

УДК 004.89

Бухонова Арина Алексеевна, студент,
Московский авиационный институт (НИУ)

НЕЙРОСЕТЕВОЙ МОНИТОРИНГ АГРОУГОДИЙ С БПЛА

Аннотация. Статья посвящена совершенствованию мониторинга сельскохозяйственных культур с использованием БПЛА и методов машинного обучения. Проведен анализ существующих подходов: наземного скаутинга, спутникового мониторинга и съемки с дронов. Обоснована перспективность комбинированного использования методов с акцентом на автоматизированную обработку аэрофотоснимков. В качестве предмета исследования рассматриваются нейронные сети для семантической сегментации изображений с целью выявления стрессовых зон (очаги заболеваний, дефицит питания, водный стресс). Применение интеллектуальных систем анализа данных позволяет повысить точность и оперативность оценки состояния посевов, снизить трудозатраты и создать основу для развития технологий точного земледелия.

Ключевые слова: Точное земледелие, мониторинг сельскохозяйственных культур, беспилотные летательные аппараты (БПЛА), дистанционное зондирование, машинное обучение, нейронные сети, семантическая сегментация, стрессовое состояние растений, обнаружение заболеваний, автоматизация.

Введение

Сельское хозяйство является важной составляющей экономики нашей страны. В частности, немаловажную роль играет агрономический сектор. Очевидным способом повышения его доходности является увеличение урожайности. Однако на урожайность растений влияет значительное количество факторов, таких как количество осадков, дефицит или избыток органических и минеральных удобрений, развитие болезней и вредителей. По оценкам отраслевых исследований, потери урожая из-за несвоевременного выявления стрессов, заболеваний и очагов заражения могут составлять от 10 до 30%, а в отдельных случаях для конкретных культур (или, например, при вспышках грибных заболеваний, локальных засухах) – до 40% потенциального урожая [1].

Последствия воздействия указанных факторов на ранних стадиях не всегда могут быть легко обнаружены человеком. Это связано с ограниченной точкой обзора, с человеческим фактором и высокой трудоёмкостью полевого скаутинга. Кроме того, зоны воздействия стрессов часто имеют мозаичный характер и могут охватывать десятки и сотни гектаров. В связи с этим становится актуальным использование беспилотных летательных аппаратов (БПЛА) для контроля сельскохозяйственных стрессовых зон.

В настоящее время БПЛА активно применяются в мировом сельском хозяйстве: по оценкам аналитических агентств, глобальный рынок сельскохозяйственных дронов демонстрирует устойчивый рост (CAGR ~30%), а парк таких устройств исчисляется сотнями тысяч единиц, охватывая десятки стран и сотни видов культур [2].

Однако мониторинг и интерпретация полученных данных, выполняемые исключительно человеком, остаются ненадёжными и трудозатратными. В связи с этим особую актуальность приобретает автоматическое детектирование и классификация внешних признаков состояния растений с использованием методов машинного обучения и компьютерного зрения. Такие системы позволяют выявлять стрессовые зоны на ранних стадиях.

С экономической точки зрения внедрение подобных интеллектуальных систем обеспечивает значительный эффект. По обобщённым оценкам, затраты на полевой скаутинг



могут быть снижены на 30-60%, расходы на СЗР и удобрения – на 15-25% за счёт дифференцированного внесения, а прирост урожайности может составлять 5-15% в зависимости от культуры и условий возделывания [3, 4, 5].

Целью работы является совершенствование мониторинга аграрных угодий за счёт разработки и внедрения методики автоматизированного выявления и классификации признаков стрессового состояния сельскохозяйственных культур по данным дистанционного зондирования с помощью БПЛА.

Реализация поставленной цели позволит не только автоматизировать процесс мониторинга и повысить его точность, но и сформировать научно обоснованную базу для дальнейшего совершенствования систем точного земледелия и оптимизации агротехнических решений.

Объектом исследования является процесс мониторинга состояния сельскохозяйственных культур на аграрных угодьях с использованием данных дистанционного зондирования.

В рамках данного исследования процесс мониторинга рассматривается как совокупность этапов сбора, обработки и анализа визуальной и спектральной информации, а также принятия решений на её основе. Особое внимание уделяется автоматизации интерпретации данных с применением методов машинного обучения, что позволяет повысить объективность оценки состояния культур и снизить влияние человеческого фактора. Таким образом, объект исследования охватывает как технологическую, так и организационную составляющие мониторинга аграрных угодий в условиях современного точного земледелия.

Предметом исследования являются архитектуры сверточных нейронных сетей (Convolutional Neural Networks, CNN), предназначенные для семантической сегментации аэрофотоснимков сельскохозяйственных угодий. Основная задача заключается в пиксельной классификации изображений, полученных с БПЛА, с целью точного выделения (сегментации) проблемных зон, таких как участки с дефицитом питательных веществ, очаги заболеваний растений, зоны водного стресса или повреждения, вызванные вредителями.

1. Анализ методов мониторинга состояния сельскохозяйственных культур

Мониторинг состояния сельскохозяйственных культур является ключевым элементом точного земледелия и направлен на выявление проблемных зон, своевременное определение отклонений в развитии растений и принятие соответствующих агротехнических решений. На сегодняшний день применяются несколько основных подходов, которые различаются по масштабу охвата, точности и степени автоматизации.

- Наземный скаутинг является традиционным методом мониторинга. Он включает визуальный осмотр полей человеком и фиксацию признаков стрессового состояния растений, заболеваний или недостатка питательных веществ.

- Спутниковый мониторинг основан на анализе данных дистанционного зондирования Земли. Часто применяются вегетационные индексы (например, NDVI, GNDVI) для оценки состояния растительного покрова и выявления аномалий.

- Мониторинг с помощью беспилотных летательных аппаратов (БПЛА) обеспечивает высокое пространственное разрешение и гибкость съёмки.

- Ещё один способ мониторинга – использование стационарных датчиков на полях (IoT-системы, датчики влажности, температуры и содержания питательных веществ) и мобильных наземных платформ с камерами и сенсорами.

Каждый из рассмотренных методов мониторинга обладает своими преимуществами и ограничениями, что определяет их применимость в разных условиях и для различных культур.

Наземный скаутинг прост в реализации и не требует сложного оборудования, однако он трудоёмок, субъективен и ограничен в масштабах. На больших или труднодоступных полях



скаутинг не обеспечивает равномерного покрытия и оперативного выявления проблемных участков, что может приводить к потере части урожая из-за позднего реагирования.

Преимущества спутникового мониторинга заключаются в охвате больших территорий и возможности регулярного наблюдения. Однако данный метод имеет ограничения: относительно низкое пространственное разрешение не позволяет выявлять мелкие и локальные проблемы, периодичность съёмки зависит от орбиты спутника и облачности, а качество данных снижается при неблагоприятных погодных и атмосферных условиях.

Использование БПЛА позволяют быстро получать данные с точностью до отдельных растений, что особенно важно на крупных и сложных по рельефу полях. Аэрофотосъёмка в сочетании с мультиспектральными или гиперспектральными камерами расширяет возможности визуального и спектрального анализа состояния посевов. Основными ограничениями остаются необходимость в квалифицированных операторах, организация полётов и обработка больших объёмов данных, что решается за счёт внедрения современных алгоритмов анализа изображений, включая методы машинного обучения.

Дополнительные сенсорные системы и мобильные платформы дают непрерывные или периодические измерения отдельных параметров, но не обеспечивают полного пространственного охвата и требуют существенных вложений в оборудование и обслуживание. Их целесообразно использовать в сочетании с БПЛА или спутниковыми данными для калибровки и уточнения показателей.

В целом анализ показывает, что наиболее эффективным подходом является комбинированное использование методов с акцентом на автоматизированный анализ данных с БПЛА, что обеспечивает высокую точность, оперативность и масштабируемость мониторинга, снижая трудозатраты и повышая эффективность управления агротехническими процессами.

2. Реализация

Как уже было сказано ранее для своевременного реагирования на ранние сигналы ухудшения состояния растений требуется регулярный сбор данных. Однако, даже если мы упростим эту задачу с помощью спутника, дронов или специальных датчиков, большое количество времени уйдёт на обработку и анализ всей собранной информации. Что не позволит нам оперативно принимать меры. К тому же, как и в любой работе, выполняемой людьми, нельзя исключать человеческий фактор. Поэтому было принято решение использовать для обработки нейронные сети. В качестве входных данных были выбраны снимки с беспилотника, как оптимального инструмента сбора необходимой информации.

Беспилотник должен быть оснащён мультиспектральной камерой, с помощью которой можно будет получать изображения в RED и NIR диапазонах (рис. 1, 2), необходимых для расчёта вегетативного индекса NDVI (вегетативный индекс).




Рисунок 1. Фотография поля в NIR-диапазоне сделанная с помощью БПЛА






Рисунок 2. Фотография поля в RED-диапазоне сделанная с помощью БПЛА

Вычислив данный индекс для каждой точки фотографии и нормализовав его до диапазона от -1 до 1 для удобной последующей обработки, можно будет разбить поле на области, где значения от 1 до 0,5 будут считаться нормальным состоянием растений, от 0,5 до 0 представляют собой среднюю степень тяжести проблемы: слабовыраженную, вялую растительность, а от 0 до -0,5 это большая растительность или даже голая почва. Значения меньше -0,5 не рассматриваются в качестве отдельной категории потому, что, как правило, такой индекс NDVI имеют водные объекты, облака или техногенные объекты. Таким образом, мы получим два изображения: исходный снимок и снимок, на котором будут отмечены проблемные зоны (рис. 3, 4).

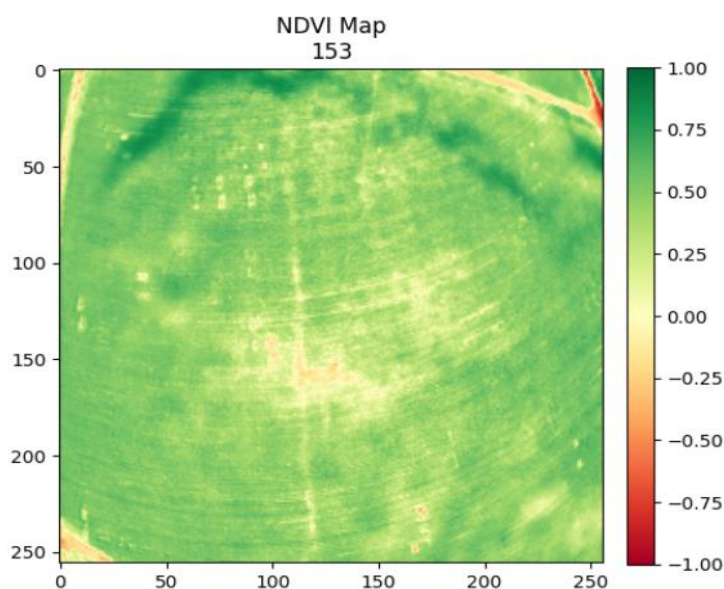


Рисунок 3. Визуализация рассчитанного индекса NDVI






Рисунок 4. Выделенные проблемные зоны

Для автоматического выделения проблемных участков на аэрофотоснимках применяются методы семантической сегментации на основе свёрточных нейронных сетей (CNN). В отличие от классификации или детекции объектов, семантическая сегментация выполняет попиксельную классификацию изображения, что позволяет точно определять границы трёх типов зон: «нормальное состояние», «средняя степень стресса» и «плохое состояние». Такой подход оптимально соответствует задаче мониторинга полей, поскольку не требует различения отдельных объектов внутри одного класса.

В рамках исследования были реализованы три архитектуры нейронных сетей, наиболее часто применяемые для сельскохозяйственного мониторинга с использованием БПЛА, а также был проведён их сравнительный анализ.

FCN (Fully Convolutional Network) – полностью свёрточная сеть, состоящая из кодера и декодера со skip-соединениями. Кодер выделяет карты признаков и уменьшает пространственное разрешение, а декодер с помощью транспонированных свёрток восстанавливает исходный размер изображения и строит пиксельную маску. FCN позволяет обрабатывать изображения произвольного размера, демонстрирует хорошую производительность и даёт возможность использовать предобученные сети в качестве кодера.

DeepLab – архитектура, ключевой особенностью которой являются расширенные (дилатационные) свёртки и модуль ASPP (Atrous Spatial Pyramid Pooling). ASPP представляет собой «пирамиду» свёрток с разными коэффициентами расширения, что позволяет сети одновременно анализировать объекты различных масштабов – от мелких очагов заболеваний до крупных зон дефицита питания – без потери пространственного разрешения. DeepLab обеспечивает высокую точность сегментации, но требует значительных вычислительных ресурсов.

U-Net – усовершенствованная версия FCN, построенная по симметричной схеме «кодер-декодер» с перекрёстными соединениями (skip-connections). На каждом этапе декодера информация из соответствующего слоя кодера объединяется с текущими признаками, что позволяет сохранять мелкие детали и границы объектов. U-Net хорошо обучается на ограниченных наборах данных и обеспечивает высокую точность сегментации при относительно небольшом количестве обучаемых параметров.



Обучение и тестирование моделей проводилось на датасете «Corn field mapped in Brazil» (521 мультиспектральное изображение посевов кукурузы, общая площадь съёмки – 274 га). Для оценки качества работы моделей использовались метрики F1-score (среднее гармоническое точности и полноты) и IoU (Intersection over Union – пересечение по объединению). Сравнение результатов показало, что U-Net демонстрирует наилучшие показатели: для класса «плохое состояние» F1-score достиг 85,05%, IoU – 75,35%, что в среднем на 3–9% выше аналогичных метрик FCN и DeepLab. На основе проведённого анализа U-Net была признана наиболее эффективной архитектурой для интеграции в систему мониторинга на базе БПЛА.

Заключение

В данной работе мы рассмотрели основные из существующих методов мониторинга сельскохозяйственных угодий. Их сравнение по критериям точности, масштабируемости, оперативности, затратам труда и стоимости показывает, что наиболее эффективный подход заключается в их комбинированном использовании, при котором выбор конкретного метода определяется задачами, доступными ресурсами и особенностями условий возделывания.

Для решения задачи автоматического выявления и классификации проблемных зон на полях были применены методы семантической сегментации на основе свёрточных нейронных сетей. В ходе исследования реализованы и проанализированы три архитектуры – FCN, DeepLab и U-Net. Обучение моделей проводилось на датасете мультиспектральных изображений «Corn field mapped in Brazil» с использованием вегетационного индекса NDVI для формирования целевых масок трёх классов состояния растений.

Результаты эксперимента показали, что архитектура U-Net демонстрирует наилучшие показатели по метрикам F1-score и IoU, превосходя FCN и DeepLab в среднем на 3–9%. U-Net обеспечивает высокую точность определения границ стрессовых зон, хорошо обучается на ограниченных наборах данных и показывает оптимальный баланс между качеством сегментации и вычислительными затратами, что делает её наиболее подходящей для интеграции в системы мониторинга на базе БПЛА.

Разработанное решение может функционировать в двух режимах: в реальном времени (при размещении вычислителя на борту дрона) или постфактум (при обработке данных на наземном центре). Это позволяет адаптировать систему под различные хозяйственные задачи и доступные ресурсы.

Таким образом, предложенный подход к нейросетевому мониторингу агроугодий с использованием БПЛА способствует оперативному выявлению проблемных участков, снижению трудозатрат на полевой скаутинг, более рациональному применению средств защиты растений и удобрений, а в конечном счёте – повышению урожайности сельскохозяйственных культур и экономической эффективности аграрного производства. Дальнейшие исследования могут быть направлены на оптимизацию моделей для работы в реальном времени на маломощных бортовых вычислителях, а также на расширение функционала системы за счёт интеграции дополнительных спектральных каналов и алгоритмов прогнозирования развития стрессовых ситуаций.

Список литературы:

1. Savary, S. The global burden of pathogens and pests on major food crops / S. Savary, L. Willocquet, S. J. Pethybridge [et al.] // Nature Ecology & Evolution. – 2019. – Vol. 3, No. 3. – P. 430-439. – DOI: 10.1038/s41559-018-0793-y.
2. Global Agriculture Drones Market – Global Forecast to 2030 / MarketsandMarkets // marketsandmarkets.com. – 2025. – URL: <https://www.marketsandmarkets.com/Market-Reports/agriculture-drones-market-23709764.html> (дата обращения: 13.03.2026).



3. New Drone Technology Revolutionizes Pest Management on Oregon Vineyards // Barchart.com. – 2026. – URL: <https://www.barchart.com/story/news/849255/new-drone-technology-revolutionizes-pest-management-on-oregon-vineyards> (дата обращения: 13.03.2026).

4. How precision agriculture could save your farm thousands (while protecting Alberta's soil) // Organics Farming, The Canadian Way. – 2026. – URL: <https://organicagcentre.ca/sustainable-agro-economics/how-precision-agriculture-could-save-your-farm-thousands-while-protecting-albertas-soil/> (дата обращения: 13.03.2026).

5. How precision agriculture could save your farm thousands (while protecting Alberta's soil) // Organics Farming, The Canadian Way. – 2026. – URL: <https://organicagcentre.ca/sustainable-agro-economics/how-precision-agriculture-could-save-your-farm-thousands-while-protecting-albertas-soil/> (дата обращения: 13.03.2026).

6. Альт, В. В. Применение БПЛА для мониторинга и ухода за посевами зерновых культур / В. В. Альт, А. А. Солошенко, С. П. Исакова [и др.] // Сельскохозяйственные машины и технологии. – 2025. – Т. 19, № 4. – С. 11-19. – DOI: 10.22314/2073-7599-2025-19-4-11-19. – EDN: VWQHJC.

7. Ценч, Ю. С. Развитие систем управления полетом и средств аэрофотосъемки беспилотных воздушных судов сельскохозяйственного назначения / Ю. С. Ценч, Р. К. Курбанов, Н. И. Захарова // Сельскохозяйственные машины и технологии. – 2024. – Т. 18, № 2. – С. 11-19. – DOI: 10.22314/20737599-2024-18-2-11-19.

8. Урасова, А. А. Применение беспилотных летательных аппаратов в сельском хозяйстве РФ: оценка региональной популярности потребительских предпочтений / А. А. Урасова, Л. В. Глезман, С. С. Федосеева // Экономика региона. – 2023. – Т. 19, № 4. – С. 1146-1160. – DOI: 10.17059/ekon.reg.2023-4-15.

9. Применение дистанционного зондирования и сенсорных технологий для сбора и обработки данных в точном земледелии / [авторы не указаны] // iacj.ru. – 2024. – С. 1752-1768. – URL: <https://iacj.ru/ru/nauka/article/102650/view> (дата обращения: 13.03.2026).

10. Абрамов, Н. В. Использование беспилотного летательного аппарата для мониторинга за состоянием агроценозов и составления электронных карт полей / Н. В. Абрамов, С. А. Семизоров, С. В. Шерстобитов [и др.] // Земледелие. – 2021. – № 8. – С. 8-12. – DOI: 10.24412/0044-3913-2021-8-8-12. – URL: <https://cyberleninka.ru/article/n/ispolzovanie-bespilotnogo-letatel'nogo-apparata-dlya-monitoringa-za-sostoyaniem-agrotsenozov-i-sostavleniya-elektronnyh-kart-poley> (дата обращения: 13.03.2026).

11. Rishikesavan, S. Potential and Pitfalls of Using Drone Technology in Sustainable Agriculture: An Overview / S. Rishikesavan, P. Kannan, S. Pazhanivelan [et al.] // Journal of Agricultural Machinery. – 2025. – Vol. 15, No. 3. – P. 459-490. – URL: <https://agris.fao.org/search/en/records/68b8038e00eb27ce11355e3d> (date of access: 13.03.2026).

12. Федоров, Д. Е. Обзор роботов для полевого мониторинга / Д. Е. Федоров, А. С. Берг // Актуальные научно-технические средства и сельскохозяйственные проблемы: XIII Национальная научно-практическая конференция с международным участием. – Кемерово: Кузбасский ГАУ, 2025. – С. 647-651. – URL

13. https://www.ksai.ru/upload/files/sborniki/2025/actual_2025_06/files/basic-html/page647.html (дата обращения: 13.03.2026).

14. Чижик, С. Интегрированная система точного земледелия с использованием беспилотных летательных аппаратов / С. Чижик, С. Антошук, Е. Галушко [и др.] // Наука и инновации. – 2021. – № 9 (223). – С. 42-47. – URL: <https://cyberleninka.ru/article/n/integrirovannaya-sistema-tochnogo-zemledeliya-s-ispolzovaniem-bespilotnyh-letatel'nyh-apparatov> (дата обращения: 13.03.2026).



15. Guebsi, R. Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges / R. Guebsi, S. Mami, K. Chokmani // Drones. – 2024. – Vol. 8, No. 11. – P. 686. – DOI: 10.3390/drones8110686.

16. Алейников, А. Ф. Рациональный метод оценки биотических стрессов растений с использованием машинного обучения / А. Ф. Алейников, А. А. Фуст // Сибирский вестник сельскохозяйственной науки. – 2025. – Т. 55, № 4. – С. 83-95. – DOI: 10.26898/0370-8799-2025-4-9.

