

Разработка системы детектирования участков с дефектами развития посевов кукурузы по фотографии с БПЛА

Д.А. Полещенко, В.А. Петров, И.С. Михайлов, М.С. Шулик

*Старооскольский технологический институт им. А.А. Угарова (филиал)
Национального исследовательского технологического университета «МИСИС», Россия,
г. Старый Оскол*

Аннотация: В этой работе была исследована разработанная система детектирования участков с дефектами развития посевов кукурузы по фотографии, выполненной беспилотным летательным аппаратом (БПЛА) с применением компьютерного зрения. Для решения задачи обнаружения таких участков были рассмотрены структуры нейронных сетей семейства YOLOv5 и YOLOv8. Применение разработанного программного обеспечения позволит сократить трудовые и временные затраты на анализ изображений, что в свою очередь позволит уменьшить время реагирования при обнаружении проблемных зон на сельскохозяйственных полях для достижения большей урожайности.

Ключевые слова: сегментация экземпляров, YOLOv5, YOLOv8.

Введение

Оценка состояния сельскохозяйственных полей производится агрономами, что позволяет повысить эффективность на каждом этапе выращивания культур. В последние годы в агропромышленном комплексе растет популярность беспилотных летательных аппаратов (БПЛА) [1]. Они позволяют сделать снимки местности за минимальное время, тем самым агроном может более эффективно оценивать текущую ситуацию на сельскохозяйственных полях.

С помощью снимков, сделанных БПЛА, становится возможным выявить следующие проблемы на полях:

- распространение сорной растительности;
- появление растений с отстающим развитием;
- поражение растений насекомыми, грызунами и транспортом.

Повреждения культур, указанные выше, могут быть хорошо различимы на снимках, сделанных БПЛА, при условии, что снимки будут делаться при хороших погодных условиях (отсутствие осадков и освещенности не ниже 12000 люкс).

Для анализа полей требуется большое количество изображений, исчисляемое от нескольких сотен до нескольких тысяч. Такой объем данных приводит к высоким временным и трудовым затратам для их анализа агрономами. Поэтому целью данной работы является создание программного обеспечения на основе компьютерного зрения для анализа состояния полей.

Наличие проблем возможно определять автоматически с помощью нейросетевых методов. Работа [2] посвящена картированию растительности водно-болотных угодий с использованием сегментации изображений, полученных с БПЛА. Были рассмотрены различные классификаторы machine learning (ML) и модели deep learning (DL). Наилучшее качество сегментации ($\approx 90\%$) показала комбинация архитектуры ResNet50 и SegNet. В тех задачах, где сети необходимо обучать для каждого отдельного участка и различных условий, авторы предлагают использовать классификаторы ML.

В работе [3] для определения пропусков в рядах сахарного тростника используется Object-based Image Analysis (OBIA) [4]. Предложен алгоритм, состоящий из следующих этапов: идентификация рядов посевов сахарного тростника; идентификация существующего сахарного тростника в этих рядах; извлечение пропусков и создание карт посевов по площади. По результатам исследования соотношение расчетной и наблюдаемой длины пропуска имело коэффициент детерминации равный 0,97.

В работе [5] разработана модификация алгоритма сегментации растительности на основе сетей ResNet50 и ResNet101, отличающаяся уникальным подбором параметров, включением искусственного увеличения размеченного набора данных, позволяющая строить маски регионов объектов на изображениях сверхвысокого пространственного разрешения в условиях малых выборок.

Задача распознавания проблемных участков может быть решена с помощью детектирования и сегментации экземпляров, что позволяет

локализовать экземпляры каждого объекта из всех возможных классов. Но малый объем выборок, связанный с сезонностью процесса выращивания сельскохозяйственных культур и стабильностью идентифицируемых объектов в рамках одного сезона, затрудняет выполнение поставленной задачи.

Подготовка наборов данных

Для активного развития машинного зрения в растениеводстве требуются большие наборы данных, связанные с сельским хозяйством. В настоящее время таких данных в открытом доступе находится малое количество. Примеры датасетов и их свойства представлены в таблице № 1.

Таблица № 1

Свойства датасетов

Название	Количество изображений	Количество классов	Размер изображений
Crop/Weed discrimination [6]	15336	2	1296x966
DeepWeeds [7]	17509	8	1920x1200
Agriculture-Vision [8]	21061	6	512x512

Все датасеты представленные в таблице выше, были сформированы из изображений, которые сделаны в разных климатических зонах и с разным составом почвы.

Для наибольшей эффективности системы, датасет собран из изображений, полученных на территории Белгородской области. Было получено 603 фотографии кукурузных полей с помощью БПЛА DJI Phantom 4 Pro. Разрешение каждой фотографии 5472x3648 пикселей, что велико для стандартного входа нейронной сети (640x640 пикселей, 512x512 пикселей, в зависимости от архитектуры). При подаче на нейронную сеть столь большого изображения, оно будет сжиматься нейронной сетью до формата входного тензора, это повлечет за собой потерю в четкости изображений на входе нейронной сети, в следствие чего и потерю точности предсказаний. Поэтому

решено разделить каждую фотографию на части размером 640x640 пикселей, расширив датасет до 3618 фотографий.

Нейронной сети необходимо выделять следующие классы на кукурузных полях: сорняки (weed cluster) и плохой рост посевов (nutrient deficiency). Фотографии были размечены под нужные классы (см. рисунок 1).




Рис. 1. – Примеры разметки фотографий

Далее из датасета были убраны изображения, на которых нет разметки, и произведена аугментация, с помощью отражений по горизонтали, поворотов, изменения насыщенности, яркости и шума. Итоговый датасет имеет 3283 фотографии.

Обзор структур нейронных сетей

При решении задач детектирования и сегментации объектов существует проблема – малая емкость обучающей выборки. Целесообразно использовать модель YOLO, которая ориентируется на обучение сети за один проход данных, что может позволить нивелировать проблему малого объема обучающих данных [9].

YOLOv5 является самой развитой и долго поддерживаемой версией, а YOLOv8 - самой новой версией, релиз которой вбирает в себя опыт предыдущих версий. Каждая модель имеет пять модификаций, отличающихся точностью работы и размером: n – nano, s – small, m – medium, l – large и x – extra large.

В таблице 2 представлена параметры качества mAP50-95 для bounding box и масок объектов на датасете COCO val2017 и количество параметров каждой модели нейронных сетей согласно документации [10,11].

Таблица № 2

Точность моделей YOLO

Модель	mAP ^{box} 50-95	mAP ^{mask} 50-95	Количество параметров (М)
YOLOv5n-seg	0,276	0,234	2,0
YOLOv8n-seg	0,367	0,305	3,4
YOLOv5s-seg	0,376	0,317	22,0
YOLOv8s-seg	0,446	0,368	11,8
YOLOv5m-seg	0,376	0,317	22,0
YOLOv8m-seg	0,499	0,408	27,3
YOLOv5l-seg	0,490	0,399	47,9
YOLOv8l-seg	0,523	0,426	46,0
YOLOv5x-seg	0,490	0,399	88,8
YOLOv8x-seg	0,534	0,434	71,8

Для поставленной задачи важны точность оценки и скорость обработки изображений. Были рассмотрены модели следующих размеров: nano – самая быстрая и менее точная модель, medium – средняя по параметрам, extra large – наиболее точная и самая медленная.

Обучение нейронных сетей

Модели из семейства YOLOv5 были обучены на наборе данных с инициализацией модели с предварительно обученными весами на наборе данных COCO. Модель обучали в течение 30 эпох с размером пакета 16 и начальной скоростью обучения 0,01. Графики обучения представлены на рисунке 2.

По результатам обучения наименьшее значение ошибки по маскам сегментации имеет модель YOLOv5x-seg.

Модели семейства YOLOv8 были обучены при следующих гиперпараметрах:

- количество эпох – 30;

- размер пакета – 16;
- скорость обучения – 0,01.

Графики обучения представлены на рисунке 3.

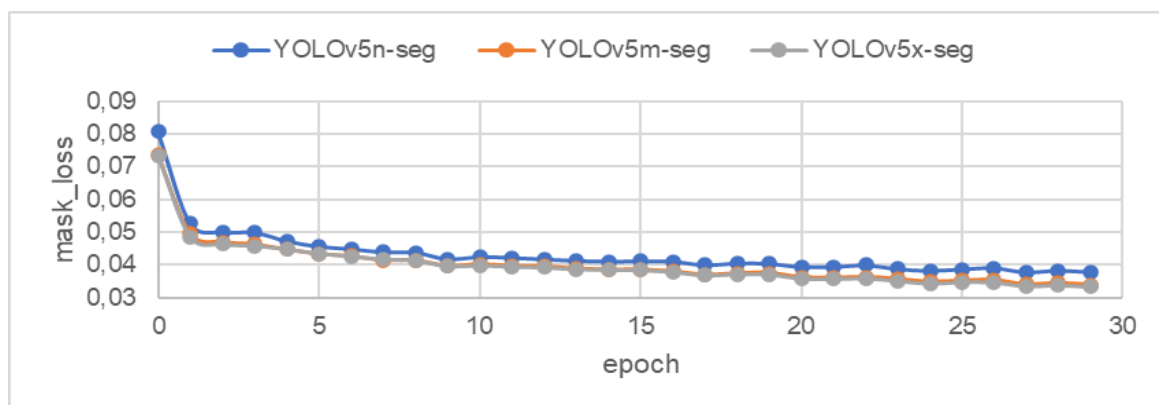


Рис. 2. – Графики обучения моделей семейства YOLOv5

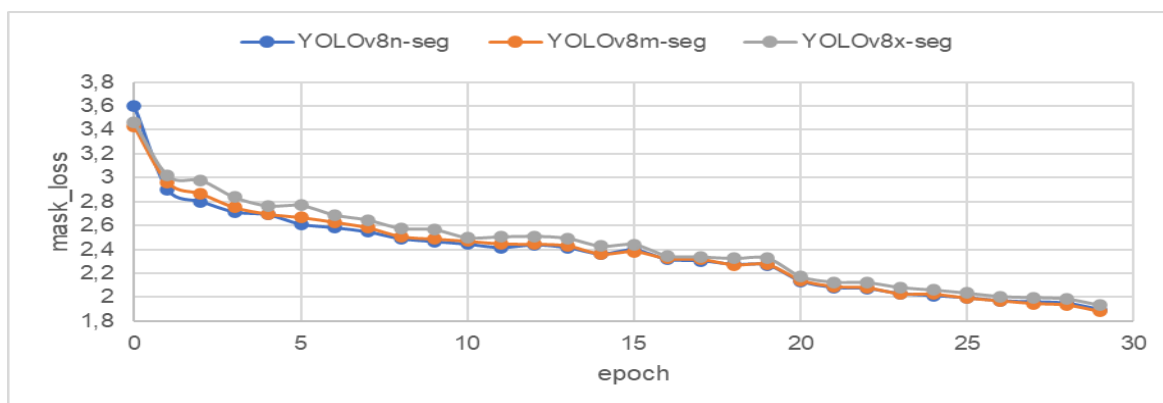


Рис. 3. – Графики обучения моделей семейства YOLOv8

По результатам обучения наименьшее значение ошибки по маскам сегментации имеет модель YOLOv8m-seg.

Разработка программного обеспечения

Была разработана система распознавания проблемных участков сельскохозяйственных угодий по фотографии с БПЛА со следующим функционалом:

- загрузка снимков полей, требующих сканирования на наличие проблем;
- просмотр загруженных снимков;

- сканирование загруженных снимков;
- просмотр результатов определения проблемных участков на полях;
- просмотр координат участков на карте.

Система включает в себя:

- главную форму;
- форма просмотра загруженных изображений;
- формы просмотра отсканированных изображений;

При запуске программы открывается окно главной формы, и сразу запускаются две функции: проверка количества загруженных изображений и проверка соответствия загруженных изображений со сканированными изображениями.

Количество загруженных изображений выводится на экран, как и состояние сканирования изображений (см. рисунок 4).

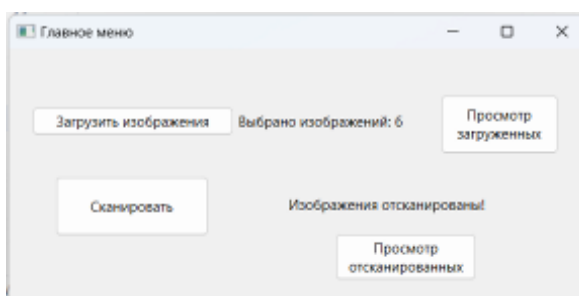


Рис. 4. – Главная форма

Загружаемые в систему изображения проходят обработку и результат отображается на форме просмотра отсканированных изображений, представленной на рисунке 5.

На данной форме показываются координаты снимка, также можно посмотреть место на Яндекс Картах, где была сделана данная фотография, нажав кнопку «Показать на карте» (см. рисунок 6).

На отсканированных фото можно увидеть проблемы, связанные с плохим ростом посевов (красный квадрат) и сорняковую растительность (розовый квадрат).



Рис. 5. – Форма просмотра отсканированных изображений




Рис. 6. – Просмотр проблемных участков на полях

Результаты

Несмотря на то, что при обучении лучшими оказались сети YOLOv5x-seg и сети YOLOv8m-seg было принято решение тестировать все модели на данных, не входящих в обучающую выборку.

Тестирование проводилось на Intel(R) Core(TM) i5-10300H CPU @ 2.50GHz с целью проверки скорости работы системы без применения графических процессоров. В таблице 3 и на рисунке 7 представлены

результаты тестирования нейронных сетей. Указана скорость, как среднее время обработки одного изображения в ms.

Таблица № 3

Результаты тестирования моделей

Модель	Box		Mask		Speed (ms)
	mAP ⁵⁰	mAP ⁵⁰⁻⁹⁵	mAP ⁵⁰	mAP ⁵⁰⁻⁹⁵	
YOLOv5n-seg	0,543	0,240	0,521	0,192	1,023
YOLOv8n-seg	0,600	0,345	0,577	0,266	1,140
YOLOv5m-seg	0,58	0,292	0,591	0,239	4,744
YOLOv8m-seg	0,554	0,313	0,555	0,262	5,300
YOLOv5x-seg	0,689	0,366	0,624	0,276	12,428
YOLOv8x-seg	0,560	0,296	0,560	0,260	12,664

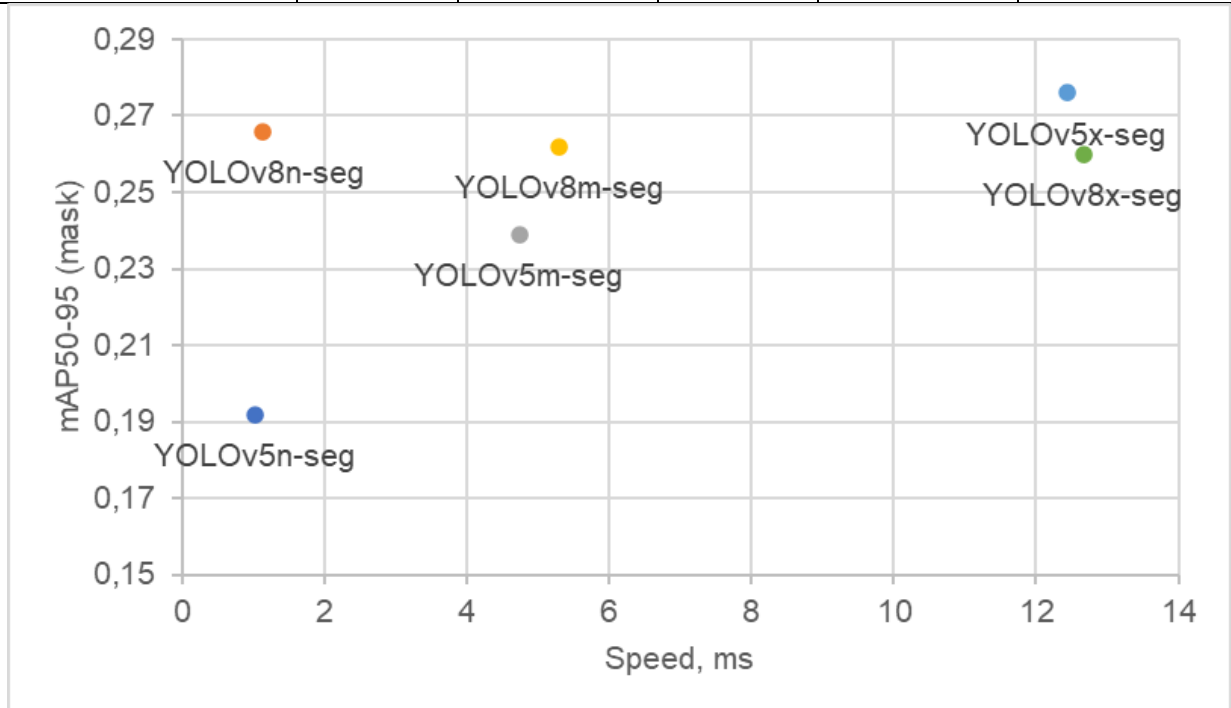


Рис. 7. – Зависимость точности mAP^{50-95 (mask)} от скорости работы моделей

Исходя из полученных результатов, лучшую точность имеет модель YOLOv5x-seg, но является одной из самых медленных. Оптимальной по времени работы и точности можно принять модель YOLOv8n-seg для использования в разрабатываемой системе. В последующем выбор моделей может осуществляться, исходя из имеющихся аппаратных средств.

Заключение

Таким образом, разработанная система распознавания проблемных участков сельскохозяйственных угодий по фотографии с БПЛА позволяет сократить трудовые и временные затраты на анализ изображений. Для автоматизированного выявления проблемных участков целесообразно использовать нейронные сети семейства YOLO, включающего в себя различные структуры по размеру и качеству работы, что позволит подобрать оптимальную структуру, удовлетворяющую требованиям точности и скорости обработки.

Работа выполнена при частичной финансовой поддержке Совета по грантам Президента РФ (проект СП-551.2022.5).

Литература

1. Bouguettaya A. et al. Deep learning techniques to classify agricultural crops through UAV imagery: A review // Neural Computing and Applications. 2022. V. 34. №. 12. pp. 9511-9536.
 2. Bhatnagar S., Gill L., Ghosh B. Drone image segmentation using machine and deep learning for mapping raised bog vegetation communities // Remote Sensing. 2020. V. 12. №. 16. P. 2602.
 3. de Souza C.H.W., Lamparelli R.A.C., Rocha J.V., Magalhães P.S.G. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images // Computers and Electronics in Agriculture. 2017. V. 143. pp. 49-56.
 4. Blaschke T. Object based image analysis for remote sensing // ISPRS journal of photogrammetry and remote sensing. 2010. V. 65. №. 1. pp. 2-16.
 5. Сафонова А.Н. Методы машинного обучения при обработке изображений сверхвысокого пространственного разрешения на примере задач классификации растительности: автореф. дис. канд. тех. наук: 05.13.17. Красноярск, 2020. 24 с.
-

6. Crop vs weed discrimination dataset // Lincoln Centre for Autonomous Systems URL: icas.lincoln.ac.uk/wp/research/data-sets-software/crop-vs-weed-discrimination-dataset/ (дата обращения: 09.06.2023).

7. Olsen A., Konovalov D.A., Philippa B., Ridd P., Wood J.C., Johns J., Banks W., Girgenti B., Kenny O., Whinney J., Calvert B., Azghadi M.R., White R.D. DeepWeeds: A multiclass weed species image dataset for deep learning // Scientific reports. 2019. V. 9. №. 1. P. 2058.

8. Agriculture-vision database // Agriculture-Vision. URL: agriculture-vision.com/agriculture-vision-2020/dataset (дата обращения: 09.06.2023).

9. Poleshchenko D., Petrov V., Mikhailov I. Detection of Sunflower Plants in UAV Photos // 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA). IEEE, 2022. pp. 385-388.

10. Comprehensive Guide to Ultralytics YOLOv5 // Ultralytics YOLOv8 Docs. URL: docs.ultralytics.com/yolov5/ (Дата обращения: 27.06.2023).

11. Ultralytics YOLOv8 Docs // Ultralytics YOLOv8 Docs. URL: docs.ultralytics.com/ (Дата обращения: 27.06.2023).

References

1. Bouguettaya A. et al. Neural Computing and Applications. 2022. V. 34. №. 12. pp. 9511-9536.

2. Bhatnagar S., Gill L., Ghosh B. Remote Sensing. 2020. V. 12. №. 16. p. 2602.

3. de Souza C. H. W., Lamparelli R. A. C., Rocha J. V., Magalhães P. S. G. Computers and Electronics in Agriculture. 2017. V. 143. pp. 49-56.

4. Blaschke T. ISPRS journal of photogrammetry and remote sensing. 2010. V. 65. №. 1. pp. 2-16.

5. Safonova A.N. Metody mashinnogo obucheniya pri obrabotke izobrazheniy sverkhvysokogo prostranstvennogo razresheniya na primere zadach klassifikatsii



rastitelnosti [Methods of machine learning in processing of ultra-high spatial resolution images on the example of vegetation classification tasks]. Extended abstract of candidate's thesis. Krasnoiarsk, 2020. 24 p.

6. Crop vs weed discrimination dataset. URL: lcas.lincoln.ac.uk/wp/research/data-sets-software/crop-vs-weed-discrimination-dataset/ (accessed: 09/06/23).

7. Olsen A., Konovalov D.A., Philippa B., Ridd P., Wood J.C., Johns J., Banks W., Girgenti B., Kenny O., Whinney J., Calvert B., Azghadi M.R., White R.D. Scientific reports. 2019. V. 9. №. 1. p. 2058.

8. Agriculture-vision database. URL: agriculture-vision.com/agriculture-vision-2020/dataset (accessed: 09/06/23).

9. Poleshchenko D., Petrov V., Mikhailov I. 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA). IEEE, 2022. pp. 385-388.

10. Comprehensive Guide to Ultralytics YOLOv5. URL: docs.ultralytics.com/yolov5/ (accessed: 27/06/23).

11. Ultralytics YOLOv8 Docs. URL: docs.ultralytics.com/ (accessed: 27/06/23).