

# ТЕХНИКА И ТЕХНОЛОГИИ АПК

ОРИГИНАЛЬНАЯ СТАТЬЯ

УДК 631.34:004.896

<https://doi.org/10.26897/2687-1149-2025-6-4-16>



## Интеллектуальная система учета и картографирования всходов сахарной свеклы по данным RGB-аэрофотосъемки с применением методов глубокого обучения

С.Г. Мударисов<sup>1,2,3</sup>, И.Р. Мифтахов<sup>2</sup>, И.М. Фархутдинов<sup>3</sup>

<sup>1,2,3</sup> Башкирский государственный аграрный университет; г. Уфа, Россия

<sup>1</sup> [salavam@gmail.com](mailto:salavam@gmail.com); <https://orcid.org/0000-0001-9344-2606>

<sup>2</sup> [info323@bk.ru](mailto:info323@bk.ru); <https://orcid.org/0000-0002-3125-3532>

<sup>3</sup> [ildar1702@mail.ru](mailto:ildar1702@mail.ru); <https://orcid.org/0000-0002-6443-8584>

**Аннотация.** Современное растениеводство требует высокоточной и оперативной оценки густоты стояния сельскохозяйственных культур. Для сахарной свеклы данный показатель напрямую влияет на урожайность и рентабельность производства. Целью исследований является разработка и апробация методики автоматизированного учета всходов сахарной свеклы с использованием беспилотных летательных аппаратов (БПЛА) и алгоритмов глубокого обучения, обеспечивающей высокую точность и скорость обработки данных. Полевые исследования проведены в 2025 г. в Буздякском районе Республики Башкортостан на посевах промышленного гибрида сахарной свеклы. Съемка выполнялась БПЛА DJI Phantom 4 Pro с RGB-камерой на высоте 20 м. Первичная сегментация растительности проводилась по индексу Excess Green (ExG) с последующей бинаризацией и морфологической фильтрацией. Для детекции и классификации проростков применены архитектуры YOLOv8n и YOLOv5m, обученные на размеченной выборке аэрофотоснимков. Точность алгоритмов оценивалась сравнением с результатами визуального подсчета на контрольных участках. Модель YOLOv8n продемонстрировала наилучшие показатели (Precision – 0,80; Recall – 0,70; AP50-0,75;  $R^2$  – 0,99) при минимальной относительной ошибке 1,11% и RMSE3,0. YOLOv5m показала сопоставимую корреляцию ( $R^2$  – 0,98), но уступила по полноте и точности. Разработанный алгоритм позволил сформировать карту пространственного распределения всходов, пригодную для интеграции в системы точного земледелия. Предложенная технология обеспечивает сокращение трудозатрат на учет всходов в десятки раз по сравнению с ручными методами и исключает субъективные ошибки. Полученные результаты подтверждают возможность промышленного внедрения метода для оперативной оценки состояния посевов, принятия решений о пересеве и дифференцированного внесения агротехнологических мероприятий. Перспективы дальнейших исследований связаны с расширением функционала алгоритма для одновременного картографирования сорной растительности и адаптации метода к другим культурам.

**Ключевые слова:** сахарная свекла; подсчет всходов; автоматизированный подсчет всходов; беспилотный летательный аппарат; БПЛА; технологии глубокого обучения; нейросеть; компьютерное зрение; YOLO; системы точного земледелия; аэрофотосъемка

**Финансирование:** Исследование выполнено за счет гранта Российского научного фонда № 25-16-20094; <https://rscf.ru/project/25-16-20094/>.

Материалы, представленные в статье, получены в рамках реализации программы развития ФГБОУ ВО Башкирский ГАУ программы стратегического академического лидерства «Приоритет-2030».

**Для цитирования:** Мударисов С.Г., Мифтахов И.Р., Фархутдинов И.М. Интеллектуальная система учета и картографирования всходов сахарной свеклы по данным RGB-аэрофотосъемки с применением методов глубокого обучения // Агроинженерия. 2025. Т. 27, № 6. С. 4-16. <https://doi.org/10.26897/2687-1149-2025-6-4-16>

## ORIGINAL ARTICLE

## Automated sugar beet seedling detection and mapping using a UAV-borne RGB camera and deep learning techniques

S.G. Mudarisov<sup>1</sup>✉, I.R. Miftakhov<sup>2</sup>, I.M. Farkhutdinov<sup>3</sup>

<sup>1,2,3</sup> Bashkir State Agrarian University; Ufa, Russia

<sup>1</sup> salavam@gmail.com✉; <https://orcid.org/0000-0001-9344-2606>

<sup>2</sup> info323@bk.ru; <https://orcid.org/0000-0002-3125-3532>

<sup>3</sup> ildar1702@mail.ru; <https://orcid.org/0000-0002-6443-8584>

**Abstract.** Accurate and timely assessment of plant stand density is crucial for modern crop production, directly impacting sugar beet yield and profitability. This study aims to develop and validate a highly accurate automated method for counting sugar beet seedlings using unmanned aerial vehicles (UAVs) and deep learning algorithms, optimizing both precision and processing speed. Field experiments were conducted in 2025 on commercial sugar beet fields in the Buzdyak district of the Republic of Bashkortostan. A DJI Phantom 4 Pro UAV equipped with an RGB camera captured aerial imagery from a 20-meter altitude. Initial vegetation segmentation employed the Excess Green (ExG) index, followed by binarization and morphological filtering. The YOLOv8n and YOLOv5m deep learning architectures, trained on a manually annotated dataset of aerial images, were then implemented for seedling detection and classification. Algorithm performance was rigorously evaluated against manual seedling counts on control plots. The YOLOv8n model demonstrated superior performance (Precision: 0.80; Recall: 0.70; AP50: 0.75;  $R^2$ : 0.99), achieving a minimum relative error of 1.11% and a root mean squared error (RMSE) of 3.0. While YOLOv5m exhibited comparable correlation ( $R^2$ : 0.98), it displayed lower recall and precision. The developed algorithm enables the generation of spatial distribution maps of seedlings, readily integrated into precision agriculture systems. This technology significantly reduces labor costs for seedling counting – by orders of magnitude compared to manual methods – while also eliminating subjective errors. The obtained results demonstrate the feasibility for industrial implementation, enabling rapid crop condition assessment, informed replanting decisions, and targeted site-specific agro-technological interventions. Future research will focus on expanding the algorithm to incorporate simultaneous weed mapping and adapting it for use with other crops.

**Keywords:** sugar beet; automated seedling counting; unmanned aerial vehicle; deep learning; computer vision; YOLO; precision agriculture; aerial imagery

**Funding:** This research was supported by a grant from the Russian Science Foundation No. 25-16-20094; <https://rscf.ru/project/25-16-20094/>.

The materials presented in the article were obtained within the program of strategic academic leadership “Priopity-2030” in the development program of the Federal State Budgetary Educational Institution of Higher Education “Bashkir State Agrarian University”

**For citation:** Mudarisov S.G., Miftakhov I.R., Farkhutdinov I.M. Automated sugar beet seedling detection and mapping using a UAV-borne RGB camera and deep learning techniques. *Agricultural Engineering (Moscow)*. 2025;27(6):4-16 (In Russ.). <https://doi.org/10.26897/2687-1149-2025-6-4-16>

### Введение

Автоматизированный подсчет всходов сельскохозяйственных культур является актуальной задачей в агроинженерии [0]. В первые недели после посева равномерность и плотность распределения растений по полю критически влияют на дальнейший рост и урожайность культуры [2, 3]. В частности, для сахарной свеклы установлено, что конечный урожай корнеплодов и выход сахара существенно зависят от плотности стояния растений. Неравномерные и разреженные всходы могут быть вызваны биотическими факторами (некачественные или пораженные вредителями семена, болезни всходов)

и абиотическими стрессами: засухой, образованием почвенной корки, градом, ветровой эрозией, заморозками и пр. Обычно фермеры оценивают количество всходов сахарной свеклы вручную на небольших контрольных участках (около 10 м<sup>2</sup>) в фазе семядолей – первых настоящих листьев (ВВСН 10-12), после чего полученные данные экстраполируются на весь участок. Если средняя численность проросших растений оказывается ниже критического уровня (~ 45 тыс/га), то поле подлежит пересеву. Густота около 82...110 тыс/га считается оптимальной для максимальной урожайности и качества продукции [4].

Визуальный подсчет молодых растений на больших площадях связан с высокими затратами труда и времени. Например, для учета всходов на селекционных делянках вручную может потребоваться до 120...250 человеко-часов на 1 га, причем пересчету подвергается лишь 20...50% площади опытного поля [4].

Детальный мониторинг полевой всхожести необходим в семеноводстве и селекции. Процент дружных всходов и доля жизнеспособных семян зачастую решают, будет ли новый сорт сахарной свеклы принят рынком [4]. Сведения о количестве взошедших растений на разных участках поля имеют прикладное значение для прогнозирования урожайности и выявления зон с проблемными условиями (уплотнение почвы, подтопление и др.).

Помимо собственно культуры, на численность и развитие всходов сильно влияет конкуренция со стороны сорняков. Без эффективной защиты посевов сорная растительность способна снизить урожай корнеплодов сахарной свеклы до 90...95% от потенциала [4]. Именно поэтому современное выращивание свеклы предусматривает комплекс мероприятий по контролю сорняков включая междурядную обработку и дифференцированное применение гербицидов. Для оптимизации таких приемов требуются точные данные о местоположении и густоте сорной растительности в посевах. Актуальной научной задачей является разработка автоматизированных методов учета всходов и сорняков на поле, позволяющих аграриям быстро получать объективную информацию о посевах и оперативно принимать решения о частичном пересеве редких участков, локальной подкормке или выборочном гербицидном прополочном вмешательстве.

Беспилотные летательные аппараты (БПЛА, или дроны) с бортовыми камерами позволяют получать данные по требованию и в оптимальные сроки фенологического развития растений [5]. Аэрофотосъемка с малых высот дает оперативные снимки поля высокого разрешения. Даже обычные RGB-камеры, установленные на БПЛА, способны фиксировать отдельные проростки и сорняки на больших площадях с пространственным разрешением порядка 1 см и выше [6]. Для анализа таких данных применяются методы компьютерного зрения. Ранние подходы основывались на пороговой сегментации изображений, выделении зеленых пикселей растительности и последующей фильтрации и морфологическом разделении объектов для подсчета числа отдельных растений [6]. Однако традиционные алгоритмы обработки изображений

недостаточно надежны при изменении условий съемки и фонового окружения (освещенность, тени, структура почвы и т.д.) [6, 7]. Более того, подобные методы требуют ручной настройки порогов и признаков для каждого случая, что затрудняет их масштабирование.

В качестве современного решения выступают технологии глубокого обучения – в частности, сверточные нейронные сети (CNN), которые автоматически обучаются выявлению нужных объектов на изображениях [8]. Разработаны два основных подхода: 1) семантическая сегментация изображений с выделением классов «Растение» и «Фон» и дальнейший подсчет отдельных особей по сегментационной маске; 2) объектное детектирование, при котором нейросеть обнаруживает и локализует каждое растение ограничивающим прямоугольником или точкой центра [8]. Оба подхода успешно применяются для различных культур. Например, Lottes и соавт. использовали полносвязные сверточные сети (FCN) на последовательности изображений с наземного робота для одновременного определения точек стеблей и классификации растений (культурных или сорных) на посевах сахарной свеклы [9]. С развитием беспилотных технологий эти наработки были перенесены на аэрофотосъемку. Barreto и соавт. (2021) реализовали полностью автоматический подсчет растений на ортомозаике посева сахарной свеклы с помощью глубокого нейросетевого алгоритма и достигли средней погрешности менее 5% по сравнению с визуальным счетом. Их подход успешно протестирован на кукурузе и клубнике и продемонстрировал ошибку прогнозирования числа растений < 4%. Схожих результатов добились и другие исследователи. Так, для учета густоты всходов хлопчатника с дрона с помощью нейросети YOLOv3 получено совпадение с наземным контролем с коэффициентом детерминации  $R^2 \sim 0,96...0,97$  [10, 11]. Эти примеры подтверждают, что сочетание БПЛА и методов машинного зрения способно обеспечить быстрый и точный подсчет растений на поле, практически нивелируя человеческий фактор. В то же время в условиях России и, в частности, Республики Башкортостан подобные технологии пока не получили широкого распространения, что определяет научную и прикладную значимость данных исследований.

**Цель исследований:** разработка и апробация методики автоматического подсчета всходов сахарной свеклы с использованием беспилотного летательного аппарата и алгоритмов машинного зрения в условиях Республики Башкортостан.

## Материалы и методы

Полевые исследования проводили в 2025 г. на опытных посевах сахарной свеклы в Буздякском районе Республики Башкортостан (54°35' с.ш., 54°35' в.д.). Почвенный покров участка представлен черноземами выщелоченными, характеризующимися высокой влагоемкостью и содержанием гумуса 5,5...6,2%, что соответствует агрономически благоприятным условиям для возделывания сахарной свеклы [12]. Климат района – умеренно континентальный с продолжительным безморозным периодом (130-140 суток) и суммой активных температур выше 10°C порядка 2200...2400°C [12].

Посев выполнен промышленным гибридом сахарной свеклы в середине мая с междурядьями 45 см и нормой высева ~100 тыс. семян/га. Уход за посевами осуществлялся в соответствии с рекомендациями ВНИИССС<sup>1</sup> включая химическую прополку для минимизации сорной растительности.

Аэрофотосъемка и автоматизированный подсчет всходов выполняли в ранний вегетационный период, соответствующий фазам 1...4 настоящих листа по российской классификации и кодам BBCH 12-14<sup>2</sup> [13]. На данном этапе растения четко

идентифицируются по форме розетки, но еще не происходит смыкания листьев в рядках, что минимизирует ошибки сегментации [14].

Для фиксации стадий развития растений использовали систему фаз по российской агрономической классификации с приведением соответствий международной шкале BBCH (табл. 1).

Для обеспечения полного цикла исследований: от получения ортофотоснимков и построения цифровых моделей поверхности до статистической обработки данных и обучения нейросетевых алгоритмов – применили следующие приборы и оборудование:

- беспилотный летательный аппарат DJI Phantom 4 Pro с RGB-камерой (20 Мп, объектив – 8,8 мм, эквивалент фокусного расстояния – 24 мм, пространственное разрешение ~0,8 см/пиксель при высоте полета 20 м);

- двухчастотный GNSS-приемник (RTK) с точностью ±2 см для создания опорных точек;

- вычислительная станция: процессор Intel Core i7-9700K, графический ускоритель NVIDIA GTX 1080 (8 ГБ VRAM), 32 ГБ оперативной памяти;

- программное обеспечение: Agisoft Metashape Professional 1.8.4 (фотограмметрическая обработка),

Таблица 1

Соответствие фаз развития сахарной свеклы по российской системе и шкале BBCH

Table 1

Alignment of sugar beet development phases based on the Russian System and the BBCH Scale

| Фаза развития (российская система)   | Основные признаки   | Код BBCH | Примечания                                     |
|--------------------------------------|---|----------|--|
| Всходы                               | Появление проростков на поверхности почвы, видны семядольные листья | 09-10    | Массовые всходы при 70...80% проросших семян   |
| Семядоли                             | Развиты только семядольные листья, настоящие отсутствуют            | 10       | Длительность – 5-7 дней                        |
| 1...2 настоящих листа                | Появление первой пары настоящих листьев                             | 12       | Начало активного фотосинтеза                   |
| 3...4 настоящих листа                | Листовая розетка увеличивается, листья располагаются под углом      | 14       | Активное наращивание вегетативной массы        |
| 5...6 настоящих листьев              | Розетка закрывает значительную часть междурядья                     | 16       | Начало формирования оптимальной густоты полога |
| Смыкание листьев в рядках            | Листья соседних растений соприкасаются в ряду, почва затенена       | 19-31    | Снижение испарения влаги, подавление сорняков  |
| Смыкание листьев по междурядьям      | Формируется сплошной листовой полог                                 | 31-39    | Максимальная площадь листовой поверхности      |
| Интенсивное утолщение корнеплода     | Быстрый прирост массы корнеплода                                    | 41-49    | Увеличение диаметра и массы                    |
| Накопление сахара                    | Замедление роста массы, активный синтез и отложение сахара          | 49-89    | Период максимального содержания сахара         |
| Биологическая (техническая) спелость | Прекращение роста, пожелтение листьев, готовность к уборке          | 89       | Оптимальный срок уборки                        |

<sup>1</sup> Всесоюзный научно-исследовательский институт сахарной свеклы и сахара (примеч. авт.).

<sup>2</sup> BBCH-scale (beet). Wikipedia. URL: [https://en.wikipedia.org/wiki/BBCH-scale\\_\(beet\)](https://en.wikipedia.org/wiki/BBCH-scale_(beet)) (дата обращения: 15.08.2025)



Python 3.10, библиотеки OpenCV, scikit-image, scikit-learn, PyTorch 2.0, LabelStudio (разметка датасета).

Полетное задание планировали так, чтобы покрыть всю площадь опыта с продольным и поперечным перекрытием снимков ~75%, позволяющим затем сшивать изображения в единый ортофотоплан. Камера была откалибрована и ориентирована строго вниз (угол съемки NADIR), экспозиция устанавливалась вручную исходя из условий освещения во избежание пересвеченных участков.

Полученные аэрофотоснимки предварительно подвергали фотограмметрической обработке в специализированном программном комплексе Agisoft Metashape Professional (версия 1.8.4). На первом этапе выполнялось импортирование набора снимков, их выравнивание (align photos) и автоматическое определение внутренних параметров камеры (focal length, principal point, distortion coefficients). Для повышения геометрической точности создавался набор опорных точек (Ground Control Points, GCP), координаты которых были измерены при помощи двухчастотного GNSS-приемника в режиме RTK с точностью  $\pm 2$  см. После оптимизации выравнивания камер было выполнено построение плотного облака точек в режиме (high quality mode), на основе которого формировались цифровая модель поверхности (DSM) и ортофотоплан в геопривязанном виде (WGS84/UTM Zone 40N).

Для обеспечения достоверности предложенной методики автоматизированного подсчета всходов сахарной свеклы проведен комплекс статистических процедур. Точность работы алгоритмов оценивали по ключевым метрикам компьютерного зрения (Precision, Recall, F1-score, AP50, AP50:95). Для проверки согласованности автоматического и визуального подсчета использовали коэффициент

детерминации ( $R^2$ ) и величину среднеквадратической ошибки (RMSE).


Для оценки статистической значимости различий между автоматическим и ручным подсчетом применяли t-критерий Стьюдента (двусторонний,  $p < 0,05$ ), а также бутстрэп-анализ с формированием 1000 псевдобыборок, позволившим получить 95%-ные доверительные интервалы для ключевых метрик. Данный подход позволил не только подтвердить высокую точность автоматизированного метода, но и исключить вероятность случайных совпадений результатов.

Выбор архитектур YOLO обусловлен их высокой эффективностью в задачах объектной детекции в реальном времени. Модель YOLOv8n включена в исследования как облегченный вариант с низким числом параметров (~3,2 млн, обеспечивающий высокую скорость инференса ( $>120$  FPS на GPU) и потенциальную интеграцию в мобильные и встраиваемые системы для полевых условий. Модель YOLOv5m, напротив, характеризуется увеличенным числом параметров (~21,2 млн, что повышает ее способность к обобщению, особенно при сложных условиях съемки (наличие сорняков, неоднородный фон, вариации освещенности). Сопоставительный анализ двух моделей позволил количественно оценить компромисс между вычислительной сложностью и точностью подсчета.

После фотограмметрической подготовки изображений в Agisoft Metashape дальнейшая обработка выполнялась в среде Python 3.10 с использованием библиотек OpenCV, NumPy, scikit-image и scikit-learn. Разработанный алгоритм автоматического выделения растений включал в себя два этапа: сегментацию по вегетационному индексу и классификацию растительных объектов.

Первый этап включал в себя 5 операций:

1. Сегментация растительности по показателю избытка зелени (Excess Green, ExG) (рис. 1) [15-17].



**Рис. 1. Сегментация растительности по показателю избытка зелени (Excess Green, ExG):**

а – оригинальное изображение; б – Excess Green, ExG индекс; в – сегментация растительности ( $ExG > \text{порога}$ )

**Fig. 1. Vegetation segmentation based on the Excess Green (ExG) index:**

a – original image; b – Excess Green, ExG index; c – vegetation segmentation ( $ExG > \text{threshold}$ )

Для каждого пикселя ортофотоплана вычисляли показатель избытка зелени с нормализованными каналами по формуле:

$$\text{ExG}_n = 2g - r - b,$$

а для «сырых» значений (8-бит) –

$$\text{ExG} = 2G - R - B,$$

где  $R$ ,  $G$ ,  $B$  – цифровые значения каналов красного, зеленого и синего цвета, нормированные в диапазон 0...255. Данный индекс эффективно выделяет зеленую растительность на фоне почвы при съемке в видимом диапазоне, не требуя мультиспектральных данных [17].

2. Бинаризация и формирование маски растительности (рис. 2).

На основе полученной карты ExG проводилась автоматическая бинаризация по методу Оцу, который определяет порог разделения классов «Растительность» и «Фон», исходя из распределения значений индекса [18]. Оптимальный порог  $t^*$  определялся путем максимизации межклассовой дисперсии:

$$t^* = \arg \max_t \sigma_b^2(t);$$

$$\sigma_b^2(t) = \omega_0(t)\omega_1(t)[\mu_0(t) - \mu_1(t)]^2,$$

где  $\omega_k$  – доли классов «Фон»/«Растительность»;  $\mu_k$  – их средние яркости.

Адаптивный учет различий в освещенности и цветовой температуре по полю позволил сформировать бинарную маску, на которой пиксели с ExG выше порога обозначались как «Зеленая растительность».

3. Предварительная фильтрация и морфологическая обработка.

Для устранения шумов и мелких артефактов, вызванных отражением света от влажной почвы или

растительных остатков, применяли морфологические операции:

– открытие (opening) с ядром  $3 \times 3$  пикселя для удаления точечных шумов;

– закрытие (closing) с ядром  $5 \times 5$  пикселей для сглаживания границ объектов:

$$M \circ B = (M \ominus B) \oplus B;$$

$$M \cdot B = (M \oplus B) \ominus B,$$

где  $\oplus$ ,  $\ominus$  – дилатация и эрозия.

4. Выделение контуров и подготовка ROI (regions of interest).

Контурные растительных объектов определяли методом поиска связанных компонент (Connected Components Analysis). Каждая связанная область сохранялась как отдельный ROI с координатами ограничивающего прямоугольника.

5. Передача ROI в классификатор.

На этом этапе выполнялось различение культурных растений и остальных слоев с использованием обученной сверточной сети. На вход модели подавались фрагменты исходного RGB-изображения, соответствующие найденным ROI, что позволяло учитывать текстурные и морфологические признаки объекта, а не только цветовые характеристики.

Метод ExG + пороговая бинаризация применен на первом этапе как вычислительно легкий способ быстрой фильтрации фоновых пикселей, позволяющий существенно сократить объем данных, обрабатываемых нейросетью. Это важно при анализе ортофотопланов большой площади (сотни мегапикселей), когда прямая сегментация всей сцены глубокими моделями требует значительных вычислительных ресурсов [16, 17].

На втором этапе исследований для дифференциации культурных проростков использовали




Рис. 2. Результаты бинаризации и построения маски растительности по индексу избытка зелени (ExG) с применением морфологической фильтрации:

а – бинаризация (метод Оцу); б – очищенная маска растительности; в – выделенная растительность

Fig. 2. Results of binarization and vegetation mask construction based on the Excess Green (ExG) index with the application of morphological filtering:

a – binarization (Otsu method); b – refined vegetation mask; c – extracted vegetation

обученную сверточную нейронную сеть на базе архитектур YOLOv8n и YOLOv5 [19]. В отличие от подхода пиксельной сегментации (FCN) методика YOLO выполняет прямое обнаружение и локализацию объектов на изображении в виде ограничивающих рамок (bounding boxes) и классовых меток, что позволяет значительно ускорить обработку данных и упростить интеграцию алгоритма в полевые мобильные системы.

Модель обучалась на размеченной вручную выборке, включающей в себя 800 фрагментов аэрофотоснимков в фазе развития BBCH 12-14. Разметка выполнялась в программе LabelStudio, где эксперт указывал ограничивающие рамки для каждого проростка сахарной свеклы и остальных объектов – сорняков (рис. 3).

Для каждой рамки присваивался соответствующий класс: «Свекла» – класс 0, «Остальной» – класс 1. Разметка сохранялась в формате YOLO (txt-файлы с нормализованными координатами центра, ширины и высоты рамки относительно размеров изображения). Для обучения и оценки моделей датасет был случайным образом разделен на 3 подмножества: обучающую выборку (70%), валидационную (20%) и тестовую (10%).

При формировании датасета учитывались следующие принципы:

- в каждое подмножество включались изображения из разных участков поля, чтобы исключить переобучение на фоне;

- валидационные и тестовые изображения не пересекались с обучающими по пространственным координатам;

- баланс классов «Свекла»/«Остальное» контролировался на уровне количества аннотированных объектов, а не только числа изображений.

Распределение объектов по классам и подмножествам представлено в таблице 2.

В процессе обучения выполнялась аугментация данных с использованием инструментов, встроенных в PyTorch и Ultralytics YOLO [20]:

- геометрические трансформации (повороты  $\pm 15^\circ$ , масштабирование  $0,9-1,1 \times$ , горизонтальные отражения);

- фотометрические трансформации (изменение яркости  $\pm 20\%$ , контрастности  $\pm 20\%$ , насыщенности  $\pm 15\%$ );

- случайное изменение гаммы и добавление гауссова шума ( $\sigma = 0,01 \dots 0,03$ ).

Обучение моделей YOLOv8n и YOLOv5 проводили в среде PyTorch 2.0 на графическом процессоре NVIDIA GTX 1080 с использованием методики трансферного обучения. Начальные веса были инициализированы на основе предварительно обученных моделей на датасете COCO, что позволило ускорить сходимость и повысить точность на малом объеме данных. В процессе обучения использовалась функция потерь, включающая в себя компоненты CIoU Loss для регрессии координат рамок, Binary



**Рис. 3. Пример аннотирования аэрофотоснимка посевов сахарной свеклы в системе Label Studio:**  
красный – класс «Свекла»; синий – класс «Остальное-сорняки»

**Fig. 3. Example of annotating an aerial photograph of sugar beet crops in the Label Studio system:**  
red – class “Beet”; blue – class “Other – weeds”



Таблица 2

## Распределение объектов в датасете по классам и подмножествам

Table 2

## Distribution of objects in the dataset by classes and subsets

| Подмножество          | Количество изображений, ед. | Класс «Свекла», шт. | Класс «Остальное», шт. | Всего объектов, шт. |
|-----------------------|-----------------------------|---------------------|------------------------|---------------------|
| Обучающая выборка     | 560                         | 29 120              | 3 360                  | 32 480              |
| Валидационная выборка | 160                         | 8 320               | 960                    | 9 280               |
| Тестовая выборка      | 80                          | 4 160               | 480                    | 4 640               |
| Итого                 | 800                         | 41 600              | 4 800                  | 46 400              |

Cross-Entropy (BCE) для классификации и BCE с логитами для сегментационной маски (в случае YOLOv8n-seg).

В процессе обучения отслеживали ключевые метрики качества: точность (Precision), полноту (Recall) и среднюю точность при различных порогах IoU – mAP@0.5 и mAP@0.5:0.95. Дополнительно фиксировали значения функций потерь для различных компонентов модели (box\_loss, seg\_loss, cls\_loss, dfl\_loss) как на обучающей, так и на валидационной выборках.

Для получения непосредственно количества растений алгоритм обрабатывал выходные bounding boxes класса «Свекла» из результатов детекции:

- исключались рамки с вероятностью ниже 0,5 (score threshold);
- применялось Non-Maximum Suppression (NMS) с порогом IoU = 0,45 для устранения дубликатов;
- каждой оставшейся рамке присваивались координаты центра, которые считались положением растения.

Автоматизированный подсчет всходов сахарной свеклы выполнялся простым суммированием всех центроидов детекций класса «Свекла». Полученные данные масштабировались до значения на 1 га:

$$N_{\text{га}} = \frac{N_{\text{plot}}}{A_{\text{plot}}} \cdot 10^4,$$

где  $N_{\text{plot}}$  – число растений на контрольной площадке;  $A_{\text{plot}}$  – площадь этой площадки, м<sup>2</sup>.

Для контроля точности автоматического счета произведен традиционный визуальный подсчет растений на ряде пробных участков. На поле выбрали 15 пробных квадратов площадью 5 × 2 м в различных зонах (с краю поля, в центральной части, на участках с признаками ухудшенных условий). В фазу 2...4 настоящих листьев (ВВСН 12-14) два наблюдателя вручную подсчитали количество всходов внутри каждого такого квадрата, стараясь не пропустить скрытые сорняками или находящиеся в тени экземпляры. Эти данные послужили эталонными значениями (ground truth) для оценки алгоритма. Автоматизированный подсчет всходов по ортофотоснимкам

осуществлялся для тех же участков. Из общей карты выделяли фрагменты, соответствующие контрольным квадратикам, и извлекали число обнаруженных алгоритмом проростков внутри них. Точность оценивали по нескольким метрикам: а) абсолютной разнице между автоматическим и контрольным количеством растений; б) относительной ошибке в процентах, рассчитываемой по формуле  $E = |N_{\text{авто}} - N_{\text{визуал}}| / N_{\text{визуал}} \cdot 100\%$ ; в) коэффициенту детерминации ( $R^2$ ) линейной зависимости между автоматически подсчитанным и фактическим числом растений по всем выборкам.

### Результаты и их обсуждение

Автоматическая детекция и сегментация всходов сахарной свеклы на аэрофотоснимках, полученных с беспилотного летательного аппарата, осуществлены в результате обучения и сравнительной оценки двух архитектур сверточных нейронных сетей YOLOv8n и YOLOv5m. Оценка эффективности моделей выполнялась по ключевым метрикам компьютерного зрения включая точность (Precision), полноту (Recall) и среднюю точность определения (mAP) при различных порогах IoU, а также по функциям потерь для детекции (box\_loss), сегментации (seg\_loss) и классификации (cls\_loss).

Построенные графики (рис. 4, 5) отражают динамику изменения метрик и функций потерь, позволяя визуально оценить процесс сходимости моделей и выявить различия в их обучаемости, обобщающей способности и вычислительной производительности.

У YOLOv8n кривая train/box\_loss снижается с 1,4 до 0,35, а val/box\_loss демонстрирует устойчивое падение с 1,45 до 0,85 без значительных выбросов. Потери сегментации (seg\_loss) и классификации (cls\_loss) уменьшаются синхронно для тренировочной и валидационной выборок, что указывает на более стабильную сходимость. Precision(B) достигает 0,80; Recall(B) – около 0,70; mAP50(B) – 0,75; mAP50-95(B) – около 0,60. Для сегментации масок метрики выше, чем у YOLOv5m, – mAP50(M) ~0,69 и mAP50-95(M) ~0,37.






Рис. 4. Динамика обучения модели YOLOv8n при детекции и сегментации всходов сахарной свеклы

Fig. 4. Training dynamics of the YOLOv8n model for detection and segmentation of sugar beet seedlings

Из данных графиков рисунка 5 следует, что train/box\_loss для YOLOv5m снижается с  $\approx 1,75$  до 0,3. При этом val/box\_loss колеблется в диапазоне 1,15...1,25, что указывает на возможные проблемы с обобщением; seg\_loss и cls\_loss также уменьшаются, но валидационные значения для сегментации растут после 100-й эпохи, что может говорить о начале переобучения. Precision(B) стабилизируется в районе 0,72; Recall(B) – около 0,44; mAP50(B) достигает примерно 0,51, а mAP50-95(B) – 0,33. Для масок (M) показатели значительно ниже: mAP50(M) – около 0,025,

mAP50-95(M) – менее 0,007, что отражает сложность задачи сегментации для данной архитектуры.

Для сравнения работы YOLOv8n и YOLOv5m при детекции всходов сахарной свеклы использовали метрики Precision (P), Recall (R), Average Precision (AP) и F1-score 1-3. Precision отражает долю верных детекций, Recall – полноту обнаружения [0, 0]. AP рассчитывался при пороге IoU = 0,5 (AP50) и как среднее по порогам 0,5...0,95 (AP50:95). F1-score позволяет оценить баланс точности и полноты (табл. 3).




Рис. 5. Динамика обучения модели YOLOv5m при детекции и сегментации всходов сахарной свеклы

Fig. 5. Training dynamics of the YOLOv5m model for detection and segmentation of sugar beet seedlings

Таблица 3

Результаты оценки качества моделей на тестовых данных

Table 3

Results of quality assessment of models on test data

| Модель  | Precision (P) | Recall (R) | AP50 | AP50:95 | F1-score |
|---------|---------------|------------|------|---------|----------|
| YOLOv8n | 0,80          | 0,70       | 0,75 | 0,60    | 0,75     |
| YOLOv5m | 0,72          | 0,44       | 0,51 | 0,33    | 0,54     |

YOLOv8n продемонстрировала лучшие результаты по всем показателям, особенно по Recall (0,70 против 0,44) и AP50 (0,75 против 0,51), что указывает на более высокую способность к обобщению.

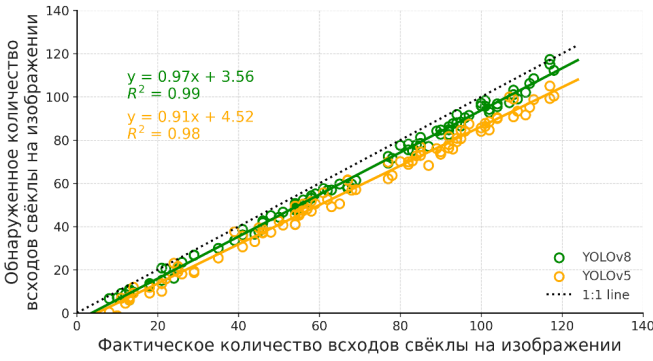
В ходе исследований фактическое количество всходов сахарной свеклы на тестовых изображениях сравнивалось с количеством обнаруженных всходов с помощью моделей YOLOv8n и YOLOv5m (рис. 6).

Установлено, что обе модели демонстрируют высокую корреляцию с реальным количеством растений, при этом коэффициент детерминации ( $R^2$ ) составил 0,99 для YOLOv8n и 0,98 для YOLOv5m. Однако модель YOLOv5m показала большую погрешность с репрезентативным наклоном 0,91, в то время как YOLOv8n наиболее точно соответствовала фактическому количеству обнаружений с наклоном 0,97. YOLOv8n обеспечила наилучшие результаты по детекции и подсчету всходов сахарной свеклы, которые были наиболее близки к фактическому количеству растений и лучше отражали реальные полевые условия. Визуализация результатов работы обеих моделей с демонстрацией различий в сегментации, количестве выявленных объектов и корректности выделения растений сахарной свеклы относительно класса остальных представлена на рисунке 7.

Визуальный анализ полученного ортофотомозаика и результатов сегментации показал, что разработанный алгоритм успешно обнаруживает большинство всходов сахарной свеклы.

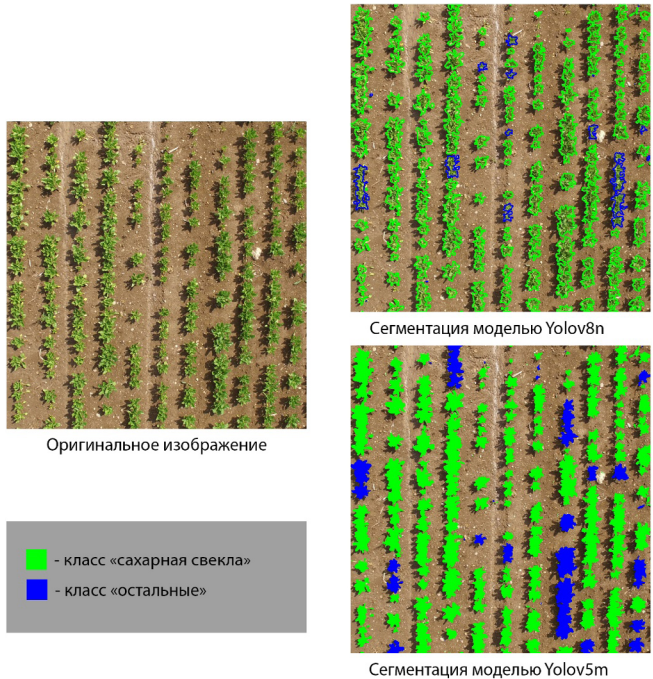
Установленные различия в точности детекции дополнительно подтверждены количественными расчетами. В таблице 4 для каждой модели приведены количество детектированных растений на опытном участке площадью 25 м<sup>2</sup> и на 1 га, а также значения контрольного подсчета, относительной ошибки, RMSE и коэффициента детерминации  $R^2$ .

Анализ данных показывает, что YOLOv8n обеспечивает минимальную относительную ошибку (1,11%) и наименьшее значение RMSE (3,0), которые указывают на более высокую стабильность детекции по сравнению с YOLOv5m. При этом обе модели демонстрируют высокий коэффициент детерминации ( $R^2 > 0,98$ ), что подтверждает их надежную



**Рис. 6. Сравнение фактического и обнаруженного количества всходов сахарной свеклы на тестовом изображении при использовании различных методов глубокого обучения**

**Fig. 6. Comparison of the actual and detected number of sugar beet seedlings in a test image when using various deep learning methods**



**Рис. 7. Результаты сегментации всходов сахарной свеклы и сорной растительности по данным БПЛА с использованием моделей YOLOv8n и YOLOv5m**

**Fig. 7. Segmentation results of sugar beet seedlings and weeds from UAV data using YOLOv8n and YOLOv5m models**

**Сравнительные результаты автоматической детекции всходов сахарной свеклы моделями YOLOv8n и YOLOv5m**

Таблица 4

Table 4

**Comparative results of automatic detection of sugar beet seedlings by YOLOv8n and YOLOv5m models**

| Модель  | Площадь участка, м <sup>2</sup> | Детекты, $N_{plot}$ , шт. | Пересчет на 1 га, $N_{га}$ , шт. | Контроль, $N_{gt}$ , шт. | Относительная ошибка, % | RMSE | $R^2$ |
|---------|---------------------------------|---------------------------|----------------------------------|--------------------------|-------------------------|------|-------|
| YOLOv8n | 25                              | 712                       | 28 480                           | 720                      | 1,11                    | 3,0  | 0,99  |
| YOLOv5m | 25                              | 688                       | 27 520                           | 720                      | 4,44                    | 6,4  | 0,98  |

корреляцию с фактическим количеством растений. YOLOv5m, несмотря на несколько большую ошибку (4,44%) и RMSE (6,4), также показала удовлетворительную точность и может использоваться в задачах полевого мониторинга, но для высокой точности подсчета более предпочтительной является модель YOLOv8n.

Результаты проведенных нами исследований находятся на уровне лучших мировых достижений в этой области. Ранее А.А. Barreto и соавт. [4] на посевах сахарной свеклы при различных параметрах съемки получили среднюю ошибку прогноза числа растений 4,6%. При этом они отметили рост погрешности на более поздних этапах роста и при уменьшении интервала между растениями, и эти тенденции полностью согласуются с нашими наблюдениями. В работе S. Oh [11], посвященной учету густоты хлопчатника с помощью дрона, достигнута сопоставимая точность коэффициента детерминации  $R^2 \sim 0,97$  и RMSE порядка 0,5 растения на 1 м ряда. Предложенный метод подсчета свеклы демонстрирует эффективность, сопоставимую с методами для других культур, подтверждая универсальность подхода на основе глубокого обучения.

Отметим преимущество автоматизированного подхода, заключающееся не только в высокой точности, но и в оперативности и масштабируемости. На полный облет поля площадью ~20 га и обработку данных в наших исследованиях уходило менее одного рабочего дня, тогда как ручной подсчет с аналогичной детализацией потребовал бы несколько дней работы группы агрономов.

Автоматический метод исключает субъективные ошибки и вариабельность оценок разных наблюдателей. Кроме того, помимо общего числа растений, наш алгоритм предоставляет геокоординаты каждого проростка, что позволяет визуализировать пространственное распределение густоты всходов на карте поля. Это дает ценные сведения для дифференцированного управления посевами: например, можно выделить зоны с изреженными всходами и своевременно провести там подсев или коррекцию ухода. Современные онлайн-платформы (например, Proofminder, Agremo и др.) уже реализуют похожие функции, предоставляя отчеты о посеве на основе снимков дронов.

Следует отметить, что условия проведения съемки и стадии развития растений существенно влияют на качество распознавания. Наш опыт подтверждает рекомендации практиков: оптимальным временем для аэрофотосъемки всходов является фаза, когда растения достаточно подросли для уверенного обнаружения, но еще не сомкнулись листьями.

Для сахарной свеклы это интервал примерно от 2 до 6 настоящих листьев (ВВСН 12-16). Съемка на более ранней стадии (семядоли) может привести к пропуску самых мелких проростков или ошибочной классификации комочков почвы как растения. С другой стороны, в фазе смыкания листового полога отдельные растения уже трудно различимы даже визуально – здесь метод может недооценивать численность по причине слияния смежных особей. В таких случаях возможна модификация подхода: использование нейросетей, генерирующих карту плотности (density map), либо комбинирование RGB-снимков с данными других сенсоров (например, лидаром или мультиспектральной камерой), что помогло бы разделять перекрывающиеся объекты. Еще один фактор – наличие сорной растительности. В нашем эксперименте фон сорняков был слабым (благодаря вовремя проведенной химпрополке), но при обилии сорняков необходимо дополнять обучающую выборку примерами сорных растений, чтобы сеть не смогла перепутать их со свеклой. Использование мультиспектральных снимков (включая ближний ИК-диапазон) могло бы упростить эту задачу, так как индексы типа NDVI легче отделяют культурные всходы от некоторых видов сорняков. Уже существуют успешные примеры применения мультиспектральных камер на дронах для классификации свеклы и сорняков по отражательным характеристикам, и в перспективе интеграция спектральных признаков в нашу модель может повысить ее надежность.

Данные исследования показали принципиальную осуществимость и высокую эффективность автоматического учета всходов сахарной свеклы в условиях Республики Башкортостан. Полученные нами уровни точности (ошибка порядка нескольких процентов) свидетельствуют о том, что технология готова к внедрению в производственных хозяйствах. Автоматический подсчет может использоваться агрономическими службами для подтверждения качества посева и принятия решений о частичном пересевании. Карта распределения всходов может быть основой для дифференцированного ухода: участки с угнетенными всходами можно точно подкормить, а на равномерных густых всходах можно снизить нормы удобрений или гербицидов с целью экономии ресурсов.

В перспективе планируется адаптация разработанного алгоритма для мобильных устройств (например, быстрая обработка данных непосредственно в полевых условиях на ноутбуке или планшете), а также расширение функциональности до одновременного учета сорной растительности. Последнее позволит считать всходы и генерировать карту засоренности посева для прецизионной междурядной обработки



или выборочного опрыскивания гербицидами. Оправданной стала бы проверка метода на других культурах, выращиваемых в регионе (например, подсолнечнике, кукурузе), что может внести вклад в развитие универсальных систем мониторинга посевов на основе БПЛА.

### Выводы

Для условий Республики Башкортостан разработана и экспериментально подтверждена методика автоматизированного учета всходов сахарной свеклы на основе аэрофотосъемки с БПЛА и алгоритмов глубокого обучения. Показано, что комбинация пороговой сегментации и сверточной нейронной сети обеспечивает высокую достоверность результатов, сопоставимую с визуальным

контролем. Наилучшие показатели продемонстрировала модель YOLOv8n (Precision = 0,80; Recall = 0,70; AP50 = 0,75;  $R^2$  = 0,99; ошибка = 1,11%; RMSE = 3,0), что статистически значимо превосходит результаты YOLOv5m (Precision = 0,72; Recall = 0,44;  $R^2$  = 0,98; ошибка = 4,44%; RMSE = 6,4;  $p < 0,05$ ).

Внедрение разработанной технологии позволяет снизить трудоемкость подсчета всходов в 30...40 раз по сравнению с ручными методами, исключает субъективные ошибки наблюдателей и обеспечивает агронома объективными данными о пространственном распределении густоты стояния растений. Построенные карты могут быть интегрированы в системы точного земледелия для оптимизации агротехнологических решений, повышения урожайности и ресурсной эффективности производства сахарной свеклы.

### Список источников / References

1. Альт В.В., Пестунов И.А., Мельников П.В., Ёлкин О.В. Автоматизированное обнаружение сорняков и оценка качества всходов сельскохозяйственных культур по RGB-изображениям // Сибирский вестник сельскохозяйственной науки. 2018. Т. 48, № 5. С. 52-60. <https://doi.org/10.26898/0370-8799-2018-5-7>
- Alt V.V., Pestunov I.A., Melnikov P.V., Elkin O.V. Automated detection of weeds and evaluation of crop sprouts quality based on RGB images. *Siberian Herald of Agricultural Science*. 2018;48(5):52-60. (In Russ.) <https://doi.org/10.26898/0370-8799-2018-5-7>
2. Бастаубаева Н.Л., Бекбатыров М.Б., Табынбаева Л.К., Буряходжа А.М. Формирование запрограммированного урожая сахарной свеклы путем воздействия основных элементов регулирования // Сахар. 2021. № 10. С. 32-38. EDN: XTUBQI
- Bastaubaeva N.L., Bekbatyrov M.B., Tabynbaeva L.K., Burakhjoja A.M. Formation of a programmed sugar beet harvest by influencing the basic elements of regulation. *Sakhar*. 2021;10:32-38. (In Russ.)
3. Василенко В.В., Василенко С.В. Инверсия семян и ее влияние на качество пунктирного посева // Вестник Воронежского государственного аграрного университета. 2019. Т. 12, № 2. С. 102-108. EDN: WMRPRL
- Vasilenko V.V., Vasilenko S.V. Inversion of seeds and its effect on the quality of single-grain sowing. *Vestnik of Voronezh State Agrarian University*. 2019;12(2):102-108. (In Russ.) EDN: WMRPRL
4. Barreto A.A., Lottes P., Yamati F.R.I. et al. Automatic UAV-based counting of seedlings in sugar beet fields and extension to maize and strawberry. *Computers and Electronics in Agriculture*. 2021;191:106493. <https://doi.org/10.1016/j.compag.2021.106493>
5. Голтыяпин В.Я., Голубев И.Г. Направления и опыт использования беспилотных летательных аппаратов для обследования земель сельскохозяйственного назначения // Актуальные вопросы развития аграрного сектора экономики Байкальского региона: Материалы Всероссийской (национальной) научно-практической конференции, посвященной Дню российской науки, Улан-Удэ, 4-10 февраля 2021 г. Улан-Удэ: Бурятская государственная сельскохозяйственная академия имени В.Р. Филиппова, 2021. С. 81-85. EDN: OWFSMS
- Goltyapin V.Ya., Golubev I.G. Areas and experience of using unmanned aerial vehicles for surveying agricultural lands. *Aktualnye voprosy razvitiya agrarnogo sektora ekonomiki baykalskogo regiona: Proceedings of the All-Russian (National) scientific and practical conference dedicated to the Day of Russian Science*, Ulan-Ude, February 04-10, 2021. Ulan-Ude: Buryat State Agricultural Academy named after V.R. Filippov, 2021. Pp. 81-85.
6. Zhang S., Yang Y., Tu L. et al. Comparison of YOLO-based sorghum spike identification detection models and monitoring at the flowering stage. *Plant Methods*. 2025;21(20). <https://doi.org/10.1186/s13007-025-01338-z>
7. Casado-García A., Heras J., Milella A., Marani R. Semi-supervised deep learning and low-cost cameras for the semantic segmentation of natural images in viticulture. *Precision Agriculture*. 2022;23(6):2001-2026. <https://doi.org/10.1007/s11119-022-09929-9>
8. Мударисов С.Г., Мифтахов И.Р. Методы глубокого обучения и технологии БПЛА для идентификации заболеваний сельскохозяйственных растений // Сельскохозяйственные машины и технологии. 2024. Т. 18, № 4. С. 24-33. <https://doi.org/10.22314/2073-7599-2024-18-4-24-33>
- Mudarisov S.G., Miftakhov I.R. Deep learning methods and UAV technologies for crop disease detection. *Agricultural Machinery and Technologies*. 2024;18(4):24-33. (In Russ.) <https://doi.org/10.22314/2073-7599-2024-18-4-24-33>
9. Lottes P., Behley J., Milioto A., Stachniss C. Fully convolutional networks with sequential information for robust crop and weed detection in precision farming. *IEEE Robotics and Automation Letters*. 2018;3(4):2870-2877. <https://doi.org/10.48550/arXiv.1806.03412>
10. Logeshwaran J., Srivastava D., Kumar K.S. et al. Improving crop production using an agro-deep learning framework in precision agriculture. *BMC Bioinformatics*. 2024;25:341. <https://doi.org/10.1186/s12859-024-05970-9>
11. Oh S., Chang A., Ashapure A. et al. Plant counting of cotton from UAS imagery using deep learning-based object detection framework. *Remote Sensing*. 2020;12(18):2981. <https://doi.org/10.3390/rs12182981>
12. Миннихметов И.С., Мурзабулатов Б.С., Шафеева Э.И., Лыкасов О.Н. Развитие сельского хозяйства Буздякского района Республики Башкортостан // Вестник Башкирского государственного аграрного университета. 2021. № 1 (57). С. 27-34. EDN: XLXCGQ
- Minniakhmetov I.S., Murzabulatov B.S., Shafeeva E.I., Lykasov O.N. Development of agriculture in the Buzdyaksky



district of the Republic of Bashkortostan. *Vestnik Bashkir State Agrarian University*. 2021;1:27-34. (In Russ.)

13. Бушнев А.С., Орехов Г.И., Котлярова И.А. и др. Эффективность технологических приемов возделывания материнской линии подсолнечника // *Аграрная наука Евро-Северо-Востока*. 2025. Т. 26, № 1. С. 115-128. <https://doi.org/10.30766/2072-9081.2025.26.1.115-128>

Bushnev A.S., Orekhov G.I., Kotlyarova I.A. et al. Efficiency of technological methods of cultivation of sunflower maternal line. *Agricultural Science Euro-North-East*. 2025;26(1):115-128. (In Russ.) <https://doi.org/10.30766/2072-9081.2025.26.1.115-128>

14. Сычёва И.В., Сычёв С.М., Осипов А.А. Оценка распространённости болезней на гибридах сахарной свеклы // *Вестник Брянской государственной сельскохозяйственной академии*. 2024. № 2 (102). С. 31-36. EDN: VCIEZH

Sycheva I.V., Sychev S.M., Osipov A.A. Evaluation of disease prevalence on sugar beet hybrids. *Vestnik Bryanskoy GSKhA*. 2024;2:31-36. (In Russ.)

15. Han X., Wang H., Yuan T. et al. A rapid segmentation method for weed based on CDM and ExG index. *Crop Protection*. 2023;172:106321. <https://doi.org/10.1016/j.cropro.2023.106321>

16. Vaghefi S.A., Ibrahim M.F., Mohd M.H. et al. Optimized weed image classification via parallel convolutional neural networks integrating an excess green index channel. *International journal of electrical and computer engineering systems*. 2025;16(3):205-216. <https://doi.org/10.32985/ijeces.16.3.2>

17. Ueno T., Nagano Sh., Moriyuki Sh. et al. Optimized excess-green image binarization for accurate estimation of lettuce seedling leaf-area in a plant factory. *Environmental Control in Biology*. 2022;60(3):153-159. <https://doi.org/10.2525/ecb.60.153>

18. Сухобок Ю.А., Тен Е.Е., Пономарчук Ю.В., Шоберг К.А. Автоматический поиск рельсовых стыков

с использованием методов обработки // *Актуальные теоретико-методологические и прикладные проблемы виртуальной реальности и искусственного интеллекта: Материалы Международной научной конференции*. Хабаровск: Дальневосточный государственный университет путей сообщения, 2021. С. 56-63. EDN: AEKRDH

Sukhobok Yu.A., Ten Ye.E., Ponomarchuk Yu.V., Shoberg K.A. Railway gap detection based on image processing and deep learning techniques. *Aktualnye teoretiko-metodologicheskie i prikladnye problemy virtualnoy realnosti i iskusstvennogo intellekta: Proceedings of the International Scientific Conference*. 2021. Khabarovsk: Far Eastern State University of Railway Transport. Pp. 56-63

19. Кутырёв А.И. Сверточная нейронная сеть для сегментации цветков яблони на изображениях // *Аграрная наука Евро-Северо-Востока*. 2024. Т. 25, № 5. С. 949-961. <https://doi.org/10.30766/2072-9081.2024.25.5.949-961>

Kutyrev A.I. Convolutional neural network for segmentation of apple blossoms in images. *Agricultural Science Euro-North-East*. 2024;25(5):949-961. (In Russ.) <https://doi.org/10.30766/2072-9081.2024.25.5.949-961>

20. Ронкин М.В., Акимова Е.Н., Мисилов В.Е., Решетников К.И. Обзор применения глубоких нейронных сетей и параллельных архитектур в задачах фрагментации горных пород // *Вестник Южно-Уральского государственного университета. Серия «Вычислительная математика и информатика»*. 2023. Т. 12, № 4. С. 5-54. <https://doi.org/10.14529/cmse230401>

Ronkin M.V., Akimova E.N., Misilov V.E., Reshetnikov K.I. Review on application of deep neural networks and parallel architectures for rock fragmentation problems. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2023;12(4):5-54. (In Russ.) <https://doi.org/10.14529/cmse230401>

### Информация об авторах

<sup>1</sup> Мударисов Салават Гумерович, д-р техн. наук, профессор; [salavam@gmail.com](mailto:salavam@gmail.com); <https://orcid.org/0000-0001-9344-2606>; SPIN-код: 6893-9957

<sup>2</sup> Мифтахов Ильнур Ринатович, канд. техн. наук; [info323@bk.ru](mailto:info323@bk.ru); <https://orcid.org/0000-0002-3125-3532>; SPIN-код: 9429-5990

<sup>3</sup> Фархутдинов Илдар Мавляирович, д-р техн. наук, доцент; [ildar1702@mail.ru](mailto:ildar1702@mail.ru); <https://orcid.org/0000-0002-6443-8584>; SPIN-код: 8646-6670

<sup>1,2,3</sup> Башкирский государственный аграрный университет, кафедра мехатронных систем и машин аграрного производства; 450001, Российская Федерация, Республика Башкортостан, г. Уфа, ул. 50 лет Октября, 34

### Вклад авторов

С.Г. Мударисов – руководство исследованиями, методология; И.Р. Мифтахов – проведение исследований, верификация данных, визуализация, создание окончательной версии (доработка) рукописи и ее редактирование; И.М. Фархутдинов – анализ предметной области, проведение исследований

### Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов и несут ответственность за плагиат.

Статья поступила 26.09.2025, после рецензирования и доработки 10.10.2025; принята к публикации 13.10.2025

### Author Information

Salavat G. Mudarisov<sup>1</sup>, DSc (Eng), Professor; [salavam@gmail.com](mailto:salavam@gmail.com); <https://orcid.org/0000-0001-9344-2606>; Scopus Author ID: 57200284613

Ilnur R. Miftakhov<sup>2</sup>, CSc (Eng); [info323@bk.ru](mailto:info323@bk.ru); <https://orcid.org/0000-0002-3125-3532>

Ildar M. Farkhutdinov<sup>3</sup>, DSc (Eng), Associate Professor; [ildar1702@mail.ru](mailto:ildar1702@mail.ru); <https://orcid.org/0000-0002-6443-8584>; ResearcherID: G-2816-2018

<sup>1,2,3</sup> Bashkir State Agrarian University, Department of Mechatronic Systems and Machines for Agricultural Production; St. 50 years of October, 34, Ufa, 450001, Republic of Bashkortostan, Russian Federation

### Author Contributions

S.G. Mudarisov: research supervision, methodology. I.R. Miftakhov: investigation, data verification, visualization, writing – review and editing of the manuscript. I.M. Farkhutdinov: research background analysis, investigation.

### Conflict of interests

The authors declare no conflict of interests and are responsible for plagiarism.

Received 26.09.2025; Revised 10.10.2025; Accepted 13.10.2025