

УДК 631.5 : 004.8

Научная статья



Открытый доступ

DOI: 10.32634/0869-8155-2025-397-08-122-128

Д.Е. Фёдоров ✉

С.Н. Быков

Кузбасский государственный аграрный университет им. В.Н. Полецовка, Кемерово, Россия

✉ fedorov_de@inbox.ru

Поступила в редакцию: 06.05.2025

Одобрена после рецензирования: 13.07.2025

Принята к публикации: 28.07.2025

© Фёдоров Д.Е., Быков С.Н.

Research article



Open access

DOI: 10.32634/0869-8155-2025-397-08-122-128

Dmitry E. Fedorov ✉

Sergey N. Bykov

Kuzbass State Agrarian University named after V.N. Poletskov, Kemerovo, Russia

✉ fedorov_de@inbox.ru

Received by the editorial office: 06.05.2025

Accepted in revised: 13.07.2025

Accepted for publication: 28.07.2025

© Fedorov D.E., Bykov S.N.

Мониторинг посевов гороха с нейросетевой обработкой изображений, полученных с использованием БПЛА

РЕЗЮМЕ

Статья посвящена разработке и апробации технологии распознавания ростков гороха и оценки его биомассы на основе снимков с БПЛА с использованием нейронных сетей. Производили посев гороха сорта Рокет посевным комплексом «Кузбасс» в Топкинском районе Кемеровской области на площади 21,55 га. Тип почвы — слабовыщелоченный чернозем. Предшественник — яровая пшеница. Глубина заделки семян 6 см, норма высева 1,1 млн семян на 1 га. Аэрофотосъемку выполняли через три недели квадрокоптером с разрешением фотокамеры 20МП с высоты полета 3 м. Съемки выполняли в два этапа — ранним утром в условиях облачности для получения изображений ростков гороха без теней и в дневное время с тенями для ростков и сорной растительности. В результате для обучения нейросети были сформированы два комплекта исходных фотографий по 120 шт. На основе полученных датасетов проводили обучение модели нейросети Ultralytics YOLOv8. Тестирование полученных моделей выполняли в программе на языке Python для пакетной обработки изображений и подсчета количества растений на каждом снимке. Точность распознавания ростков по первому датасету составила 97,3%, по второму — 67,3%. Это обусловлено различными условиями съемки. Объединение двух датасетов позволило получить точность распознавания 94,7%. Это несколько ниже первого варианта, но значительно ближе к реальным условиям аэрофотосъемки. Результатом работы является программа, позволяющая производить пакетную обработку изображений для автоматического подсчета ростков гороха и расчета их площади на снимках.

Ключевые слова: БПЛА, программное обеспечение, машинное обучение, нейросеть, горох, посе́вы

Для цитирования: Фёдоров Д.Е., Быков С.Н. Мониторинг посевов гороха с нейросетевой обработкой изображений полученных с использованием БПЛА. *Аграрная наука*. 2025; 397(08): 122–128.

<https://doi.org/10.32634/0869-8155-2025-397-08-122-128>

Monitoring of pea crops with neural network processing of images obtained using UAVs

ABSTRACT

The article is devoted to the development and testing of technology for recognizing pea sprouts and estimating its biomass based on images from UAVs using neural networks. Rocket peas were sown by the “Kuzbass” sowing complex in the Topkinsky district of the Kemerovo Region on an area of 21.55 hectares. The soil type is slightly leached chernozem. The predecessor is spring wheat. The seed depth is 6 cm, the seeding rate is 1.1 million seeds per 1 hectare. Aerial photography was performed three weeks later with a quadcopter with a 20MP camera resolution from a flight altitude of 3 m. The shooting was carried out in two stages — in the early morning in cloudy conditions to obtain images of pea shoots without shadows and in the daytime with shadows from sprouts and weeds. As a result, two sets of 120 source photos were generated to train the neural network. Based on the obtained datasets, the Ultralytics YOLOv8 neural network model was trained. Testing of the obtained models was performed in a Python program for batch image processing and counting the number of plants in each image. The accuracy of recognizing sprouts on the first dataset was 97.3%, on the second — 67.3%. This is due to the different shooting conditions. Combining the two datasets allowed for a recognition accuracy of 94.7%. This is slightly lower than the first option, but much closer to the actual conditions of aerial photography. The result of the work is a program that allows batch image processing for automatic counting of pea sprouts and calculating their area in the images.

Key words: UAV, software, machine learning, neural network, peas, crops

For citation: Fedorov D.E., Bykov S.N. Monitoring of pea crops with neural network processing of images obtained using UAVs. *Agrarian science*. 2025; 397(08): 122–128 (in Russian). <https://doi.org/10.32634/0869-8155-2025-397-08-122-128>

Введение/Introduction

Актуальной организационной и технической проблемой производителей зерновых и комовых культур является получение оперативной информации о состоянии посевов. При этом для ранних стадий вегетации выявляются процент всхожести растений и динамика биомассы, а для последующих стадий определяются наличие заболеваний и обеспеченность удобрениями. Производительность мониторинга полей достигается за счет использования беспилотных летательных аппаратов (БПЛА) с последующей обработкой снимков методами искусственного интеллекта [1].

Из существующих технологий, рассмотренных в отечественных публикациях, можно отметить работы А.Ф. Рогачева, А.Ф. Чешковой, посвященных технологиям анализа изображений широкого спектра полевых культур по индексу NDVI для оценки динамики роста растений и выявления заболеваний [2–4]. В работах А.И. Кутырёва, В.В. Демидчик предлагаются технологии оценки биомассы растений по форме и цвету листьев в видимом и инфракрасном спектрах [5, 6]. В работе А.Е. Молина рассмотрена технология оценки обеспеченности зерновых культур азотом по снимкам полей в RGB-спектре [7]. Работа В.С. Семенюк посвящена системам точечного опрыскивания на основе распознавания сорняков и болезней нейронными сетями [8].

Получение изображений в рассмотренных выше работах осуществляется с использованием квадрокоптеров различных моделей. При съемках на высоте от 5 до 30 м устанавливаются камеры с разрешением от 12 до 20 МП. При съемках на высоте от 30 до 100 м разрешение составляет от 20 до 40 МП. Для обработки изображений используются сверточные нейронные сети различных конфигураций.

Аналогичные технологии рассмотрены в зарубежных публикациях. В работах E. Cini, F. Marzietti [9, 10] предлагается технология автоматического распознавания и картирования инвазивных растений для воздушного мониторинга и разработки мер по противодействию их распространению. Работа L.S. Costa [11] посвящена технологии идентификации и классификации растений в тропической саванне с помощью БПЛА, оснащенного мультиспектральной камерой.

В работе A. Prasad [12] рассматривается технология диагностики растений по снимкам, полученным с помощью БПЛА. При этом используется двухэтапный подход к машинному обучению, который последовательно анализирует низкоточные и высокоточные изображения. В работе Jun Zhang предлагается технология фенотипирования китайской капусты по снимкам с дронов. Геометрические параметры растений рассчитываются на основе количества пикселей для каждого отдельного растения с учетом расстояния БПЛА

до поверхности поля. Мониторинг растительности в данных технологиях выполняется с помощью БПЛА, а обработка изображений ведется на основе нейронных сетей [13].

Цели исследования — разработать и апробировать технологию распознавания ростков выращиваемых полевых культур на примере гороха и прогнозирования динамики роста культур по их биомассе на основе снимков БПЛА с использованием нейронных сетей.

Для ее достижения необходимо было: выполнить аэрофотосъемку полей со всходами гороха в различных условиях освещенности; обучить и проверить работоспособность нейросети для распознавания ростков гороха на снимках; оценить точность распознавания ростков гороха разработанной нейросетью; определить программными методами площадь листьев гороха по полученным изображениям; вывести регрессионную зависимость массы наземной части растений от площади листьев.

Материалы и методы исследования / Materials and methods

Для проведения исследований был выбран широко используемый в России и рекомендуемый для зоны Западной Сибири горох сорта Рокет.

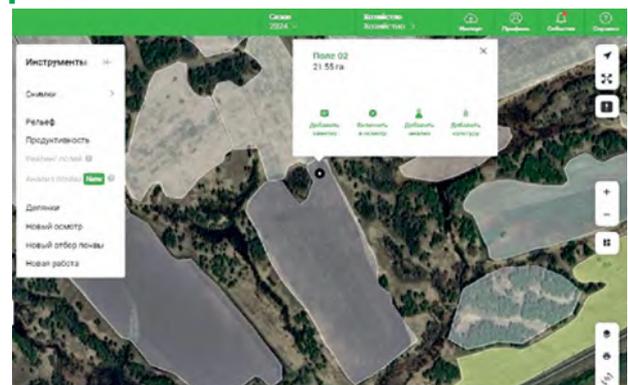
Общая площадь поля составила 21,55 га

Посев проводили на полях Топкинского технического техникума в Топкинском районе Кемеровской области Российской Федерации. Координаты центра поля: 55,237° с. ш., 85,457° в. д. (рис. 1).

Выбор поля обусловлен распространенным для региона типом почвы. Это слабовыщелоченный чернозем. Предшественник — яровая пшеница. Выполнена предпосевная осенняя обработка полей луцильником. Посев осуществляли 15 мая 2024 года посевным комплексом «Кузбасс» (ООО «Агро», Россия). В соответствии с агротехническими требованиями для данного сорта, механическим составом, влажностью и температурой почвы глубина заделки семян выбрана 6 см, норма высева 1,1 млн семян на 1 га.

Рис. 1. Карта исследуемого поля в облачном сервисе ExactFarming¹

Fig. 1. Map of the field under study in the ExactFarming cloud service



¹ <https://exactfarming.com/>

Аэрофотосъемку проводили 5 июня 2024 года. Использовали квадрокоптер DJI Mavic 3 Cine (DJI, Китай). Выбор указанного квадрокоптера обусловлен высоким качеством получаемых изображений со встроенной фотокамеры (разрешение фотоснимков составляло 20 МП). Высота полета 3 м.

Съемки выполняли в два этапа — ранним утром в условиях облачности для получения изображений ростков гороха и сорняков без теней (рис. 2а) и в дневное время с тенями от ростков и сорняков (рис. 2б). В результате были сформированы два комплекта исходных фотографий для обучения нейросети (в каждом комплекте (выборке) по 50 изображений).

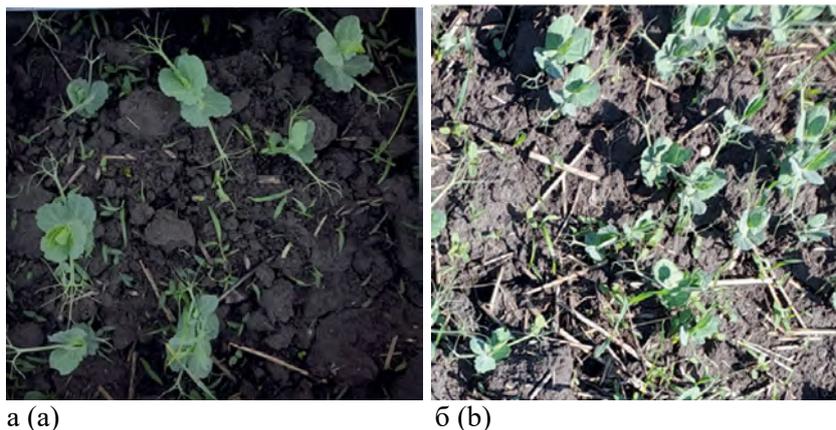
Далее на полученных фотографиях производили разметку данных с использованием сервиса roboflow². Полученный датасет подвергали аугментации — искусственному увеличению исходных данных за счет модификации существующих фотографий (поворот на разные углы, отражение по горизонтали и вертикали). После аугментации количество фотографий в каждом датасете составило 120.

После получения датасетов проводили обучение модели нейросети Ultralytics YOLOv8 (правообладатель Ultralytics, Испания). Данная версия нейросети по сравнению с предыдущими обладает более сложной архитектурой, включающей в себя новые блоки, такие как C2f, SPPF и Focus. Эти блоки улучшают процесс извлечения признаков и повышают точность детектирования.

Для обучения была выбрана простая начальная модель с наименьшим количеством параметров — yolov8n. Обучение проводили с использованием сервиса Yandex Datasphere³ [15]. Затем проводили тестирование полученных моделей. Для этих целей была написана программа на языке Python (США) для пакетной обработки изображений и подсчета количества растений на каждом снимке.

Для выведения регрессионной зависимости массы наземной части растений от площади листьев все ростки, оказавшиеся на изображениях, в этот же день срезали под корень и без

Рис. 2. Примеры фотографий первой (а) и второй (б) обучающих выборок
Fig. 2. Examples of photographs of the first (a) and second (b) training samples



мытья и высушивания взвешивали на электронных весах с точностью делений 0,01 г.

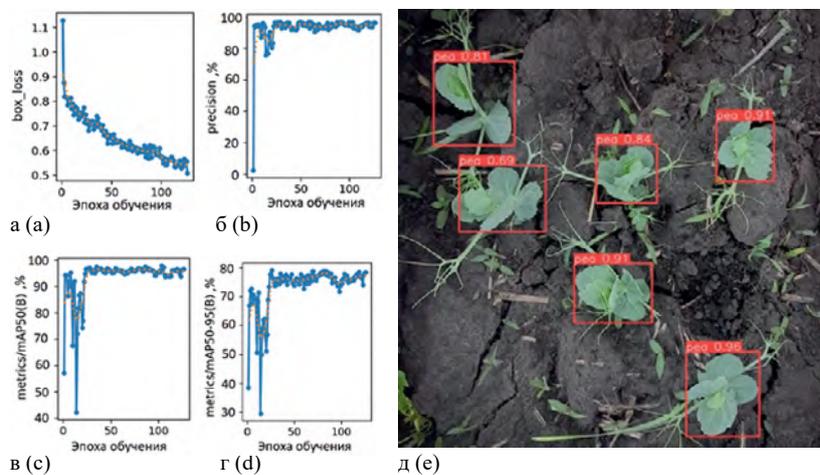
Математическую обработку результатов, статистический анализ и оценку достоверности осуществляли в программе MS Excel (США).

Результаты и обсуждение / Results and discussion

Обучение нейросети по первому датасету длилось порядка 120 эпох (итераций). В течение одной эпохи производится один полный проход нейросети через обучающий набор данных для коррекции параметров (весов) в нужную сторону. В результате была получена первая модель (модель № 1). Графики обучения по первому датасету, а также пример работы модели № 1 показаны на рисунке 3.

Было проведено тестирование полученной модели № 1 на независимой тестовой выборке фотографий первого датасета, которые не использовали при обучении модели (рис. 3д). Точность

Рис. 3. Графики box loss (а), precision (б), метрик mAP50 (в), mAP50-95 (г) и пример работы модели № 1 на тестовой выборке первого датасета (д)
Fig. 3. Graphs of box loss (a), precision (b), mAP50 (c), mAP50-95 (d) metrics and an example of model No. 1 running on the test sample of the first dataset (d)



² <https://roboflow.com>

³ <https://yandex.cloud/ru/services/datasphere>

оценивали по тому, сколько раз нейросеть правильно предположила количество и расположение ростков на фотографии. Точность распознавания ростков по полученной модели составила 97,3% (рис. 3б).

Затем модель № 1 была протестирована на выборке фотографий из второго датасета (рис. 2б). В этом случае точность составила гораздо ниже — 67,3%. Это обусловлено различными условиями съемки: на фотографиях второго датасета присутствуют неровности поля и сорняки, которые практически отсутствовали в первом датасете.

На следующем этапе было проведено обучение модели нейросети № 2 по второму датасету. Графики обучения модели № 2, а также пример распознавания растений на тестовой выборке второго датасета представлены на рисунке 4.

Точность модели № 2 по тестовой выборке второго датасета составила 82,1%. При этом обучение длилось около 120 эпох (итераций обучения), после которых значение метрик не увеличивалось.

Далее путем объединения первого и второго датасетов был получен третий. Обучающие графики и пример работы модели № 3 по тестовой выборке третьего датасета представлены на рисунке 5.

Объединение двух выборок позволило значительно повысить точность распознавания ростков гороха по смешанной выборке — до 94,7%. Длительность обучения при этом была значительно больше, чем в предыдущих случаях, и составила порядка 500 эпох. Это обусловлено большим количеством исходных фотографий.

Известно, что если делать фотографии для датасета при одних и тех же условиях (одинаковая освещенность, масштаб и т. д.) и получить специализированный набор данных, то модель будет более узконаправленной и будет работать хорошо с фотографиями, полученными при таких же условиях, и хуже — на фотографиях с другими условиями съемки [14, 16].

С другой стороны, если делать фотографии при разных условиях, то модель будет более универсальной и будет работать на более широком спектре снимков, полученных при разных условиях. Если взять эти обе модели и применять их к специализированному набору фотографий

Рис. 4. Графики box loss (а), precision (б), метрик mAP50 (в), mAP50-95 (г) и пример работы модели № 2 на тестовой выборке второго датасета (д)

Fig. 4. Graphs of box loss (a), precision (b), mAP50 (c), mAP50-95 (d) metrics and an example of model No. 2 running on the test sample of the second dataset (d)

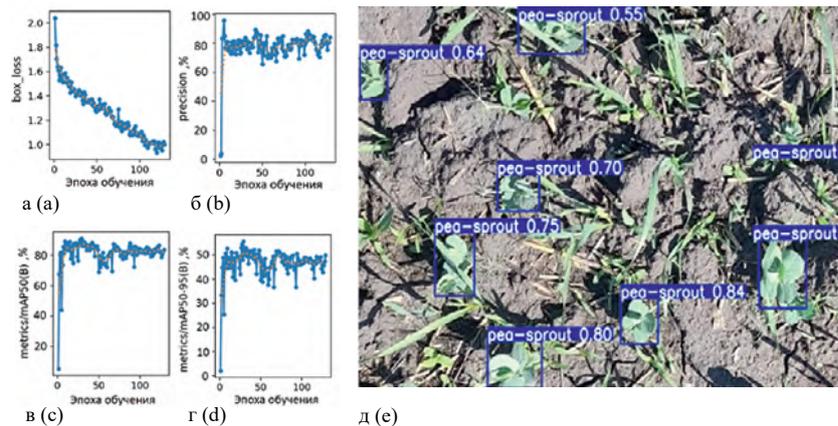
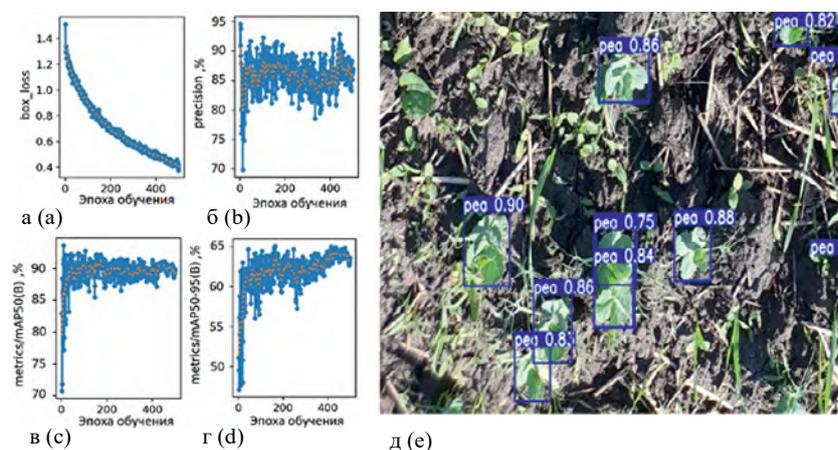


Рис. 5. Графики box loss (а), precision (б), метрик mAP50 (в), mAP50-95 (г) и пример работы модели № 3 на тестовой выборке третьего датасета (д)

Fig. 5. Graphs of box loss (a), precision (b), mAP50 (c), mAP50-95 (d) metrics and an example of model No. 3 running on the test sample of the third dataset (d)



(которые использовались для узконаправленной модели), то первая модель должна показать лучший результат.

Однако в данной работе результат оказался неоднозначным, что может быть обусловлено тем фактом, что набор фотографий в датасете № 3 превышал таковой для датасета № 1 и датасета № 2. В итоге модель № 3 вышла более универсальной и показывающей достаточно высокую точность для обоих наборов фотографий.

Следующим этапом исследований была проверка гипотезы о том, что по площади каждого растения на снимке можно определить его массу. Для этих целей провели взвешивание образцов ростков гороха, которые были на снимках в датасете № 1. Вместе с этим нами написана программа на языке Python и детектор Ultralytics YOLOv8, использующие модель № 3 нейросети, которая рассчитывала площадь ростков гороха на снимках.

После указания папки программа в теле цикла последовательно обрабатывает весь пакет изображений, определяет на каждом координаты ростков гороха и по ограничивающей рамке

производит расчет площади ростков. При этом формируются список с площадью растений на каждом снимке и общая площадь всех растений.

В результате было получено облако точек зависимости массы растения от его площади на снимке (рис. 6).

По представленному на графике облаку точек было получено линейное уравнение регрессии, позволяющее определить массу растений по их площади на снимке:

$$m = 0,0138s + 0,196, \quad (1)$$

где: m — масса растения, г; s — площадь листьев растения, см^2 .

Достоверность аппроксимации R^2 указанного выше уравнения определяли по следующей формуле:

$$R^2 = 1 - \frac{\sum_{i=1}^N [y_i - F(x_i)]^2}{\sum_{i=1}^N [y_i - \bar{F}(x_i)]^2}, \quad (2)$$

где N — количество измерений; y_i — фактическое значение массы растений в i -й точке; $F(x_i)$ — расчетное значение массы растений в i -й точке; $\bar{F}(x_i)$ — среднее значение $F(x_i)$.

Величина достоверности аппроксимации составила $R^2 = 0,7171$.

Далее были рассчитаны значения массы растений по уравнению и проведено сравнение полученных значений с фактическими. В результате получены значения отклонений δ_i фактических значений от расчетных (рис. 7) по формуле:

$$\delta_i = y_i - F(x_i), \quad (3)$$

Было рассчитано среднее значение отклонений $\bar{\delta}$ по формуле:

$$\bar{\delta} = \frac{\sum_{i=1}^N [y_i - F(x_i)]}{N} \times 100, \quad (4)$$

Среднее значение отклонений составило 12,5%.

Из представленного графика (рис. 7) видно, что с увеличением площади растения величина отклонений значений, полученных по уравнению, от фактических значений уменьшается, что повышает достоверность.

Выводы/Conclusions

В результате проведенной работы на основе экспериментальных исследований было проанализировано влияние качественного и количественного состава исходных фотографий на точность распознавания ростков гороха нейросетью. Установлено, что использование смешанной выборки исходных фотографий, содержащей изображения растений при различных условиях съемки, позволяет значительно

Рис. 6. Графики зависимости массы растений от их площади на снимке

Fig. 6. Graphs of the dependence of plant mass on their area in the picture

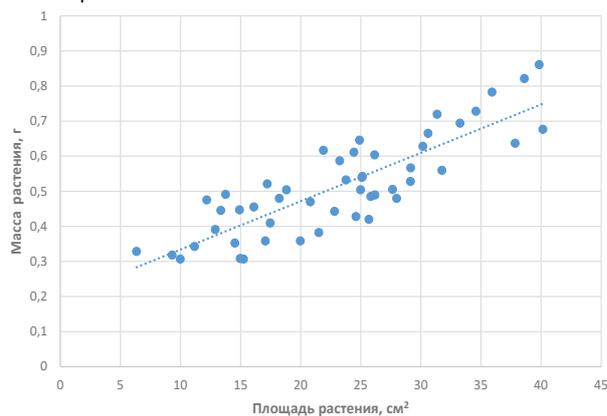
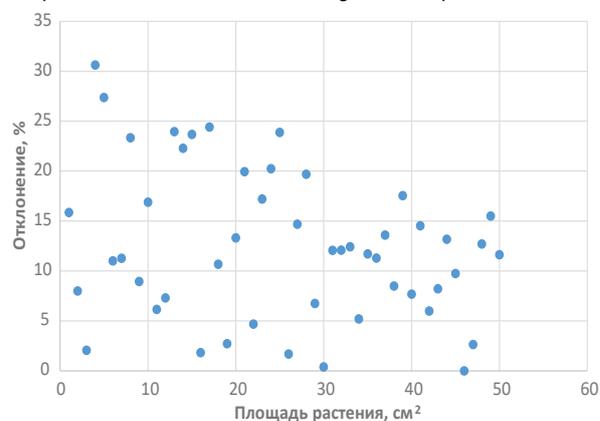


Рис. 7. Величина отклонения фактических значений массы растений от полученного уравнения регрессии

Fig. 7. The magnitude of the deviation of the actual values of plant mass from the obtained regression equation



повысить достоверность работы модели нейросети.

Получена модель, которая способна распознавать ростки гороха на снимках с точностью 94,7%. При этом стоит отметить, что данное значение не является пределом. Увеличить точность можно за счет использования большего количества фотографий в датасете, а также использованием версии моделей с большим количеством параметров. Однако в этом случае неизбежно возрастают трудозатраты на подготовку данных для машинного обучения, так как увеличивается объем работ на разметку данных.

Рост объема исходных данных влечет за собой повышение продолжительности самого обучения модели, а следовательно, и стоимость использования вычислительных мощностей. Кроме того, скорость распознавания у моделей с большим числом параметров существенно выше. Получено уравнение, позволяющее рассчитать массу растения от его площади на снимке. В целом разработанная и апробированная технология распознавания ростков гороха и оценки его биомассы показала свою работоспособность, позволяет получить достаточно достоверные результаты и может быть рекомендована к использованию.

Все авторы несут ответственность за работу и представленные данные. Все авторы внесли равный вклад в работу. Авторы в равной степени принимали участие в написании рукописи и несут равную ответственность за плагиат. Авторы объявили об отсутствии конфликта интересов.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Рогачев А.Ф., Мелихова Е.В., Белоусов И.С. Исследование развития и продуктивности сельскохозяйственных культур с применением беспилотных летательных аппаратов. *Известия Нижневолжского агроуниверситетского комплекса: Наука и высшее профессиональное образование*. 2019; (4): 329–339. <https://www.elibrary.ru/vqaviv>
2. Чешкова А.Ф. Обзор современных методов обнаружения и идентификации болезней растений на основе анализа гиперспектральных изображений. *Вавиловский журнал генетики и селекции*. 2022; 26(2): 202–213 (на англ. яз.). <https://doi.org/10.18699/VJGB-22-25>
3. Рогачев А.Ф., Белоусов И.С. Нейросетевое выявление проблемных участков состояния посевов методами искусственного интеллекта. *Известия Нижневолжского агроуниверситетского комплекса: Наука и высшее профессиональное образование*. 2022; (3): 459–466. <https://www.elibrary.ru/bjzmzny>
4. Мударисов С.Г., Мифтахов И.Р. Автоматическое обнаружение и идентификация болезней пшеницы с использованием методов глубокого обучения и применением дронов в режиме реального времени. *Вестник Казанского государственного аграрного университета*. 2024; 19(2): 90–104. <https://doi.org/10.12737/2073-0462-2024-90-104>
5. Кутырёв А.И., Филиппов Р.А. Распознавание генеративных частей земляники садовой с использованием сверточной нейронной сети (CNN). *Таврический вестник аграрной науки*. 2023; (2): 72–86. <https://doi.org/10.5281/zenodo.8271986>
6. Демидчик В.В. и др. Феномика растений: фундаментальные основы, программно-аппаратные платформы и методы машинного обучения. *Физиология растений*. 2020; 67(3): 227–245. <https://doi.org/10.31857/S0015330320030069>
7. Молин А.Е., Блеканов И.С., Митрофанов Е.П., Митрофанова О.А. Методы генерации синтетических данных для обучения нейросетей в задаче сегментации уровня азотного режима растений на снимках беспилотных летательных аппаратов на сельскохозяйственном поле. *Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления*. 2024; 20(1): 20–33. <https://doi.org/10.21638/11701/spbu10.2024.103>
8. Семенов В.С., Никитин Е.А. Разработка системы точечного внесения жидких средств химизации на основе моделей сверточной нейронной сети. *Сельскохозяйственные машины и технологии*. 2021; 15(2): 41–45. <https://doi.org/10.22314/2073-7599-2021-15-1-41-45>
9. Cini E., Marzioletti F., Paterni M., Berton A., Acosta A.T.R., Ciccarelli D. Integrating UAV imagery and machine learning via Geographic Object Based Image Analysis (GEOBIA) for enhanced monitoring of *Yucca gloriosa* in Mediterranean coastal dunes. *Ocean & Coastal Management*. 2024; 258: 107377. <https://doi.org/10.1016/j.ocecoaman.2024.107377>
10. Marzioletti F., Frate L., De Simone W., Frattaroli A.R., Acosta A.T.R., Carranza M.L. Unmanned Aerial Vehicle (UAV)-Based Mapping of *Acacia saligna* Invasion in the Mediterranean Coast. *Remote Sensing*. 2021; 13(17): 3361. <https://doi.org/10.3390/rs13173361>
11. Costa L.S. et al. Woody Plant Encroachment in a Seasonal Tropical Savanna: Lessons about Classifiers and Accuracy from UAV Images. *Remote Sensing*. 2023; 15(9): 2342. <https://doi.org/10.3390/rs15092342>
12. Prasad A., Mehta N., Horak M., Bae W.D. A Two-Step Machine Learning Approach for Crop Disease Detection Using GAN and UAV Technology. *Remote Sensing*. 2022; 14(19): 4765. <https://doi.org/10.3390/rs14194765>
13. Zhang J. et al. Multispectral Drone Imagery and SRGAN for Rapid Phenotypic Mapping of Individual Chinese Cabbage Plants. *Plant Phenomics*. 2022; 2022: 0007. <https://doi.org/10.34133/plantphenomics.0007>
14. Парасич А.В., Парасич В.А., Парасич И.В. Формирование обучающей выборки в задачах машинного обучения. Обзор. *Информационно-управляющие системы*. 2021; (4): 61–70. <https://doi.org/10.31799/1684-8853-2021-4-61-70>
15. Брагинский М.Я., Тараканов Д.В. Фенотипирование растений адаптивной системой обработки изображений на базе сверточных нейронных сетей. *Вестник кибернетики*. 2021; (2): 6–16. <https://doi.org/10.34822/1999-7604-2021-2-6-16>

All authors bear responsibility for the work and presented data. All authors made an equal contribution to the work. The authors were equally involved in writing the manuscript and bear the equal responsibility for plagiarism. The authors declare no conflict of interest.

REFERENCES

1. Rogachev A.F., Melikhova E.V., Belousov I.S. Research of development and productivity of agricultural crops using unmanned aerial vehicles. *Proceedings of Nizhnevolzskiy agrouniversity complex: science and higher vocational education*. 2019; (4): 329–339 (in Russian). <https://www.elibrary.ru/vqaviv>
2. Cheshkova A.F. A review of hyperspectral image analysis techniques for plant disease detection and identification. *Vavilov Journal of Genetics and Breeding*. 2022; 26(2): 202–213. <https://doi.org/10.18699/VJGB-22-25>
3. Rogachev A.F., Belousov I.S. Neural network identification of problem areas of the state of crops by methods of artificial intelligence. *Proceedings of Nizhnevolzskiy agrouniversity complex: science and higher vocational education*. 2022; (3): 459–466 (in Russian). <https://www.elibrary.ru/bjzmzny>
4. Mudarisov S.G., Miftahov I.R. Automatic detection and identification of wheat diseases using deep learning and real-time drones. *Vestnik of Kazan State Agrarian University*. 2024; 19(2): 90–104 (in Russian). <https://doi.org/10.12737/2073-0462-2024-90-104>
5. Kutyrev A.I., Filippov R.A. Recognition of generative parts of *Fragaria* × *ananassa* using convolutional neural network (CNN). *Taurida Herald of the Agrarian Sciences*. 2023; (2): 72–86 (in Russian). <https://doi.org/10.5281/zenodo.8271986>
6. Demidchik V.V. et al. Plant Phenomics: Fundamental Bases, Software and Hardware Platforms, and Machine Learning. *Russian Journal of Plant Physiology*. 2020; 67(3): 397–412. <https://doi.org/10.1134/S1021443720030061>
7. Molin A.E., Blekanov I.S., Mitrofanov E.P., Mitrofanova O.A. Synthetic data generation methods for training neural networks in the task of segmenting the level of crop nitrogen status on UAV images of agricultural fields. *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*. 2024; 20(1): 20–33 (in Russian). <https://doi.org/10.21638/11701/spbu10.2024.103>
8. Semenyuk V.S., Nikitin E.A. System Development for Liquid Chemicals Point Injection Based on Convolutional Neural Network Models. *Agricultural Machinery and Technologies*. 2021; 15(2): 41–45 (in Russian). <https://doi.org/10.22314/2073-7599-2021-15-1-41-45>
9. Cini E., Marzioletti F., Paterni M., Berton A., Acosta A.T.R., Ciccarelli D. Integrating UAV imagery and machine learning via Geographic Object Based Image Analysis (GEOBIA) for enhanced monitoring of *Yucca gloriosa* in Mediterranean coastal dunes. *Ocean & Coastal Management*. 2024; 258: 107377. <https://doi.org/10.1016/j.ocecoaman.2024.107377>
10. Marzioletti F., Frate L., De Simone W., Frattaroli A.R., Acosta A.T.R., Carranza M.L. Unmanned Aerial Vehicle (UAV)-Based Mapping of *Acacia saligna* Invasion in the Mediterranean Coast. *Remote Sensing*. 2021; 13(17): 3361. <https://doi.org/10.3390/rs13173361>
11. Costa L.S. et al. Woody Plant Encroachment in a Seasonal Tropical Savanna: Lessons about Classifiers and Accuracy from UAV Images. *Remote Sensing*. 2023; 15(9): 2342. <https://doi.org/10.3390/rs15092342>
12. Prasad A., Mehta N., Horak M., Bae W.D. A Two-Step Machine Learning Approach for Crop Disease Detection Using GAN and UAV Technology. *Remote Sensing*. 2022; 14(19): 4765. <https://doi.org/10.3390/rs14194765>
13. Zhang J. et al. Multispectral Drone Imagery and SRGAN for Rapid Phenotypic Mapping of Individual Chinese Cabbage Plants. *Plant Phenomics*. 2022; 2022: 0007. <https://doi.org/10.34133/plantphenomics.0007>
14. Parasich A., Parasich V., Parasich I. Training set formation in machine learning problems. Survey. *Information and Control Systems*. 2021; (4): 61–70 (in Russian). <https://doi.org/10.31799/1684-8853-2021-4-61-70>
15. Braginsky M.Ya., Tarakanov D.V. Plant phenotyping by an adaptive image processing system based on convolutional neural networks. *Proceedings in Cybernetics*. 2021; (2): 6–16 (in Russian). <https://doi.org/10.34822/1999-7604-2021-2-6-16>

16. Рогачев А.Ф., Мелихова Е.В. Мультиклассовое распознавание аэрофотоснимков участков сельскохозяйственных полей. *Известия Нижневолжского агроуниверситетского комплекса: Наука и высшее профессиональное образование*. 2020; (3): 142–152. <https://doi.org/10.32786/2071-9485-2020-03-14>

ОБ АВТОРАХ

Дмитрий Евгеньевич Фёдоров

кандидат технических наук
fedorov_de@inbox.ru
<https://orcid.org/0000-0002-8641-0662>

Сергей Николаевич Быков

кандидат технических наук
agro-kem@rambler.ru

Кузбасский государственный аграрный университет,
им. В.Н. Полецкова,
ул. им. Марковцева, 5, Кемерово, 650056, Россия

16. Rogachev A.F., Melikhova E.V. Multi-class recognition of aerial images of agricultural fields. *Proceedings of Nizhnevolzskiy agrouniversity complex: science and higher vocational education*. 2020; (3): 142–152 (in Russian). <https://doi.org/10.32786/2071-9485-2020-03-14>

ABOUT THE AUTHORS

Dmitry Evgenievich Fedorov

Candidate of Technical Sciences
fedorov_de@inbox.ru
<https://orcid.org/0000-0002-8641-0662>

Sergey Nikolaevich Bykov

Candidate of Technical Sciences
agro-kem@rambler.ru

Kuzbass State Agrarian University named after
V.N.Poletskov,
5 Markovtsev Str., Kemerovo, 650056, Russia

СИБИРСКАЯ АГРАРНАЯ НЕДЕЛЯ

Международная агропромышленная выставка



5–7 ноября 2025

350+

компаний
принимают участие

8500+

профессиональных
посетителей

ЛИДЕРЫ РЫНКА ПРЕДСТАВЛЯЮТ

- Сельхозтехнику и оборудование.
- Технологии для растениеводства и животноводства.
- Решения для переработки, хранения и логистики.

НАЙДИТЕ СВОИХ КЛИЕНТОВ НА СИБИРСКОЙ АГРАРНОЙ НЕДЕЛЕ!

sibagroweek.ru



Место проведения :

**НОВОСИБИРСК
ЭКСПО ЦЕНТР**

Организатор:



СИБИРСКАЯ
ВЫСТАВОЧНАЯ
КОМПАНИЯ

+7 (383) 304-83-88

sibagroweek

@sibagroweek

РЕКЛАМА 0+

