

Искусственный интеллект и дистанционное зондирование Земли в сельском хозяйстве: обзор

А. Н. Сафонова¹, Ю. А. Маглинец², Д. И. Каплун¹

¹ Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, 197022, Россия
E-mails: safonova.nastya1@gmail.com, dikaplun@etu.ru

² Сибирский федеральный университет, Красноярск, 660041, Россия
E-mail: ymaglinets@sfu-kras.ru

В третьем десятилетии XXI в. развитие методов искусственного интеллекта позволило вывести соответствующие алгоритмы, в частности, основанные на моделях глубокого обучения (ГО), на первые позиции при анализе данных ДЗЗ в агромониторинге, позволяя повысить точность и эффективность при решении задач обнаружения объектов и их классификации, анализа изменений и др. Было опубликовано около тысячи статей, включая около 69 обзорных. Однако ни одно исследование не пыталось охватить весь спектр достижений в приложениях ГО с ДЗЗ в агромониторинге. Цель данного обзора заключается в выявлении основных трендов и пробелов в знаниях при разработке приложений дистанционного агромониторинга посредством изучения соответствующих обзоров. Следуя рекомендуемым руководящим принципам, были выявлены 37 обзорных исследований, опубликованных в период с 2020 по март 2024 г. В выбранных обзорах обсуждаются различные задачи агромониторинга и методы их решения, включая такие аспекты, как архитектуры ГО, источники данных, оценка производительности моделей, возникающие проблемы. Используя библиометрический анализ, настоящее исследование выявило общие темы, выделило производительность моделей ГО, пробелы в знаниях и тенденции развития этой области знаний. Насколько нам известно, в этой статье представлен наиболее полный обзор данной области и обозначены будущие направления исследований.

Ключевые слова: искусственный интеллект, глубокое обучение, дистанционное зондирование Земли, агромониторинг, сельское хозяйство, обзор

Одобрена к печати: 24.10.2025
DOI: 10.21046/2070-7401-2026-23-3-9-24

Введение

Сельскохозяйственные системы производят продукты питания, волокна и биоэнергетические ресурсы, важные для общества, при этом отрицательно влияя на биоразнообразие и способствуя изменению климата из-за выбросов парниковых газов. Аэрокосмические исследования, в сравнении с традиционными средствами наблюдения состояния агроценозов, позволяют получить существенную экономию средств и оперативность в принятии решений. Глубокое обучение (ГО) позволило революционизировать способы обработки данных и в задачах мониторинга, прогнозирования и анализа закономерностей в больших пространственных и временных масштабах. Использование методов ГО, способных автоматически извлекать сложные характеристики из больших объёмов данных, привело к значительному улучшению точности и эффективности решения различных задач сельскохозяйственного прогнозирования. Темы, охватываемые приложениями ГО в дистанционном агромониторинге, обширны и быстро развиваются. Например, обсуждаются такие задачи, как прогнозирование урожайности (Darra et al., 2023; Darwin et al., 2021; Joshi et al., 2023; Yu et al., 2024), болезни растений (Abbas et al., 2023; Kouadio et al., 2023; Kuswidiyanto et al., 2022; Ouhami et al., 2021), картирование (García-Berná et al., 2020; Joshi et al., 2023; Messina, Modica, 2022), обнаружение риса (Rosle et al., 2021; Zheng et al., 2022), управление оливковыми садами (Messina, Modica, 2022), производство кофе (Hunt et al., 2020), обнаружение сои (Arjoune et al., 2022; Darwin et al., 2021), обнаружение сорняков (Liu et al., 2021; Mesías-Ruiz et al., 2023; Rakhmatulin et al., 2021) и прочее.

С 2016 г. исследователи начали активно внедрять алгоритмы ГО в различные задачи анализа изображений с использованием дистанционного зондирования Земли (ДЗЗ) в области сельского хозяйства, включая классификацию сцен (Nawaz et al., 2022; Rakhmatulin et al., 2021; Teixeira et al., 2023) и обнаружение объектов (Ariza-Sentís et al., 2024; Kouadio et al., 2023; Nawaz et al., 2022; Shi et al., 2020). Первоначально применялись алгоритмы ГО на основе многослойных скрытых нейронных сетей (НС). Такие алгоритмы называются глубокими НС (Rakhmatulin et al., 2021). Кроме того, рекуррентные НС активно использовались для обработки последовательности данных (Cao et al., 2023; Mesías-Ruiz et al., 2023). Далее, своё развитие получили такие алгоритмы, как автокодировщики (Jiang, 2018), генеративно-сопоставительные сети (Jozdani et al., 2022), длинная краткосрочная память (Astolfi et al., 2021), трансформаторы (Wang et al., 2024) и другие. За период с 2016 по 2023 г. почти четыре тысячи публикаций о внедрении ГО в дистанционный агромониторинг. В среднем количество статей растёт со скоростью 60 % в год (рис. 1).




Рис. 1. Количество статей в период с 2016 по июль 2024 г., посвящённых внедрению алгоритмов ГО в дистанционный агромониторинг на основе базы данных Web of Science Core Collection

С резким расширением научной сферы количество обзорных статей продолжает расти с каждым годом. По состоянию на июль 2024 г. в области дистанционного агромониторинга насчитывается около 69 обзорных статей, посвящённых приложениям ГО. Каждая из этих статей вносит вклад в консолидацию знаний по конкретной теме. Однако в настоящее время отсутствуют исследования, предоставляющие всесторонний обзор текущих достижений по ключевым направлениям в данной области, что затрудняет понимание общего состояния исследований и позиционирование собственных работ в этой сфере.

Цель настоящего обзорного исследования заключается в охвате всего прогресса в области приложений ГО в аэрокосмическом агромониторинге за период с 2020 по март 2024 г. посредством анализа существующих обзорных статей и определения ключевых тематических направлений. Хотя провести полный обзор всех соответствующих исследований невозможно, мы считаем, что анализ обзорных статей может быть эффективным способом охвата основных направлений.

В рамках данного подхода мы определяем ключевые темы, которые привлекли внимание в последние годы, и меньше акцентируем внимание на темах, появившихся относительно недавно. Определяются и анализируются объём и разнообразие приложений, включая классификацию изображений, обнаружение объектов, выявление изменений и картографирование земельного покрова. Эффективность и точность алгоритмов и архитектур ГО в задачах ДЗЗ оцениваются на основе синтеза изученной литературы. Данный анализ сравнивает различные подходы и определяет наиболее эффективные стратегии для конкретных приложений.

Кроме того, методы, применяемые в рассматриваемых исследованиях, включая предварительную обработку данных, сетевые архитектуры, алгоритмы оптимизации и методы интерпретации моделей критически оцениваются. Определяются сильные и слабые стороны этих методов, а также выделяются потенциальные области для улучшения.

Методы

Для проведения настоящего обзора мы использовали методологию, изложенную в работе (Arksey, O'Malley, 2005) и Д. Левак с соавторами (Levac et al., 2010), а также руководящие рекомендации по осуществлению обзорных исследований (Westphaln et al., 2021). Обзор реализует методологический подход к синтезу знаний, который включает определение преобладающих тенденций и выявление ключевых проблем в рамках определённой области знаний или академической дисциплины. Данный подход предназначен для предоставления исследователям, политикам и практическим специалистам информативных идей, способствующих принятию обоснованных решений и научному прогрессу. Основным исследовательским интересом в настоящей статье был сосредоточен на изучении приложений ГО в области ДЗЗ на основе любого типа обзорной статьи. Мы выделили пять шагов этой методологии: а) выявление релевантных исследований; б) отбор исследований; в) составление диаграммы данных; г) сравнение, обобщение и представление результатов и д) определение проблем и ограничений. Для построения диаграммы данного обзора использовалось методическое руководство «Предпочтительные элементы отчётности для систематических обзоров и метаанализов» PRISMA (англ. Preferred Reporting Items for Systematic reviews and Meta-Analyses) (Haddaway et al., 2022).

Источник данных и критерии поиска

Поиск литературы проводился 4 июля 2024 г. в электронной базе данных Web of Science. Критерии поиска не ограничивались датой, временем, темой или типом исследования. Однако в запрос был включён критерий отбора «обзорные статьи». Для поиска данных мы использовали следующие ключевые слова: {«дистанционное зондирование Земли» И «глубокое обучение» И «сельское хозяйство»}.

Критерии отбора

Критерии приемлемости для включения статьи в обзор были следующими: а) рецензирование; б) доступ к полной версии статьи и в) включение тем «глубокое обучение», «дистанционное зондирование» и «сельское хозяйство».

Выборка обзорных публикаций

Отбор релевантных обзорных статей проводился в три этапа. На первом этапе проверялись только заголовки и аннотации для исключения статей, не соответствующих критериям включения. На втором этапе авторы просматривали полные тексты статей и осуществляли их отбор. Важно отметить, что разногласия разрешались через обсуждения с участием всех авторов. Третий этап заключался в извлечении и обобщении данных.

Обобщение и синтез данных

Данные были объединены в электронную таблицу и импортированы в программное обеспечение Zotero для проведения обзора и отбора релевантных статей на основе анализа названий и аннотаций обзорных статей. Затем данные, включая результаты всех этапов фильтрации, были экспортированы из базы данных Web of Science в формате BibTex для дальнейшего анализа.

Результаты

Поиск и отбор обзорных публикаций

Мы выявили 69 статей в базе данных Web of Science по состоянию на 4 июля 2024 г. (шаг 1). Поисковый запрос охватывал все годы, представленные в базе данных, подлежащим нахождению временем стал период с 2020 по июль 2024 г. После удаления дубликатов и исключения статей не обзорного характера были отобраны 69 уникальных ссылок для анализа заголовков и аннотаций с целью их включения в настоящее исследование (шаг 2). На шаге 3 были исключены 11 статей как «неполнотекстовые», поскольку они не соответствовали критериям нашего обзора. Полнотекстовые версии всех оставшихся исследований были получены и проанализированы на шаге 4, что привело к отбору 42 статей. На шаге 5 были исключены некоторые работы по следующим причинам: нерелевантность, отсутствие упоминания о домене ДЗЗ или отсутствие ссылок на ГО и сельскохозяйственную область. В результате для детального анализа было отобрано 37 исследований. Процесс отбора релевантных обзорных статей был выполнен в соответствии с блок-схемой PRISMA (рис. 2) (Haddaway et al., 2022; Rethlefsen et al., 2021).




Рис. 2. Диаграмма потока PRISMA иллюстрирует стратегию поиска, показывая этапы идентификации и отбора статей. В результате этого процесса было отобрано 37 обзорных статей, признанных приемлемыми для включения в обзор, охватывающий период с 2020 по июль 2024 г.

Основные характеристики включённых обзорных публикаций

Количество обзорных статей увеличилось за последние пять лет, однако остаётся относительно низким (максимум 10 статей в 2023 г.) по сравнению с общим числом публикаций по соответствующим темам (рис. 3а, см. с. 13). Этот контраст может свидетельствовать о том, что, хотя количество приложений продолжает расти, скорость увеличения тем исследований (см. рис. 3б) не успевает за ростом числа приложений. Таким образом, наш подход представляется эффективным для выявления ключевых тем в быстро развивающейся области.

Типы обзорных статей включали систематические, общие, комплексные обзоры, обзоры современного состояния и литературные обзоры. Некоторые обзоры включали также другие типы, такие как краткий, библиометрический, контекстуальный обзор и метаанализ. Основные различия между этими типами обзоров заключаются в следующем:

- Систематический обзор подразумевает структурированный и методический подход к выявлению, отбору и анализу соответствующих исследований по конкретному вопросу.
- Общий обзор предоставляет общий анализ исследований, проведённых в определённой области.
- Комплексный обзор охватывает широкий спектр исследований, теорий и концепций, связанных с определённой темой.
- Современный обзор акцентирует внимание на самых актуальных и передовых исследованиях в данной области.
- Литературный обзор следует считать обобщающим термином, который охватывает различные типы работ, суммирующих и оценивающих существующую литературу по теме, однако уровень детализации и строгости может значительно варьироваться.
- Краткий обзор предлагает сжатую версию основных результатов исследований по определённой теме.
- Библиометрический обзор включает количественный анализ моделей публикаций, частоты цитирования и других библиографических данных для изучения тенденций, влияний и взаимосвязей в данной области.
- Контекстуальный анализ обеспечивает исследование релевантной литературы и исследований.
- Метаанализ можно определить как статистический метод, объединяющий данные из нескольких исследований для получения количественного резюме или оценки общего эффекта или результата, представляющего интерес.




Рис. 3. Основные характеристики включённых обзорных статей с января 2015 по июль 2023 г.:
 а — количество обзорных статей в год; б — типы обзоров; в — области исследований

Большинство публикаций относилось к теме ДЗЗ, достигнув 56,7 % (21/37). Науки о технологиях составили 43,2 % (16/37), науки об окружающей среде — 40,5 % (15/37), науки о Земле — 37,8 % (14/37), науки о растениях — 18,9 % (7/37), агрономия — 16,2 % (6/37), сель-

ское хозяйство — 5,4 % (2/37) и другие категории — 10,8 % (4/37) (см. *рис. 3в*). Следует отметить, что одной статье может быть присвоено несколько категорий.

Наибольшее количество статей было опубликовано в издательстве MDPI (*англ.* Multidisciplinary Digital Publishing Institute) — 64,8 % (24/37), наиболее релевантными источниками выступают журналы Remote Sensing, Agriculture, Agronomy, Applied Sciences, Drones и Sensors. Далее следуют публикации в Elsevier — 16,2 % (6/37), Frontiers — 5,4 % (2/37), Taylor and Francis — 5,4 % (2/37) и другие источники — 10,8 % (4/37).




Рис. 4. График совпадения ключевых слов на английском языке

Три наиболее цитируемых документа были представлены М. Вайс с соавторами (Weiss et al., 2020), Т. Каттенборном с коллегами (Kattenborn et al., 2021) и В. Ши и др. (Shi et al., 2020). Вайс с соавторами (Weiss et al., 2020) представили обзор метаанализа, в котором обсуждают важность мониторинга роста и состояния сельскохозяйственных культур с использованием технологий ДЗЗ в различных экологических контекстах и временных разрешениях. Они подчеркнули необходимость мониторинга в режиме, близком к реальному времени, для оперативного реагирования на экстремальные события и для устойчивой оптимизации методов управления. Каттенборн с коллегами (Kattenborn et al., 2021) акцентируют внимание на значении ДЗЗ в таких задачах, как сохранение природных ресурсов, лесное и сельское хозяйство. В работе освещаются достижения в таких технологиях, как радиолокация с синтезированной апертурой и беспилотные летательные аппараты (БПЛА), для детальных наблюдений за растительным покровом. Также исследуется, как ГО, в частности свёрточные НС, революционизирует анализ пространственных закономерностей в данных наблюдения за Землёй. Ши с коллегами (Shi et al., 2020) сосредоточены на современных методах, приложениях и проблемах применения искусственного интеллекта (ИИ) для обнаружения изменений с использованием данных ДЗЗ. В статье обсуждается, как технологии ИИ могут улучшить процессы обнаружения изменений в различных областях, таких как городское планирование,

мониторинг окружающей среды, сельское хозяйство, оценка стихийных бедствий и обновление карт. Цель обзора — освещение процесса внедрения, источников данных, фреймворков и областей применения методов обнаружения изменений на основе ИИ.

Используя анализ совпадений ключевых слов, мы обнаружили, что наиболее распространёнными и часто встречающимися ключевыми словами в исследованиях были: глубокое обучение (15 из 37), дистанционное зондирование (14 из 37), классификация (14 из 37), машинное обучение (8 из 37), сельское хозяйство (6 из 37), точное земледелие (6 из 37), БПЛА (5 из 37), обнаружение объектов (3 из 37) и другие (рис. 4, см. с. 14). Наибольший кластер (красный) представляет собой центральную область с использованием таких ключевых слов, как дистанционное зондирование, глубокое обучение, машинное обучение и сельское хозяйство. В то время как другой кластер (синий) демонстрирует более специфические термины, а именно: гиперспектральное изображение, изображение, компьютерное зрение, обработка, глубокая НС и другие. Тематика охватывает обработку изображений, извлечение признаков, интерпретацию и реконструкцию изображений.

Обзор сельскохозяйственных задач в приложениях глубокого обучения для дистанционного зондирования Земли

С использованием технологий ГО и ДЗЗ было успешно решено множество различных задач (рис. 5), таких как обнаружение болезней растений (Abbas et al., 2023; Bouguettaya et al., 2022; Kouadio et al., 2023; Kuswidiyanto et al., 2022; Neupane, Baysal-Gurel, 2021; Ouhami et al., 2021), точное управление сельским хозяйством (Ariza-Sentís et al., 2024; Liu et al., 2021; Radočaj et al., 2023), прогнозирование урожайности (Darra et al., 2023; Darwin et al., 2021; Yu et al., 2024), картирование (García-Berná et al., 2020; Joshi et al., 2023; Li et al., 2020), интеллектуальное земледелие (El Sakka et al., 2024; Mohamed et al., 2021), обнаружение сорняков (Rakhmatulin et al., 2021; Rosle et al., 2021; Sharma et al., 2022) и многие другие.




Рис. 5. Сельскохозяйственные задачи с использованием приложений ГО и ДЗЗ за последние 5 лет, где каждый год представлен отдельным цветом, а цифры в прямоугольниках указывают количество публикаций, посвящённых каждой задаче в соответствующем году

Также представлены обзоры, посвящённые изучению конкретных культур: картирование кофе (Hunt et al., 2020), мониторинг риса (Zheng et al., 2022), управление оливковыми садами (Messina, Modica, 2022) и обнаружение сои (Arjoune et al., 2022; Astolfi et al., 2021). Кроме того, выполнены обширные исследования по задачам ГО, таким как классификация изображений (Bouguettaya et al., 2022; Teixeira et al., 2023), обнаружение объектов (Cao et al., 2023; Nawaz et al., 2022; Shi et al., 2020) и сегментация изображений (Li et al., 2024).

Для решения различных типов задач использовались разные типы данных ДЗЗ, а именно: гиперспектральные (García-Berná et al., 2020; Kuswidiyanto et al., 2022), мультиспектральные (Zheng et al., 2022), оптические (Hunt et al., 2020; Teixeira et al., 2023). В отдельный класс вынесены вопросы получения изображений с помощью БПЛА (Bouguettaya et al., 2022; Cao et al., 2023; Kouadio et al., 2023; Liu et al., 2021; Neupane, Baysal-Gurel, 2021; Shahi et al., 2023; Tanaka et al., 2024), а также тематика консолидации мультимодальных данных (Teixeira et al., 2023; Zheng et al., 2022). Гиперспектральные данные, как правило, собираются с использованием сенсоров высокого спектрального разрешения, таких как HyMap (*англ.* Hyperspectral Mapper), AVIRIS (*англ.* Airborne Visible/Infrared Imaging Spectrometer) или Hyperion, и обеспечивают детальную информацию о химическом составе и состоянии поверхности. Мультиспектральные данные обычно получают со спутников, например Sentinel-2, Landsat-8, которые обеспечивают баланс между пространственным и спектральным разрешением. Оптические данные включают в себя как панхроматические, так и RGB-изображения (*англ.* Red, Green, Blue), полученные с орбитальных или воздушных платформ. Для получения изображений с БПЛА часто применяются RGB-камеры высокого разрешения, мульти- и гиперспектральные сенсоры, а также тепловизоры, установленные на дронах различных конфигураций (например, DJI Phantom, Mavic, eBee, Matrice). Мультимодальные подходы включают в себя интеграцию данных из разных источников, таких как спутниковые изображения, данные с БПЛА, а также табличные и метеорологические данные, что позволяет улучшить точность предсказаний и повысить устойчивость моделей к неполному или зашумлённому вводу.

Хотя данные ДЗЗ, получаемые со спутников, пользуются большой популярностью, в сельском хозяйстве чаще применяются БПЛА (Abbas et al., 2023; Rejeb et al., 2022). Дроны играют ключевую роль в мониторинге, обнаружении и диагностике состояния сельскохозяйственных культур. Особенно широко применяются многороторные БПЛА, такие как DJI Phantom 4 RTK, DJI Matrice 300 RTK и SenseFly eBee, благодаря их манёвренности, стабильности и возможности установки различных типов сенсоров. Наиболее часто используются трёхканальные RGB-камеры (например, Sony Alpha, DJI Zenmuse X5), охватывающие красный, зелёный и синий спектры, однако для более совершенного анализа всё чаще применяются мультиспектральные камеры (например, MicaSense RedEdge-MX, Parrot Sequoia) и тепловизоры (например, FLIR Vue Pro). Эти сенсоры позволяют фиксировать физиологическое состояние растений, оценивать вегетационные индексы (NDVI (*англ.* Normalized Difference Vegetation Index), GNDVI (*англ.* Green Normalized Difference Vegetation Index) и т. д.), определять влажность почвы и выявлять стрессовые факторы на ранних стадиях.

Обнаружение в реальном времени зачастую реализуется на основе периферийных вычислений (*англ.* edge computing) с использованием встроенных вычислительных модулей, таких как NVIDIA Jetson Nano, Jetson Xavier или Raspberry Pi, интегрированных с БПЛА. Эти устройства позволяют выполнять предварительную обработку изображений, сегментацию, классификацию и принятие решений на месте без необходимости передачи данных на удалённые серверы, что значительно ускоряет цикл принятия решений и снижает требования к каналу связи.

Преимущества технологии дронов включают высокое пространственное разрешение (до 1–2 см/пиксель), оперативность получения данных, гибкость использования и возможность охвата значительных территорий при сравнительно низких затратах (Abbas et al., 2023; Rejeb et al., 2022). Это делает их надёжным инструментом для мониторинга сельскохозяйственных угодий, позволяя не только снизить потребность в ручном труде, но и повысить эффективность управления полевыми работами. Беспилотные летательные аппараты активно

применяются для раннего выявления заболеваний растений, стресса от недостатка воды или питательных веществ, а также для оценки биомассы и прогнозирования урожайности, позволяя фермерам принимать обоснованные агрономические решения и минимизировать потери урожая.

Методы глубокого обучения, обычно используемые для дистанционного зондирования Земли

За последние пять лет ИИ и ГО произвели революцию в сельскохозяйственной отрасли, обеспечив более точный и эффективный анализ изображений. В данном разделе представлены основные методы ГО, которые наиболее часто применяются для решения различных сельскохозяйственных задач. К числу этих методов относятся свёрточные НС (27/37), временное моделирование (8/37) (Cao et al., 2023; Joshi et al., 2023; Liu et al., 2021; Mesías-Ruiz et al., 2023; Nawaz et al., 2022; Neupane, Baysal-Gurel, 2021; Rakhmatulin et al., 2021; Tanaka et al., 2024), трансферное обучение (3/37) (Arjoun et al., 2022; Rakhmatulin et al., 2021; Teixeira et al., 2023), трансформаторы (2/37) (Teixeira et al., 2023; Wang et al., 2024), а также неконтролируемое или полуконтролируемое обучение (1/37) (Shi et al., 2020) и другие.

Свёрточные НС являются одним из самых эффективных инструментов для детекции различных типов растительности по данным ДЗЗ. Они широко применяются для решения таких задач, как обнаружение отдельных растений, их сегментация и выявление болезней растений. Многие исследования утверждают, что этот метод превосходит традиционные методы машинного обучения. Модульность общих архитектур ГО обеспечивает высокую гибкость в адаптации, что позволяет применять их в мультимодальных приложениях. Наиболее часто используемые архитектуры НС включают AlexNet, VGG-16, VGG-19, ResNet-50, DenseNet и U-Net.

Другим важным методом ГО, активно применяемым в задачах мониторинга растительности, представляется временное моделирование. Этот подход особенно эффективен при анализе последовательных наблюдений за состоянием культур, позволяя выявлять динамику роста, аномалии и предсказывать развитие стрессовых факторов. Временное моделирование нашло широкое применение в различных сельскохозяйственных сценариях, особенно в сочетании с данными, полученными с БПЛА, оснащёнными RGB-, мультиспектральными и тепловизионными камерами. Используемые платформы включают как лёгкие дроны с фиксированным крылом, обеспечивающие длительное время полёта, так и манёвренные многороторные модели для локального и детального мониторинга. Обнаружение объектов в реальном времени представляет собой сложную задачу, включающую не только аппаратное (дроны, сенсоры, вычислительные модули), но и программное (алгоритмы компьютерного зрения и обработки данных) обеспечение. Для реализации потоковой обработки часто применяются одноплатные компьютеры и GPU-модули (например, NVIDIA Jetson Xavier NX, Jetson Nano или Google Coral TPU), которые монтируются непосредственно на дронах или наземных станциях. Эти устройства позволяют не только собирать данные, но и обрабатывать видеопоток или серию изображений в реальном времени, выполняя задачи детекции, классификации и сегментации без задержек, что критически важно при реагировании на чрезвычайные ситуации (например, выявление очагов болезней, пожаров, вредителей). Наиболее распространёнными алгоритмами для обнаружения объектов в реальном времени являются YOLO (*англ.* You Only Look Once), в различных версиях (YOLO-V3, V4, V5), MobileNet-V2, U-Net, SSD (*англ.* Single Shot Detection), FCN (*англ.* Fully Convolutional Networks), а также классические архитектуры, такие как AlexNet, ResNet-18 и SegNet. Эти модели успешно внедряются в задачи семантической и инстанс-сегментации, подсчёта растений, распознавания видов культур, а также детектирования стрессов и заболеваний. Использование лёгких и оптимизированных моделей (например, Tiny-YOLO или MobileNet-SSD) особенно актуально в условиях ограниченных вычислительных ресурсов на борту дронов, где важны как точность, так и скорость обработки.

Трансферное обучение представляет собой один из самых мощных методов ГО, часто используемых для повышения точности классификации объектов и улучшения производительности алгоритмов. Этот метод позволяет переносить знания модели, предварительно обученной на большом наборе данных, на новый набор данных, содержащий похожие объекты, или на меньший обучающий набор. Использование трансферного обучения может существенно повысить точность классификации культур при первоначальном обучении на значительном наборе данных с аналогичными характеристиками. Однако данный метод наиболее эффективен, когда исходные и целевые наборы данных имеют схожие свойства, а количество обучающих образцов ограничено (Safonova et al., 2023). Использование трансферного обучения продемонстрировало многообещающие результаты в классификации культур, снижая требования к объёмам данных для обучения модели ГО.

Для решения проблемы забывания информации в рекуррентных НС с течением времени и медленной скорости обработки данных были разработаны преобразователи. Механизм самовнимания выступает основным элементом модели преобразователя, фиксируя контекстную информацию для каждого элемента входной последовательности. Стандартная модель преобразователя состоит из четырёх модулей: входного, выходного, кодера и декодера, где последние два реализуют механизмы самовнимания. Исследования показывают, что преобразователи, в отличие от рекуррентных НС, достигают более высокой точности на больших наборах данных, однако у них существует тенденция к переобучению на малых наборах данных. Преобразователи чаще всего применяются для таких задач, как картирование типов культур, прогнозирование урожайности риса и обнаружение заболеваний ложной мучнистой росой.

Неконтролируемое и полуконтролируемое обучение стали важными методами из-за проблем маркировки больших наборов данных, а также требуемых временных и трудовых затрат. Хотя неконтролируемое обнаружение изменений не требует маркированных обучающих образцов, отсутствие предварительных знаний иногда делает его непригодным для задач, требующих семантической информации. Полуконтролируемое обучение использует неточные или недостаточно маркированные образцы в качестве априорных знаний для решения этой проблемы, что может быть реализовано с использованием методов агрегации меток, итеративного обучения, глубоких генеративных моделей, стратегий генерации образцов или новых функций стоимости.

Проблемы, ограничения и будущие направления исследований

Как показано в анализируемой литературе, основные проблемы и ограничения применения ИИ и ГО для ДЗЗ в сельском хозяйстве связаны с ограниченностью и недостаточностью данных (Arjoune et al., 2022). Для успешной реализации решений в различных географических регионах и для разных сельскохозяйственных культур необходимо разработать эффективные, действенные и обобщаемые модели, а также уделить внимание прозрачности прогнозов (Joshi et al., 2023). Также отмечается высокая стоимость гиперспектральных изображений. Качество изображений по-прежнему зависит от внешних факторов, таких как время съёмки, погодные условия, изменения в освещении, неисправности или ошибки при обслуживании оборудования и окклюзия объектов (Rakhmatulin et al., 2021). Эти факторы приводят к использованию небольших наборов данных, что может негативно сказаться на производительности моделей ИИ.

Несмотря на это, были разработаны различные методы ГО, позволяющие эффективно работать с небольшими выборками. С другой стороны, некоторые исследования указывают на сложность обработки больших наборов данных, что требует значительных вычислительных ресурсов от НС. Недостаток вычислительных мощностей может привести к неоптимальным решениям при обучении моделей ГО. Кроме того, существуют две другие важные проблемы: нехватка общедоступных наборов данных для обучения алгоритмов ГО и сложность одновременной классификации нескольких классов (например, различных болезней расте-

ний и вредителей), что ограничивает эффективность алгоритмов ГО (Ariza-Sentís et al., 2024). Вычислительная эффективность становится всё более актуальной проблемой для ГО; по мере увеличения объёма данных и сложности моделей растут и требования к вычислительной мощности.

Несмотря на широкую популярность и эффективность применения ГО и ДЗЗ в сельском хозяйстве, остаётся ряд нерешённых вопросов, представляющих собой направления для будущих исследований. В последние годы наблюдается растущая тенденция к внедрению приложений ИИ в сельскохозяйственный сектор, который считается одним из наиболее перспективных направлений развития экономики. Будущие исследования могут быть сосредоточены на интеграции данных с нескольких датчиков, слиянии данных, работе с малыми данными, данными полевых экспериментов, организации хранилищ данных, а также на использовании методов машинного обучения, таких как ансамблевое обучение и генетические алгоритмы, для повышения точности прогнозирования физиологических признаков сельскохозяйственных культур (Ouhami et al., 2021; Safonova et al., 2023; Tanaka et al., 2024). Реализация высокоточных карт для выявления сельскохозяйственных культур и сорняков с использованием данных ДЗЗ может быть дополнительно усовершенствована (Rosle et al., 2021).

Перспективы ИИ в сельском хозяйстве также могут включать вопросы гетерогенной обработки больших наборов данных, неконтролируемого ИИ, надёжность ИИ и концепцию граничного интеллекта (Shahi et al., 2023). Увеличение доступности методов визуализации признаков, изученных с помощью свёрточных НС, поможет не только интерпретировать, но и обучаться на таких моделях, улучшая понимание сигналов растительности, полученных из ДЗЗ (Kattenborn et al., 2021). Однако, поскольку трансформаторы требуют больше параметров, чем свёрточные НС, необходимо продолжить исследования по повышению скорости вывода для улучшения производительности трансформаторов (Teixeira et al., 2023; Wang et al., 2024). Значительным потенциалом также обладают трёхмерные карты, позволяющие более точно понимать особенности наблюдаемой местности (Jurado et al., 2022; Shi et al., 2020). В ближайшем будущем как качество, так и количество данных значительно возрастут, что позволит создать пригодные для использования трёхмерные наборы данных из множества источников для заданной области.

Другие перспективные направления исследований связаны с разработкой недорогих и удобных для пользователя БПЛА, включая многосенсорные карданные подвесы, интеграцию с новыми сельскохозяйственными технологиями, повышение эффективности сбора и обработки данных, разнообразные сценарии испытаний, а также этические аспекты, связанные с соответствующими регуляторными нормами (Kouadio et al., 2023; Neupane, Baysal-Gurel, 2021).

Заключение

Применение искусственного интеллекта, глубокого обучения и дистанционного зондирования Земли становится всё более распространённым в решении практических задач в сельском хозяйстве. Сложность и объём данных, получаемых различными методами ДЗЗ, способствовали разработке алгоритмов ГО, которые изменили подходы к получению, обработке и анализу данных. В настоящей статье представлен обзор литературных источников, посвящённых применению ГО и ДЗЗ в сельском хозяйстве за последние пять лет, с января 2020 по июль 2024 г. В результате исследования были выявлены общие темы, проанализирована производительность моделей ГО, определены существующие пробелы в знаниях и обозначены направления для будущих исследований в данной области.

Работа выполнена при финансовой поддержке Российского научного фонда, грант № 22-76-10042, <https://rscf.ru/project/22-76-10042/>.

Литература

1. Abbas A., Zhang Z., Zheng H. et al. Drones in plant disease assessment, efficient monitoring, and detection: A way forward to smart agriculture // *Agronomy*. 2023. V. 13. Iss. 6. Article 1524. 26 p. DOI: 10.3390/agronomy13061524.
2. Ariza-Sentís M., Vélez S., Martínez-Peña R. et al. Object detection and tracking in Precision Farming: a systematic review // *Computers and Electronics in Agriculture*. 2024. V. 219. Article 108757. 19 p. DOI: 10.1016/j.compag.2024.108757.
3. Arjoune Y., Sugunaraaj N., Peri S. et al. Soybean cyst nematode detection and management: a review // *Plant Methods*. 2022. V. 18. Iss. 1. Article 110. 39 p. DOI: 10.1186/s13007-022-00933-8.
4. Arksey H., O'Malley L. Scoping studies: towards a methodological framework // *Intern. J. Social Research Methodology*. 2005. V. 8. Iss. 1. P. 19–32. DOI: 10.1080/1364557032000119616.
5. Astolfi G., Pache M. C. B., Menezes G. V. et al. Combining syntactic methods with LSTM to classify soybean aerial images // *IEEE Geoscience and Remote Sensing Letters*. 2021. V. 18. Iss. 12. P. 2182–2186. DOI: 10.1109/LGRS.2020.3014938.
6. Bouguettaya A., Zarzour H., Kechida A., Taberkit A. M. Deep learning techniques to classify agricultural crops through UAV imagery: a review // *Neural Computing and Applications*. 2022. V. 34. P. 9511–9536. DOI: 10.1007/s00521-022-07104-9.
7. Cao Z., Kooistra L., Wang W. et al. Real-time object detection based on UAV remote sensing: A systematic literature review // *Drones*. 2023. V. 7. Iss. 10. Article 620. 29 p. DOI: 10.3390/drones7100620.
8. Darra N., Anastasiou E., Kriezis O. et al. Can yield prediction be fully digitalized? A systematic review // *Agronomy*. 2023. V. 13. Iss. 9. Article 2441. 53 p. DOI: 10.3390/agronomy13092441.
9. Darwin B., Dharmaraj P., Prince S. et al. Recognition of bloom/yield in crop images using deep learning models for smart agriculture: A review // *Agronomy*. 2021. V. 11. Iss. 4. Article 646. 22 p. DOI: 10.3390/agronomy11040646.
10. El Sakka M., Mothe J., Ivanovici M. Images and CNN applications in smart agriculture // *European J. Remote Sensing*. 2024. V. 57. Iss. 1. Article 2352386. 29 p. DOI: 10.1080/22797254.2024.2352386.
11. García-Berná J. A., Ouhbi S., Benmouna B. et al. Systematic mapping study on remote sensing in agriculture // *Applied Sciences*. 2020. V. 10. Iss. 10. Article 3456. 29 p. DOI: 10.3390/app10103456.
12. Haddaway N. R., Page M. J., Pritchard C. C., McGuinness L. A. PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and Open Synthesis // *Campbell Systematic Reviews*. 2022. V. 18. Iss. 2. Article e1230. 12 p. DOI: 10.1002/cl2.1230.
13. Hunt D. A., Tabor K., Hewson J. H. et al. Review of remote sensing methods to map coffee production systems // *Remote Sensing*. 2020. V. 12. Iss. 12. Article 2041. 23 p. DOI: 10.3390/rs12122041.
14. Jiang W. Object-based deep convolutional autoencoders for high-resolution remote sensing image classification // *J. Applied Remote Sensing*. 2018. V. 12. Iss. 3. Article 035002. DOI: 10.1117/1.JRS.12.035002.
15. Joshi A., Pradhan B., Gite S., Chakraborty S. Remote-sensing data and deep-learning techniques in crop mapping and yield prediction: A systematic review // *Remote Sensing*. 2023. V. 15. Iss. 8. Article 2014. 26 p. DOI: 10.3390/rs15082014.
16. Jozdani S., Chen D., Pouliot D., Johnson B. A. A review and meta-analysis of generative adversarial networks and their applications in remote sensing // *Intern. J. Applied Earth Observation and Geoinformation*. 2022. V. 108. Article 102734. 22 p. DOI: 10.1016/j.jag.2022.102734.
17. Jurado J. M., López A., Pádua L., Sousa J. J. Remote sensing image fusion on 3D scenarios: A review of applications for agriculture and forestry // *Intern. J. Applied Earth Observation and Geoinformation*. 2022. V. 112. Article 102856. 23 p. DOI: 10.1016/j.jag.2022.102856.
18. Kattenborn T., Leitloff J., Schiefer F., Hinz S. Review on convolutional neural networks (CNN) in vegetation remote sensing // *ISPRS J. Photogrammetry and Remote Sensing*. 2021. V. 173. P. 24–49. DOI: 10.1016/j.isprsjprs.2020.12.010.
19. Kouadio L., El Jarroudi M., Belabess Z. et al. A review on UAV-based applications for plant disease detection and monitoring // *Remote Sensing*. 2023. V. 15. Iss. 17. Article 4273. 23 p. DOI: 10.3390/rs15174273.
20. Kuswidiyanto L. W., Noh H.-H., Han X. Plant disease diagnosis using deep learning based on aerial hyperspectral images: A review // *Remote Sensing*. 2022. V. 14. Iss. 23. Article 6031. 24 p. DOI: 10.3390/rs14236031.
21. Levac D., Colquhoun H., O'Brien K. K. Scoping studies: advancing the methodology // *Implementation Science*. 2010. V. 5. Iss. 1. Article 69. 9 p. DOI: 10.1186/1748-5908-5-69.
22. Li K., Yang S., Dong R. et al. Survey of single image super-resolution reconstruction // *IET Image Processing*. 2020. V. 14. Iss. 11. P. 2273–2290. DOI: 10.1049/iet-ipr.2019.1438.
23. Li J., Cai Y., Li Q. et al. A review of remote sensing image segmentation by deep learning methods // *Intern. J. Digital Earth*. 2024. V. 17. Iss. 1. Article 2328827. 34 p. DOI: 10.1080/17538947.2024.2328827.

24. Liu J., Xiang J., Jin Y. *et al.* Boost precision agriculture with unmanned aerial vehicle remote sensing and edge intelligence: A survey // *Remote Sensing*. 2021. V. 13. Iss. 21. Article 4387. 31 p. DOI: 10.3390/rs13214387.
25. Mesías-Ruiz G.A., Pérez-Ortiz M., Dorado J. *et al.* Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review // *Frontiers in Plant Science*. 2023. V. 14. Article 1143326. 22 p. DOI: 10.3389/fpls.2023.1143326.
26. Messina G., Modica G. The role of remote sensing in olive growing farm management: A research outlook from 2000 to the present in the framework of precision agriculture applications // *Remote Sensing*. 2022. V. 14. Iss. 23. Article 5951. 40 p. DOI: 10.3390/rs14235951.
27. Mohamed E.S., Belal A.A., Abd-Elmabod S.K. *et al.* Smart farming for improving agricultural management // *The Egyptian J. Remote Sensing and Space Sciences*. 2021. V. 24. Iss. 3. P. 971–981. DOI: 10.1016/j.ejrs.2021.08.007.
28. Nawaz S.A., Li J., Bhatti U.A. *et al.* AI-based object detection latest trends in remote sensing, multimedia and agriculture applications // *Frontiers in Plant Science*. 2022. V. 13. Article 1041514. 21 p. DOI: 10.3389/fpls.2022.1041514.
29. Neupane K., Baysal-Gurel F. Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review // *Remote Sensing*. 2021. V. 13. Iss. 19. Article 3841. 23 p. DOI: 10.3390/rs13193841.
30. Ouhami M., Hafiane A., Es-Saady Y. *et al.* Computer vision, IoT and data fusion for crop disease detection using machine learning: A survey and ongoing research // *Remote Sensing*. 2021. V. 13. Iss. 13. Article 2486. 24 p. DOI: 10.3390/rs13132486.
31. Radočaj D., Plaščak I., Jurišić M. Global navigation satellite systems as state-of-the-art solutions in precision agriculture: A review of studies indexed in the Web of Science // *Agriculture*. 2023. V. 13. Iss. 7. Article 1417. 17 p. DOI: 10.3390/agriculture13071417.
32. Rakhmatulin I., Kamilaris A., Andreassen C. Deep neural networks to detect weeds from crops in agricultural environments in real-time: A review // *Remote Sensing*. 2021. V. 13. Iss. 21. Article 4486. 24 p. DOI: 10.3390/rs13214486.
33. Rejeb A., Abdollahi A., Rejeb K., Treiblmaier H. Drones in agriculture: A review and bibliometric analysis // *Computers and Electronics in Agriculture*. 2022. V. 198. Article 107017. 19 p. DOI: 10.1016/j.compag.2022.107017.
34. Rethlefsen M.L., Kirtley S., Waffenschmidt S. *et al.* PRISMA-S: an extension to the PRISMA statement for reporting literature searches in systematic reviews // *Systematic Reviews*. 2021. V. 10. Iss. 1. Article 39. 19 p. DOI: 10.1186/s13643-020-01542-z.
35. Rosle R., Che'Ya N.N., Ang Y. *et al.* Weed detection in rice fields using remote sensing technique: A review // *Applied Sciences*. 2021. V. 11. Iss. 22. Article 10701. 25 p. DOI: 10.3390/app112210701.
36. Safonova A., Ghazaryan G., Stiller S. *et al.* Ten deep learning techniques to address small data problems with remote sensing // *Intern. J. Applied Earth Observation and Geoinformation*. 2023. V. 125. Article 103569. 17 p. DOI: 10.1016/j.jag.2023.103569.
37. Shahi T.B., Xu C.-Y., Neupane A., Guo W. Recent advances in crop disease detection using UAV and deep learning techniques // *Remote Sensing*. 2023. V. 15. Iss. 9. Article 2450. 29 p. DOI: 10.3390/rs15092450.
38. Sharma R., Mishra D.R., Levi M.R., Sutter L.A. Remote sensing of surface and subsurface soil organic carbon in tidal wetlands: a review and ideas for future research // *Remote Sensing*. 2022. V. 14. Iss. 12. Article 2940. 21 p. DOI: 10.3390/rs14122940.
39. Shi W., Zhang M., Zhang R. *et al.* Change detection based on artificial intelligence: State-of-the-art and challenges // *Remote Sensing*. 2020. V. 12. Iss. 10. Article 1688. 35 p. DOI: 10.3390/rs12101688.
40. Tanaka T.S.T., Wang S., Jørgensen J.R. *et al.* Review of crop phenotyping in field plot experiments using UAV-mounted sensors and algorithms // *Drones*. 2024. V. 8. Iss. 6. Article 212. 21 p. DOI: 10.3390/drones8060212.
41. Teixeira I., Morais R., Sousa J.J., Cunha A. Deep learning models for the classification of crops in aerial imagery: A review // *Agriculture*. 2023. V. 13. Iss. 5. Article 965. 24 p. DOI: 10.3390/agriculture13050965.
42. Wang R., Ma L., He G. *et al.* Transformers for remote sensing: a systematic review and analysis // *Sensors*. 2024. V. 24. Iss. 11. Article 3495. 23 p. DOI: 10.3390/s24113495.
43. Weiss M., Jacob F., Duveiller G. Remote sensing for agricultural applications: a meta-review // *Remote Sensing of Environment*. 2020. V. 236. Article 111402. DOI: 10.1016/j.rse.2019.111402.
44. Westphal K.K., Regoecki W., Masotya M. *et al.* From Arksey and O'Malley and beyond: Customizations to enhance a team-based, mixed approach to scoping review methodology // *MethodsX*. 2021. V. 8. Article 101375. 14 p. DOI: 10.1016/j.mex.2021.101375.
45. Yu F., Wang M., Xiao J. *et al.* Advancements in utilizing image-analysis technology for crop-yield estimation // *Remote Sensing*. 2024. V. 16. Iss. 6. Article 1003. 30 p. DOI: 10.3390/rs16061003.
46. Zheng J., Song X., Yang G. *et al.* Remote sensing monitoring of rice and wheat canopy nitrogen: A review // *Remote Sensing*. 2022. V. 14. Iss. 22. Article 5712. 29 p. DOI: 10.3390/rs14225712.

Artificial intelligence and remote sensing in agriculture: A review

A. N. Safonova¹, Yu. A. Maglinets², D. I. Kaplun¹

¹ Saint Petersburg Electrotechnical University, Saint Petersburg 197022, Russia
E-mails: safonova.nastya1@gmail.com, dikaplun@etu.ru

² Siberian Federal University, Krasnoyarsk 660041, Russia
E-mail: ymaglinets@sfu-kras.ru

In the third decade of the 21st century, the development of artificial intelligence has enabled algorithms, particularly those based on deep learning (DL) models, to take a leading position in the analysis of remote sensing data for agromonitoring. This advancement has allowed for improved accuracy and efficiency in tasks such as object detection and classification, change analysis, etc. Approximately one thousand articles have been published on this topic, including around 69 review papers. However, none has attempted to cover the entire spectrum of achievements in DL applications with remote sensing data in agromonitoring. The aim of this review is to identify the main trends and knowledge gaps in the development of remote agromonitoring applications by examining relevant review papers. Following recommended guidelines, 37 review studies published from 2020 to March 2024 were identified. The selected reviews discuss various agromonitoring tasks and methods for their resolution, including aspects such as DL architectures, data sources, model performance evaluation, and emerging challenges. Using bibliometric analysis, this study reveals common themes, highlights DL models performance, knowledge gaps, and development trends in this field. To the best of our knowledge, we present the most comprehensive review of this area and outline future research directions.

Keywords: artificial intelligence, deep learning, remote sensing, agromonitoring, agriculture, review

Accepted: 24.10.2025

DOI: 10.21046/2070-7401-2026-23-3-9-24

References

1. Abbas A., Zhang Z., Zheng H. et al., Drones in plant disease assessment, efficient monitoring, and detection: A way forward to smart agriculture, *Agronomy*, 2023, V. 13, Iss. 6, Article 1524, 26 p., DOI: 10.3390/agronomy13061524.
2. Ariza-Sentís M., Vélez S., Martínez-Peña R. et al., Object detection and tracking in Precision Farming: a systematic review, *Computers and Electronics in Agriculture*, 2024, V. 219, Article 108757, 19 p., DOI: 10.1016/j.compag.2024.108757.
3. Arjoune Y., Sugunaraj N., Peri S. et al., Soybean cyst nematode detection and management: a review, *Plant Methods*, 2022, V. 18, Iss. 1, Article 110, 39 p., DOI: 10.1186/s13007-022-00933-8.
4. Arksey H., O'Malley L., Scoping studies: towards a methodological framework, *Intern. J. Social Research Methodology*, 2005, V. 8, Iss. 1, pp. 19–32, DOI: 10.1080/1364557032000119616.
5. Astolfi G., Pache M. C. B., Menezes G. V. et al., Combining syntactic methods with LSTM to classify soybean aerial images, *IEEE Geoscience and Remote Sensing Letters*, 2021, V. 18, Iss. 12, pp. 2182–2186, DOI: 10.1109/LGRS.2020.3014938.
6. Bouguettaya A., Zarzour H., Kechida A., Taberkit A. M., Deep learning techniques to classify agricultural crops through UAV imagery: a review, *Neural Computing and Applications*, 2022, V. 34, pp. 9511–9536, DOI: 10.1007/s00521-022-07104-9.
7. Cao Z., Kooistra L., Wang W. et al., Real-time object detection based on UAV remote sensing: A systematic literature review, *Drones*, 2023, V. 7, Iss. 10, Article 620, 29 p., DOI: 10.3390/drones7100620.
8. Darra N., Anastasiou E., Kriezi O. et al., Can yield prediction be fully digitalized? A systematic review, *Agronomy*, 2023, V. 13, Iss. 9, Article 2441, 53 p., DOI: 10.3390/agronomy13092441.
9. Darwin B., Dharmaraj P., Prince S. et al., Recognition of bloom/yield in crop images using deep learning models for smart agriculture: A review, *Agronomy*, 2021, V. 11, Iss. 4, Article 646, 22 p., DOI: 10.3390/agronomy11040646.
10. El Sakka M., Mothe J., Ivanovici M., Images and CNN applications in smart agriculture, *European J. Remote Sensing*, 2024, V. 57, Iss. 1, Article 2352386, 29 p., DOI: 10.1080/22797254.2024.2352386.
11. García-Berná J. A., Ouhbi S., Benmouna B. et al., Systematic mapping study on remote sensing in agriculture, *Applied Sciences*, 2020, V. 10, Iss. 10, Article 3456, 29 p., DOI: 10.3390/app10103456.

12. Haddaway N. R., Page M. J., Pritchard C. C., McGuinness L. A., PRISMA2020: An R package and Shiny app for producing PRISMA 2020-compliant flow diagrams, with interactivity for optimised digital transparency and Open Synthesis, *Campbell Systematic Reviews*, 2022, V. 18, Iss. 2, Article e1230, 12 p., DOI: 10.1002/cl2.1230.
13. Hunt D. A., Tabor K., Hewson J. H. et al., Review of remote sensing methods to map coffee production systems, *Remote Sensing*, 2020, V. 12, Iss. 12, Article 2041, 23 p., DOI: 10.3390/rs12122041.
14. Jiang W., Object-based deep convolutional autoencoders for high-resolution remote sensing image classification, *J. Applied Remote Sensing*, 2018, V. 12, Iss. 3, Article 035002, DOI: 10.1117/1.JRS.12.035002.
15. Joshi A., Pradhan B., Gite S., Chakraborty S., Remote-sensing data and deep-learning techniques in crop mapping and yield prediction: A systematic review, *Remote Sensing*, 2023, V. 15, Iss. 8, Article 2014, 26 p., DOI: 10.3390/rs15082014.
16. Jozdani S., Chen D., Pouliot D., Johnson B. A., A review and meta-analysis of generative adversarial networks and their applications in remote sensing, *Intern. J. Applied Earth Observation and Geoinformation*, 2022, V. 108, Article 102734, 22 p., DOI: 10.1016/j.jag.2022.102734.
17. Jurado J. M., López A., Pádua L., Sousa J. J., Remote sensing image fusion on 3D scenarios: A review of applications for agriculture and forestry, *Intern. J. Applied Earth Observation and Geoinformation*, 2022, V. 112, Article 102856, 23 p., DOI: 10.1016/j.jag.2022.102856.
18. Kattenborn T., Leitloff J., Schiefer F., Hinz S., Review on convolutional neural networks (CNN) in vegetation remote sensing, *ISPRS J. Photogrammetry and Remote Sensing*, 2021, V. 173, pp. 24–49, DOI: 10.1016/j.isprsjprs.2020.12.010.
19. Kouadio L., El Jarroudi M., Belabess Z. et al., A review on UAV-based applications for plant disease detection and monitoring, *Remote Sensing*, 2023, V. 15, Iss. 17, Article 4273, 23 p., DOI: 10.3390/rs15174273.
20. Kuswidiyanto L. W., Noh H.-H., Han X., Plant disease diagnosis using deep learning based on aerial hyperspectral images: A review, *Remote Sensing*, 2022, V. 14, Iss. 23, Article 6031, 24 p., DOI: 10.3390/rs14236031.
21. Levac D., Colquhoun H., O'Brien K. K., Scoping studies: advancing the methodology, *Implementation Science*, 2010, V. 5, Iss. 1, Article 69, 9 p., DOI: 10.1186/1748-5908-5-69.
22. Li K., Yang S., Dong R. et al., Survey of single image super-resolution reconstruction, *IET Image Processing*, 2020, V. 14, Iss. 11, pp. 2273–2290, DOI: 10.1049/iet-ipr.2019.1438.
23. Li J., Cai Y., Li Q. et al., A review of remote sensing image segmentation by deep learning methods, *Intern. J. Digital Earth*, 2024, V. 17, Iss. 1, Article 2328827, 34 p., DOI: 10.1080/17538947.2024.2328827.
24. Liu J., Xiang J., Jin Y. et al., Boost precision agriculture with unmanned aerial vehicle remote sensing and edge intelligence: A survey, *Remote Sensing*, 2021, V. 13, Iss. 21, Article 4387, 31 p., DOI: 10.3390/rs13214387.
25. Mesías-Ruiz G. A., Pérez-Ortiz M., Dorado J. et al., Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review, *Frontiers in Plant Science*, 2023, V. 14, Article 1143326, 22 p., DOI: 10.3389/fpls.2023.1143326.
26. Messina G., Modica G., The role of remote sensing in olive growing farm management: A research outlook from 2000 to the present in the framework of precision agriculture applications, *Remote Sensing*, 2022, V. 14, Iss. 23, Article 5951, 40 p., DOI: 10.3390/rs14235951.
27. Mohamed E. S., Belal A. A., Abd-Elmabod S. K. et al., Smart farming for improving agricultural management, *The Egyptian J. Remote Sensing and Space Sciences*, 2021, V. 24, Iss. 3, pp. 971–981, DOI: 10.1016/j.ejrs.2021.08.007.
28. Nawaz S. A., Li J., Bhatti U. A. et al., AI-based object detection latest trends in remote sensing, multimedia and agriculture applications, *Frontiers in Plant Science*, 2022, V. 13, Article 1041514, 21 p., DOI: 10.3389/fpls.2022.1041514.
29. Neupane K., Baysal-Gurel F., Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review, *Remote Sensing*, 2021, V. 13, Iss. 19, Article 3841, 23 p., DOI: 10.3390/rs13193841.
30. Ouhami M., Hafiane A., Es-Saady Y. et al., Computer vision, IoT and data fusion for crop disease detection using machine learning: A survey and ongoing research, *Remote Sensing*, 2021, V. 13, Iss. 13, Article 2486, 24 p., DOI: 10.3390/rs13132486.
31. Radočaj D., Plaščak I., Jurišić M., Global navigation satellite systems as state-of-the-art solutions in precision agriculture: A review of studies indexed in the Web of Science, *Agriculture*, 2023, V. 13, Iss. 7, Article 1417, 17 p., DOI: 10.3390/agriculture13071417.
32. Rakhmatulin I., Kamilaris A., Andreassen C., Deep neural networks to detect weeds from crops in agricultural environments in real-time: A review, *Remote Sensing*, 2021, V. 13, Iss. 21, Article 4486, 24 p., DOI: 10.3390/rs13214486.
33. Rejeb A., Abdollahi A., Rejeb K., Treiblmaier H., Drones in agriculture: A review and bibliometric analysis, *Computers and Electronics in Agriculture*, 2022, V. 198, Article 107017, 19 p., DOI: 10.1016/j.compag.2022.107017.

34. Rethlefsen M. L., Kirtley S., Waffenschmidt S. et al., PRISMA-S: an extension to the PRISMA statement for reporting literature searches in systematic reviews, *Systematic Reviews*, 2021, V. 10, Iss. 1, Article 39, 19 p., DOI: 10.1186/s13643-020-01542-z.
35. Rosle R., Che'Ya N. N., Ang Y. et al., Weed detection in rice fields using remote sensing technique: A review, *Applied Sciences*, 2021, V. 11, Iss. 22, Article 10701, 25 p., DOI: 10.3390/app112210701.
36. Safonova A., Ghazaryan G., Stiller S. et al., Ten deep learning techniques to address small data problems with remote sensing, *Intern. J. Applied Earth Observation and Geoinformation*, 2023, V. 125, Article 103569, 17 p., DOI: 10.1016/j.jag.2023.103569.
37. Shahi T. B., Xu C.-Y., Neupane A., Guo W., Recent advances in crop disease detection using UAV and deep learning techniques, *Remote Sensing*, 2023, V. 15, Iss. 9, Article 2450, 29 p., DOI: 10.3390/rs15092450.
38. Sharma R., Mishra D. R., Levi M. R., Sutter L. A., Remote sensing of surface and subsurface soil organic carbon in tidal wetlands: a review and ideas for future research, *Remote Sensing*, 2022, V. 14, Iss. 12, Article 2940, 21 p., DOI: 10.3390/rs14122940.
39. Shi W., Zhang M., Zhang R. et al., Change detection based on artificial intelligence: State-of-the-art and challenges, *Remote Sensing*, 2020, V. 12, Iss. 10, Article 1688, 35 p., DOI: 10.3390/rs12101688.
40. Tanaka T. S. T., Wang S., Jørgensen J. R. et al., Review of crop phenotyping in field plot experiments using UAV-mounted sensors and algorithms, *Drones*, 2024, V. 8, Iss. 6, Article 212, 21 p., DOI: 10.3390/drones8060212.
41. Teixeira I., Morais R., Sousa J. J., Cunha A., Deep learning models for the classification of crops in aerial imagery: A review, *Agriculture*, 2023, V. 13, Iss. 5, Article 965, 24 p., DOI: 10.3390/agriculture13050965.
42. Wang R., Ma L., He G. et al., Transformers for remote sensing: a systematic review and analysis, *Sensors*, 2024, V. 24, Iss. 11, Article 3495, 23 p., DOI: 10.3390/s24113495.
43. Weiss M., Jacob F., Duveiller G., Remote sensing for agricultural applications: a meta-review, *Remote Sensing of Environment*, 2020, V. 236, Article 111402, DOI: 10.1016/j.rse.2019.111402.
44. Westphaln K. K., Regoeczi W., Masotya M. et al., From Arksey and O'Malley and beyond: Customizations to enhance a team-based, mixed approach to scoping review methodology, *MethodsX*, 2021, V. 8, Article 101375, 14 p., DOI: 10.1016/j.mex.2021.101375.
45. Yu F., Wang M., Xiao J. et al., Advancements in utilizing image-analysis technology for crop-yield estimation, *Remote Sensing*, 2024, V. 16, Iss. 6, Article 1003, 30 p., DOI: 10.3390/rs16061003.
46. Zheng J., Song X., Yang G. et al., Remote sensing monitoring of rice and wheat canopy nitrogen: A review, *Remote Sensing*, 2022, V. 14, Iss. 22, Article 5712, 29 p., DOI: 10.3390/rs14225712.