









Научная статья

НАБОР АННОТИРОВАННЫХ ИЗОБРАЖЕНИЙ СОЕВОГО ПОЛЯ ДЛЯ НАСТРОЙКИ МОДЕЛЕЙ ДЕТЕКТИРОВАНИЯ РАСТЕНИЙ

Равиль И. Мухамедиев^{1,2} д.инж.н. , Валентин В. Смурьгин¹ , Людмила А. Городецкая¹ , Диас Құсайын¹ , Адилхан Сымагулов¹ , Надия Р. Юничева^{2,3*} к.т.н. .

¹ КазНИТУ им. К.И. Сатпаева, Алматы, Казахстан; ravil.muhamedyev@gmail.com (РИМ), valentinsmurygin@gmail.com (BBC), ludmila260601@gmail.com (ЛАГ), a.symagulov@satbayev.university (АС), diac.kusain@gmail.com (ДК);

² Институт информационных и вычислительных технологий КН МНВО РК, Алматы, Казахстан; naduni@mail.ru (НPIO), ravil.muhamedyev@gmail.com (РИМ);

³ Алматинский Университет энергетики и связи им. Г. Даукеева, Алматы, Казахстан; naduni@mail.ru (НPIO);

*Автор корреспонденции: Надия Р. Юничева, naduni@mail.ru

КЛЮЧЕВЫЕ СЛОВА

точное земледелие, соя, детектирование, данные с БПЛА, нейронные сети, YOLOv8.

АБСТРАКТ

В статье представлен аннотированный датасет Soybean_2021_Almalaybak, предназначенный для задач автоматического анализа сельскохозяйственных территорий на основе аэрофотоснимков, полученных с использованием беспилотного летательного аппарата (БПЛА). Датасет включает изображения соевых полей, охватывающие различные фазы роста растений и содержащие ручную разметку 12 классов объектов, включая культурный и сорные виды. Работа акцентирует внимание на значении полевых данных, отражающих реалистичное состояние агроландшафтов, для обучения устойчивых моделей компьютерного зрения.

В качестве базовой модели была использована YOLOv8x — современная архитектура для одновременной локализации и классификации объектов. Модель обучалась на размеченной выборке из 300 изображений без применения аугментации, что позволило получить эталонную оценку точности. Экспериментальные результаты продемонстрировали высокую эффективность модели: F1-score по классу Glycine max (соя) составил 0.933, а метрика mAP@0.5 — 0.72. Несмотря на ограниченный объем данных и частичную аннотацию, модель показала устойчивость к вариативности полевых условий и несбалансированности классов.

По статье:

Получено: 13.01.2026

Пересмотрено: 15.02.2026

Принято: 31.03.2026

Опубликовано: 01.04.2026

Для цитирования:

Мухамедиев Р., Смурьгин В., Городецкая Л., Құсайын Д., Сымагулов А., Юничева Н. Набор аннотированных изображений соевого поля для настройки моделей детектирования растений // Гидрометеорология и экология, 121 (1), 2026, 100-109.

1. ВВЕДЕНИЕ

Современное сельское хозяйство находится в условиях постоянного роста требований к эффективности производства, обусловленных увеличением численности населения, ограниченностью природных ресурсов и необходимостью повышения продуктивности агросистем. Одним из перспективных направлений повышения эффективности агропроизводства является внедрение технологий искусственного интеллекта (ИИ) и методов точного земледелия [1]. Как подчеркивается в работе Cosmin Pora [2], ИИ способен трансформировать аграрный сектор за счёт интеграции экспертных систем, сенсорных технологий и автономных роботов. Однако автор отмечает неравномерное распространение подобных решений, связанное с инфраструктурными, экономическими и технологическими барьерами. Несмотря на это, наблюдается устойчивая тенденция к расширению применения интеллектуальных систем в задачах мониторинга состояния посевов, автоматизации полевых работ и поддержки принятия решений.

Одной из ключевых задач в рамках точного земледелия является своевременное распознавание культурных и сорных растений. Автоматизация этих процессов с применением алгоритмов компьютерного зрения и машинного обучения позволяет

оптимизировать агротехнические мероприятия, снижая потребность в гербицидах, повышая урожайность и снижая производственные издержки [3]. Однако разработка надёжных систем для классификации и детектирования растений требует наличия репрезентативных и качественно аннотированных наборов данных, отражающих реальное разнообразие полевых условий, растений и стадий их развития.

Существующие датасеты, созданные для решения подобных задач, демонстрируют значительное разнообразие в условиях съёмки, типах культур и способах аннотирования [4, 5, 6]. Так, Crop/Weed Field Image Dataset [7] включает изображения морковных полей, полученные при помощи робота *Wopigob* на органической ферме, с аннотациями по типу растительности (культура или сорняк) и масками вегетации. Данный датасет применялся для задач фенотипирования, включая сегментацию и классификацию растений, и подчёркивает значение открытого доступа к полевым данным. Аналогичный по тематике Carrot-Weed dataset [8] также содержит изображения растений моркови и сорняков в естественных условиях освещённости, что делает его полезным для устойчивого обучения моделей.

Для задач классификации проростков растений в контролируемых условиях в исследовании [9] предложили датасет изображений 12 видов культурных и сорных растений на ранних стадиях развития. Целью работы было формирование стандартизированной базы для обучения алгоритмов точечного удаления сорняков. Несмотря на значимость этой работы, её ограничения связаны с лабораторными условиями съёмки и ограниченным набором видов, что подчёркивает необходимость создания новых датасетов, приближенных к реальным полевым условиям.

Отдельное внимание уделяется датасетам, охватывающим разнообразие видов и стадий роста растений. В работе [10] был представлен подход к автоматизированной оценке фенофаз 18 видов сорных растений на основе изображений, полученных в полевых условиях. С применением архитектуры Inception-v3 и более 11 000 аннотированных изображений достигнута точность 96 % при классификации по числу листьев с допустимым отклонением. Это подтверждает потенциал сверточных нейронных сетей в условиях высокого визуального шума сельскохозяйственного производства и демонстрирует необходимость создания разнообразных и реалистичных наборов данных.

В области изучения соевых культур и сопутствующих сорных растений особое внимание привлекает работа [11], в которой представлена система автоматического детектирования сорняков на изображениях, полученных с БПЛА. Используется более 15 000 изображений, включающих сою, почву, злаковые и двудольные сорняки, авторы обучили модель на основе архитектуры CaffeNet. Сегментация изображений осуществлялась с помощью алгоритма SLIC, а итоговая точность классификации превысила 98 %, что демонстрирует эффективность ConvNet-моделей в аграрных задачах. Несмотря на высокую ценность этого датасета, он ограничен фиксированным разрешением и типом сенсора, а также не предполагает аннотирования на уровне отдельных экземпляров растений.

В свою очередь, работа WeedMap [12] демонстрирует подход к семантической сегментации посевов с использованием мультиспектральных изображений. Съёмка осуществлялась с БПЛА, а обработка данных велась на основе метода скользящего окна и свёрточных нейронных сетей. Важным аспектом этой работы стало выравнивание спектральных каналов и радиометрическая калибровка, позволившие улучшить точность сегментации. Представленный датасет включает вручную аннотированные мультиспектральные изображения сахарной свёклы и сорняков и иллюстрирует преимущества многоаспектных изображений при решении аграрных задач.

Таким образом, несмотря на наличие различных наборов данных, ориентированных на задачи распознавания культурных и сорных растений, в открытом доступе по-прежнему ощущается дефицит изображений, полученных в реальных

условиях соевых полей, с аннотациями, пригодными для обучения современных моделей детекции объектов. В настоящей работе представлен новый аннотированный датасет, собранный в Алматинской области Казахстана с использованием дрона DJI Mavic Mini 2. Набор включает RGB-изображения высокого разрешения с разметкой культурных растений и сорняков и предназначен для обучения и валидации моделей детекции, таких как YOLOv8. Целью создания данного датасета является содействие разработке устойчивых систем автоматического мониторинга сельхозугодий и восполнение нехватки открытых полевых данных для задач точного земледелия в условиях соевых культур.

2. ОПИСАНИЕ ДАТАСЕТА

Набор данных Soybean_2021_Almalymbak представляет собой коллекцию аннотированных RGB-изображений высокого разрешения, предназначенных для обучения и тестирования алгоритмов компьютерного зрения в задачах автоматического выявления и локализации сои (*Glycine max*) и сорных растений на сельскохозяйственных угодьях. Изображения были получены с помощью беспилотного летательного аппарата (БПЛА) в рамках полевых исследований, проводившихся в селе Алмалыбак Алматинской области (Казахстан), на экспериментальных участках, находящихся в ведении Казахского научно-исследовательского института земледелия и растениеводства (село Алмалыбак, Алматинская область, Казахстан; координаты: 43°13' N, 76°42' E).

Съёмка проводилась с использованием беспилотного летательного аппарата DJI Mavic Mini 2 (камера FC7203). Почвы исследуемой территории — светло-каштановые, преимущественно орошаемые, с низким содержанием гумуса (1.9–2.0%) и умеренными запасами основных макроэлементов (фосфор, калий, азот). Эти участки используются в аграрных экспериментах по селекции и оптимизации методов возделывания сельскохозяйственных культур, что делает актуальными задачи автоматической идентификации культурных и сорных растений.




Датасет включает 968 изображений в формате JPEG, разрешением 4000×2250 пикселей (~9 Мп). Съёмки проводились в три этапа:

- 19 мая 2021 г. (~13:00) — 376 изображений (папка soybean-1), относительная высота полета — от 2.1 до 3.3 м;
- 9 июня 2021 г. (~12:00) — 200 изображений (папка soybean-2), высота полета — от 4 до 12.5 м;
- 23 июня 2021 г. (~12:00) — 392 изображения (папка soybean-3), высота полета — от 4.7 до 7.2 м.

Таблица 1 демонстрирует визуальные примеры трёх этапов роста сои, зафиксированных в ходе съёмки с беспилотного летательного аппарата. Каждый снимок представляет собой участок грядки с растущей соей, соответствующий определённой фазе развития растения. Учитывая значительное изменение плотности растительности и цветовых характеристик, изображения из разных этапов позволили учесть сезонную вариативность и повысить устойчивость обучаемых моделей к изменению условий съёмки.

Таблица 1

Примеры посевов сои, снятые в три периода роста: от ранних всходов до формирования плотного покрова

1 этап	
2 этап	
3 этап	

Съёмка выполнялась при минимальной динамике полёта с преимущественно вертикальной ориентацией камеры (угол наклона от -80° до -90°), что обеспечивает ортогональную проекцию и высокую чёткость объектов. При этом скорость движения беспилотника выдержана в пределах 1 метра в секунду.

Разметка выполнена вручную с использованием платформы CVAT в формате, совместимом с YOLOv8 (bounding box). В датасете представлены 12 классов объектов, включая культурные растения, грядки и наиболее распространённые виды сорной растительности в регионе (Таблица 2).

Таблица 2

Классы аннотированных объектов (пример: 19 мая 2021 г.)

№	Класс	Латинское название	Количество объектов (на первом этапе съёмки)
0	Грядка	Bed	2458
1	Соя	<i>Glycine max</i>	42 282
2	Ширица обыкновенная	<i>Amaranthus retroflexus</i>	6155
3	Вьюнок полевой	<i>Convolvulus arvensis</i>	385
4	Щетинник сизый	<i>Setaria glauca</i>	1897
5	Дурнишник обыкновенный	<i>Xanthium strumarium</i>	513
6	Осот розовый	<i>Cirsium arvense</i>	532
7	Просо куриное	<i>Echinochloa crusgalli</i>	0
8	Гибискус тройчатый	<i>Hibiscus trionum</i>	15

9	Канатник Теофраста	<i>Abutilon theophrasti</i>	27
10	Марь белая	<i>Chenopodium album</i>	0
11	Метлица полевая	<i>Apera spica-venti</i>	0

Рисунок 1 демонстрирует пример размеченного изображения с цветовой кодировкой классов: растения сои обозначены зелёным, грядки — красным, *Amaranthus retroflexus* — жёлтым, *Convolvulus arvensis* — голубым и т.д. Видна высокая плотность культурных растений в пределах грядок и более разреженное распределение сорной растительности. Пример иллюстрирует характерную пространственную структуру поля, разнообразие классов, а также уровень визуальной сложности, с которым сталкиваются алгоритмы при обучении и валидации.



Рисунок 1. Пример аннотированного изображения из набора данных Soybean_2021_Almalymbak

Таблица 3 представляет собой визуальную справку по основным видам сорной растительности, аннотированной в датасете Soybean_2021_Almalymbak. В таблице 3 приведены фотографии сорных растений, сделанные в полевых условиях на территории Южного Казахстана, а также указаны их русские и латинские названия. Эти виды являются наиболее распространёнными на сельскохозяйственных угодьях региона и представляют интерес для задач автоматической идентификации в агротехническом мониторинге. Эти изображения могут быть использованы в качестве наглядного пособия при аннотировании новых изображений, а также для проверки корректности работы алгоритмов компьютерного зрения.

Таблица 3

Примеры сорной растительности, произрастающей в Казахстане.

Ширица обыкновенная (<i>Amaranthus retroflexus</i>)	Вьюнок полевой (<i>Convolvulus arvensis</i>)	Щетинник сизый (<i>Setaria glauca</i>)	Дурнишник обыкновенный (<i>Xanthium strumarium</i>)	Осот розовый (<i>Cirsium arvense</i>)
---	---	---	---	--




Просо куриное (Echinochloa crusgalli)-

Гибискус тройчатый (Hibiscus trionum)

Канатник Теофраста (Abutilon theophrasti)

Марь белая (Chenopodium album)

Метлица обыкновенная, полевая (Apera spica-venti)



Датасет не подвергался аугментации или другим видам предобработки.

3. МЕТОДЫ И РЕЗУЛЬТАТЫ

3.1 Архитектура модели

Для решения задачи одновременной классификации и детекции сельскохозяйственных объектов на аэрофотоснимках соевых полей была использована модель YOLOv8 [13], относящаяся к семейству алгоритмов You Only Look Once (YOLO) [14], зарекомендовавшему себя как один из наиболее эффективных подходов к детекции объектов.

Модификация YOLOv8x была выбрана в силу своей высокой производительности и способности обрабатывать изображения с ограниченным количеством размеченных данных — что особенно актуально в аграрной сфере, где получение качественной аннотации зачастую сопряжено с трудностями. Дополнительным преимуществом модели является высокая скорость обработки, позволяющая применять её в задачах реального времени, таких как мониторинг посевов с использованием БПЛА.

3.2 Подготовка данных и обучение модели

Собранный датасет был разделён на обучающую и тестовую выборки в соотношении 80/20, что составило 300 изображений для обучения и 76 изображений для валидации. На этапе предварительного обучения аугментация данных не применялась. Это решение было принято с целью получения эталонной оценки базовой точности модели в условиях естественной вариативности полевых изображений, включая различия в освещённости, фоновом окружении, стадиях вегетации и погодных условиях.

Модель YOLOv8x была инициализирована предварительно обученными весами, полученными на обобщённом датасете COCO (Common Objects in Context) [15], и далее дообучалась на целевом наборе изображений, содержащем классы интереса. Такая стратегия переноса обучения (transfer learning) позволяет значительно ускорить сходимость модели и повысить качество предсказаний при наличии ограниченного количества размеченных данных.

Обучение проводилось в течение 300 эпох при размере батча 8 и размере входного изображения 640×640 пикселей. Указанные параметры позволили достичь сбалансированного соотношения между качеством распознавания и вычислительной эффективностью в условиях ограниченных вычислительных ресурсов.

В дальнейшем возможно применение различных техник расширения обучающей выборки, включая геометрическую и фотометрическую аугментацию, а также использование методов семантической сегментации для улучшения качества аннотаций.

3.3 Метрики оценки

Для комплексной оценки качества работы модели использовался набор как классификационных, так и детекционных метрик:

- Классификационные метрики: Precision, Recall, F1-score (как микро-, так и макроусреднённый), а также F1-score по отдельному классу (соя);
- Метрики локализации объектов: Intersection over Union (IoU), Average Precision (AP) для отдельных классов и Mean Average Precision (mAP) при различных порогах перекрытия (mAP@0.5 и mAP@0.5–0.95).

Результаты модели на валидационном наборе данных:

- mAP@0.5: 0.72
- mAP@0.5–0.95: 0.30
- Recall: 0.599
- Precision: 0.677
- F1-score (micro): 0.636
- F1-score (macro): 0.341
- F1-score по классу Glycine max (соя): 0.933

Использование указанных метрик позволяет оценить не только точность предсказаний модели в терминах классификации, но и её способность корректно локализовать объекты различных классов в природной среде.

3.4 Общая эффективность модели

Несмотря на наличие определённой несбалансированности классов, а также присутствие до 10% неразмеченных объектов на отдельных изображениях, модель продемонстрировала высокую устойчивость к подобным искажениям данных и хорошую способность к обобщению. Особенно высокие результаты были достигнуты при детекции сои, что подтверждается значением F1-score, превышающим 0.9.

Таким образом, модель YOLOv8x показала практическую применимость для задач автоматического мониторинга состояния посевов, даже в условиях ограниченного объёма данных и без применения дополнительных методов улучшения качества входных изображений.

4. ЗАКЛЮЧЕНИЕ

В данной работе представлен аннотированный датасет Soybean_2021_Almalıybak, собранный в условиях реального сельскохозяйственного производства с использованием дрона DJI Mavic Mini 2. Набор данных охватывает 12 классов объектов и отличается высокой вариативностью изображений, что делает его ценным ресурсом для задач детекции и классификации культурных и сорных растений в аграрной сфере. В отличие от многих существующих датасетов, полученных в контролируемых условиях, предложенный набор данных ориентирован на реалистичные сценарии точного земледелия и может способствовать развитию устойчивых моделей компьютерного зрения.

Эксперименты с моделью YOLOv8x продемонстрировали высокую базовую точность даже при отсутствии аугментации и ограниченном объёме данных. F1-score по классу Glycine max составил 0.933, а mAP@0.5 — 0.72, что подтверждает применимость модели в условиях вариативной съёмки и неполной аннотации.

Полученные результаты создают основу для дальнейших исследований, направленных на повышение точности модели с помощью аугментации, семантической сегментации и активного обучения. Используемый подход открывает путь к более широкому применению методов глубокого обучения в аграрной практике и развитию интеллектуальных систем мониторинга сельскохозяйственных угодий.

ДОСТУПНОСТЬ ДАННЫХ

В данном исследовании использованы собственные экспериментальные данные, соответствующие тематике работы, а также опубликованные материалы зарубежных авторов в области автоматического анализа сельскохозяйственных территорий и методов компьютерного зрения. Для задач детектирования и классификации растений применялся аннотированный набор аэрофотоснимков Soybean_2021_Almalymbak, полученный с использованием беспилотного летательного аппарата в условиях реального сельскохозяйственного производства и отражающий различные фазы роста соевых культур. Датасет с ручной разметкой доступен по ссылке https://drive.google.com/drive/folders/1ObZjrP5eW3zO0bZLeFrNd347nKULgowU?usp=drive_link и может быть использован для обучения и тестирования моделей машинного обучения. Статья написана на материале собственных исследований авторов и данных научных публикаций. Результаты обучения и оценки модели детектирования растений основаны на размеченных изображениях соевых полей и рассчитанных метриках качества (F1-score, mAP@0.5), полученных при использовании нейросетевой архитектуры YOLOv8x.

ВКЛАД АВТОРОВ

Разработка концепции - РИМ, разработка методологии - ЛАГ, ресурсы, подготовка и редактирование текста, визуализация - НРЮ, создание программного обеспечения - ВВС, ДК, АС, проведение исследования - ЛАГ, ВВС.

ФИНАНСИРОВАНИЕ

Работа выполнена при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан (проект программно-целевого финансирования № BR24992908 «Система поддержки агротехнических мероприятий в растениеводстве на базе комплекса средств мониторинга и методов искусственного интеллекта (Agroscore)»).

СПИСОК ЛИТЕРАТУРЫ

1. Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., Naqvi, S. A. H., Rao, M. J., Mosa, W. F. A., Abbas, Q., Hussain, A., Hassan, M. Z., & Zhou, L. (2023). Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture. *Agronomy*, 13(6), 1524. <https://doi.org/10.3390/agronomy13061524>
2. Popa, C. (2011). Adoption of artificial intelligence in agriculture. *Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Agriculture*, 68(1), 1–7. <https://doi.org/10.15835/buasvmcn-agr:6454>
3. Lottes, P., Hörferlin, M., Sander, S., Stachniss, C. (2017). Effective vision-based classification for separating sugar beets and weeds for precision farming. *Journal of Field Robotics*, 34(6), 1160–1178. <https://doi.org/10.1002/rob.21675>
4. Sa, I., Chen, Z., Popović, M., Khanna, R., Liebisch, F., Nieto, J., & Siegwart, R. (2017). WeedNet: Dense semantic weed classification using multispectral images and MAV for smart farming. *IEEE Robotics and Automation Letters*, 3(1), 588–595. <https://doi.org/10.1109/LRA.2017.2774979>
5. Olsen, A., Konovalov, D. A., Philippa, B., Ridd, P., Wood, J. C., Johns, J., White, R. D. (2019). DeepWeeds: A multiclass weed species image dataset for deep learning. *Scientific Reports*, 9, 2058. <https://doi.org/10.1038/s41598-018-38343-3>
6. Leminen Madsen, S., Mathiassen, S. K., Dyrmann, M., Laursen, M. S., Paz, L. C., Jørgensen, R. N. (2020). Open plant phenotype database of common weeds in Denmark. *Remote Sensing*, 12(8), 1246. <https://doi.org/10.3390/rs12081246>
7. Haug, S., & Ostermann, J. (2015). A crop/weed field image dataset for the evaluation of computer vision based precision agriculture tasks. In *Computer Vision – ECCV 2014 Workshops* (pp. 105–116). Springer International Publishing. https://doi.org/10.1007/978-3-319-16178-5_8
8. Lameski, P., Zdravevski, E., Trajkovic, V., & Kulakov, A. (2017). Weed detection dataset with RGB images taken under variable light conditions. In A. Goleva, D. Trajanov, & A. Stojanovski (Eds.), *ICT Innovations 2017: Data-Driven Innovation* (pp. 112–119). Springer. https://doi.org/10.1007/978-3-319-67597-8_11
9. Giselsson, T. M., Jørgensen, R. N., Jensen, P. K., Dyrmann, M., & Midtby, H. S. (2017). A public image database for benchmark of plant seedling classification algorithms. *arXiv preprint arXiv:1711.05458* <https://doi.org/10.48550/arXiv.1711.05458>
10. Teimouri, N., Dyrmann, M., Nielsen, P. R., Mathiassen, S. K., Somerville, G. J., & Jørgensen, R. N. (2018). Weed growth stage estimator using deep convolutional neural networks. *Sensors*, 18(5), 1580. <https://doi.org/10.3390/s18051580>
11. dos Santos Ferreira, A., Freitas, D. M., da Silva, G. G., Pistori, H., Folhes, M. T. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314–324. <https://doi.org/10.1016/j.compag.2017.10.027>
12. Sa, I., Popović, M., Khanna, R., Chen, Z., Lottes, P., Liebisch, F., Siegwart, R. (2018). WeedMap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. *Remote Sensing*, 10(9), 1423.
13. [ML Paper] Explanation of all of YOLO series Part 11 - https://zenn.dev/yuto_mo/articles/14a87a0db17dfa (date of access: 15.10.2025)
14. Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, NV, USA, 27–30 June 2016; pp. 779–788. <https://doi.org/10.1109/CVPR.2016.91>
15. Набор данных COCO - <https://docs.ultralytics.com/ru/datasets/detect/coco/> (date of access: 06.10.2025)

REFERENCES

1. Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., Naqvi, S. A. H., Rao, M. J., Mosa, W. F. A., Abbas, Q., Hussain, A., Hassan, M. Z., & Zhou, L. (2023). Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture. *Agronomy*, 13(6), 1524. <https://doi.org/10.3390/agronomy13061524>
2. Popa, C. (2011). Adoption of artificial intelligence in agriculture. *Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca. Agriculture*, 68(1), 1–7. <https://doi.org/10.15835/buasvmcn-agr:6454>
3. Lottes, P., Hörferlin, M., Sander, S., Stachniss, C. (2017). Effective vision-based classification for separating sugar beets and weeds for precision farming. *Journal of Field Robotics*, 34(6), 1160–1178. <https://doi.org/10.1002/rob.21675>
4. Sa, I., Chen, Z., Popović, M., Khanna, R., Liebisch, F., Nieto, J., & Siegwart, R. (2017). WeedNet: Dense semantic weed classification using multispectral images and MAV for smart farming. *IEEE Robotics and Automation Letters*, 3(1), 588–595. <https://doi.org/10.1109/LRA.2017.2774979>
5. Olsen, A., Konovalov, D. A., Philippa, B., Ridd, P., Wood, J. C., Johns, J., White, R. D. (2019). DeepWeeds: A multiclass weed species image dataset for deep learning. *Scientific Reports*, 9, 2058. <https://doi.org/10.1038/s41598-018-38343-3>
6. Leminen Madsen, S., Mathiassen, S. K., Dyrmann, M., Laursen, M. S., Paz, L. C., Jørgensen, R. N. (2020). Open plant phenotype database of common weeds in Denmark. *Remote Sensing*, 12(8), 1246. <https://doi.org/10.1038/s41598-018-38343-3>
7. Haug, S., & Ostermann, J. (2015). A crop/weed field image dataset for the evaluation of computer vision based precision agriculture tasks. In *Computer Vision – ECCV 2014 Workshops* (pp. 105–116). Springer International Publishing.
8. Lameski, P., Zdravevski, E., Trajkovic, V., & Kulakov, A. (2017). Weed detection dataset with RGB images taken under variable light conditions. In A. Goleva, D. Trajanov, & A. Stojanovski (Eds.), *ICT Innovations 2017: Data-Driven Innovation* (pp. 112–119). Springer. https://doi.org/10.1007/978-3-319-16178-5_8
9. Giselsson, T. M., Jørgensen, R. N., Jensen, P. K., Dyrmann, M., & Midtby, H. S. (2017). A public image database for benchmark of plant seedling classification algorithms. *arXiv preprint arXiv:1711.05458*. https://doi.org/10.1007/978-3-319-67597-8_11
10. Teimouri, N., Dyrmann, M., Nielsen, P. R., Mathiassen, S. K., Somerville, G. J., & Jørgensen, R. N. (2018). Weed growth stage estimator using deep convolutional neural networks. *Sensors*, 18(5), 1580. <https://doi.org/10.3390/s18051580>
11. dos Santos Ferreira, A., Freitas, D. M., da Silva, G. G., Pistori, H., Folhes, M. T. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314–324. <https://doi.org/10.1016/j.compag.2017.10.027>
12. Sa, I., Popović, M., Khanna, R., Chen, Z., Lottes, P., Liebisch, F., Siegwart, R. (2018). WeedMap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. *Remote Sensing*, 10(9), 1423.
13. [ML Paper] Explanation of all of YOLO series Part 11 - https://zenn.dev/yuto_mo/articles/14a87a0db17dfa (date of access: 15.10.2025)
14. Redmon, J.; Divvala, S.; Girshick, R.; Farhadi, A. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016*; pp. 779–788. <https://doi.org/10.1109/CVPR.2016.91>
15. COCO dataset - <https://docs.ultralytics.com/ru/datasets/detect/coco/> (date of access: 06.10.2025)

ӨСІМДІКТЕРДІ АНЫҚТАУ ҮЛГІЛЕРІН РЕТТЕУГЕ АРНАЛҒАН АННОТАЦИЯЛАНҒАН СОЯ АЛҚАБЫ КЕСКІНДЕРІНІҢ ЖИНАҒЫ

Равиль И. Мухамедиев^{1,2}, т.ғ.д. (инж.), Валентин В. Смурыгин¹, Людмила А. Городецкая¹, Диас Құсайын¹, Адилхан Сымагулов¹, Надия Р. Юничева^{2,3*}, т.ғ.к.

¹ К.И. Сәтпаев атындағы Қазақ ұлттық техникалық университеті, Алматы, Қазақстан; ravil.muhamedyev@gmail.com (Р.И.М.), valentinsmurygin@gmail.com (В.В.С.), ludmila260601@gmail.com (Л.А.Г.), a.symagulov@satbayev.university (А.С.), diac.kusain@gmail.com (Д.Қ.);

² ҚР БҒМ Информатика және есептеу техникасы институты, Алматы, Қазақстан; naduni@mail.ru (Н.Р.Ю.), ravil.muhamedyev@gmail.com (Р.И.М.);

³ Г. Дәукенов атындағы Алматы энергетика және байланыс университеті, Алматы, Қазақстан; naduni@mail.ru (Н.Р.Ю.)

*Автор-хатшы: Надия Р. Юничева, naduni@mail.ru

ТҮЙІН СӨЗДЕР

Дәл егіншілік, соя, анықтау, Ұшқышсыз ұшу аппараттарының деректері, нейрондық желілер, YOLOv8.

АБСТРАКТ

Бұл мақалада пилотсыз ұшу аппаратын (ПҰА) пайдаланып алынған әуеден түсірілген суреттерге негізделген ауылшаруашылық алқаптарын автоматтандырылған талдауға арналған аннотацияланған Soybean_2021_Almalubak деректер жиынтығы ұсынылған. Деректер жиынтығына әртүрлі өсу кезеңдерін қамтитын және дақылдар мен арамшөп түрлерін қоса алғанда, қолмен белгіленген 12 нысан класын қамтитын соя егістіктерінің суреттері кіреді. Мақалада сенімді компьютерлік көру модельдерін оқыту үшін

Мақала жайында:

Жіберілді: 13.01.2026
Қайта қаралды: 15.02.2026
Қабылданды: 31.03.2026
Жарияланды: 01.04.2026

нақты ауылшаруашылық ландшафттарын көрсететін далалық деректердің маңыздылығы атап өтілген.

Базалық модель ретінде бір мезгілде объектілерді локализациялау және жіктеуге арналған заманауи архитектура YOLOv8x пайдаланылды. Модель 300 суреттен тұратын белгіленген жиынтықта үлкейтусіз оқытылды, бұл эталондық дәлдікті бағалауға мүмкіндік берді. Тәжірибелік нәтижелер модельдің жоғары өнімділігін көрсетті: Glycine max (соя) класы үшін F1-балы 0,933, ал mAP@0,5 метрикасы 0,72 болды. Деректер көлемінің шектеулі болуына және ішінара аннотацияға қарамастан, модель егістіктердің өзгергіштігі мен сынып теңгерімсіздігіне беріктігін көрсетті.

ANNOTATED IMAGE SET OF SOYBEAN FIELDS FOR TRAINING PLANT DETECTION MODELS

Ravil I. Mukhamediev^{1,2}, doc. eng. sci., Valentin V. Smurygin¹, Lyudmila A. Gorodetskaya¹, Dias Qusain¹, Adilkhan Symagulov¹, Nadiya R. Yunicheva^{2,3*} candidate of technical sciences

¹ Satbayev University, Almaty, Kazakhstan; ravil.muhamedyev@gmail.com (R.M.), valentinsmurygin@gmail.com (V.S.), lyudmila260601@gmail.com (L.A.G.), a.symagulov@satbayev.university (A.S.), diac.kusain@gmail.com (D.Q.);

² Institute of Information and Computational Technologies, MES RK, Almaty, Kazakhstan; naduni@mail.ru (N.R.Y.), ravil.muhamedyev@gmail.com (R.I.M.);

³ Almaty University of Power Engineering and Telecommunications named after G. Daukeyev, Almaty, Kazakhstan; naduni@mail.ru (N.R.Y.)

*Corresponding author: Nadiya R. Yunicheva, naduni@mail.ru

KEY WORDS

precision agriculture,
soybeans,
detection,
UAV data, neural networks,
YOLOv8.

About article:

Received: 13.01.2026
Revised: 15.02.2026
Accepted: 31.03.2026
Published: 01.04.2026

ABSTRACT

This article presents annotated Soybean_2021_Almalymbak dataset designed for automatic analysis of agricultural areas based on aerial photographs obtained using unmanned aerial vehicles (UAVs). The dataset includes images of soybean fields covering various stages of plant growth and containing manual labelling of 12 object classes, including cultivated and weed species. The work emphasises the importance of field data reflecting the realistic state of agricultural landscapes for training robust computer vision models.

YOLOv8x, a modern architecture for simultaneous object localisation and classification, was used as the base model. The model was trained on a labelled sample of 300 images without augmentation, which allowed for a benchmark accuracy assessment. The experimental results demonstrated the high efficiency of the model: the F1-score for the Glycine max (soybean) class was 0.933, and the metric mAP@0.5 was 0.72. Despite the limited amount of data and partial annotation, the model showed resistance to variability in field conditions and class imbalance.

Примечание издателя: заявления, мнения и данные во всех публикациях принадлежат только автору (авторам), а не журналу "Гидрометеорология и экология" и/или редактору (редакторам).