

5.2.3. РЕГИОНАЛЬНАЯ И ОТРАСЛЕВАЯ ЭКОНОМИКА
(ЭКОНОМИЧЕСКИЕ НАУКИ)

Научная статья

УДК 338.27

DOI: 10.53914/issn2071-2243_2025_1_169

EDN: MIQZOW

**Интеграция машинного обучения в систему прогнозирования
экономических параметров агропродовольственного сектора**

**Александр Алексеевич Дубовицкий¹, Эльвира Анатольевна Климентова²,
Владислав Александрович Шацкий³**

^{1, 2, 3} Мичуринский государственный аграрный университет, Мичуринск, Россия

¹ Klim1-408@yandex.ru[✉]

Аннотация. Агропродовольственный сектор (АПС) представляет собой подсистему национальной экономики, ориентированную на удовлетворение потребностей всего населения в продуктах питания, сохраняющую и поддерживающую его жизнедеятельность, а также содействующую эффективной занятости и социокультурному развитию жителей, проживающих в сельской местности. Несмотря на комплекс факторов неопределенности, негативно влияющих на функционирование агропродовольственных экономических систем (АПЭС), минимизация рисков, влияющих на функционирование экономических субъектов, создает новые возможности для повышения их конкурентоспособности и эффективности. Основой минимизации рисков выступает повышение предсказуемости изменчивости внешней среды на основе прогнозирования. Представлены результаты обоснования необходимости, возможностей и направлений интеграции машинного обучения (Machine Learning – ML) в систему прогнозирования экономических параметров АПС. Исследование было выполнено с опорой на накопленный научный и практический опыт прогнозирования экономических систем и развития ML. Систематизированы традиционные методы прогнозирования и методы ML, показано место искусственных нейронных сетей (ANN) в этой системе. Рассмотрены преимущества и недостатки использования ML для прогнозирования АПС, условия целесообразности интеграции ML в традиционную систему прогнозирования, практические аспекты использования математического алгоритма для моделирования агропродовольственных систем, а также условия совершенствования информационной инфраструктуры в целях обеспечения доступности источников данных и технологий их обработки. Оптимальный подход к совершенствованию прогнозирования видится на основе интеграции методов ML в традиционную систему, сложившуюся и применяемую экономическими субъектами в течение уже продолжительного времени. Этот подход к прогнозированию расширяет возможности участников АПЭС, позволяя оценивать риски, принимать решения, разрабатывать стратегии и более эффективно противостоять вызовам неопределенности.

Ключевые слова: агропродовольственный сектор (АПС), агропродовольственная экономическая система (АПЭС), сельское хозяйство, прогнозирование, принципы, методы, искусственный интеллект, машинное обучение, нейронные сети

Финансирование: статья подготовлена по результатам исследований, выполненных при финансовой поддержке Российского научного фонда, научный проект № 25-28-01313, <https://rscf.ru/project/25-28-01313/>.

Для цитирования: Дубовицкий А.А., Климентова Э.А., Шацкий В.А. Интеграция машинного обучения в систему прогнозирования экономических параметров агропродовольственного сектора // Вестник Воронежского государственного аграрного университета. 2025. Т. 18, № 1(84). С. 169–189. https://doi.org/10.53914/issn2071-2243_2025_1_169-189.

5.2.3. REGIONAL AND SECTORAL ECONOMICS
(ECONOMIC SCIENCES)

Original article

**Integration of machine learning into the forecasting system
of economic parameters of agrifood sector**

Aleksandr A. Dubovitskiy¹, Elvira A. Klimentova², Vladislav A. Shatskiy³

^{1, 2, 3} Michurinsk State Agrarian University, Michurinsk, Russia

¹ klim1-408@yandex.ru[✉]

Abstract. The agri-food sector (AFS) is a subsystem of the national economy focused on meeting the food needs of the entire population, preserving and supporting their livelihoods, as well as contributing to effective employment and socio-cultural development of residents living in rural areas. Despite the complex of uncertainty factors that negatively affect the functioning of agri-food economic systems (AFES), minimizing the risks affecting the functioning of economic entities creates new opportunities to increase their competitiveness and efficiency. The basis for

minimizing risks is to increase the predictability of environmental variability based on forecasting. The results of substantiation of the necessity, possibilities and directions of integration of machine learning (Machine Learning – ML) into the forecasting system of economic parameters of APS are presented. The research was carried out based on the accumulated scientific and practical experience in forecasting economic systems and ML development. Traditional forecasting methods and ML methods are systematized, and the place of artificial neural networks (ANN) in this system is shown. The advantages and disadvantages of using ML for agri-food economic systems forecasting, the conditions for the feasibility of integrating ML into a traditional forecasting system, the practical aspects of using a mathematical algorithm for modeling agri-food systems, as well as the conditions for improving the information infrastructure in order to ensure the availability of data sources and processing technologies are considered. The optimal approach to improving forecasting is seen based on the integration of ML methods into the traditional system that has developed and has been used by economic entities for a long time. This approach to forecasting expands the capabilities of participants in agri-food economic systems, allowing them to assess risks, make decisions, develop strategies and more effectively face the challenges of uncertainty.

Key words: agrifood system, agriculture, forecasting, principles, methods, artificial intelligence, machine learning, neural networks

Funding: the article was prepared based on the results of research supported by the Russian Science Foundation, Project No. 25-28-01313, <https://rscf.ru/project/25-28-01313/>.

For citation: Dubovitskiy A.A., Klimentova E.A., Shatskiy V.A. Integration of machine learning into the forecasting system of economic parameters of the agrifood sector. *Vestnik Voronezhskogo gosudarstvennogo agrarnogo universiteta* = *Vestnik of Voronezh State Agrarian University*. 2025;18(1):169-189. (In Russ.). https://doi.org/10.53914/issn2071-2243_2025_1_169-189.

Агропродовольственный сектор представляет собой подсистему национальной экономики, ориентированную на удовлетворение потребностей всего населения в продуктах питания, сохраняя и поддерживая его жизнедеятельность, при этом содействует эффективной занятости и социокультурному развитию жителей, проживающих в сельской местности. Агропродовольственный сектор функционирует как социально-экономическая система, интегрированная в общую территориальную структуру [14], ответственную за общегосударственную продовольственную безопасность [7]. По данным Продовольственной и сельскохозяйственной организации ООН, агропродовольственные системы являются основой экономики многих стран, обеспечивая доходы более чем одного миллиарда человек и производя около 11 млрд т продовольствия ежегодно [29].

В современных условиях агропродовольственные системы подвержены многим рискам – климатическим [45], экологическим [4, 6, 25], социально-экономическим [13, 41], рискам технологическим условий [38, 39], а также геополитических процессов [55], будь то постепенные или резкие изменения, которые вызывают проблемы, негативно влияющие на функционирование экономических субъектов, снижая эффективность их деятельности [51].

Несмотря на целый комплекс факторов неопределенности, негативно влияющих на функционирование агропродовольственных систем, следует отметить, что минимизация рисков экономическими субъектами создает новые возможности для повышения конкурентоспособности и эффективности [46]. Основой минимизации рисков выступает повышение степени предсказуемости изменчивости внешней среды на основе прогнозирования агропродовольственных экономических систем.

Прогнозирование факторов, влияющих на параметры функционирования экономических субъектов на рынке сельскохозяйственных и продовольственных товаров, имеет решающее значение как для обеспечения устойчивости агропродовольственной системы в целом, так и эффективности функционирования ее отдельных элементов, включая предприятия, организации и отрасли. Однако это непростая задача, поскольку решение проблемы предсказуемости подразумевает необходимость анализа больших и очень изменчивых временных рядов, на которые сильно влияют сопутствующие условия.

В настоящее время в области прогнозирования существует множество методов, подходов и алгоритмов. Традиционно исследования по прогнозированию экономических параметров функционирования агропродовольственного сектора в значительной степени опираются на интуитивные и формализованные методы, совокупность которых составляет инструментальную базу методологии прогнозирования.

Интуитивные методы берутся за основу при попытках решения сложно прогнозируемых задач, в ситуациях, когда необходим субъективный взгляд эксперта или экспертов на возможные траектории экономического развития. Они представляют собой своеобразное научное развитие формы предвидения, которое строилось на житейском опыте и исторически использовалось для получения предсказания. Современные интуитивные методы представляют собой совокупность инструментария индивидуального и коллективного прогнозирования с применением оценок, основанных на профессиональном опыте и квалификации участников процесса (интервью, метод сценариев, метод Дельфи, мозговой штурм и др.). Несмотря на кажущуюся простоту их применения, они, как правило, требуют больших знаний в предметной области для работы, чем подходы с формализацией данных.

В отличие от интуитивных, формализованные методы основаны на более четком математическом выражении прогноза и предоставляют более полную и точную информацию, помогая лицам, принимающим решения, лучше понимать вероятность и диапазон колебаний оцениваемых параметров, тем самым способствуя адаптации к рискам внешней среды. В современных исследованиях и практике используются различные формализованные методы, которые при определенном допущении базового инструментария можно разграничить на методы экстраполяции и моделирования.

Посредством методов экстраполяции, на основе анализа одномерных временных рядов и математических функций решаются задачи прогнозирования различных процессов, когда тенденции их развития сохраняются в долгосрочной перспективе, и существует возможность их проецирования на будущие результаты. Эти методы привлекают широкое внимание своей простотой и отработанным алгоритмом, используемым уже длительное время в прогнозировании, описывают динамику оцениваемых параметров (цена, спрос, совокупное предложение и др.), однако их возможности ограничены в случаях поиска взаимосвязей между параметрами.

Более сложными в практике использования являются методы прогнозирования, основанные на моделировании различных элементов социально-экономических систем, процессов и явлений, выраженных многомерными временными рядами.

Экстраполяционные методы, являясь одними из самых распространенных и наиболее разработанных среди всей совокупности методов прогнозирования, основаны на одномерных временных рядах и требуют значительно большего объема информации для построения, что делает их более сложными для применения на практике. Эти методы используются при попытках описания причинно-следственной связи между ключевыми движущими факторами агропродовольственных систем с помощью математических функций. В общем виде они реализуются посредством статистико-экономического (корреляционно-регрессионные модели, авторегрессия интегрированного скользящего среднего (ARIMA) и др.) и экономико-математического (методы оптимизации, системно-динамического прогнозирования и т. п.) моделирования.

Факторы, влияющие на параметры функционирования экономических субъектов, имеют сложные корреляционные связи, которые меняются со временем. Наиболее простой способ их идентификации состоит в решении однофакторной регрессионной задачи поиска функции для прогнозирования будущих значений из наблюдаемой части временного ряда. Это позволяет рассматривать стандартную задачу прогнозирования обычно как локальный подход по причине того, что не учитываются структурные закономерности между несколькими факторами в системе. Многофакторные регрессионные модели устраняют этот недостаток и позволяют получить более развернутое и определенно более точное представление о влиянии среды на изучаемые параметры системы.

Оценить корреляцию во временных рядах позволяет модель ARIMA, которая расширяет стандартную регрессионную модель, интегрируя ее с оценкой скользящей

средней. Она направлена на сглаживание данных путем дифференциации временного ряда и удаления нетипичных значений, что помогает отфильтровывать определенное влияние колеблемости. Эти характеристики способствуют более достоверному описанию корреляции во временных рядах и минимизации влияния фактора волатильности, что обеспечивает определенные преимущества в процессе анализа уникальных закономерностей. Однако она, как правило, при прогнозировании сложных взаимосвязанных систем генерирует результат с определенной погрешностью [53].

Наиболее сложной с точки зрения применимости для прогнозирования является группа методов экономико-математического моделирования, включая линейное программирование, подход лямбда-итерации, нелинейное программирование, метод Лагранжа и градиентный метод. В сельском хозяйстве широкое распространение получило экономико-математическое моделирование посевных площадей, кормовых рационов и производственной структуры [11, 12]. Эти алгоритмы исследуют множество альтернатив для поиска подходящих ответов для конкретных задач оптимизации. Они хорошо подходят для дифференцируемых математических задач и применимы с небольшими вычислительными затратами и определенными навыками программирования. При этом они требуют значительного объема информации для построения, что делает их относительно более сложными для использования на практике.

Несмотря на большой накопленный опыт и относительную простоту применения традиционных формализованных методов прогнозирования, высокую интерпретируемость моделей, построенных на их основе, и обеспечение понимания причинно-следственной связи между исходными данными и результатом прогнозирования, они имеют несколько существенных недостатков.

Во-первых, несмотря на то, что рассмотренные формализованные методы, традиционно используемые в прогнозировании, построены на различной математической базе и отличаются целями, характером и условиями применения, все они имеют одно общее важное свойство: линейный характер распределения данных в процессе прогнозирования, представляемых многомерным или одномерным векторным пространством. Однако макроэкономические параметры сложных экономических систем в большинстве своем имеют крайне нелинейный характер [35], что ограничивает возможности обеспечения необходимого уровня точности прогнозирования в рамках подобных подходов.

Во-вторых, в условиях высокой изменчивости процессов внешней среды, формирующих риски и вызывающих проблемы функционирования экономических субъектов, большинство традиционных методов перестает обеспечивать желаемый уровень надежности. Так, если в процессе экстраполяции выявлена тенденция повышения урожайности какой-либо сельскохозяйственной культуры с достаточно высокой степенью достоверности, эта тенденция переносится на прогнозируемый временной интервал, игнорируя возможные риски ее колеблемости. Современная ситуация такова, что анализ прежних тенденций и сложившихся закономерностей развития уже не может быть принят за основу прогнозирования их будущих параметров.

Высокая скорость и непредсказуемость происходящих изменений в агропродовольственных системах и особенно во внешней по отношению к ним среде требует совершенствования методологии прогнозирования посредством включения в нее таких подходов, которые могли бы организовать процесс с большим уровнем точности и достоверности с учетом влияния всего спектра возможных предикторов.

Одним из таких подходов может выступить машинное обучение (Machine Learning – ML), которое в последние годы эффективно используется в различных областях и сферах деятельности, от медицины до индустрии развлечений. В аграрном секторе это картирование полей, оценка загрязненности сорными растениями и болезнями, прогнозирование урожайности; на агропродовольственных и фондовых рынках – оценка инфляции, выявление колебаний котировок акций и решение многих других задач.

Машинное обучение – это область исследований искусственного интеллекта, которая позволяет машинам учиться и совершенствоваться на основе больших наборов данных (Big Data – BD) без явного программирования. Оно включает в себя создание алгоритмов, которые могут анализировать закономерности их распределения и генерировать модели для конкретных задач, что позволяет успешно прогнозировать широкий спектр нелинейных процессов с заданным уровнем точности.

Основная цель ML состоит в том, чтобы представить реальность, используя математическую функцию, которую алгоритм не знает заранее, но которую он может определить после просмотра исходной информации. Одно из преимуществ ML состоит в том, что в процессе обработки BD происходит автоматический выбор самых важных признаков для получения наиболее достоверного результата. В итоге формируется функция, позволяющая представить будущие параметры экономических систем на основе входных значений.

Эти алгоритмы, анализируя множество альтернатив, формируют матрицу синоптических связей, которая медленно меняется в процессе ML для поиска подходящих ответов на конкретные задачи прогнозирования. Базовый принцип ML заключается не в изучении уровней событий (абстракции), а в повышении качества обработки BD, в результате чего становится возможным понимание поведения сложных экономических систем на основе анализа совокупности BD.

Существует множество подходов к классификации методов ML. На наш взгляд, наиболее полно классифицировать состав этих методов позволяет градация в зависимости от способов обучения и принципов работы алгоритма.

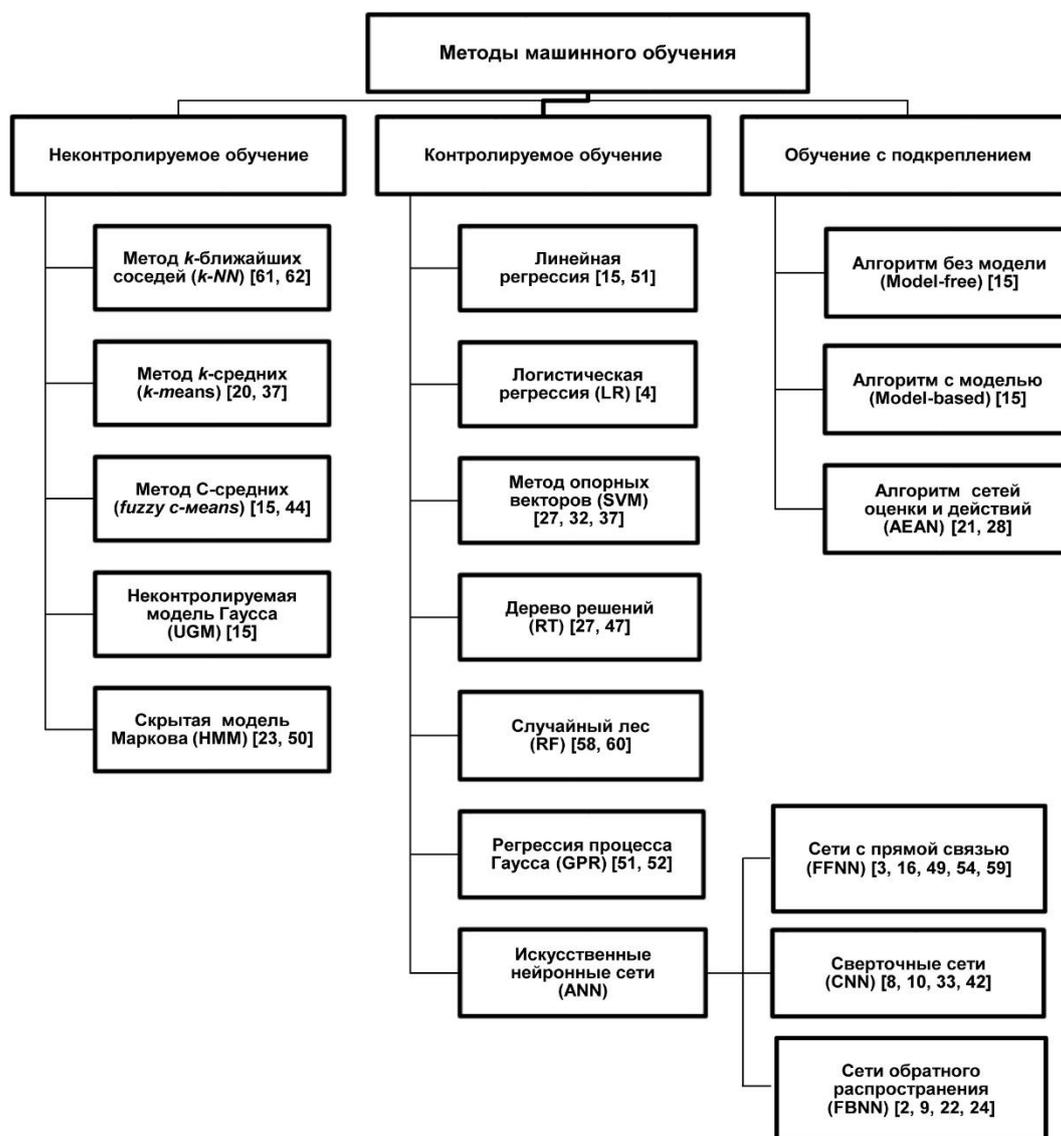
Способы ML формируются в зависимости от степени участия человека, поэтому принято выделять контролируемое, неконтролируемое обучение, а также обучение с подкреплением. В методах контролируемого машинного обучения анализ информации выполняется в процессе решения в основном двух типов задач: классификации и регрессии. При классификации совокупность BD разделяется на группы, в то время как регрессия предсказывает выходные значения путем нахождения связи между исходными параметрами. Неконтролируемое обучение преимущественно основано на решении задач кластеризации, снижения размерности и поиска ассоциаций.

Контролируемое обучение является наиболее часто используемым подходом ML, названным так из-за требования обеспечения четкого контроля процесса получения результатов человеком. Оно используется в качестве прогностического механизма, при котором часть BD, называемых входными, обрабатывается, а оставшаяся часть используется для определения точности и эффективности прогнозирования (выходные или контрольные данные). В процессе обучения совокупность входных значений сопоставляется с соответствующими выходными – алгоритм ML изучает массив представленной информации для поиска подходящего соответствия между ними [15]. После обучения контролируемый алгоритм способен прогнозировать требуемые параметры для изменяющихся условий внешней среды. Основная цель контролируемого алгоритма обучения состоит в том, чтобы предсказать правильный результат, связанный с заданными входными значениями при отсутствии видимой причинно-следственной связи между ними.

Неконтролируемое обучение предназначено для распознавания желаемых параметров из доступного набора информации без какого-либо вмешательства или контроля со стороны человека. Основное его отличие от контролируемого обучения состоит в том, что оно не использует контрольные значения для поиска скрытых закономерностей, что делает этот способ сравнительно более сложным с точки зрения реализации. Целью неконтролируемого обучения является создание модели, которая учитывает структурные и распределительные особенности информации для получения наиболее полной картины. Вместо использования метода обратной связи он основан на идентификации общих признаков с учетом наличия определенного сходства. Неконтролируемое обучение в основном представляет собой решение задач кластеризации, обнаружения аномалий или снижения размерности [20, 37, 50, 61].

Обучение с подкреплением – еще один важный способ ML, направленный на то, чтобы сформировать оптимальное поведение (реакцию) в изменяющихся условиях внешней среды. Вместо использования маркированных или немаркированных данных, оно обучается, взаимодействуя с окружающей средой через механизм проб и ошибок с целью максимизации ожидаемых вознаграждений [15]. Оно направлено на выработку решений или действий, в отличие от чистого моделирования или классификации предыдущих способов. В этом сценарии машина выступает как агент, а окружение – как ее среда. Машина использует принцип поощрения решений, связанных с ее деятельностью, чтобы выяснить, как действовать в процессе функционирования, чтобы максимизировать свои будущие вознаграждения. Обучение с подкреплением потенциально открывает возможности для глубокого обучения без участия человека благодаря обратной связи из подключенной среды. Этот способ обучения широко применяется в сферах деятельности, требующих оперативного принятия решений [21, 27].

Принципы работы ML закладывают различные алгоритмы, разработанные и адаптированные для этих целей. Алгоритмы неконтролируемого обучения не требуют маркированных данных. Основными из них являются методы кластеризации, неконтролируемая модель Гаусса и скрытая модель Маркова (см. рис.).



Классификация методов машинного обучения

Источник: составлено авторами по результатам проведенного исследования.

Алгоритм k -ближайших соседей (англ. *k-Nearest Neighbors* – *k-NN*) заключается в кластеризации совокупности данных в соответствии с их расстоянием от некоторого случайного числа k обучающих образцов [62]. Этот принцип работы алгоритма обычно называют «базовым», поскольку он не использует никаких параметров для обучения. Модель предполагает, что расстояние между точками достаточно для того, чтобы сделать вывод, не вдаваясь в характер их распределения. Решающее значение для алгоритма имеет оптимальный выбор значения k . Использование этого метода может быть затруднено в больших совокупностях, когда различия между точками уменьшаются, что может вызвать погрешность в измерении расстояния и затруднить кластеризацию. Метод *k-NN* часто используется в задачах распознавания образов, которые находят применение в социологии и экономике, при анализе социальных сетей и потребителей [61].

Метод кластеризации k -средних (англ. *k-means*) – это простой классический метод неконтролируемой кластеризации, который используется во многих приложениях из-за его простой архитектуры. Метод *k-means* не требует большой вычислительной мощности и имеет ясный рабочий принцип, что делает его доступным в реализации. Основным параметром алгоритма *k-means* является количество кластеров, на которые должны быть классифицированы точки ВД, где средние значения изучаются итеративно до тех пор, пока не будет достигнуто желаемое количество групп [44]. Несмотря на преимущества алгоритма *k-means*, его недостатком является то, что не всегда удается выявить подходящее количество кластеров. Кроме того, *k-means* очень чувствителен к масштабу точек обучающих параметров [15]. Применяется данный алгоритм при районировании территорий [37], анализе поведения потребителей и спроса [20].

Метод нечеткой кластеризации C -средних (англ. *fuzzy clustering*, *soft k-means*, *c-means*, *FCM*) является еще одним методом, который в отличие от k -средних может классифицировать принадлежность одной точки совокупности более чем одному кластеру, используя так называемую «функцию принадлежности» [44]. Основными параметрами алгоритма *FCM* являются количество кластеров, показатель нечеткости и толерантность к завершению. Как и предыдущий алгоритм, данный метод широко используется в различных приложениях из-за простоты реализации и приемлемой производительности. Однако он ограничен в применении для кластеризации совокупностей ВД сложных явлений с высоким уровнем нелинейности [15].

Неконтролируемая модель Гаусса (*Unsupervised Gaussian Model* – *UGM*) является еще одним часто используемым методом ML, который эффективно решает задачи кластеризации массивов ВД. Каждому кластеру присваивается гауссово распределение, и данный алгоритм позволяет провести распределение единиц совокупности по группам. *UGM* наиболее предпочтителен для неконтролируемых приложений, которые формируют классы с «размытыми» границами [15].

Скрытая модель Маркова (*Hidden Markov model* – *HMM*) – это алгоритм, который обеспечивает моделирование последовательных процессов принятия решений, где результаты частично случайны и частично находятся под контролем лица, принимающего решения. Он представляет собой модель, использующую процесс Маркова для вывода скрытых состояний из последовательности наблюдений в дискретном времени. В целом это эффективный инструмент для моделирования статистических свойств совокупности наблюдений, коррелирующих с ненаблюдаемой переменной состояния, где переходы между этими состояниями происходят с определенной вероятностью [23]. Его целью является стратегия принятия решений, которая максимизирует функцию совокупных эффектов. *HMM* широко используются в различных приложениях, таких как распознавание речи, финансы, прогнозировании рабочих процессов [50].

Обучение с подкреплением реализуется посредством алгоритмов на основе модели (Model-based) и без модели (Model-free). В первом случае используется заранее подготовленная модель для уменьшения рисков достижения желаемых результатов. В этом заключается главное преимущество этого метода. Кроме того, предварительное моделирование требует меньше вычислительных усилий во время непосредственного использования алгоритма. Однако при этом разработка самой модели требует более высоких вычислительных усилий и большего объема памяти по сравнению с обучением без модели [15].

Алгоритм без модели (Model-free) обучается по мере взаимодействия с окружающей средой и наблюдения за ней. Он не требует предварительно построенной и обученной модели. Поэтому model-free алгоритм требует меньше памяти и меньше вычислительных усилий, но ее реализация связана с определенными рисками обеспечения точности, вызванными несоответствием модели внешним условиям, особенно на начальном этапе обучения. Эта особенность model-free алгоритмов делает их перспективными для приложений, которым требуется адаптация посредством непрерывного обучения [15].

Алгоритм обучения сетей оценки и действий включает в себя модуль оценки действий и модуль выбора действий, информация с которых поступает в модификатор (контроллер), который обеспечивает выполнение наиболее эффективных действий на основе проведенной оценки внешней среды. Алгоритмы с подкреплением широко используются для оптимизации управления системами, требующими принятия оперативных решений [21, 27].

Основными алгоритмами контролируемого обучения являются линейная регрессия, нелинейная (логистическая) регрессия, метод опорных векторов, дерево решений, случайный лес, регрессия гауссовского процесса и искусственные нейронные сети.

Линейная регрессия (Linear regression – LR) – это контролируемый алгоритм ML, который определяет связь между зависимой переменной и одной или несколькими независимыми переменными для прогнозирования требуемого результата. Алгоритм анализирует данные с использованием линейной модели и строит линию или поверхность, которая наилучшим образом соответствует имеющимся данным [15]. Используя полученные результаты, можно предсказать будущие значения зависимой переменной на основе значений независимых переменных. Недостатком метода является ограниченность применимости к процессам с нелинейной комбинацией признаков. В исследовании агропродовольственных систем данный подход использовался при прогнозировании производства продукции [51].

Логистическая регрессия (Logistic Regression – LR) – один из важнейших алгоритмов ML для решения задач классификации, который также может использоваться в качестве аппроксиматора данных в искусственных нейронных сетях при оценке соответствия определенному критерию. LR применяется для отнесения наблюдения к одному из двух классов, например «положительное влияние фактора» и «негативное влияние фактора», или к одному из нескольких классов. LR состоит из двух этапов: обучение системы с использованием стохастического градиентного спуска и тестирование системы посредством представления входных данных в соответствие с обозначенными признаками. Главным преимуществом данного алгоритма является его небинарный и нелинейный характер [4]. Используя полученные результаты, можно предсказать класс нового входного наблюдения на основе значений независимых переменных. Применимость метода апробирована при прогнозировании устойчивости землепользования [4].

Метод опорных векторов (Support-vector machine – SVM) представляет собой тип контролируемого ML на основе последовательной числовой оптимизации для обработки ВД и решения задач классификации, способный моделировать сложные и не-

линейные процессы. Основная идея SVM заключается в трансформации входных значений в некоторое многомерное пространство, где они могут быть объединены в гиперплоскость (границу принятия решений), которая позволяет классифицировать объекты [27]. Этот алгоритм достаточно эффективен для обнаружения сложных и нелинейных зависимостей. SVM находит применение в агропродовольственном секторе при классификации болезней сельскохозяйственных культур [37], планирования производственных процессов в различных климатических условиях [32] и др.

Еще один тип модели ML для прогнозирования – дерево решений (Regression Tree – RT), относящийся к классу контролируемого обучения, способного решать задачи классификации и регрессии. Деревья решений строятся в виде иерархических структур, где каждый узел представляет собой вопрос о значении определенной переменной [27]. Ответы на эти вопросы определяют, по какому пути следовать по дереву для получения прогноза. Дерево решений является простой моделью со структурой алгоритма визуализации и может эффективно обучать относительно небольшие совокупности данных. Этот тип модели особенно полезен при работе факторами, подверженными влиянию внешних элементов. Дерево решений имеет многочисленные применения при измерении и прогнозировании различных производственных параметров [47].

Случайный лес (Random Forests – RF) – это ансамблевый алгоритм обучения для обнаружения связей внутри набора данных, который используется для классификации переменных и регрессии в задачах анализа и прогнозирования. В основе метода лежит алгоритм разделения совокупности BD на узлы, содержащих схожие элементы. Агрегация данных производится в зависимости от важных значений прогнозируемых переменных, на основе которых определяются точки разделения [36]. Подобные модели позволяют агрегировать результаты прогнозирования от отдельных классификаторов для получения итоговых параметров. ML с использованием случайного леса используется для решения многих важных агропродовольственных задач, включая идентификацию сорных растений [60] и прогнозирование урожайности [58].

Регрессия гауссовского процесса (Gaussian Process Regression – GPR) – это алгоритм контролируемого обучения, основанный на оценке регрессии набора BD, представленных в виде процесса Гаусса. GPR прогнозирует распределение анализируемых значений по тестовыми точками путем вычисления требуемых значений с учётом обучающих данных. В отличие от других методов ML, он позволяет получить точные значения для каждого параметра. Выбирая спецификации среднего и ковариации, можно включить априорные знания о пространственных функциях во время построения модели [52]. Алгоритм формализован для решения задач регрессии и вероятностной классификации, включая прогнозирование производственных показателей и логистических систем [51].

Наиболее перспективными методами МО являются искусственные нейронные сети (Artificial Neural Networks – ANN), которые представляет собой вычислительную систему, схожую по своей структуре с биологической нейронной сетью. Базовой единицей нейронной сети является искусственный нейрон, представляющий собой пороговую систему, которая получает входные сигналы, суммирует их и, если эта сумма превышает некий порог, генерирует выходной сигнал. Нейроны объединяются в слои: входной, скрытый и выходной. Нейроны входного слоя играют роль передачи данных. После активации нейронов скрытого слоя выходные данные из него перетекают в выходной слой согласно соответствующему весу, а нейроны выходного слоя генерируют конечное выходное значение в соответствии с функцией активации. Обучение моделей происходит за счет одного или нескольких скрытых слоев сети, поэтому данный алгоритм часто еще называют глубоким обучением.

В зависимости от того, как данные передаются от входного слоя к выходному, существует несколько основных видов ANN. Классический алгоритм нейронной сети основан на прямой связи – данные обрабатываются в одном направлении, от входного к выходному слою. Это нейронные сети с прямой связью (Feedforward Neural Network – FFNN), отдельные модули которой могут быть собраны в различных взаимосвязанных конфигурациях. Примерами FFNN являются однослойный перцептрон (Single-Layer Perceptron – SLP) и многослойный перцептрон (Multilayer Perceptron – MLP), сети радиальных базисных функций (Radial Basis Functions – RBF). FFNN применяются для решения задач классификации и управления динамическими системами [59].

Одними из наиболее распространенных являются сверточные нейронные сети (Convolutional Neural Networks – CNN). CNN основаны на реализации функций суммирования и фильтрации, называемых свертками. CNN имеет несколько уровней, через которые преобразуется визуально-пространственное представление изображения в семантическое [42]. Данный вид ANN чаще всего используется для решения задач классификации изображений и звука, показывая высокие результаты в обработке изображений и речевых приложениях.

Перспективной для прогнозирования технологией являются искусственные нейронные сети с алгоритмом обратного распространения (Feed-Backward Neural Network – FBNN), основанные не только на передаче информации на следующий слой, но и возможности возврата на предыдущие модули и слои, что позволяет повторно использовать вычислительные ресурсы сети для компенсации каждой ошибки, обнаруженной во время обучения. В результате FBNN могут выполнять более сложные вычисления в сравнении с FFNN [2].

Одним из видов FBNN являются рекуррентные нейронные сети (Recurrent Neural Network – RNN). В RNN информационные сигналы имеют возможность распространяться циклически, как в биологических системах. Это способствует сохранению информации при перемещении ее между слоями сети, что позволяет решать широкий круг задач, связанных с машинным обучением [2]. Примерами RNN являются сети с долговременной и кратковременной памятью (Long Short-Term Memory – LSTM) и на основе управляемых рекуррентных блоков (Gated Recurrent Units – GRU).

Областью применения и экспериментирования ANN в большинстве случаев становится прогнозирование урожайности, инфляции, цен и доходов, анализ состояния земель (см. табл.).

В целом применение ML на основе ANN в прогнозировании параметров агропродовольственных систем преимущественно основано на реализации контролируемого обучения. В некоторых случаях, связанных с принятием решений, архитектура ANN строится с подключением модулей обучения с подкреплением, хотя также имеется опыт реализации неконтролируемого обучения для решения задач кластеризации, связанных с прогнозированием урожайности.

Преимуществом ML на основе ANN является способность к абстракции признаков и обнаружению очень сложных взаимодействий между ними, что приводит к максимальной производительности во многих приложениях. В отличие от ANN многие другие распространенные модели ML, такие как методы на основе деревьев или машины опорных векторов, являются достаточно поверхностными с точки зрения ограниченной способности к абстракции признаков, и более того, некоторые из них (линейная регрессия, метод опорных векторов) предназначены для анализа линейных зависимостей.

ЭКОНОМИЧЕСКИЕ НАУКИ

Технологии и области применения ML на основе ANN в прогнозировании параметров агропродовольственных систем

Авторы, год исследований	Технология ANN	Область применения	Способ ML
Kuschewski J.G., Žak S.H., Hui S., 1993 г. [43]	FFNN	Идентификация параметров и управление динамическими системами	Контролируемое
Šťastný J., Konečný V., Trenz O., 2011 г. [54]	MLP	Прогнозирование урожайности сельскохозяйственных культур	Контролируемое
Sabri I., Bahia H., 2013 г. [49]	FFNN с алгоритмом обратного распространения (BPA)	Прогнозирование доходов	Контролируемое
Gupta S., Kashyap S., 2015 г. [31]	RNN	Прогнозирование инфляции	Контролируемое
Göçken M., Özçalıcı M., Boru A., Dosdoğru A.T., 2016 г. [30]	ANN с механизмом оптимизации поиска адаптивной информации GA	Прогнозирование котировок акций на фондовом рынке	Контролируемое
Ansari A., Riasi A., 2016 г. [16]	LR + MLP	Маркетинговое исследование и моделирование лояльности клиентов	Контролируемое
Deng Y., Bao F., Kong Y., et al., 2017 г. [21]	RNN с модулем обучения с подкреплением RL	Принятие решений на товарном и фьючерсном рынках	Контролируемое + обучение с подкреплением
Pandey A., Mishra A., 2017 г. [48]	Обобщенно-регрессионная (GRNN) с радиальными базисными функциями (RBFNN)	Прогнозирование урожайности	Контролируемое
Elavarasan D. Vincent P.M.D., 2020 г. [28]	RNN с модулем обучения Q-Learning	Прогнозирование урожайности	Контролируемое + обучение с подкреплением
Hasan A.M., Sohel F., Diepeveen D. et al., 2021 г. [33]	CNN	Обнаружение сорняков на снимках сельскохозяйственных культур	Контролируемое
Рогачев А.Ф., Белоусов И.С., 2022 г. [8]	CNN	Выявление проблемных участков состояния посевов	Контролируемое
Семкин А.Г., Воронин Е.А., 2022 г. [9]	RNN	Идентификация развития и функционирования сельскохозяйственных макрорегионов	Контролируемое
Бисчоков Р.М., 2022 г. [1]	MLP, RBFNN, GRNN	Прогноз урожайности сельскохозяйственных культур	Контролируемое
Dubovitski A., Klimentova E., Rogov M., 2022 г. [24]	LSTM + GRU	Прогнозирование цен на агропродовольственном рынке	Контролируемое
Domingo L., Grande M., Borondo F., Borondo J., 2023 г. [22]	RNN с оценкой «эхосостояния» RC	Прогнозирование кризисов цен на продовольствие с помощью резервуарных вычислений	Контролируемое
Скворцов Е.А., Ялунина Е.Н., Гусев А.С., 2023 г. [10]	CNN с системой нечеткого вывода ANFIS	Анализ финансово-экономических показателей развития сельского хозяйства	Контролируемое
Грачев А.В., 2023 г. [3]	MLP	Прогнозирование состояния работы объектов предприятий АПК	Контролируемое
Zhang W., Wu J., Wang S., Zhang Y., 2025 г. [62]	Гиперграфовая ANN	Выявление влияния колебаний цен на нефть на цены сельскохозяйственных фьючерсов	Контролируемое

Источник: составлено авторами по результатам проведенного исследования.

Следует отметить, что проведенная классификация подходов к реализации ML характеризуются определенной условностью, поскольку могут возникнуть споры о применимости отдельных алгоритмов в рамках рассмотренных способов. Многие алгоритмы меняются с течением времени, разрабатываются новые, а также обосновываются гибридные подходы на основе объединения уже существующих.

Например, ANN в основном известны своими возможностями контролируемого обучения, но они также могут быть использованы для приложений неконтролируемого обучения. Причем их использование для этих целей обеспечивает более производительный инструмент решения задач кластеризации по сравнению с традиционными методами, но требует более сложного алгоритма. Сигмовидная функция, которая формирует возможности обучения сети с использованием градиентного спуска, задает ключевой алгоритм пороговой системы активации нейрона в ANN. В то же время данный подход может использоваться как отдельный метод ML для решения задач классификации на основе логистической регрессии. Кроме того, как и ANN, для неконтролируемых приложений также можно использовать метод SVM. Благодаря своим вычислительным возможностям классификации SVM подходят для кластеров со сложными нелинейными границами.

Разнообразие методов прогнозирования, с одной стороны, затрудняет их выбор, с другой – обеспечивает возможность формирования рациональной структуры их использования в зависимости от поставленных целей и условий прогнозирования.

Преимущества использования формализованных методов, лежащих в основе традиционных систем прогнозирования, базируются на большом накопленном опыте применения и состоят в высокой интерпретируемости моделей, понимании причинно-следственных связей между исходными данными и результатом прогнозирования, высокой контролируемости самого процесса, относительно низкой потребности в вычислительных ресурсах и материально-денежных затратах.

Обратную сторону отмеченных преимуществ формируют недостатки традиционных методов прогнозирования в сравнении с методами машинного обучения. Среди них следует отметить определенно более низкую достоверность и точность прогнозов, возможность интерпретации только процессов, характеризующихся линейным распределением данных, отличающихся низкой изменчивостью и отсутствием факторов экономической и геополитической неопределенности.

Главным положительным аспектом ML является возможность анализировать большой объем данных за меньшее время и с большей точностью. Безусловным преимуществом является способность к моделированию как линейных, так и нелинейных процессов в условиях высокой экономической неопределенности и ограниченной доступности данных, а также возможность анализа крупномасштабных систем.

ML является гибким инструментом управления агропродовольственными системами, прежде всего с точки зрения повышения их предсказуемости на основе более точного прогнозирования. Оптимальный подход к прогнозированию параметров агропродовольственных систем видится на основе интеграции методов ML в традиционную систему, сложившуюся и функционирующую в экономических субъектах в течение уже продолжительного времени.

В процессе организации прогностической деятельности одновременно могут использоваться как традиционные методы, так и методы на основе машинного обучения. Одним из важных элементов в процессе функционирования системы прогнозирования является выбор модели, которая наилучшим образом справится с поставленной задачей в соответствии с принципами исследований социально-экономических систем и реализации процесса прогнозирования, в т. ч. достоверности, точности, определенности, экономической целесообразности и др. [5].

Процесс сравнения и выбора технологии прогнозирования может быть построен на оценке моделей с технической и экономической точек зрения. При оценке технической составляющей могут использоваться различные метрики оценки производительности при решении поставленных задач. Для задач классификации основными из них являются:

- чувствительность (доля истинно положительных результатов) – отражает долю положительных результатов, которые правильно идентифицированы как таковые;
- специфичность (доля истинно отрицательных результатов) – характеризует долю отрицательных результатов, которые правильно идентифицированы как таковые;
- точность – наиболее распространенная метрика, которая показывает, насколько точно модель предсказывает правильный результат на тестовых данных, определяется как отношение чувствительности к специфичности;
- ROC-кривая – метрика, позволяющая оценить производительность модели при различных порогах путем сопоставления ложно положительных и истинно положительных оценок прогноза.

Для задач регрессии:

- дисперсия (коэффициент детерминации) – измеряет долю изменчивости в прогнозах, объясненную набором данных – чем она выше, тем лучше;
- стандартная ошибка – показывает степень отклонения значений, полученных с помощью регрессии, от фактически наблюдаемых, чем меньше стандартная ошибка, тем достовернее модель соответствует фактическим значениям;
- *t*-статистика – характеризует статистическую значимость найденных числовых значений модели, определяется как отношение коэффициента регрессии к его стандартной ошибке;
- *p*-значение – показывает вероятность того, что наблюдаемая разница в результатах могла быть случайной, достоверность исследования требует обеспечения *p*-значения как правило на уровне не выше 0,05.

Использование этих и других специфичных для различных методов прогнозирования оценок позволяет сравнить точность и достоверность их использования и сделать соответствующий выбор в пользу некоторых из них.

Однако в конечном итоге решение об использовании того или иного метода принимается с учетом экономической целесообразности на основе сравнения возможных эффектов от прогнозирования с использованием выбранного метода с затратами на его осуществление. Затраты формируются на всех этапах прогнозирования параметров агропродовольственных систем, включая:

- 1) получение доступа к источникам данных;
- 2) сбор данных, отражающих характеристики, которые могут быть прямо или косвенно связаны с прогнозируемым параметром;
- 3) проведение предобработки данных, поиска аномалий и снижение размерности;
- 4) формирование базы данных факторных признаков и выбор результативного признака;
- 5) построение, обучение (при необходимости) и оценка производительности рабочей модели;
- 6) компиляция и интерпретация результатов прогнозирования, интеграция их в базу данных;
- 7) обеспечение доступности и наглядности результатов работы алгоритма.

Первый вид затрат, связанный с получением доступа к базам данных, как правило, является внешним по отношению к экономическим субъектам агропродовольственных систем. Необходимая информация может быть получена на коммерческой основе у организаций, специализирующихся на сборе и анализе данных (маркетинговые компании), и организаций, где эта функция сопряжена с основным видом деятельности (товарно-

сырьевые и фондовые биржи, логистические центры, различные маркет-плейсы и др.). При оплате неисключительных прав на доступ к базам данных затраты учитываются как авансовая дебиторская задолженность и отражаются ежемесячно по статье «Общехозяйственные расходы» до окончания срока действия договорных обязательств. Величина подобных издержек сопоставима и, возможно, постоянна при использовании различных методов прогнозирования, за тем лишь исключением, что в процессе реализации ML на основе ANN, как правило, используется больший объем информации, требующий соответственно и более высоких затрат на ее получение.

Реализация этапов прогнозирования со второго по седьмой в организациях агропродовольственного сектора может осуществляться двумя путями. Первый предполагает привлечение на договорной основе сторонних исполнителей. Решение этой задачи предлагается многими коммерческими организациями, включая бывшее подразделение Сбера – ООО «СберБизнесСофт». Этот вариант подразумевает заключение договора оказания услуг, оплату по которому, если он действует несколько месяцев, как авансовую дебиторскую задолженность по итогу также учитывают в составе управленческих (общехозяйственных) расходов. Он требует немалых финансовых затрат при индивидуальном подходе к осуществлению прогнозирования, что доступно лишь крупным компаниям.

Второй вариант предполагает наличие необходимого оборудования и собственного персонала, способного самостоятельно аккумулировать и анализировать данные, осуществлять построение моделей машинного обучения. Здесь не предусматривается существенного роста затрат, но предполагается наличие необходимых навыков сбора и обработки информации у сотрудников организации. Затраты осуществляются за счет средств организации, которые, согласно Плану счетов, отражаются в составе общехозяйственных расходов, и их общая величина не выходит за рамки издержек прошлых лет.

Эффекты прогнозирования формируются за счет предвидения и возможных корректировок производственно-финансовой деятельности, включая:

1) предвидение событий и трендов. Предвидение изменения спроса, конкурентной среды и других рыночных факторов помогает оптимизировать производственную программу и максимизировать объем продаж;

2) планирование и формирование бюджета. Прогнозы служат основанием для эффективного распределения ресурсов и финансового планирования с целью производства и реализации максимально возможного объема продукции;

3) управление рисками. Составление прогнозов помогает идентифицировать потенциальные риски, с которыми может столкнуться организация, что, в свою очередь, позволяет грамотно адаптироваться к неблагоприятному развитию событий и обеспечить стабильность бизнес-процессов;

4) принятие решений. Прогнозы предоставляют информацию, необходимую для принятия взвешенных управленческих решений в различных областях ведения бизнеса, включая производство, маркетинг, финансы и управление персоналом;

5) снижение затрат. Имея представление о будущих трендах, компания может оптимизировать использование ресурсов, например удобрений, семян, рабочей силы и уменьшить издержки.

Общий эффект прогнозирования идентифицируется как совокупность возможного прироста выручки от продаж и экономии затрат за счет принятия обоснованных решений на основе улучшения представлений о будущем развитии событий. Разница между эффектом и затратами определяет прибыль от осуществления прогнозирования, а отношение эффекта к затратам – уровень рентабельности данного процесса. Критериями эффективности в данном случае будут служить положительная величина прибыли и приемлемый уровень отраслевой рентабельности.

При этом затраты ни в коем случае не должны превышать эффекты совершенствования функционирования агропродовольственных систем на основе определенного повышения предсказуемости. С учетом этого в малом бизнесе будет, скорее всего, целесообразно использовать традиционные методы прогнозирования, в крупных агропромышленных формированиях – методы с использованием машинного обучения. Здесь даже прирост выручки в несколько процентов позволит многократно окупить затраты на организацию прогнозирования с использованием машинного обучения.

Процедура машинного обучения, включая подготовку данных для обучения, оценку и выбор модели, регуляризацию и предотвращение переобучения, может быть реализована на облачных серверах, где виртуальные машины работают с графическими видеокартами. Обзор платформ глубокого обучения с открытым исходным кодом позволяет составить список наиболее приемлемых и доступных из них.

Apache MXNet – платформа глубокого обучения с открытым исходным кодом, подходящая для создания и проведения исследовательских проектов в области компьютерного зрения, обработки речи, временных рядов и многого другого. Исходный код поддерживает MacOS, Linux, Windows, Cloud Devices. Обеспечивает возможность реализации как императивного, так и символьного программирования на 8 языковых привязках, включая Python, Scala, Julia, C++ и др. Проект инициирован в середине 2015 года, а с сентября 2023 г. реализуется в проекте Attic, управляемом Apache Attic Committee. В 2024 г. была выпущена версия 1.9.1 [17].

Фреймворк глубокого обучения *Caffe*, первоначально разработанный в 2014 г. Berkeley AI Research (BAIR) в Калифорнийском университете для обеспечения исследовательской архитектурой проектов глубокого обучения. Представляет собой достаточно простую модульную структуру, готовую к построению сетей с максимальными возможностями масштабирования для обучения и развертывания. Исходный код, основанный на оригинальной библиотеке C++ и CUDA, дополнительно реализуется в Python API и MATLAB, поддерживает Mac OS, Windows, Linux, iOS, Android и другие платформы для сборки. Позднее с запуском Caffe2 был дополнительно расширен функционал за счет поддержки крупномасштабного обучения, обеспечения большей гибкости и стресс-тестирования с использованием приложений Facebook. Здесь обеспечиваются возможности построения своих рекуррентных нейронных сетей на основе сетей LSTM. В настоящее время фреймворк Caffe2 объединен с проектом PyTorch, хотя предыдущие поколения все еще продолжают работать [18, 19].

Производительная платформа глубокого обучения с открытым исходным кодом *Deep Learning 4J (DL4J)*, созданная SkyMind, позволяющая обучать модели из Java, взаимодействуя с экосистемой Python и C++. DL4J предназначен как для коммерческого, так и некоммерческого использования. Реализация возможна в операционной среде Linux, Windows, Mac OS, Android. Варианты использования включают не только набор инструментов для запуска глубокого обучения, но и импорта моделей из других платформ ML (PyTorch, Tensorflow, Keras), предполагающих их развертывание и переобучение. Платформа содержит также возможности реализации многих других алгоритмов, включая рекурсивные нейронные сети, которые могут быть созданы на платформе или импортированы извне [26].

Фреймворковый API глубокого обучения *Keras*, подходящий для построения сетей на основе Python и интегрируемый с TensorFlow, и PyTorch. Преимущество современной версии Keras3 состоит в способности обеспечивать быстрое создание прототипа системы ML с удобным, модульным и расширяемым интерфейсом. Keras3 работает на центральных и графических процессорах, поддерживает CNN и RNN и может интегрировать другие

распространенные пакеты машинного обучения. Любая модель Keras3 может быть инициализирована как модуль PyTorch или экспортирована как модель TensorFlow. Это означает возможность использования моделей Keras с пакетами экосистемы PyTorch, с полным набором инструментов развертывания и реализации TensorFlow (таких как TF-Serving, TF.js и TFLite), а также с крупномасштабной инфраструктурой обучения TPU JAX [34, 40].

Microsoft Cognitive Toolkit (CNTK) – набор инструментов с открытым исходным кодом для коммерческого использования глубокого обучения. Он описывает нейронные сети как ряд вычислительных шагов через направленный граф. CNTK позволяет пользователю легко реализовывать и комбинировать популярные типы моделей, такие как прямые нейронные сети (FFNN), сверточные нейронные сети (CNN) и рекуррентные нейронные сети (RNN/LSTM). CNTK реализует обучение методом стохастического градиентного спуска с автоматической дифференциацией и распараллеливанием на нескольких графических процессорах и серверах. CNTK может быть включен в качестве библиотеки в программы на Python, C# и C++ или использоваться как автономный инструмент с собственным языком сценариев BrainScript. Он также может осуществлять передачу данных между другими платформами глубокого обучения (Caffe2, PyTorch). CNTK поддерживает 64-битные операционные системы Linux и Windows. Для сборки можно выбрать предварительно скомпилированные бинарные пакеты или составить набор инструментов из исходного кода, предоставленного в GitHub [34, 57].

Относительно новым предложением в области технологий глубокого обучения является *TensorFlow*. Данное приложение первоначально было разработано и предложено Google в 2015 году. Он включает в себя API Java, C++, Go и Python и предназначен для анализа данных и прогнозирования с помощью графовых нейронных сетей. Здесь возможна обработка сложных, взаимосвязанных объектов, что делает его высокопроизводительным методом прогнозирования потоков, динамики финансовых показателей и многого другого. TensorFlow поддерживает вычисления на нескольких центральных графических процессорах с использованием дополнительного CUDA и расширения SYCL. Для мобильного ML разработан TensorFlow Lite, предоставляющий API для нейронных сетей Android, хотя максимальную производительность он все-таки демонстрирует в многопоточных серверных реализациях [34, 56].

Условием использования этих платформ экономическими субъектами агропродовольственной системы является развертывание микросервисной облачной инфраструктуры. Сервисы должны обладать интерфейсом прикладного программирования (API), например в виде gRPC с протоколом http/2.0.

Заключение

Путей использования ML в прогнозировании агропродовольственного сектора достаточно много. Основным их преимуществом является обеспечение значительных возможностей моделирования сложных систем с нелинейной формой распределения данных, представляемых многомерным или одномерным векторным пространством, особенно когда число сценариев принятия решений достаточно велико.

Наиболее перспективными методами ML являются искусственные нейронные сети, объединяющие огромное количество применяемых алгоритмов.

Оптимальный подход к совершенствованию прогнозирования видится на основе интеграции методов ML в традиционную систему, сложившуюся и применяемую экономическими субъектами в течение уже продолжительного времени. Этот комплексный подход к прогнозированию расширяет возможности участников агропродовольственных экономических систем, позволяя оценивать риски, принимать решения, разрабатывать стратегии и более эффективно противостоять вызовам неопределенности.

Список источников

1. Бисчоков Р.М. Анализ, моделирование и прогноз урожайности сельскохозяйственных культур средствами искусственных нейронных сетей // Вестник Российского университета дружбы народов. Серия: Агронимия и животноводство. 2022. Т. 17, № 2. С. 146–157. DOI: 10.22363/2312-797X-2022-17-2-146-157.
2. Вакуленко С.А., Жихарева А.А. Практический курс по нейронным сетям: учебное пособие. Санкт-Петербург: Университет ИТМО, 2018. 71 с.
3. Грачев А.В. Применение нейросетевых технологий для прогнозирования состояния работы объектов предприятий АПК // Техника и технология пищевых производств. 2023. Т. 53, № 4. С. 816–823. DOI: 10.21603/2074-9414-2023-4-2481.
4. Дубовицкий А.А., Климентова Э.А. Анализ факторов, определяющих величину экологического воздействия сельскохозяйственного производства на земельные ресурсы // Аграрный вестник Урала. 2024. Т. 24, № 03. С. 381–391. DOI: 10.32417/1997-4868-2024-24-03-381-391.
5. Дубовицкий А.А., Климентова Э.А., Фецович И.В. Методологические аспекты использования искусственных нейронных сетей в прогнозировании агропродовольственных экономических систем // Экономика, труд, управление в сельском хозяйстве. 2024. № 12(118). С. 126–137. DOI: 10.33938/2412-126.
6. Косинский П.Д., Чупрякова А.Г., Меркурьев В.В. и др. Влияние причинно-следственных связей между экологическими и социальными рисками на развитие сельских территорий региона // АПК: экономика, управление. 2023. № 4. С. 82–88. DOI: 10.33305/234-82.
7. Полянская Н.М., Найданова Э.Б., Барлуков А.М. и др. Агропродовольственная система региона: сущность, структура и социально-экономическое значение // Экономический вестник Восточно-Сибирского государственного университета технологий и управления. 2024. № 1(17). С. 22–31.
8. Рогачев А.Ф., Белоусов И.С. Нейросетевое выявление проблемных участков состояния посевов методами искусственного интеллекта // Известия Нижневолжского агроуниверситетского комплекса: Наука и высшее профессиональное образование. 2022. № 3(67). С. 459–466. DOI: 10.32786/2071-9485-2022-03-52.
9. Семкин А.Г., Воронин Е.А. Концептуальная идентификация сельскохозяйственного макрорегиона как объекта управления пространственным развитием производства методами машинного обучения в информационном пространстве цифровой экономики // Экономика сельского хозяйства России. 2022. № 2. С. 62–68. DOI: 10.32651/222-62.
10. Скворцов Е.А., Ялунина Е.Н., Гусев А.С. Анализ финансово-экономических показателей развития сельского хозяйства с применением систем искусственного интеллекта // Экономика сельского хозяйства России. 2023. № 11. С. 80–86. DOI: 10.32651/2311-80.
11. Смагин Б.И. Эффективность и оптимизация функционирования аграрной сферы производства // Вестник Мичуринского государственного аграрного университета. 2019. № 4(59). С. 141–147.
12. Сушкова С.Н., Сушкова Т.Ю. Эволюция территориальных социально-экономических систем в агропродовольственной сфере Ульяновской области // Вестник Ульяновской государственной сельскохозяйственной академии. 2013. № 1(21). С. 173–177.
13. Шагайда Н. Агропродовольственный сектор // Экономическое развитие России. 2016. № 6. С. 40–45.
14. Шанина Е.Н. Экономические предпосылки и система организации межтерриториальной интеграции агропродовольственной сферы // Белгородский экономический вестник. 2014. № 2(74). С. 36–43.
15. Aliramezani M., Koch C., Shahbakhti M. Modeling, diagnostics, optimization, and control of internal combustion engines via modern machine learning techniques: A review and future directions // Progress in Energy and Combustion Science. 2022. Vol. 88. Article No. 100967. DOI: 10.1016/j.pecs.2021.100967.
16. Ansari A., Riasi A. Modelling and evaluating customer loyalty using neural networks: Evidence from startup insurance companies // Future Business Journal. 2016. Vol. 2(1). Pp. 15–30. DOI: 10.1016/j.fbj.2016.04.001.
17. Apache MXNet Website: A Flexible and Efficient Library for Deep Learning. A truly open source deep learning framework suited for flexible research prototyping and production. URL: <https://mxnet.apache.org/versions/1.9.1/>.
18. Caffe Website. Deep learning framework by BAIR. URL: <http://caffe.berkeleyvision.org/>.
19. Caffe2 Website. Deep Learning Framework. URL: <https://caffe2.ai/>.
20. Chen Y., Tan P., Li M. et al. K-means clustering method based on nearest-neighbor density matrix for customer electricity behavior analysis // International Journal of Electrical Power & Energy Systems. 2024. Vol. 161. Article No. 110165. DOI: 10.1016/j.ijepes.2024.110165.
21. Deng Y., Bao F., Kong Y. et al. Deep Direct Reinforcement Learning for Financial Signal Representation and Trading // IEEE Transactions on Neural Networks and Learning Systems. 2017. Vol. 28(3). Pp. 653–664. DOI: 10.1109/TNNLS.2016.2522401.
22. Domingo L., Grande M., Borondo F. et al. Anticipating food price crises by reservoir computing // Chaos, Solitons & Fractals. 2023. Vol. 174. Article No. 113854. DOI: 10.1016/j.chaos.2023.113854.
23. Dong X., Xie K. Temporal shifts in safety states through the COVID-19 pandemic: Insights from hidden semi-Markov models // Accident Analysis & Prevention. 2025. Vol. 211. Article No. 107875. DOI: 10.1016/j.aap.2024.107875.
24. Dubovitski A., Klimentova E., Rogov M. Applicability of machine learning models using a neural network for predicting the parameters of the development of food markets // Journal of Process Management and New Technologies. 2022. Vol. 10(3-4). Pp. 93–105. DOI: 10.5937/jouproman2203093d.
25. Dubovitski A.A., Konovalova M.E., Strelnikova T.D. et al. Assessment of the impact of climate risks on agriculture in the context of global warming // IOP Conference Series: Earth and Environmental Science. Michurinsk, 2021. Article No. 012145. DOI: 10.1088/1755-1315/845/1/012145.

26. Eclipse DeepLearning4J Website. URL: <https://deeplearning4j.org/>.
27. Elavarasan D., Vincent D.R., Sharma V. et al. Forecasting yield by integrating agrarian factors and machine learning models: A survey // *Computers and Electronics in Agriculture*. 2018. Vol. 155. Pp. 257–282. DOI: 10.1016/j.compag.2018.10.024.
28. Elavarasan D., Vincent D.R. Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications // *IEEE Access*. 2020. Vol. 8. Pp. 86886–86901. DOI: 10.1109/ACCESS.2020.2992480.
29. FAO Website. Food and Agriculture Organization of the United Nations (FAO) Publications & Statistics. URL: <https://www.fao.org/agrifood-economics/publications/detail/ru/c/1675930/>.
30. Göçken M., Özçalici M., Boru A. et al. Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction // *Expert Systems with Applications*. 2016. Vol. 44. Pp. 320–331. DOI: 10.1016/j.eswa.2015.09.029.
31. Gupta S., Kashyap S. Forecasting inflation in G-7 countries: An application of artificial neural network // *Foresight*. 2015. Vol. 17(1). Pp. 63–73. DOI: 10.1108/FS-09-2013-0045.
32. Guzmán S.M., Paz J.O., Tagert M.L.M. et al. An integrated SVR and crop model to estimate the impacts of irrigation on daily groundwater levels // *Agricultural systems*. 2018. Vol. 159. Pp. 248–259. DOI: 10.1016/j.agsy.2017.01.017.
33. Hasan A.M., Sohel F., Diepeveen D. et al. A survey of deep learning techniques for weed detection from images // *Computers and Electronics in Agriculture*. 2021. Vol. 184. Article No. 106067. DOI: 10.1016/j.compag.2021.106067.
34. Hatcher W.G., Yu W. A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends // *IEEE Access*. 2018. Vol. 6. Pp. 24411–24432. DOI: 10.1109/ACCESS.2018.2830661.
35. Haynes P., Alemna D. A systematic literature review of the impact of complexity theory on applied economics // *Economies*. 2022. Vol. 10(8). Article No. 192. DOI: 10.3390/economies10080192.
36. Herold N., Ekström M., Kala J. et al. Australian climate extremes in the 21st century according to a regional climate model ensemble: Implications for health and agriculture // *Weather and Climate Extremes*. 2018. Vol. 20. Pp. 54–68. DOI: 10.1016/j.wace.2018.01.001.
37. Huang T., Yang R., Huang W. et al. Detecting sugarcane borer diseases using support vector machine // *Information Processing in Agriculture*. 2018. Vol. 5(1). Pp. 74–82. DOI: 10.1016/j.inpa.2017.11.001.
38. Karpunina E.K., Kosorukova I.V., Dubovitski A.A. et al. State policy of transition to Society 5.0: Identification and assessment of digitalisation risks // *International Journal of Public Law and Policy*. 2021. Vol. 7(4). Pp. 334–350. DOI: 10.1504/IJPLAP.2021.118895.
39. Karpunina E.K., Lapushinskaya G.K., Arutyunova A.E. et al. Dialectics of Sustainable Development of Digital Economy Ecosystem // *Scientific and Technical Revolution: Yesterday, Today and Tomorrow*. Krasnoyarsk: Springer. 2020. Vol. 129. Pp. 486–496. DOI: 10.1007/978-3-030-47945-9_54.
40. Keras Website. Keras 3 is a multi-framework deep learning API. URL: <https://keras.io/>.
41. Klimentova E.A., Dubovitsky A.A., Yurina E.A. et al. Regional features of rural unemployment in Russia // *Economics of Agriculture*. 2021. Vol. 68(2). Pp. 357–374. DOI: 10.5937/ekoPolj2102357K.
42. Kriegeskorte N., Golan T. Neural network models and deep learning // *Current Biology*. 2019. Vol. 29(7). Pp. 231–236. DOI: 10.1016/j.cub.2019.02.034.
43. Kuschewski J.G., Žak S.H., Hui S. Application of Feedforward Neural Networks to Dynamical System Identification and Control // *IEEE Transactions on Control Systems Technology*. 1993. Vol. 1(1). Pp. 37–49. DOI: 10.1109/87.221350.
44. Likas A., Vlassis N., Verbeek J.J. The global *k*-means clustering algorithm // *Pattern Recognition*. 2003. Vol. 36(2). Pp. 451–461. DOI: 10.1016/S0031-3203(02)00060-2.
45. Ma Y., Zhou M., Li S. Weathering market swings: Does climate risk matter for agricultural commodity price predictability? // *Journal of Commodity Markets*. 2024. Vol. 36. Article No. 100423. DOI: 10.1016/j.jcomm.2024.100423.
46. Mitter H., Techen A.-K., Sinabell F. et al. Shared Socio-economic Pathways for European agriculture and food systems: The Eur-Agri-SSPs // *Global Environmental Change*. 2020. Vol. 65. Article No. 102159. DOI: 10.1016/j.gloenvcha.2020.102159.
47. Neto R.J., Souza Z.M., Medeiros Oliveira et al. Use of the decision tree technique to estimate sugarcane productivity under edaphoclimatic conditions // *Sugar Tech*. 2017. Vol. 19. Pp. 662–668. DOI: 10.1007/s12355-017-0509-7.
48. Pandey A., Mishra A. Application of artificial neural networks in yield prediction of potato crop // *Russian Agricultural Sciences*. 2017. Vol. 43(3). Pp. 266–272. DOI: 10.3103/S1068367417030028.
49. Sabri I., Bahia H. Using Artificial Neural Network Modeling in Forecasting Revenue: Case Study in National Insurance Company/Iraq // *International Journal of Intelligence Science*. 2013. Vol. 3. Pp. 136–143. DOI: 10.4236/ijis.2013.33015.
50. Scrivano S., Tolio T., Markov A. Chain model for the performance evaluation of manufacturing lines with general processing times // *Procedia CIRP*. 2021. Vol. 103. Pp. 20–25. DOI: 10.1016/j.procir.2021.10.002.
51. Singh B., Jana A.K. Forecast of agri-residues generation from rice, wheat and oilseed crops in India using machine learning techniques: Exploring strategies for sustainable smart management // *Environmental Research*. 2024. Vol. 245. Article No. 117993. DOI: 10.1016/j.envres.2023.117993.
52. Smola A.J., Schölkopf B. A tutorial on support vector regression // *Statistics and Computing*. 2004. Vol. 14. Pp. 199–222. DOI: 10.1023/B:STCO.0000035301.49549.88.
53. Sousa J., Henriques R. Intersecting reinforcement learning and deep factor methods for optimizing locality and globality in forecasting: A review // *Engineering Applications of Artificial Intelligence*. 2024. Vol. 133. Part B. Article No. 108082. DOI: 10.1016/j.engappai.2024.108082.

54. Štastný J., Konečný V., Trenz O. Agricultural data prediction by means of neural network // *Agricultural Economics (Czech Republic)*. 2011. Vol. 57(7). Pp. 356–361. DOI: 10.17221/108/2011-AGRICECON.
55. Tamasiga P., Ouassou E.H., Onyeaka H. et al. Forecasting disruptions in global food value chains to tackle food insecurity: The role of AI and big data analytics – A bibliometric and scientometric analysis // *Journal of Agriculture and Food Research*. 2023. Vol. 14. Article No. 100819. DOI: 10.1016/j.jafr.2023.100819.
56. TensorFlow Website. A comprehensive platform for machine learning. URL: <https://www.tensorflow.org/?hl=ru>.
57. The Future is Yours Website. Getting Started with the Microsoft Cognitive Toolkit. URL: <https://docs.microsoft.com/en-us/cognitive-toolkit/>.
58. Tulbure M.G., Wimberly M.C., Boe A. et al. Climatic and genetic controls of yields of Switchgrass, a model bioenergy species // *Agriculture Ecosystems and Environment*. 2012. Vol. 146(1). Pp. 121–129. DOI: 10.1016/j.agee.2011.10.017.
59. Xiang K., Li B.N., Zhang L. et al. Regularized Taylor echo state networks for predictive control of partially observed systems // *IEEE Access*. 2016. Vol. 4. Pp. 3300–3309. DOI: 10.1109/ACCESS.2016.2582478.
60. Yano I.H., Alves J.R., Santiago W.E. et al. Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier // *IFAC-Papers OnLine*. 2016. Vol. 49(16). Pp. 415–420. DOI: 10.1016/j.ifacol.2016.10.076.
61. Zhan J., Cai M. A cost-minimized two-stage three-way dynamic consensus mechanism for social network-large scale group decision-making: Utilizing K-nearest neighbors for incomplete fuzzy preference relations // *Expert Systems with Applications*. 2025. Vol. 263. Article No. 125705. DOI: 10.1016/j.eswa.2024.125705.
62. Zhang W., Wu J., Wang S., Zhang Y. Examining dynamics: Unraveling the impact of oil price fluctuations on forecasting agricultural futures prices // *International Review of Financial Analysis*. 2025. Vol. 97. Article No. 103770. DOI: 10.1016/j.irfa.2024.103770.

References

1. Bischokov R.M. Analysis, modeling and forecasting of crop yields using neural networks. *RUDN Journal of Agronomy and Animal Industries*. 2022;17(2):146-157. DOI: 10.22363/2312-797X-2022-17-2-146-157. (In Russ.).
2. Vakulenko S.A., Zhikhareva A.A. Practical course on neural networks: study guide. St. Petersburg: Information Technologies, Mechanics and Optics University Publishers; 2018. 71 p. (In Russ.).
3. Grachev A.V. Neural network technologies in predicting the operating status of agricultural enterprises. *Food Processing: Techniques and Technology*. 2023;53(4):816-823. DOI: 10.21603/2074-9414-2023-4-2481. (In Russ.).
4. Dubovitskiy A.A., Klimentova E.A. Analysis of factors determining the magnitude of the environmental impact of agricultural production on land resources. *Agrarian Bulletin of the Urals*. 2024;24(03):381-391. DOI: 10.32417/1997-4868-2024-24-03-381-391. (In Russ.).
5. Dubovitskiy A.A., Klimentova E.A., Fetskovich I.V. Methodological aspects of the use of artificial neural networks in forecasting agri-food economic systems. *Economy, labor, management in agriculture*. 2024;12(118): 126-137. (In Russ.).
6. Kosinskiy P.D., Chupriakova A.G., Merkurev V.V. et al. Impact of causal relationships between environmental and social risks on the development of rural areas of the region. *AIC: economics, management*. 2023;4:82-88. DOI: 10.33305/234-82. (In Russ.).
7. Polyanskaya N.M., Naydanova E.B., Barlukov A.M. et al. Agrifood system of the region: essence, structure and social & economic significance. *East Siberia State University of Technology and Management Economic Bulletin*. 2024;1(17):22-31. (In Russ.).
8. Rogachev A.F., Belousov I.S. Neural network identification of problem areas of the state of crops by methods of artificial intelligence. *Proceedings of the Lower Volga Agro-University Complex*. 2022;3(67):459-466. DOI: 10.32786/2071-9485-2022-03-52. (In Russ.).
9. Semkin A.G., Voronin E.A. Conceptual identification of the agricultural macroregion as an object of control of spatial development of production by Machine Learning methods in the information space of the digital economy. *Economics of Agriculture of Russia*. 2022;2:62-68. DOI: 10.32651/222-62. (In Russ.).
10. Skvortsov E.A., Ialunina E.N., Gusev A.S. Analysis of financial and economic indicators of agricultural development using artificial intelligence systems. *Economics of Agriculture of Russia*. 2023;11:80-86. DOI: 10.32651/2311-80. (In Russ.).
11. Smagin B.I. Efficiency and optimization of the functioning of agrarian sphere of production. *Bulletin of Michurinsk State Agrarian University*. 2019;4(59):141-147. (In Russ.).
12. Sushkova S.N., Sushkova T.Y. Evolution of territorial social-economic systems in the agricultural sector of Ulyanovsk region. *Vestnik of Ulyanovsk State Agricultural Academy*. 2013;1(21):173-177. (In Russ.).
13. Shagayda N. Russia's agri-food sector. *Russian Economic Developments*. 2016;6:40-45. (In Russ.).
14. Shanina E.N. Economic prerequisites and the system of organization of inter-territorial integration of agrifood sector. *Belgorod Economic Bulletin*. 2014;2(74):36-43. (In Russ.).
15. Aliramezani M., Koch C., Shahbakhti M. Modeling, diagnostics, optimization, and control of internal combustion engines via modern machine learning techniques: A review and future directions. *Progress in Energy and Combustion Science*. 2022;88:100967. DOI: 10.1016/j.peccs.2021.100967.
16. Ansari A., Riasi A. Modelling and evaluating customer loyalty using neural networks: Evidence from startup insurance companies. *Future Business Journal*. 2016;2(1):15-30. DOI: 10.1016/j.fbj.2016.04.001.

17. Apache MXNet Website: A Flexible and Efficient Library for Deep Learning. A truly open source deep learning framework suited for flexible research prototyping and production. URL: <https://mxnet.apache.org/versions/1.9.1/>.
18. Caffe Website. Deep learning framework by BAIR. URL: <http://caffe.berkeleyvision.org/>.
19. Caffe2 Website. Deep Learning Framework. URL: <https://caffe2.ai/>.
20. Chen Y., Tan P., Li M. et al. K-means clustering method based on nearest-neighbor density matrix for customer electricity behavior analysis. *International Journal of Electrical Power & Energy Systems*. 2024;161:110165. DOI: 10.1016/j.ijepes.2024.110165.
21. Deng Y., Bao F., Kong Y. et al. Deep Direct Reinforcement Learning for Financial Signal Representation and Trading. *IEEE Transactions on Neural Networks and Learning Systems*. 2017;28(3):653-664. DOI: 10.1109/TNNLS.2016.2522401.
22. Domingo L., Grande M., Borondo F. et al. Anticipating food price crises by reservoir computing. *Chaos, Solitons & Fractals*. 2023;174:113854. DOI: 10.1016/j.chaos.2023.113854.
23. Dong X., Xie K. Temporal shifts in safety states through the COVID-19 pandemic: Insights from hidden semi-Markov models. *Accident Analysis & Prevention*. 2025;211:107875. DOI: 10.1016/j.aap.2024.107875.
24. Dubovitski A., Klimentova E., Rogov M. Applicability of machine learning models using a neural network for predicting the parameters of the development of food markets. *Journal of Process Management and New Technologies*. 2022;10(3-4):93-105. DOI: 10.5937/jouproman2203093d.
25. Dubovitski A.A., Konovalova M.E., Strelnikova T.D. et al. Assessment of the impact of climate risks on agriculture in the context of global warming. *IOP Conference Series: Earth and Environmental Science*. Michurinsk, 2021. Article No. 012145. DOI: 10.1088/1755-1315/845/1/012145.
26. Eclipse DeepLearning4J Website. URL: <https://deeplearning4j.org/>.
27. Elavarasan D., Vincent D.R., Sharma V. et al. Forecasting yield by integrating agrarian factors and machine learning models: A survey. *Computers and Electronics in Agriculture*. 2018;155:257-282. DOI: 10.1016/j.compag.2018.10.024.
28. Elavarasan D., Vincent D.R. Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications. *IEEE Access*. 2020;8:86886-86901. DOI: 10.1109/ACCESS.2020.2992480.
29. FAO Website. Food and Agriculture Organization of the United Nations (FAO) Publications & Statistics. URL: <https://www.fao.org/agrifood-economics/publications/detail/ru/c/1675930/>.
30. Göçken M., Özçalici M., Boru A. et al. Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction. *Expert Systems with Applications*. 2016;44:320-331. DOI: 10.1016/j.eswa.2015.09.029.
31. Gupta S., Kashyap S. Forecasting inflation in G-7 countries: An application of artificial neural network. *Foresight*. 2015;17(1):63-73. DOI: 10.1108/FS-09-2013-0045.
32. Guzmán S.M., Paz J.O., Tagert M.L.M. et al. An integrated SVR and crop model to estimate the impacts of irrigation on daily groundwater levels. *Agricultural Systems*. 2018;159:248-259. DOI: 10.1016/j.agsy.2017.01.017.
33. Hasan A.M., Sohel F., Diepeveen D. et al. A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture*. 2021;184:106067. DOI: 10.1016/j.compag.2021.106067.
34. Hatcher W.G., Yu W. A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends. *IEEE Access*. 2018;6:24411-24432. DOI: 10.1109/ACCESS.2018.2830661.
35. Haynes P., Alemna D. A systematic literature review of the impact of complexity theory on applied economics. *Economies*. 2022;10(8):192. DOI: 10.3390/economies10080192.
36. Herold N., Ekström M., Kala J. et al. Australian climate extremes in the 21st century according to a regional climate model ensemble: Implications for health and agriculture. *Weather and Climate Extremes*. 2018;20:54-68. DOI: 10.1016/j.wace.2018.01.001.
37. Huang T., Yang R., Huang W. et al. Detecting sugarcane borer diseases using support vector machine. *Information Processing in Agriculture*. 2018;5(1):74-82. DOI: 10.1016/j.inpa.2017.11.001.
38. Karpunina E.K., Kosorukova I.V., Dubovitski A.A. et al. State policy of transition to Society 5.0: Identification and assessment of digitalisation risks. *International Journal of Public Law and Policy*. 2021;7(4):334-350. DOI: 10.1504/IJPLAP.2021.118895.
39. Karpunina E.K., Lapushinskaya G.K., Arutyunova A.E. et al. Dialectics of Sustainable Development of Digital Economy Ecosystem. *Scientific and Technical Revolution: Yesterday, Today and Tomorrow*. Krasnoyarsk: Springer. 2020; 129:486-496. DOI: 10.1007/978-3-030-47945-9_54.
40. Keras Website. Keras 3 is a multi-framework deep learning API. URL: <https://keras.io/>.
41. Klimentova E.A., Dubovitskiy A.A., Yurina E.A. et al. Regional features of rural unemployment in Russia. *Economics of Agriculture*. 2021;68(2):357-374. DOI: 10.5937/ekoPolj2102357K.
42. Kriegeskorte N., Golan T. Neural network models and deep learning. *Current Biology*. 2019;29(7):231-236. DOI: 10.1016/j.cub.2019.02.034.
43. Kuschewski J.G., Žak S.H., Hui S. Application of Feedforward Neural Networks to Dynamical System Identification and Control. *IEEE Transactions on Control Systems Technology*. 1993;1(1):37-49. DOI: 10.1109/87.221350.
44. Likas A., Vlassis N., Verbeek J.J. The global k-means clustering algorithm. *Pattern Recognition*. 2003;36(2):451-461. DOI: 10.1016/S0031-3203(02)00060-2.
45. Ma Y., Zhou M., Li S. Weathering market swings: Does climate risk matter for agricultural commodity price predictability? *Journal of Commodity Markets*. 2024;36:100423. DOI: 10.1016/j.jcomm.2024.100423.

46. Mitter H., Techen A.-K., Sinabell F. et al. Shared Socio-economic Pathways for European agriculture and food systems: The Eur-Agri-SSPs. *Global Environmental Change*. 2020;65:102159. DOI: 10.1016/j.gloenvcha.2020.102159.
47. Neto R.J., Souza Z.M., Medeiros Oliveira et al. Use of the decision tree technique to estimate sugarcane productivity under edaphoclimatic conditions. *Sugar Tech*. 2017;19:662-668. DOI: 10.1007/s12355-017-0509-7.
48. Pandey A., Mishra A. Application of artificial neural networks in yield prediction of potato crop. *Russian Agricultural Sciences*. 2017;43(3):266-272. DOI: 10.3103/S1068367417030028.
49. Sabri I., Bahia H. Using Artificial Neural Network Modeling in Forecasting Revenue: Case Study in National Insurance Company/Iraq. *International Journal of Intelligence Science*. 2013;3:136-143. DOI: 10.4236/ijis.2013.33015.
50. Scrivano S., Tolio T., Markov A. Chain model for the performance evaluation of manufacturing lines with general processing times. *Procedia CIRP*. 2021;103:20-25. DOI: 10.1016/j.procir.2021.10.002.
51. Singh B., Jana A.K. Forecast of agri-residues generation from rice, wheat and oilseed crops in India using machine learning techniques: Exploring strategies for sustainable smart management. *Environmental Research*. 2024;245:117993. DOI: 10.1016/j.envres.2023.117993.
52. Smola A.J., Schölkopf B. A tutorial on support vector regression. *Statistics and Computing*. 2004;14:199-222. DOI: 10.1023/B:STCO.0000035301.49549.88.
53. Sousa J., Henriques R. Intersecting reinforcement learning and deep factor methods for optimizing locality and globality in forecasting: A review. *Engineering Applications of Artificial Intelligence*. 2024;133(B):108082. DOI: 10.1016/j.engappai.2024.108082.
54. Šťastný J., Konečný V., Trenz O. Agricultural data prediction by means of neural network. *Agricultural Economics (Czech Republic)*. 2011;57(7):356-361. DOI: 10.17221/108/2011-AGRICECON.
55. Tamasiga P., Ouassou E.H., Onyeaka H. et al. Forecasting disruptions in global food value chains to tackle food insecurity: The role of AI and big data analytics – A bibliometric and scientometric analysis. *Journal of Agriculture and Food Research*. 2023;14:100819. DOI: 10.1016/j.jafr.2023.100819.
56. TensorFlow Website. A comprehensive platform for machine learning. URL: <https://www.tensorflow.org/?hl=ru>.
57. The Future is Yours Website. Getting Started with the Microsoft Cognitive Toolkit. URL: <https://docs.microsoft.com/en-us/cognitive-toolkit/>.
58. Tulbure M.G., Wimberly M.C., Boe A. et al. Climatic and genetic controls of yields of Switchgrass, a model bioenergy species. *Agriculture Ecosystems and Environment*. 2012;146(1):121-129. DOI: 10.1016/j.agee.2011.10.017.
59. Xiang K., Li B.N., Zhang L. et al. Regularized Taylor echo state networks for predictive control of partially observed systems. *IEEE Access*. 2016;4:3300-3309. DOI: 10.1109/ACCESS.2016.2582478.
60. Yano I.H., Alves J.R., Santiago W.E. et al. Identification of weeds in sugarcane fields through images taken by UAV and Random Forest classifier. *IFAC-Papers OnLine*. 2016;49(16):415-420. DOI: 10.1016/j.ifacol.2016.10.076.
61. Zhan J., Cai M. A cost-minimized two-stage three-way dynamic consensus mechanism for social network-large scale group decision-making: Utilizing K-nearest neighbors for incomplete fuzzy preference relations. *Expert Systems with Applications*. 2025;263:125705. DOI: 10.1016/j.eswa.2024.125705.
62. Zhang W., Wu J., Wang S., Zhang Y. Examining dynamics: Unraveling the impact of oil price fluctuations on forecasting agricultural futures prices. *International Review of Financial Analysis*. 2025;97:103770. DOI: 10.1016/j.irfa.2024.103770.

Информация об авторах

А.А. Дубовицкий – доктор экономических наук, профессор кафедры экономики и коммерции ФГБОУ ВО «Мичуринский государственный аграрный университет», daa1-408@yandex.ru.

Э.А. Климентова – кандидат экономических наук, доцент кафедры экономики и коммерции ФГБОУ ВО «Мичуринский государственный аграрный университет», klim1-408@yandex.ru.

В.А. Шацкий – ассистент кафедры математики, физики и информационных технологий ФГБОУ ВО «Мичуринский государственный аграрный университет», site.mgau@yandex.ru.

Information about the authors

A.A. Dubovitskiy, Doctor of Economic Sciences, Professor, the Dept. of Economics and Commerce, Michurinsk State Agrarian University, daa1-408@yandex.ru.

E.A. Klimentova, Candidate of Economic Sciences, Docent, the Dept. of Economics and Commerce, Michurinsk State Agrarian University, klim1-408@yandex.ru.

V.A. Shatskiy, Assistant, the Dept. of Mathematics, Physics and Information Technology, Michurinsk State Agrarian University, site.mgau@yandex.ru.

Статья поступила в редакцию 15.12.2024; одобрена после рецензирования 25.01.2025; принята к публикации 28.12.2025.

The article was submitted 15.12.2024; approved after reviewing 25.01.2025; accepted for publication 28.12.2025.

© Дубовицкий А.А., Климентова Э.А., Шацкий В.А., 2025