

*Войкин Егор Александрович,
бакалавр кафедры «Распределенных информационно-вычислительных
систем»
направления «Программная инженерия»
Государственного университета «Дубна»
Россия, г. Дубна*

*Мусиенко Максим Владимирович,
бакалавр кафедры «Распределенных информационно-вычислительных
систем»
направления «Программная инженерия»
Государственного университета «Дубна»
Россия, г. Дубна*

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АВТОМАТИЗАЦИИ КОНТРОЛЯ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР

***Аннотация:** В статье рассматриваются возможности применения нейронных сетей для автоматизации контроля сельскохозяйственных культур в условиях цифрового земледелия. Проанализированы основные источники данных: изображения с мобильных устройств, беспилотных летательных аппаратов, спутниковые снимки и сенсорные показатели. Показано, что сверточные нейронные сети, сегментационные архитектуры и временные модели позволяют решать задачи распознавания болезней, выявления сорняков, оценки густоты стояния растений и прогнозирования урожайности. Отдельное внимание уделено концепции мобильной системы «Цифровой агроном», в которой нейросетевая модель используется для полевого анализа изображений и поддержки агрономических решений.*

Ключевые слова: нейронные сети, сельскохозяйственные культуры, цифровой агроном, компьютерное зрение, контроль посевов, урожайность, мобильное приложение, точное земледелие.

Abstract: The article examines the application of neural networks for automated crop monitoring in digital agriculture. The main data sources are considered, including mobile images, UAV imagery, satellite data and sensor measurements. The paper shows that convolutional neural networks, semantic segmentation architectures and temporal models can be used for disease recognition, weed detection, plant density assessment and yield forecasting. Special attention is paid to the concept of a mobile Digital Agronomist system, where an embedded neural network model supports field image analysis and agronomic decision-making.

Keywords: neural networks, crops, digital agronomist, computer vision, crop monitoring, yield, mobile application, precision agriculture.

Введение

Современное сельское хозяйство постепенно переходит от календарного и визуально-экспертного управления к более точному управлению на основе данных. Рост стоимости ресурсов, нехватка квалифицированных агрономов, климатическая нестабильность и необходимость снижать потери урожая делают контроль состояния посевов одной из ключевых задач агропроизводства. Если раньше оценка культуры в поле выполнялась вручную, то сегодня для этой цели все чаще используются мобильные устройства, беспилотные летательные аппараты, спутниковые снимки, датчики влажности и температуры, а также программные системы поддержки принятия решений [1, 2].

Особую роль в этой трансформации играют нейронные сети. Их преимущество заключается в способности выявлять сложные визуальные и

числовые закономерности, которые трудно описать набором ручных правил. На практике это означает возможность распознавать болезни растений по листьям, отделять культурные растения от сорняков, подсчитывать элементы урожайной структуры, выделять зоны стресса на поле и прогнозировать урожайность по совокупности признаков [3, 4]. Для агронома такие инструменты не заменяют профессиональную экспертизу, но уменьшают рутинную нагрузку и помогают быстрее обнаруживать участки, требующие внимания.

Актуальность темы связана с тем, что контроль сельскохозяйственных культур должен выполняться непосредственно в полевых условиях, где интернет-соединение может быть нестабильным, освещение меняется в течение дня, а изображения отличаются от лабораторных наборов данных. Поэтому перспективным направлением становится не только разработка точных моделей, но и их внедрение в прикладные системы: мобильные приложения, серверные API, облачные панели мониторинга и автономные модули на базе TensorFlow Lite или аналогичных средств.

Целью данной статьи является анализ способов применения нейронных сетей для автоматизации контроля сельскохозяйственных культур и описание концепции прикладной системы, способной объединить полевой сбор данных, нейросетевой анализ изображений и расчет агрономических показателей. В качестве инженерной идеи рассматривается мобильный подход «Цифровой агроном», ориентированный на автоматизацию оценки состояния посевов и расчет урожайности зерновых и масличных культур.

Контроль сельскохозяйственных культур как задача автоматизации

Контроль сельскохозяйственных культур включает регулярное получение сведений о состоянии растений, почвы и агроценоза в целом. В практической работе агроном оценивает всходы, густоту стояния, развитие листовой поверхности, наличие сорняков, симптомы болезней, повреждения вредителями, признаки дефицита питания и факторы, влияющие на будущую

урожайность. Такие наблюдения имеют высокую ценность, но требуют времени и часто зависят от субъективной оценки специалиста.

Главная проблема ручного контроля состоит в ограниченной повторяемости измерений. Один и тот же участок поля может быть оценен разными специалистами по-разному, а при больших площадях невозможно регулярно осмотреть каждую зону с одинаковой детализацией. Кроме того, отдельные признаки становятся заметны только на ранней стадии и могут быть пропущены при беглом осмотре. В результате агропредприятие либо реагирует с задержкой, либо применяет защитные мероприятия по всей площади, хотя проблема может быть локальной.

Автоматизированный контроль строится на другой логике. Вместо единичного визуального осмотра формируется поток данных: фотографии растений, координаты геоточек, погодные условия, история обработки поля, результаты спутникового мониторинга и сведения о предыдущих урожаях. Нейронная сеть преобразует этот поток в признаки, пригодные для принятия решений: класс болезни, вероятность поражения, контур сорняка, количество растений на единицу площади, индекс вегетации или прогноз урожайности [2, 3].

Наиболее важным результатом автоматизации является не сама классификация изображения, а сокращение времени между появлением проблемы и управленческим действием. Если система обнаруживает стрессовую зону, агроном может оперативно назначить дополнительный осмотр, локальную обработку или корректировку питания. При правильной интеграции нейросетевой модуль превращается в элемент производственного контура: наблюдение — анализ — рекомендация — действие — повторная проверка.

Источники данных для нейросетевого анализа

Качество работы нейронной сети напрямую зависит от качества данных. В сельском хозяйстве данные отличаются высокой изменчивостью: одно и то

же заболевание выглядит по-разному на разных сортах, в разные фазы развития и при разном освещении. Поэтому при создании систем контроля необходимо учитывать не только архитектуру модели, но и условия получения изображений.

Первым и самым доступным источником данных являются фотографии, сделанные с мобильного телефона. Такой подход удобен для малых и средних хозяйств: агроном фиксирует лист, колос, корзинку подсолнечника или участок посева, а приложение выполняет первичный анализ. Исследование S. P. Mohanty и соавторов показало, что глубокие сверточные сети способны достигать высокой точности на контролируемых наборах изображений листьев, однако точность заметно падает при переносе на изображения из реальных условий [5]. Этот результат важен практически: модель должна обучаться не только на «чистых» фото, но и на полевых снимках с шумом, тенью, частичным перекрытием листьев и разным фоном.

Второй источник — беспилотные летательные аппараты. UAV-съемка позволяет контролировать поле целиком и выявлять пространственную неоднородность, которую трудно заметить при наземном обходе. Для анализа таких данных используются модели семантической сегментации, которые присваивают класс каждому пикселю изображения: здоровая растительность, симптом болезни, почва, тень, сорняки и другие категории. Подобный подход применялся, например, при выявлении заболеваний винограда по мультиспектральным изображениям, где комбинация видимого и инфракрасного диапазона повышала информативность данных [10].

Третий источник — спутниковые снимки и временные ряды дистанционного зондирования. Они полезны для оценки динамики посевов на больших площадях, выделения зон неоднородности, анализа севооборота и прогнозирования урожайности. Нейросетевые методы в этом случае работают не только с отдельными изображениями, но и с последовательностями, отражающими изменение состояния поля во времени. Для классификации

культур и типов земного покрова применяются сверточные и рекуррентные модели, способные учитывать спектральные, пространственные и временные признаки [11].

Четвертый источник — сенсорные данные: влажность почвы, температура, освещенность, данные метеостанций, показатели электропроводности и агрохимические сведения. Они дополняют визуальные признаки и позволяют отличать похожие внешние симптомы. Например, пожелтение листьев может быть связано с болезнью, дефицитом питания, избытком влаги или температурным стрессом. Объединение изображений и сенсорных данных повышает устойчивость выводов, но требует более сложной архитектуры хранения и обработки информации [2].

Основные нейросетевые методы

В задачах контроля сельскохозяйственных культур чаще всего используются сверточные нейронные сети (CNN). Они хорошо подходят для анализа изображений, поскольку автоматически извлекают локальные признаки: контуры, пятна, текстуры, форму листьев, повреждения и цветовые переходы. В классической постановке CNN получает изображение на входе и выдает класс: здоровое растение, конкретная болезнь или тип повреждения. Работы K. P. Ferentinos и S. Sladojevic с соавторами показали, что глубокие модели могут эффективно распознавать болезни растений по листовым изображениям [6, 7].

Однако простая классификация не всегда достаточна. Для агронома важно не только узнать, что на снимке есть болезнь, но и понять, где именно находится симптом и какую площадь он занимает. Для этого используются сегментационные архитектуры: U-Net, SegNet, DeepLab и их модификации. Они формируют карту классов по изображению и позволяют рассчитывать долю пораженной ткани, площадь сорной растительности или количество объектов. В роботизированной прополке такие модели отделяют культурные

растения от сорняков и передают результат исполнительному механизму для точечного воздействия [13, 14].

Отдельную группу составляют модели детекции объектов, например семейство YOLO, Faster R-CNN и SSD. Они применимы там, где нужно найти множество однотипных объектов: колосья, плоды, листья, сорняки, насекомых-вредителей или пятна болезни. В прикладной системе для зерновых культур детектор может определять колосья на фотографии, после чего отдельный модуль оценивает количество зерен, повреждения или фазу развития.

Для анализа временной динамики используются рекуррентные нейронные сети, LSTM, GRU и трансформерные модели. Они полезны при работе со спутниковыми временными рядами и прогнозировании урожайности, где значение имеет не одно изображение, а последовательность наблюдений за сезон. Систематический обзор работ по прогнозированию урожайности показывает, что машинное обучение и глубокие модели становятся востребованными именно благодаря способности учитывать множество факторов: погодные данные, свойства почвы, историю поля и вегетационные индексы [15].

Важным направлением является перенос обучения. В сельском хозяйстве часто не хватает размеченных данных для конкретного региона и культуры, поэтому модель предварительно обучают на крупном наборе изображений, а затем адаптируют на локальных данных хозяйства. Такой подход сокращает затраты на разметку и делает систему применимой для новых культур, но требует контроля переобучения и регулярной проверки качества на реальных снимках.

Типовые задачи контроля и нейросетевые подходы

Задача контроля	Данные	Модель	Практический результат
Болезни листьев	Фото листьев, полевые снимки	CNN, transfer learning	Класс болезни и вероятность поражения
Сорняки	RGB/UAV-изображения	U-Net, DeepLab, FCN	Карта сорной растительности для точечной обработки
Густота стояния	Фото рядков, снимки с дрона	Object detection, segmentation	Количество растений и пропуски в рядах
Стрессовые зоны	Спутниковые и мультиспектральные снимки	CNN, временные модели	Выделение неоднородных участков поля
Прогноз урожайности	Фото, погода, почва, история поля	LSTM, ансамбли, регрессия	Оценка урожая и поддержка планирования

Концепция мобильной системы «Цифровой агроном»

Практическая реализация нейросетевого контроля может быть представлена в виде мобильной системы «Цифровой агроном». Ее смысл заключается в том, чтобы перенести часть вычислений непосредственно в поле и дать агроному инструмент, который работает даже при ограниченном интернет-соединении. В такой системе пользователь получает список заданий, выбирает поле или геоточку, делает фотографию растения или учетной площадки, после чего приложение выполняет первичный анализ и сохраняет результат.

Архитектура системы может включать четыре уровня. Первый уровень — мобильное приложение, отвечающее за интерфейс, фотофиксацию, работу с геоданными и локальное хранение. Второй уровень — встроенная нейросетевая модель, например в формате TensorFlow Lite, которая выполняет классификацию, детекцию или сегментацию изображения на устройстве. Третий уровень — серверный API, через который синхронизируются задания, результаты обследований, справочники культур и обновления моделей. Четвертый уровень — аналитическая панель для агронома или руководителя, где результаты отображаются на карте поля и в виде отчетов.

Для зерновых культур один из полезных сценариев связан с оценкой урожайности на корню. Традиционно агроном выбирает учетную площадку, подсчитывает количество продуктивных стеблей, оценивает озерненность колоса и использует массу тысячи зерен. Нейросетевая система может автоматизировать часть этих операций: определять колосья на фотографии, считать видимые зерна или элементы структуры урожая, фиксировать координаты и формировать расчет. В простейшем виде расчет потенциальной урожайности может быть выражен формулой $Y = A \cdot B \cdot C / 2500$, где A — количество продуктивных стеблей на площади 0,25 кв. м, B — среднее количество зерен в колосе, C — масса 1000 зерен в граммах, а Y — урожайность в ц/га.

Для масличных культур сценарий может быть адаптирован под биологические особенности культуры. Например, для подсолнечника важны густота стояния, диаметр корзинки, состояние листьев и признаки поражения болезнями. Нейросетевой модуль может помогать выделять растения на изображении, оценивать пропуски в посеве, выявлять повреждения и сохранять результаты в привязке к полю. При накоплении данных за сезон система становится не только инструментом разового расчета, но и журналом наблюдений.

Важное преимущество мобильной реализации заключается в возможности офлайн-работы. На многих сельскохозяйственных территориях стабильная связь отсутствует, поэтому приложение должно выполнять минимум функций автономно: открывать задания, сохранять фотографии, проводить локальный инференс модели и синхронизировать данные позднее. Такой подход повышает практическую применимость системы и снижает зависимость от инфраструктуры.

Полевой цикл работы системы

Внедрение нейросетевого контроля удобно описывать как повторяемый цикл. На первом этапе формируется задание: культура, поле, фаза развития, тип обследования и перечень контрольных точек. На втором этапе агроном выполняет сбор данных: делает фотографии, при необходимости указывает комментарий и отмечает дополнительные признаки. На третьем этапе модель анализирует изображение и выдает результат: класс, вероятность, числовой показатель или маску сегментации.

На четвертом этапе результат проходит валидацию пользователем. Это принципиально важно, потому что агрономическая ошибка может привести к неверной обработке поля. Пользователь должен иметь возможность подтвердить вывод модели, исправить его или отправить изображение на дополнительную проверку. Такие исправления становятся ценными данными для последующего дообучения модели.

На пятом этапе система формирует управленческое действие: рекомендацию провести осмотр, назначить обработку, пересчитать норму внесения или продолжить наблюдение. На шестом этапе данные синхронизируются с сервером, где строится карта проблемных зон и сохраняется история. Благодаря этому контроль становится не разовым актом, а непрерывным процессом наблюдения за состоянием культуры.

Преимущества применения нейронных сетей

Первое преимущество — повышение оперативности. Нейросетевая модель способна обработать изображение за секунды, что особенно важно при массовом обследовании полей. Даже если результат требует подтверждения агрономом, система сокращает время первичной сортировки снимков и помогает быстрее определить приоритетные участки.

Второе преимущество — стандартизация контроля. Алгоритм применяет одну и ту же процедуру анализа к большому числу изображений. Это уменьшает расхождения между наблюдениями разных специалистов и делает динамику показателей более сопоставимой. Для агропредприятия это важно при построении отчетности и сравнении полей между собой.

Третье преимущество — возможность локального воздействия. Если система выделяет конкретные зоны поражения, хозяйство может перейти от сплошной обработки к дифференцированным мероприятиям. Это снижает расход средств защиты растений, удобрений и топлива, а также уменьшает экологическую нагрузку. Подобная логика соответствует принципам точного земледелия и цифровой автоматизации [1, 2].

Четвертое преимущество — накопление базы знаний хозяйства. Каждое обследование создает запись: фото, координаты, культура, фаза развития, вывод модели, решение агронома и итог. Со временем такая база позволяет выявлять устойчивые проблемные зоны, оценивать эффективность обработок и точнее планировать следующий сезон.

Ограничения и риски внедрения

Несмотря на значительный потенциал, нейросетевые системы контроля имеют ограничения. Наиболее распространенная проблема — переносимость модели. Модель, обученная на одном регионе, сорте или наборе условий, может хуже работать на другом поле. Причины включают отличия в освещении, фазе развития, структуре почвы, сорном составе, сортах и агротехнике. Поэтому внедрение должно сопровождаться локальной проверкой качества.

Вторая проблема — качество разметки. Для обучения нужны изображения, где правильно указаны классы болезней, контуры сорняков или объекты подсчета. Ошибки в разметке приводят к тому, что модель воспроизводит неверные закономерности. В сельском хозяйстве это особенно опасно, поскольку визуально похожие симптомы могут иметь разные причины и требовать разных действий.

Третья проблема — интерпретируемость. Пользователь должен понимать, почему система выдала тот или иной результат. В противном случае агроном либо будет слепо доверять модели, либо полностью отвергнет ее выводы. Практическим решением являются тепловые карты, маски сегментации, отображение зоны изображения, повлиявшей на вывод, и возможность сравнить результат с эталонными примерами.

Четвертая проблема — ответственность за решение. Нейронная сеть должна рассматриваться как инструмент поддержки, а не как единственный источник решения. Особенно это важно при назначении химической обработки, оценке экономического ущерба и формировании прогноза урожайности. Итоговое решение должно оставаться за специалистом, а система должна сохранять исходные данные и историю изменений.

Пятая проблема — техническая эксплуатация. Мобильное приложение должно корректно работать на устройствах с разной производительностью, экономно расходовать батарею, хранить данные без потерь и безопасно синхронизировать результаты. Если система неудобна в поле, даже точная модель не будет использоваться регулярно.

Оценка эффективности нейросетевого контроля

Оценивать нейросетевую систему необходимо на нескольких уровнях. Первый уровень — технические метрики модели. Для классификации используются accuracy, precision, recall и F1-мера; для сегментации — IoU и Dice; для регрессии урожайности — MAE, RMSE и MAPE. Однако высокие

лабораторные показатели не гарантируют практической эффективности, если тестовые данные не отражают реальные условия эксплуатации.

Второй уровень — агрономическая полезность. Система должна не просто распознавать изображение, а помогать принимать решения. Поэтому важно измерять, насколько раньше выявляется проблема, уменьшается ли площадь необоснованных обработок, сокращается ли время обследования и повышается ли точность расчетов урожайности.

Третий уровень — экономический эффект. Для хозяйства важны затраты на внедрение, обучение персонала, обслуживание серверов, обновление моделей и покупку оборудования. Экономическая выгода появляется тогда, когда система снижает потери урожая, уменьшает перерасход ресурсов или повышает производительность специалистов. В этом смысле нейросетевой контроль должен оцениваться как часть производственного процесса, а не как отдельная техническая демонстрация.

Четвертый уровень — устойчивость эксплуатации. Система должна сохранять качество при изменении сезона, культуры, региона и устройства съемки. Для этого необходимы регулярное пополнение датасета, контроль ошибок, версия моделей и процедура обратной связи от пользователей.

Перспективы развития

В ближайшие годы можно ожидать дальнейшего сближения нейронных сетей, мобильных приложений и систем управления агропредприятиями. Наиболее перспективным направлением является мультимодальный анализ, при котором модель одновременно учитывает фотографию растения, координаты, погодные данные, фазу развития, историю обработок и спутниковые индексы. Такой подход способен лучше отличать болезнь от стрессов, вызванных погодой или дефицитом питания.

Еще одно направление — использование облегченных архитектур для работы на мобильных устройствах. Модели должны быть достаточно точными, но при этом компактными и быстрыми. Для этого применяются

квантование, обрезка сети, дистилляция знаний и специальные мобильные архитектуры. Это особенно важно для малых хозяйств, где нет возможности постоянно использовать облачные вычисления.

Перспективным также является федеративное обучение. Оно позволяет улучшать модель на данных разных хозяйств без передачи исходных изображений на общий сервер. Для сельского хозяйства это важно из-за вопросов коммерческой тайны, персональных данных и права собственности на агрономическую информацию. При полноценной реализации такой подход может ускорить накопление данных и одновременно снизить риски утечки данных.

Наконец, нейросетевой контроль будет развиваться в сторону более тесной интеграции с исполнительными механизмами: роботизированной прополкой, дифференцированным внесением средств защиты растений, автоматическим планированием маршрутов обследования и системами предупреждения. В этом случае модель становится не только аналитическим модулем, но и частью автоматизированного управления агропроизводством.

Заключение

Применение нейронных сетей для автоматизации контроля сельскохозяйственных культур является одним из наиболее перспективных направлений цифрового земледелия. Нейросетевые методы позволяют анализировать изображения растений, выделять признаки болезней и сорняков, оценивать состояние посевов, подсчитывать элементы урожайной структуры и строить прогнозы на основе разнородных данных.

Наиболее практичным вариантом внедрения является не изолированная модель, а прикладная система, объединяющая мобильное приложение, локальный инференс, серверную синхронизацию и накопление истории наблюдений. Концепция «Цифровой агроном» показывает, как идеи компьютерного зрения могут быть связаны с повседневной работой агронома:

от фотофиксации в поле до расчета урожайности и формирования карты проблемных зон.

При этом нейронные сети не отменяют роль специалиста. Их эффективность зависит от качества данных, локальной адаптации, понятности результата и правильной организации производственного процесса. Поэтому оптимальной является гибридная модель, в которой алгоритм выполняет быстрый анализ и рутинные операции, а агроном принимает итоговое решение с учетом опыта, экономических факторов и агротехнического контекста.

Таким образом, автоматизация контроля культур с применением нейронных сетей способна повысить точность наблюдений, сократить трудозатраты, ускорить обнаружение проблем и создать основу для более рационального использования ресурсов. Дальнейшее развитие таких систем связано с расширением полевых датасетов, мультимодальными моделями, мобильным инференсом и безопасным обменом агрономическими данными.

Список используемых источников:

1. ФАО. Продовольственная и сельскохозяйственная организация ООН. Состояние продовольствия и сельского хозяйства – 2022. Использование автоматизации в сельском хозяйстве для трансформации агропродовольственных систем. Рим: ФАО, 2022. DOI: 10.4060/cb9479en. [Электронный ресурс] URL: <https://www.fao.org/3/cb9479en/cb9479en.pdf> (дата обращения: 10.07.2026)
2. Wolfert S., Ge L., Verdouw C., Bogaardt M.-J. Большие данные в умном земледелии – обзор // Agricultural Systems. 2017. Vol. 153. P. 69–80. DOI: 10.1016/j.agsy.2017.01.023. [Электронный ресурс] URL: <https://doi.org/10.1016/j.agsy.2017.01.023> (дата обращения: 10.07.2026)
3. Liakos K. G., Busato P., Moshou D., Pearson S., Bochtis D. Машинное обучение в сельском хозяйстве: обзор // Sensors. 2018. Vol. 18, no. 8. Article

2674. DOI: 10.3390/s18082674. [Электронный ресурс] URL: <https://doi.org/10.3390/s18082674> (дата обращения: 10.07.2026)

4. Kamilaris A., Prenafeta-Boldú F. X. Глубокое обучение в сельском хозяйстве: обзор // *Computers and Electronics in Agriculture*. 2018. Vol. 147. P. 70–90. DOI: 10.1016/j.compag.2018.02.016. [Электронный ресурс] URL: <https://doi.org/10.1016/j.compag.2018.02.016> (дата обращения: 10.07.2026)

5. Mohanty S. P., Hughes D. P., Salathé M. Использование глубокого обучения для обнаружения болезней растений по изображениям // *Frontiers in Plant Science*. 2016. Vol. 7. Article 1419. DOI: 10.3389/fpls.2016.01419. [Электронный ресурс] URL: <https://doi.org/10.3389/fpls.2016.01419> (дата обращения: 10.07.2026)

6. Ferentinos K. P. Модели глубокого обучения для обнаружения и диагностики болезней растений // *Computers and Electronics in Agriculture*. 2018. Vol. 145. P. 311–318. DOI: 10.1016/j.compag.2018.01.009. [Электронный ресурс] URL: <https://doi.org/10.1016/j.compag.2018.01.009> (дата обращения: 10.07.2026)

7. Sladojevic S., Arsenovic M., Anderla A., Culibrk D., Stefanovic D. Распознавание болезней растений по классификации изображений листьев на основе глубоких нейронных сетей // *Computational Intelligence and Neuroscience*. 2016. Article ID 3289801. DOI: 10.1155/2016/3289801. [Электронный ресурс] URL: <https://doi.org/10.1155/2016/3289801> (дата обращения: 10.07.2026)

8. Lu Y., Yi S., Zeng N., Liu Y., Zhang Y. Идентификация болезней риса с помощью глубоких сверточных нейронных сетей // *Neurocomputing*. 2017. Vol. 267. P. 378–384. DOI: 10.1016/j.neucom.2017.06.023. [Электронный ресурс] URL: <https://doi.org/10.1016/j.neucom.2017.06.023> (дата обращения: 10.07.2026)

9. Rahman C. R., Arko P. S., Ali M. E., Khan M. A. I., Apon S. H., Nowrin F., Wasif A. Идентификация и распознавание болезней и вредителей

риса с помощью сверточных нейронных сетей // arXiv:1812.01043. 2018.
[Электронный ресурс] URL: <https://arxiv.org/abs/1812.01043> (дата обращения:
10.07.2026)