материалах временных рядов длительных полевых опытов (1996–2018 гг.), проведенных в лесостепи Новосибирской области, нами выявлены признаки, определяющие степень засоренности посевов и оценен их вклад в предиктивную модель. С использованием алгоритма CART построения дерева решений разработана модель прогноза засоренности посевов и сформулированы логические правила развития сорняков

в зависимости от управляющих воздействий и агрометеоусловий, при этом коэффициент детерминации (R^2) прогнозной модели был равен 0,8 [17]. В предыдущем исследовании [18] показана возможность применения Байесовской сети доверия и мультиномиальной логистической регрессии для прогнозирования степени засоренности сельскохозяйственных земель. Прогнозные результаты обеих моделей совпали в 79% случаев.

Прогнозирование болезней растений в настоящее время осуществляют с помощью построения моделей трех видов:

- на основании данных о погоде;
- на основании обработки изображений;
- на основании различных типов данных, полученных из разных источников.

При этом используют следующие алгоритмы машинного обучения: SVM (метод опорных векторов), LDA (линейный дискриминантный анализ), QDA (квадратичный дискриминантный анализ), CCT (компактное дерево классификации), MLR (мультилинейная регрессия), KNN (к-ближайший сосед), DT (дерево решений), RF (случайный лес), MLP (многослойный персептрон), BN (Байесовская сеть), HMM (скрытая модель Маркова), ANN (искусственная нейронная сеть), CNN (сверточная нейронная сеть), BPN (нейронная сеть обратного распространения) и др. Утверждается, что применение алгоритмов машинного обучения позволяет прогнозировать начало заболевания на предсимптомной стадии или на ранней стадии заболевания [19]. Для обучения моделей идентификации болезней растений и оценки степени заболевания используют набор данных PlantVillage, который состоит из 54 309 изображений [20].

Модели прогнозирования урожайности сельскохозяйственных культур в научных исследованиях по земледелию, как уже отмечалось, должны решать задачи планирования (имитации) урожая и управляющих воздействий в камеральных условиях перед выходом в поле. Больших успехов в прогнозировании урожайности удалось достичь с помощью машинного обучения. Применяемые алгоритмы примерно такие же, как и при прогнозировании болезней растений,

с некоторыми вариациями. Входные переменные также варьируются, но в основном учитываются почвенные и погодные данные, а также управляющие воздействия. Заблаговременность прогнозов составляет 1–2 мес до уборки урожая, в некоторых работах показана возможность прогноза на начало посева. Точность прогнозов варьирует в зависимости от применяемых алгоритмов и количества признаков, включенных в модель. Коэффициент детерминации (R^2) обычно составляет 0,8–0,9.

Для прогнозирования урожайности сельскохозяйственных культур с учетом влияния различных элементов агротехники (чередование культур, приемы обработки почвы, дозы удобрений, степень защиты посевов от вредных организмов) необходимо использовать временные ряды данных длительных полевых опытов и анализировать их с помощью методов искусственного интеллекта. Например, для этой цели нами использована нейронная сеть прямого распространения (FFNN). В качестве предикторов определены качественные факторы (система основной обработки почвы, предшествующая культура, применение техногенных средств, размещение культуры в севообороте) и метеорологические показатели (среднедекадные температуры воздуха и суммы осадков), определяющие урожайность яровой пшеницы за 2001–2018 гг. в лесостепи Новосибирской области. Выполнено построение трех моделей, позволяющее осуществить прогноз урожайности культуры на будущий вегетационный период в зависимости от заданных параметров. Коэффициенты детерминации моделей (R^2) составили 0,90; 0,92 и 0,93, средняя абсолютная ошибка изменялась в пределах $0,05 \pm 0,03$ [21].

Для анализа результатов полевых опытов и прогнозирования урожайности сельскохозяйственных культур с помощью различных алгоритмов машинного обучения нами разработана программа Crop Yield Analysis & Forecast (CYAF). Входными данными для программы могут выступать результаты полевых опытов любого участка с неограниченным количеством зафиксированных факторов и

условий, значения которых могут измеряться как по качественной, так и по количественной шкалам. Комплексность использования методов анализа данных, сочетание параметрических и непараметрических подходов обеспечивают достаточно высокую точность прогнозирования урожайности культур [22].

В последнее время с целью прогнозирования урожайности сельскохозяйственных культур увеличилось количество исследований по применению данных дистанционного зондирования в виде различных вегетационных индексов (VI) в качестве дополнительных признаков. В частности, применяют следующие индексы: NDVI, EVI (улучшенный индекс растительности), NIRv (отражательная способность растительности в ближней инфракрасной области), SAVI (индекс растительности с поправкой на почву), LAI (индекс площади листьев), GAI (индекс зеленой зоны), DM (общее содержание надземного сухого вещества), NDWI (нормализованный разностный индекс влажности), LST (температура поверхности земли) и др. Эти индексы рассчитывают на основании измерений спектрального отражения, которые обнаруживаются несколькими системами передачи данных, такими как спутники, беспилотные летательные аппараты (БПЛА) и портативные устройства. В целом преимуществами спектрального дистанционного зондирования являются скорость, неразрушаемость и масштабируемость. Однако удобство использования вегетационных индексов для прогнозирования урожайности ограничено тем фактом, что большинство их калибровок действительно только для конкретных культур и периодов их роста [23].

Для прогнозирования урожайности также широко применяют БПЛА. Например, использование БПЛА и компьютерного зрения сделали возможными 3D-реконструкции для получения ортомозаичных фотоснимков и 3D-фотограмметрических облаков точек с использованием метода «структура по движению» (Structure from Motion – SfM). SfM – это метод компьютерного зрения, который включает стереоизображения с несколькими видами для сопоставления объектов, получе-

ния 3D-структуры и оценки положения и ориентации камеры. Доказано, что подход SfM позволяет оценивать структурную информацию о посевах, такую как размер кроны, высота растений и форма листьев [24]. Эти данные затем используют для моделирования аллометрической зависимости между урожайностью и накоплением биомассы в различные периоды вегетации сельскохозяйственных культур.

В рамках развития парадигмы исследований по земледелию целесообразно сформировать также понимание необходимости анализа эффективности агротехнологий сельскохозяйственных культур и агрономического менеджмента в конкретных условиях землепользования. Вопросы агрономических исследований должны эволюционировать – от учета отдельных факторов – к исследованию взаимодействия между их широким спектром. Для этих целей необходимо шире применять возможности мониторинга.

Интеграция данных мониторинга современными цифровыми технологиями природных объектов и посевов сельскохозяйственных культур с геоинформационным моделированием и искусственным интеллектом даст возможность создать автоматизированную цифровую систему управления земледелием (ЦСУЗ).

ЦСУЗ – это основанная на правилах и знаниях СППР, которая объединяет:

- технологии мониторинга *in situ* и дистанционного зондирования посевов и природных объектов;
- интеллектуальный анализ результатов мониторинга и длительных полевых опытов с применением алгоритмов машинного обучения;
- формирование архетипов систем земледелия и их масштабирование;
- моделирование пространственных объектов и классификация земель с использованием ГИС и др. [25].

Адаптация к природно-климатическим условиям и производственным ресурсам требует от специалистов на местах со временем (чаще всего ежегодно) корректировать свои технологии возделывания сельскохо-

зяйственных культур и минимизировать риски. В связи с этим для принятия оптимальных управленческих решений специалист (агроном) должен обладать высоким уровнем квалификации, чтобы грамотно и в сжатые сроки провести трудоемкие операции по сбору и анализу данных. Результат производственного процесса напрямую зависит от степени квалификации агронома, который должен владеть не только агротехнологическими знаниями, но и способностью обрабатывать разнородные потоки информации. В то же время объем агрономических знаний велик, а условия их реализации существенно разнятся. Специалисту, занятому непосредственно в производстве, трудно полностью оценить их и, следовательно, выработать приемлемую стратегию и тактику «хозяйственного поведения» в зависимости от текущей и прогнозируемой обстановки. Проектирование и реализация научно обоснованной адаптивной агротехнологии определенной культуры и сорта на конкретном поле с его геоморфологическими, почвенными, гидрологическими и другими природными особенностями является на самом деле объективно сложной задачей. В связи с этим для повышения эффективности производственной деятельности и принятия обоснованных управленческих решений целесообразно использовать цифровые технологии при выполнении каждого процесса.

Однако следует отметить, что существуют как объективные, так и субъективные проблемы с привязкой научных данных (внедрение инноваций) к процессу принятия решений, которые можно сформулировать в следующих категориях:

- наука часто возникает из теории, которая не всегда учитывает потребности тех, кто принимает решения;
- отдельные люди различаются в том, как они понимают и интерпретируют научную информацию в силу когнитивных причин, а также из-за различных интересов, целей и предшествующих знаний;
- участники принятия решений часто обладают «местными знаниями», основанными на опыте, который ставит под сомнение выводы ученых;

– научную информацию разрабатывают и представляют для оказания влияния, а не просто для информирования, поэтому участники принятия решений по понятным причинам оспаривают ее или не доверяют ей [26].

Одним из вариантов решения по увеличению доверия к научным результатам может быть использование методологии «гражданской науки» (citizen science) [27]. Суть ее заключается в том, что в исследованиях принимают участие непосредственно специалисты на местах. Считается, что сочетание формальных исследований научно-исследовательских учреждений и неформальных знаний агрономов может повысить эффективность за счет предложения более подходящих решений на местном уровне. Этого можно добиться, передавая определенные задачи на аутсорсинг участникам и конвергируя отдельные этапы исследований и адаптации. За счет такого приема появляется надежда не только получать адекватную информацию для последующего анализа, но и привлекать специалистов к широкому обсуждению результатов. Реализация подходов гражданской науки с эффектом участия может сделать разработку агротехнологий не только более эффективной, но и повысить эколого-экономическую устойчивость разработанных инноваций.

Для реализации инноваций в мировой науке в последнее время получило развитие направление по изучению различных эффектов в масштабе [28, 29]. Масштабирование становится все более популярным направлением исследований в целях устойчивого развития и является одной из важнейших задач, стоящих перед научным сообществом. Масштабирование связано с адаптацией, усвоением и использованием инноваций в более широких сообществах производителей или пространственных объектах. Этот подход обычно воспринимается как результат целенаправленных усилий, которые приводят к определенным результатам для общества, таким как поддержание доступности продовольствия, создание рабочих мест и экономический рост. В этом смысле масштабирование ассоциируется с позитивными изменениями, и высокие

целевые показатели стали индикаторами для тех, кто финансирует, внедряет и оценивает научные результаты. Растущая популярность данного направления способствовала восприятию того, что масштабирование – это то, что можно делать и к чему следует стремиться при достижении целей устойчивого развития сельского хозяйства.

Также в целях освоения инноваций по сельскому хозяйству в развитых в информационном отношении странах используют различные сетевые структуры [30]. Например, сетевые Web-платформы с участием многих заинтересованных сторон расширяют сотрудничество, осуществляют обучение, обмен знаниями и опытом, оказывают влияние на взаимодействие между сельхозпроизводителями, исследователями и другими участниками. Утверждается, что сетевые платформы повышают когнитивный потенциал инноваций и вносят вклад в их масштабирование.

ВЫВОДЫ

1. Интеллектуальное земледелие является в настоящее время основной парадигмой рационального использования земельных ресурсов, увеличения биоразнообразия, уменьшения негативного воздействия на окружающую среду, повышения продуктивности растениеводства и окупаемости невозобновляемых ресурсов. Осуществлять эту парадигму возможно с помощью интеграции современных цифровых технологий и методов искусственного интеллекта.

2. Севообороты, являясь основой внутрихозяйственной системы земледелия, должны быть гибкими и рассматриваться в альтернативных вариантах: циклическим с фиксированной длиной, циклическим с переменной длиной и менее структурированном циклическим с сильно варьируемой длиной. Формирование севооборотов можно осуществлять моделированием их продуктивности с использованием различных подходов искусственного интеллекта на основе временных рядов урожайности культур и данных дистанционного зондирования.

3. Выбор системы основной обработки почвы возможен с помощью предиктивных мо-

делей урожайности возделываемых культур и других базовых параметров ее эффективности с помощью машинного обучения, принимая обработку почвы за наиболее важный признак.

4. Управление питательными веществами в посевах сельскохозяйственных культур и разработка рекомендаций по срокам, дозам и способам внесения удобрений возможно осуществлять с помощью моделей на основе искусственного интеллекта. Синхронизацию внесения удобрений со свойствами почв, погодными условиями и возделываемыми культурами регулируют с помощью различных подходов к цифровому управлению.

5. Защиту посевов сельскохозяйственных культур от вредных организмов реализуют в системе прогнозирования их развития на основании данных о погоде, управляющих воздействиях, изображений листьев растений или других типов данных с применением алгоритмов машинного обучения.

6. Модели прогнозирования урожайности сельскохозяйственных культур в научных исследованиях по земледелию должны решать задачи планирования (имитации) урожая и управляющих воздействий в камеральных условиях перед выходом в поле. На основании результатов виртуальных моделей разрабатывают программы и планы полевых исследований с целью их валидации.

7. Выбор и сопровождение агротехнологий реализуют в системе учета взаимодействия широкого спектра условий и факторов с помощью проксимального и дистанционного зондирования (мониторинга). Интеграция данных мониторинга современными цифровыми технологиями природных объектов и посевов сельскохозяйственных культур с геоинформационным моделированием и искусственным интеллектом дает возможность создать систему поддержки принятия решений и реализовать ее в виде ЦСУЗ.

8. В целях масштабирования и адаптации инноваций целесообразно использовать возможности гражданской науки и сетевых Web-платформ.

СПИСОК ЛИТЕРАТУРЫ

1. Maffezzoli F., Ardolino M., Bacchetti A., Perna M., Renga F. Agriculture 4.0: A systematic literature review on the paradigm, technologies and benefits // *Futures*. 2022. Vol. 142. P. 102998. DOI: 10.1016/j.futures.2022.102998.
2. Karunathilake E., Le A.T., Heo S., Chung Y.S., Mansoor S. The path to smart farming: Innovations and opportunities in precision agriculture // *Agriculture*. 2023. Vol. 13. N 8. P. 1593. DOI: 10.3390/agriculture13081593.
3. Saiz-Rubio V., Rovira-Más F. From smart farming towards agriculture 5.0: A review on crop data management // *Agronomy*. 2020. Vol. 10. N 2. P. 207. DOI: 10.3390/agronomy10020207.
4. De la Parte M.S.E., Martínez-Ortega J.F., Castillejo P. Spatio-temporal semantic data management systems for IoT in agriculture 5.0: Challenges and future directions // *Internet of Things*. 2024. Vol. 25. P. 101030. DOI: 10.1016/j.iot.2023.101030.
5. Fenz S., Neubauer T., Heurix J., Friedel J.K., Wohlmuth M.-L. AI-and data-driven pre-crop values and crop rotation matrices // *European Journal of Agronomy*. 2023. Vol. 150. P. 126949. DOI: 10.1016/j.eja.2023.126949.
6. 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. DOI: 10.1016/j.atech.2022.100152.
7. Liang Z., Xubc Z., Chengabc J., Maab B., Congb W.-F., Zhang C.F., van der Werf W., Groot J.C.J. Designing diversified crop rotations to advance sustainability: A method and an application // *Sustainable Production and Consumption*. 2023. Vol. 40. P. 532–544. DOI: 10.1016/j.spc.2023.07.018.
8. Gokhale C.S., Sharma N. Optimizing crop rotations via Parrondo's paradox for sustainable agriculture // *Royal Society Open Science*. 2023. Vol. 10. N 5. P. 221401. DOI: 10.1098/rsos.221401.
9. 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. DOI: 10.1016/j.compag.2022.106686.
10. Ogieriakhi M.O., Woodward R.T. Understanding why farmers adopt soil conservation tillage: A systematic review // *Soil Security*. 2022. Vol. 9. P. 100077. DOI: 10.1016/j.soisec.2022.100077.
11. Abbaspour-Gilandeh Y., Abbaspour-Gilandeh M., Babaie H.A. Shahgoli G. Modeling agricultural soil bulk density using artificial neural network and adaptive neuro-fuzzy inference system // *Earth Science Informatics*. 2023. Vol. 16. P. 57–65. DOI: 10.1007/s12145-022-00920-6.
12. Каличкин В.К., Максимович К.Ю., Федоров Д.С., Гарафутдинова Л.В. Концептуальная модель цифрового управления азотом в посевах сельскохозяйственных культур // *Российская сельскохозяйственная наука*. 2024. № 1. С. 54–63. DOI: 10.31857/S2500262722040000.
13. Austin R., Osmond D., Shelton S. Optimum nitrogen rates for maize and wheat in North Carolina // *Agronomy Journal*. 2019. Vol. 111. N 5. P. 2558–2568. DOI: 10.2134/agronj2019.04.0286.
14. Sharma V., Tripathi A.K., Mittal H. Technological revolutions in smart farming: Current trends, challenges & future directions // *Computers and Electronics in Agriculture*. 2022. Vol. 201. P. 107217. DOI: 10.1016/j.compag.2022.107217.
15. Somwanshi K., Sonawane P.R., Nagraj P., Lohar T.S., Jadhav M.S. Crop Prediction and Fertilizer Recommendation Using Machine Learning // *International Journal of Engineering Research and Applications*. 2023. Vol. 13. N 3. P. 28–32. DOI: 10.9790/9622-13032832.
16. Ge W., Zhou J., Zheng P., Yuan L., Rottok L.T. A recommendation model of rice fertilization using knowledge graph and case-based reasoning // *Computers and Electronics in Agriculture*. 2024. Vol. 219. P. 108751. DOI: 10.1016/j.compag.2024.108751.
17. Каличкин В.К., Альсова О.К., Максимович К.Ю., Васильева Н.В. Прогнозирование засоренности посевов с использованием методов машинного обучения // *Российская сельскохозяйственная наука*. 2022. № 1. С. 88–94. DOI: 10.31857/S2500-2627202210-0.
18. Каличкин В.К., Максимович К.Ю., Шнак В.А., Галимов Р.Р., Пакуль А.Л. Применение Байесовской сети доверия и мультиномиальной логистической регрессии для прогнозирования степени засоренности сельскохозяйственных земель // *Южно-Сибирский научный вестник*. 2021. № 6 (40). С. 10–17. DOI: 10.25699/SSSB.2021.40.6.049.

19. Fenu G., Mallocci F.M. Forecasting plant and crop disease: an explorative study on current algorithms // *Big Data and Cognitive Computing*. 2021. Vol. 5. N 1. P. 2. DOI: 10.3390/bdcc5010002.
20. Ahmad A., Saraswat D., El Gamal A. A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools // *Smart Agricultural Technology*. 2023. Vol. 3. P. 100083. DOI: 10.1016/j.atech.2022.100083.
21. Максимович К.Ю., Федоров Д.С., Каличкин В.К., Васильева Н.В., Галимов Р.Р., Кузимова Т.А., Руксен В.С. Прогнозирование урожайности яровой пшеницы на основе использования нейронной сети в условиях лесостепи Приобья // *Южно-Сибирский научный вестник*. 2022. № 6. С. 333–338.
22. Каличкин В.К., Федоров Д.С., Альсова О.К., Максимович К.Ю. Разработка программы анализа и прогнозирования урожайности сельскохозяйственных культур // *Достижения науки и техники АПК*. 2022. Т. 36. № 1. С. 51–56. DOI: 10.53859/02352451_2022_36_1_51.
23. Rose M., Rose T., Kage H. Spectral reflection and crop parameters: can the disentanglement of primary and secondary traits lead to more robust and extensible prediction models? // *Precision Agriculture*. 2023. Vol. 24. P. 607–626. DOI: 10.1007/s11119-022-09961-9.
24. Song Y., Wang J., Shan B. Estimation of Winter Wheat Yield from UAV-Based Multi-Temporal Imagery Using Crop Allometric Relationship and SAFY Model // *Drones*. 2021. Vol. 5. P. 78. DOI: 10.3390/drones5030078.
25. Каличкин В.К., Максимович К.Ю. Методология формирования цифровой системы управления земледелием // *Сибирский вестник сельскохозяйственной науки*. 2024. Т. 54. № 3. С. 5–20. DOI: 10.26898/0370-8799-2024-3-1.
26. Stern P.C., Wolske K.S., Dietz T. Design principles for climate change decisions // *Current Opinion in Environmental Sustainability*. 2021. Vol. 52. P. 9–18. DOI: 10.1016/j.cosust.2021.05.002.
27. Van De Gevel J., van Etten J., Deterding S. Citizen science breathes new life into participatory agricultural research. A review // *Agronomy for Sustainable Development*. 2020. Vol. 40. N 5. P. 1–17. DOI: 10.1007/s13593-020-00636-1.
28. Schut M., Leeuwis C., Thiele G. Science of Scaling: Understanding and guiding the scaling of innovation for societal outcomes // *Agricultural Systems*. 2020. Vol. 184. P. 102908. DOI: 10.1016/j.agsy.2020.102908.
29. Woltering L., Lenero E.M.V., Boa-Alvarado M., Loon J.V., Ubels J., Leeuwis C. Supporting a systems approach to scaling for all; insights from using the Scaling Scan tool // *Agricultural Systems*. 2024. Vol. 217. P. 103927. DOI: 10.1016/j.agsy.2024.103927.
30. Van Ewijk E., Ataa-Asantewaa M., Asubonteng K.O., Van Leynseele Y.P.B., Derkyi M., Laven A., Ros-Tonen M.A.F. Farmer-Centred Multi-stakeholder Platforms: From Iterative Approach to Conceptual Embedding // *Journal of the Knowledge Economy*. 2024. DOI: 10.1007/s13132-023-01661-7.

REFERENCES

1. Maffezzoli F., Ardolino M., Bacchetti A., Perona M., Renga F. Agriculture 4.0: A systematic literature review on the paradigm, technologies and benefits. *Futures*, 2022, vol. 142, p. 102998. DOI: 10.1016/j.futures.2022.102998.
2. Karunathilake E., Le A.T., Heo S., Chung Y.S., Mansoor S. The path to smart farming: Innovations and opportunities in precision agriculture. *Agriculture*, 2023, vol. 13, no. 8, p. 1593. DOI: 10.3390/agriculture13081593.
3. Saiz-Rubio V., Rovira-Más F. From smart farming towards agriculture 5.0: A review on crop data management. *Agronomy*, 2020, vol. 10, no. 2, p. 207. DOI: 10.3390/agronomy10020207.
4. De la Parte M.S.E., Martínez-Ortega J.F., Castillejo P. Spatio-temporal semantic data management systems for IoT in agriculture 5.0: Challenges and future directions. *Internet of Things*, 2024, vol. 25, p. 101030. DOI: 10.1016/j.iot.2023.101030.
5. Fenz S., Neubauer T., Heurix J., Friedel J.K., Wohlmuth M.-L. AI-and data-driven pre-crop values and crop rotation matrices. *European Journal of Agronomy*, 2023, vol. 150, p. 126949. DOI: 10.1016/j.eja.2023.126949.
6. 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. DOI: 10.1016/j.atech.2022.100152.

7. Liang Z., Xubc Z., Chengabc J., Maab B., Congb W.-F., Zhang C.F., van der Werf W., Groot J.C.J. Designing diversified crop rotations to advance sustainability: A method and an application. *Sustainable Production and Consumption*, 2023, vol. 40, pp. 532–544. DOI: 10.1016/j.spc.2023.07.018.
8. Gokhale C.S., Sharma N. Optimizing crop rotations via Parrondo's paradox for sustainable agriculture. *Royal Society Open Science*, 2023, vol. 10, no. 5, p. 221401. DOI: 10.1098/rsos.221401.
9. 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. DOI: 10.1016/j.compag.2022.106686.
10. Ogieriakhi M.O., Woodward R.T. Understanding why farmers adopt soil conservation tillage: A systematic review. *Soil Security*, 2022, vol. 9, p. 100077. DOI: 10.1016/j.soisec.2022.100077.
11. Abbaspour-Gilandeh Y., Abbaspour-Gilandeh M., Babaie H.A. Shahgoli G. Modeling agricultural soil bulk density using artificial neural network and adaptive neuro-fuzzy inference system. *Earth Science Informatics*, 2023, vol. 16, pp. 57–65. DOI: 10.1007/s12145-022-00920-6.
12. Kalichkin V.K., Maksimovich K.Yu., Fedorov D.S., Garafutdinova L.V. Conceptual model of digital nitrogen management in agricultural crops. *Rossiyskaya sel'skohozyajstvennaya nauka = Russian Agricultural Sciences*, 2024, no. 1, pp. 54–63. (In Russian). DOI: 10.31857/S2500262722040000.
13. Austin R., Osmond D., Shelton S. Optimum nitrogen rates for maize and wheat in North Carolina. *Agronomy Journal*, 2019, vol. 111, no. 5, pp. 2558–2568. DOI: 10.2134/agronj2019.04.0286.
14. Sharma V., Tripathi A.K., Mittal H. Technological revolutions in smart farming: Current trends, challenges & future directions. *Computers and Electronics in Agriculture*, 2022, vol. 201, p. 107217. DOI: 10.1016/j.compag.2022.107217.
15. Somwanshi K., Sonawane P.R., Nagraj P., Lohar T.S., Jadhav M.S. Crop Prediction and Fertilizer Recommendation Using Machine Learning. *International Journal of Engineering Research and Applications*, 2023, vol. 13, no. 3, pp. 28–32. DOI: 10.9790/9622-13032832.
16. Ge W., Zhou J., Zheng P., Yuan L., Rottok L.T. A recommendation model of rice fertilization using knowledge graph and case-based reasoning. *Computers and Electronics in Agriculture*, 2024, vol. 219, p. 108751. DOI: 10.1016/j.compag.2024.108751.
17. Kalichkin V.K., Alsova O.K., Maksimovich K.Yu., Vasilyeva N.V. Application of machine learning to forecast the contamination of crops. *Rossiyskaya sel'skohozyajstvennaya nauka = Russian Agricultural Sciences*, 2022, no. 1, pp. 88–94. (In Russian). DOI: 10.31857/S2500-2627202210-0.
18. Kalichkin V.K., Maksimovich K.Yu., Shpak V.A., Galimov R.R., Pakul A.L. Application of the Bayesian trust network and multinomial logistic regression to predict the degree of contamination of agricultural lands. *Yuzhno-Sibirskij nauchnyj vestnik = South-Siberian Scientific Bulletin*, 2021, no. 6 (40), pp. 10–17. (In Russian). DOI: 10.25699/SSSB.2021.40.6.049.
19. Fenu G., Mallocci F.M. Forecasting plant and crop disease: an explorative study on current algorithms. *Big Data and Cognitive Computing*, 2021, vol. 5, no. 1, p. 2. DOI: 10.3390/bd-cc5010002.
20. Ahmad A., Saraswat D., El Gamal A. A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. *Smart Agricultural Technology*, 2023, vol. 3, p. 100083. DOI: 10.1016/j.atech.2022.100083.
21. Maksimovich K.Yu., Fedorov D.S., Kalichkin V.K., Vasilyeva N.V., Galimov R.R., Kizimova T.A., Riksen V.S. Forecasting the yield of spring wheat based on the use of a neural network in the conditions of the forest steppe of the Ob region. *Yuzhno-Sibirskij nauchnyj vestnik = South-Siberian Scientific Bulletin*, 2022, no. 6, pp. 333–338. (In Russian).
22. Kalichkin V.K., Fedorov D.S., Alsova O.K., Maksimovich K.Yu. Development of software for analyzing and forecasting crop yields. *Dostizheniya nauki i tekhniki APK = Achievements of Science and Technology of AIC*, 2022, vol. 36, no. 1, pp. 51–56. (In Russian). DOI: 10.53859/02352451_2022_36_1_51.
23. Rose M., Rose T., Kage H. Spectral reflection and crop parameters: can the disentanglement of primary and secondary traits lead to more robust and extensible prediction models? *Precision*

- Agriculture*, 2023, vol. 24, pp. 607–626. DOI: 10.1007/s11119-022-09961-9.
24. Song Y., Wang J., Shan B. Estimation of Winter Wheat Yield from UAV-Based Multi-Temporal Imagery Using Crop Allometric Relationship and SAFY Model. *Drones*, 2021, vol. 5, p. 78. DOI: 10.3390/drones5030078.
25. Kalichkin V.K., Maksimovich K.Yu. Methodology for forming a digital farming management system. *Sibirskij vestnik sel'skohozyajstvennoj nauki = Siberian Herald of Agricultural Science*, 2024, vol. 54, no. 3, pp. 5–20. (In Russian). DOI: 10.26898/0370-8799-2024-3-1.
26. Stern P.C., Wolske K.S., Dietz T. Design principles for climate change decisions. *Current Opinion in Environmental Sustainability*, 2021, vol. 52, pp. 9–18. DOI: 10.1016/j.cosust.2021.05.002.
27. Van De Gevel J., van Etten J., Deterding S. Citizen science breathes new life into participatory agricultural research. A review. *Agronomy for Sustainable Development*, 2020, vol. 40, no. 5, pp. 1–17. DOI: 10.1007/s13593-020-00636-1.
28. Schut M., Leeuwis C., Thiele G. Science of Scaling: Understanding and guiding the scaling of innovation for societal outcomes. *Agricultural Systems*, 2020, vol. 184, p. 102908. DOI: 10.1016/j.agsy.2020.102908.
29. Woltering L., Lenero E.M.V., Boa-Alvarado M., Loon J.V., Ubels J., Leeuwis C. Supporting a systems approach to scaling for all; insights from using the Scaling Scan tool. *Agricultural Systems*, 2024, vol. 217, p. 103927. DOI: 10.1016/j.agsy.2024.103927.
30. Van Ewijk E., Ataa-Asantewaa M., Asubonteng K.O., Van Leynseele Y.P.B., Derkyi M., Laven A., Ros-Tonen M.A.F. Farmer-Centred Multi-stakeholder Platforms: From Iterative Approach to Conceptual Embedding. *Journal of the Knowledge Economy*, 2024. DOI: 10.1007/s13132-023-01661-7.

ИНФОРМАЦИЯ ОБ АВТОРЕ

✉ **Каличкин В.К.**, доктор сельскохозяйственных наук, профессор, главный научный сотрудник; **адрес для переписки:** Россия, 630501, Новосибирская область, р.п. Краснообск, а/я 463; e-mail: vk.kalichkin@gmail.com

AUTHOR INFORMATION

✉ **Vladimir K. Kalichkin**, Doctor of Science in Agriculture, Professor, Head Researcher; **address:** PO Box 463, Krasnoobsk, Novosibirsk Region, 630501, Russia; e-mail: vk.kalichkin@gmail.com

Дата поступления статьи / Received by the editors 18.04.2024

Дата принятия к публикации / Accepted for publication 15.05.2024

Дата публикации / Published 21.10.2024