



Выбор оптимальной методики идентификации угодий на землях сельскохозяйственного назначения с использованием нейронных сетей

Д.А. Гура^{1,2}✉, Р.А. Дьяченко^{1,3}, А.М. Барышева¹,
А.А. Коломыцев¹, В.В. Довгаль¹

¹ Кубанский государственный технологический университет, Краснодар, Россия

² Кубанский государственный аграрный университет, Краснодар, Россия

³ Московский физико-технический институт (национальный исследовательский университет), Москва, Россия

✉ gda-kuban@mail.ru

ЦИТИРОВАНИЕ Гура Д.А., Дьяченко Р.А., Барышева А.М., Коломыцев А.А., Довгаль В.В. Выбор оптимальной методики идентификации угодий на землях сельскохозяйственного назначения с использованием нейронных сетей // Известия вузов «Геодезия и аэрофотосъемка». 2025. Т. 69. № 2. С. 124–138. DOI:10.30533/GiA-2025-029.

КЛЮЧЕВЫЕ СЛОВА земли сельскохозяйственного назначения, идентификация угодий, виноградные насаждения, ИНС, детекция изображений, искусственный интеллект, Mask R-CNN, YOLOv8, YOLOv5, метрики, mAP, Precision, Recall

АННОТАЦИЯ Представлены результаты исследования по выбору оптимальной нейронной сети для идентификации угодий на землях сельскохозяйственного назначения на примере виноградных насаждений в целях актуализации ведения государственного реестра земель сельскохозяйственного назначения. Основная задача идентификации угодий — выявить расхождения между информацией федерального реестра виноградных насаждений об использовании земельных участков и их фактическим состоянием. Для проведения экспериментов были выбраны нейросети YOLOv5, YOLOv8, Mask R-CNN, чаще всего применяемые для распознавания объектов на изображениях. Нейросети предлагают передовые методы анализа изображений, применимые для автоматизированной идентификации виноградных насаждений на землях сельскохозяйственных угодий. Эффективность их работы по задаче детекции определена с помощью вычисления метрик Precision, Recall и mAP на валидационном наборе данных. В исследовании представлены результаты сравнения моделей YOLOv5, YOLOv8, Mask R-CNN, по которым можно отследить эффективность их работы. Сравнение моделей показало, что для набора изображений земельных участков с угодьями на примере

виноградных насаждений модель YOLOv5 предпочтительнее в отношении задач, требующих постепенного улучшения с увеличением числа эпох, в то время как Mask R-CNN обеспечивает стабильные высокие результаты даже при небольшом количестве эпох. YOLOv8 существенно отстает по всем показателям, особенно на ранних этапах, и демонстрирует самую низкую производительность.

1 Введение

Достоверность сведений по учету земельных участков на землях сельскохозяйственного назначения с учетом вида угодий важна для устойчивого развития страны [1]. Необходимо владеть актуальной информацией о состоянии земель сельскохозяйственного назначения и, в частности, о землях, которые когда-либо использовались для того или иного сельскохозяйственного угодья (пашни, пастбища, многолетние насаждения, например виноградные), сейчас используются и потенциально могли бы использоваться в будущем [2].

Данный вопрос является актуальным в связи с постановлением Правительства РФ от 2 февраля 2023 года № 154 «О порядке ведения государственного реестра земель сельскохозяйственного назначения»¹ и статьей 15.1 Федерального закона № 101-ФЗ «О государственном регулировании обеспечения плодородия земель сельскохозяйственного назначения»². В данном исследовании объектом выступают земельные участки, занятые сельскохозяйственными угодьями, на примере виноградных насаждений. Отдельно необходимо отметить важность проведения мероприятий по учету виноградных насаждений на земельных участках. Нормативно данный вопрос отражен в Федеральном законе № 468-ФЗ «О виноградарстве и виноделии в Российской Федерации»³. Согласно данному закону, работы по учету и оценке соответствия состояния земельных участков сельскохозяйственного назначения, занятых виноградными насаждениями, данным федерального реестра осуществляет специально уполномоченный орган исполнительной власти (в рабочие группы по учету особо ценных земель вошли представители региональных департаментов имущественных отношений, архитектуры и градостроительства, а также Министерства сельского хозяйства). Основная задача учета — выявить расхождения между информацией федерального реестра виноградных насаждений и их фактическим состоянием [3].

Виноградарство как одна из ключевых отраслей агропромышленного комплекса требует комплексного управления для обеспечения высокого качества продукции. Выявление и мониторинг земельных участков, занятых виноградными насаждениями, является важной задачей, решение которой может существенно улучшить управление ресурсами, планирование урожаев [4, 5]. Для сбора информации о земельных участках, занятых виноградными насаждениями, могут применяться различные средства фото- и видеофиксации, а также технологии лазерного сканирования с применением лидаров и беспилотных воздушных судов [6, 7]. Обработка изображений и точек лазерного отражения планируется с применением систем, основанных на нейронных сетях [8]. Существующие нейронные сети, такие как Mask R-CNN, YOLOv5 и YOLOv8,

1 Постановление Правительства Российской Федерации от 2 февраля 2023 г. № 154 «О порядке ведения государственного реестра земель сельскохозяйственного назначения». [Электронный ресурс]. Режим доступа: <http://government.ru/docs/all/145983> (дата обращения: 15.11.2024).

2 Федеральный закон от 16 июля 1998 г. № 101-ФЗ «О государственном регулировании обеспечения плодородия земель сельскохозяйственного назначения». [Электронный ресурс]. Режим доступа: <http://www.kremlin.ru/acts/bank/12650> (дата обращения: 15.11.2024).

3 Федеральный закон от 27 декабря 2019 г. № 468-ФЗ «О виноградарстве и виноделии в Российской Федерации» (с изм. и доп., вступ. в силу с 1 марта 2024 г.). [Электронный ресурс]. Режим доступа: https://www.consultant.ru/document/cons_doc_LAW_370480/29c722a2e14ced463ec3d6cb6cbeb97df5ef355e/#dst100010 (дата обращения: 15.11.2024).

предлагают передовые методы анализа изображений, которые могут быть применены для автоматизированной идентификации виноградных насаждений [9].

На сегодняшний день опубликован целый ряд работ по идентификации земель, в том числе земель сельскохозяйственного назначения [10, 11]. При этом вопросам выбора архитектуры нейронной сети для идентификации земельных участков, занятых виноградными насаждениями, уделено недостаточное внимание [12]. Проблематика исследования заключается в объеме материалов, требующих разметки данных для обучающих наборов, длительности процесса обучения нейронной сети, объеме экспериментальной части, сложности рассматриваемых архитектур нейронной сети, адаптации иерархии наборов данных [13].

Таким образом, целью работы является выбор оптимальной нейронной сети для идентификации земельных участков, занятых виноградными насаждениями. Для решения данной проблемы необходимо провести анализ указанных выше нейронных сетей относительно метрик mAP, Precision, Recall.

2 Материалы и методы

Исследование направлено на оценку эффективности трех современных моделей машинного обучения — YOLOv5, YOLOv8 и Mask R-CNN — применительно к задаче обнаружения земельных участков с виноградными насаждениями на изображениях. Для реализации задач обнаружения объектов в данном исследовании используются модели YOLOv5 и YOLOv8, которые доступны в открытом репозитории⁴. Для достижения цели в исследовании были выбраны следующие методы [9]:

- 1) подобрать датасеты виноградных насаждений, чтобы в дальнейшем можно было их идентифицировать на реальных фотографиях;
- 2) выполнить адаптацию иерархии датасетов;
- 3) выполнить обучение моделей на тестовых датасетах;
- 4) выполнить оценку полученных результатов на валидационных изображениях;
- 5) определить модели с наилучшими значениями метрик.

В современном сельском хозяйстве использование передовых технологий играет ключевую роль в повышении эффективности производства и оптимизации использования земельных ресурсов. Одной из таких инноваций является применение нейронных сетей для анализа земельных участков с целью определения и оптимизации посадки виноградных насаждений.

3 Результаты и обсуждение

3.1 Методы решения задачи исследования

YOLOv5 — это модель машинного обучения, предназначенная для обнаружения объектов на изображениях и в видео. Она выделяется своей высокой скоростью и точностью. YOLOv5 относится к одноэтапным детекторам. Это означает, что она выполняет обнаружение объектов за один проход по изображению, в отличие от двухэтапных моделей, таких как Faster R-CNN или Mask R-CNN.

⁴ Ultralytics GitHub. [Электронный ресурс]. Режим доступа: <https://github.com/ultralytics/ultralytics> (дата обращения: 03.02.2024).

Основной принцип работы YOLOv5 заключается в разделении изображения на сетку и предсказании прямоугольных рамок (*англ.* bounding boxes) и вероятностей классов объектов для каждой ячейки сетки. Сеть обучается предсказывать координаты рамок и соответствующие им классы объектов, используя прямой регрессионный подход. Архитектура YOLOv5 разделена на две части: backbone и head [9, 10].


В YOLOv5 используется архитектура CSP (*англ.* Cross Stage Partial Networks) [14] для backbone и PAN (*англ.* Path Aggregation Network) [15] для слияния признаков из различных уровней сети, что позволяет улучшить распознавание объектов разных масштабов. В процессе обучения YOLOv5 минимизирует ошибку предсказания bounding boxes (границ объектов) [12] и классов объектов, используя соответствующие функции потерь, такие как бинарная кросс-энтропия (*англ.* Binary Cross-Entropy) для классов и среднеквадратичная ошибка (*англ.* Mean Squared Error) для координат bounding boxes. Это помогает модели лучше различать объекты и точнее определять их местоположение на изображении. Архитектура YOLOv5 представлена на рис. 1.

Рис. 1

Архитектура YOLOv5

Fig. 1

Architecture YOLOv5



Mask R-CNN — сверточная нейронная сеть, предназначенная для выполнения задач сегментации, а также обнаружения объектов на фотографиях [9]. Одной из ключевых характеристик Mask R-CNN является разделение всей архитектуры на ряд компонентов, включая сеть-основу (*англ.* backbone) [9, 10], сеть предложений регионов (*англ.* Region Proposal Network, RPN) [8, 14], голову детектора объектов и голову сегментации. Сеть-основа представляет собой мощную сверточную архитектуру, такую как ResNet, которая извлекает признаки из изображения. В процессе обработки изображение проходит через несколько слоев сверток и преобразований, что позволяет сети выделить ключевые признаки, необходимые для дальнейшей детекции и сегментации объектов.


Сеть предложений регионов (RPN) [16] отвечает за генерацию предложений регионов, которые содержат объекты. Это промежуточный этап, который помогает сети сосредоточиться на наиболее значимых частях изображения. Данная сеть производит множество прямоугольных регионов, среди которых затем выбираются те, которые с наибольшей вероятностью содержат объекты.

Следующим этапом является применение RoIAlign (*англ.* Region of Interest Align) [17], необходимое для точного выравнивания предложений регионов на карте признаков. Этот метод позволяет избежать проблем, связанных с интерполяцией при использовании RoIPool (*англ.* Region of Interest Pooling) [18], обеспечивая точные и стабильные маски объектов.

Голова детектора объектов предсказывает классы объектов и точные координаты bounding box для каждого обнаруженного объекта на изображении. Это позволяет не только определить, где находится объект, но и к какому классу он принадлежит.

Основная особенность Mask R-CNN заключается в наличии дополнительной головы для предсказания масок сегментации объектов. Эта часть архитектуры позволяет точно выделить контуры объектов на изображении, что особенно важно для задач с высокой детализацией. В рамках данного исследования была использована стандартная архитектура Mask R-CNN, изображенная на рис. 2⁵ [9, 18].

Рис. 2 
Архитектура Mask R-CNN
Fig. 2
Architecture Mask R-CNN



YOLOv8 представляет собой одну из последних версий архитектуры YOLO. Сеть позволяет обнаруживать объекты, классифицировать и сегментировать изображения [9, 19]. В архитектуру YOLOv8 входят два основных компонента: backbone и head [9]. В архитектуру базовой сети (backbone) и головы (head) сети YOLOv8 были внесены изменения [10], чтобы улучшить производительность модели [18]. В частности, улучшены методы свертки и нормализации, а также добавлены новые слои для лучшего извлечения признаков [19]. Архитектура YOLOv8 представлена на рис. 3⁶.

В целях определения наиболее результативной модели машинного обучения для работы с изображениями на одном и том же наборе данных обучались различные архитектуры нейронных сетей. Затем модели сравнивались по показателям Precision и Recall, которые рассчитывались на основе результатов обнаружения объектов на тестовых изображениях [9].

В исследовании ключевые метрики были получены на основании матрицы ошибок, которая показывает, насколько хорошо модель классификации справляется с предсказанием классов. Эта матрица представляет нормализованную версию ошибок, полученных при лучшей детекции с использованием модели YOLOv5, обученной на 50 эпохах (рис. 4).

В итоге лучшая матрица ошибок показала, что модель правильно предсказала 92 % объектов как виноградные насаждения, ошибочно классифицировала 8 % объектов, которые на самом деле являются виноградными насаждениями, как фон, правильно классифицировала 100 % объектов, которые действительно являются фоном, и не классифицировала фон как виноградные насаждения. В исследовании для оценки качества результатов были использованы метрики Precision, Recall и mean Average Precision (mAP) [9].

5 Getting Started with Mask R-CNN for Instance Segmentation. [Электронный ресурс]. Режим доступа: <https://www.mathworks.com/help/vision/ug/getting-started-with-mask-r-cnn-for-instance-segmentation.html> (дата обращения: 10.10.2024).

6 Algorithm principles and implementation with YOLOv8. [Электронный ресурс]. Режим доступа: https://github.com/open-mmlab/mmyolo/blob/main/docs/en/recommended_topics/algorithm_descriptions/yolov8_description.md (дата обращения: 10.10.2024).

Рис. 3 

Архитектура YOLOv8

Fig. 3

Architecture YOLOv8

YOLOv8





Рис. 4 ➤

Матрица ошибок для модели YOLOv5 на 50 эпохах

Fig. 4

Error matrix for the YOLOv5 model at 50 epochs



3.2 Результаты экспериментов


Рис. 5 

Показатели метрик для модели YOLOv5 в зависимости от количества эпох

Fig. 5

Metrics for the YOLOv5 model depending on the number of epochs

Для каждой полученной модели замеры метрик Precision, Recall и mAP проводились на 10, 20, 50 и 100 эпохах обучения [9]. Для обучения моделей применялась технология аугментации данных [20]. Были построены графики, демонстрирующие значения метрик Precision, Recall и mAP [21] на валидационных наборах данных при выбранных количествах эпох [9]. На рис. 5 представлен график, показывающий значения метрик для модели YOLOv5 в зависимости от количества эпох.



Объекты, которые были обнаружены на изображении с помощью обученной модели YOLOv5, приведены на рис. 6 [9].

На рис. 7 приведены показатели метрик для модели YOLOv8. Результат обнаружения объектов на изображении, полученный с помощью обученной модели YOLOv8, показан на рис. 8.

На рис. 9 показаны объекты, которые были обнаружены на изображении с помощью обученной модели Mask R-CNN [9].

График, демонстрирующий значения метрик для модели Mask R-CNN в зависимости от количества эпох, приведен на рис. 10.

Рис. 6 

Результаты детектирования моделью YOLOv5

Fig. 6

Detection results model YOLOv5

Рис. 7 ✓

Показатели метрик для модели YOLOv8 в зависимости от количества эпох

Fig. 7

Metric indicators for YOLOv8 based on the number of epochs




Рис. 8 ✓

Результаты детектирования моделью YOLOv8

Fig. 8

Detection results model YOLOv8



Рис. 9 ✓

Идентификация виноградных насаждений при помощи Mask R-CNN

Fig. 9

Identifying Grape Plantations Using Mask R-CNN




Рис. 10

Показатели метрик для модели Mask R-CNN в зависимости от количества эпох


Fig. 10

Metric indicators for Mask R-CNN based on the number of epochs


mAP за эпоху




mAP за эпоху




Precision за эпоху



Precision за эпоху



Recall за эпоху



Recall за эпоху



На основе полученных значений метрик составлена таблица сравнения для моделей Mask R-CNN, YOLOv5 и YOLOv8 [9] (табл. 1).

Таблица 1

Выявление наилучших параметров обучения моделей

Table 1

Identifying the best parameters for training models

Метрики	Архитектура	Показатель, количество эпох			
		10	20	50	100
Precision	YOLOv5	0,79	0,82	0,96	0,96
	YOLOv8	0,0427	0,043	0,0427	0,33
	Mask R-CNN	0,832	0,85	0,85	0,85
Recall	YOLOv5	0,75	0,79	0,85	0,92
	YOLOv8	0,33	0,34	0,3347	0,0022
	Mask R-CNN	0,655	0,7	0,72	0,72
mAP	YOLOv5	0,38	0,46	0,55	0,6
	YOLOv8	0,0125	0,013	0,0125	0,017
	Mask R-CNN	0,458	0,46	0,46	0,46

4 Выводы

Сравнение моделей YOLOv5, YOLOv8 и Mask R-CNN, результаты которого представлены в табл. 1, показало, что для набора изображений с виноградными насаждениями модель YOLOv5 может быть предпочтительнее в отношении задач, требующих постепенного улучшения с увеличением числа эпох, в то время как Mask R-CNN обеспечивает стабильные высокие результаты даже при небольшом количестве эпох. YOLOv8 существенно отстает по всем показателям, особенно на ранних этапах, и демонстрирует самую низкую производительность. При сравнении результатов исследования на 100 эпохах лучшие результаты при обучении показала нейронная сеть YOLOv5 по метрикам Precision — 96 %, Recall — 92 %, mAP — 60 %.

Таким образом, исследование показывает, что идентификация угодий на землях сельскохозяйственного назначения на примере виноградных насаждений в рамках актуального ведения государственного реестра земель сельскохозяйственного назначения может быть осуществлена при помощи распознавания образов с применением нейросетевых технологий. В рамках исследования были обучены модели YOLOv5, YOLOv8 и Mask R-CNN на одном наборе изображений, содержащем земельные участки с виноградными насаждениями в качестве целевых объектов. Эффективность их работы по задаче детекции была определена с помощью вычисления метрик Precision, Recall и mAP на валидационном наборе данных.

Проведенные исследования и полученные результаты будут полезны для трехмерной идентификации объектов недвижимости — процесса трехмерного отображения местности и объектов недвижимости, размещенных на ней; определения их геометрических параметров с целью учета, оценки и дальнейшего мониторинга.

БИБЛИОГРАФИЯ

1. Кузнецов П.Н., Котельников Д.Ю. Автоматизированный технологический комплекс мониторинга и диагностики виноградников // Вестник аграрной науки Дона. 2021. Т. 4. № 56. С. 16–23.
2. Студенкова Н.А., Добротворская Н.И. Современные проблемы инвентаризации и кадастрового учета земель сельскохозяйственного назначения // Сборник материалов XVII Международного научного конгресса «Интерэкспо ГЕО-Сибирь»: в 8 т. Новосибирск: СГУГиТ, 2021. Т. 3. № 2. С. 198–204. DOI:10.33764/2618-981X-2021-3-2-198-204.
3. Кузнецов П.Н., Котельников Д.Ю., Воронин Д.Ю. Нейросетевое автоматизированное детектирование признаков ухудшения состояния виноградных насаждений // Проблемы научной мысли. 2023. Т. 2. № 8. С. 48–55.
4. Кузнецов П.Н., Котельников Д.Ю., Воронин Д.Ю. Технология автоматизированного мониторинга состояния виноградника // Аграрная наука. 2023. № 3. С. 109–116. DOI:10.32634/0869-8155-2023-368-3-109-116.
5. Wang T., Gan V.J. Automated joint 3D reconstruction and visual inspection for buildings using computer vision and transfer learning // Automation in Construction. 2023. Vol. 149. 104810. DOI:10.1016/j.autcon.2023.104810.
6. Гура Д.А., Марковский И.Г., Пшидаток С.К. Методика мониторинга объектов недвижимости с помощью трехмерного лазерного сканирования в специфике городских земель // Геодезия и картография. 2021. Т. 82. № 4. С. 45–53. DOI:10.22389/0016-7126-2021-970-4-45-53.
7. Dhanya V.G., Subeesh A., Kushwaha N.L., et al. Deep learning based computer vision approaches for smart agricultural applications // Artificial Intelligence in Agriculture. 2022. Vol. 6. P. 211–229. DOI:10.1016/j.aiia.2022.09.007.
8. Дьяченко Р.А., Довгаль В.В., Гура Д.А. К вопросу сравнения эффективности нейронных сетей YOLOv8 и U-Net в задачах сегментации территориальных объектов // Информационные технологии. 2024. Т. 30. № 9. С. 480–485. DOI:10.17587/it.30.480-485.
9. Антюфеев В.В., Рябов В.А. Опыт агроклиматологического обоснования проектов плодовых насаждений в Северном Причерноморье в эпоху глобального потепления // Известия Оренбургского государственного аграрного университета. 2017. Т. 4. № 66. С. 252–256.
10. Филонова М.А., Хорошко М.Б. Применение средств машинного зрения в виноградных хозяйствах: подготовка данных и обучение модели // Управление большими системами: сборник научных трудов XIX Всероссийской школы-конференции молодых ученых (Воронеж, 5–8 сентября 2023 г.). Воронеж: ВГТУ, 2023. С. 417–424.
11. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Proceedings of the 25th International Conference on Neural Information Processing Systems (Lake Tahoe, Nevada, Dec. 2012). 2012. Vol. 1. P. 1097–1105.
12. Wang, C.Y., Bochkovskiy A., Liao H.Y.M. CSPNet: A new backbone that can enhance learning capability of CNN // Proceedings of the IEEE/CVF Conference on Computer

- Vision and Pattern Recognition Workshops (CVPRW). Seattle, WA, USA, 2020. P. 1571–1580. DOI:10.1109/CVPRW50498.2020.00203.
13. Liu S., Qi L., Qin H., et al. Path Aggregation Network for Instance Segmentation // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, UT, USA, 2018. P. 8759–8768. DOI:10.1109/CVPR.2018.00913.
 14. Ren S., He K., Girshick R., et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence (June 1, 2017). 2017. Vol. 39. No. 6. P. 1137–1149. DOI:10.1109/TPAMI.2016.2577031.
 15. Girshick R. Fast R-CNN // Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile, 2015. P. 1440–1448. DOI:10.1109/ICCV.2015.169.
 16. He K., Gkioxari G., Dollár P., et al. Mask R-CNN // Proceedings of the IEEE International Conference on Computer Vision (ICCV). Venice, Italy, 2017. P. 2980–2988. DOI:10.1109/ICCV.2017.322.
 17. Paletta Q., Terrén-Serrano G., Nie Y., et al. Advances in solar forecasting: Computer vision with deep learning // Advances in Applied Energy. 2023. Vol. 11. 100150. DOI:10.1016/j.adapen.2023.100150.
 18. Talaat F.M., ZainEldin H. An improved fire detection approach based on YOLO-v8 for smart cities // Neural Comput & Applic. 2023. Vol. 35. P. 20939–20954. DOI:10.1007/s00521-023-08809-1.
 19. Липилин Д.А., Евтушенко Д.Д. Оценка качества городской среды с применением геоинформационных систем на примере микрорайонов города Краснодара // Геология и геофизика Юга России. 2022. Т. 12. № 3. С. 195–210. DOI:10.46698/VNC.2022.72.93.013.
 20. Pogorelov A.V., Laguta A.A., Natrebin P.B., et al. Analysis of the bottom topography of the reservoir due to sediment trapping (according to the Krasnodar reservoir, Russia) // Geography, Environment, Sustainability. 2023. Vol. 16. No. 3. P. 102–112.
 21. Chengjun Chen, Chunlin Zhang, Jinlei Wang, et al. Semantic segmentation of mechanical assembly using selective kernel convolution UNet with fully connected conditional random field // Measurement. 2023. Vol. 209. 112499. DOI:10.1016/j.measurement.2023.112499.

АВТОРЫ Гуря Дмитрий Андреевич

ФГБОУ ВО «Кубанский государственный аграрный университет имени И.Т. Трубилина»,
Краснодар, Россия;
ФГБОУ ВО «Кубанский государственный технологический университет» (КубГТУ),
Краснодар, Россия
кафедра кадастра и геоинженерии, Институт строительства и транспортной
инфраструктуры
канд. техн. наук, доцент
 0000-0002-2748-9622

Дьяченко Роман Александрович

✉ djachenko.roman@kubstu.ru
ФГАОУ ВО «Московский физико-технический институт (национальный
исследовательский университет)», Москва, Россия;
ФГБОУ ВО «Кубанский государственный технологический университет» (КубГТУ),
Краснодар, Россия
кафедра автоматизации производственных процессов, Институт компьютерных
систем и информационной безопасности
д-р техн. наук, профессор
 0000-0003-1244-1228

Барышева Алиса Михайловна

✉ alisa_barysheva03@mail.ru
ФГБОУ ВО «Кубанский государственный технологический университет» (КубГТУ),
Краснодар, Россия
кафедра информационных систем и программирования, Институт компьютерных
систем и информационной безопасности
 0009-0006-6163-0171

Коломыцев Арсений Александрович

✉ mills@inbox.ru

ФГБОУ ВО «Кубанский государственный технологический университет» (КубГТУ),

Краснодар, Россия

кафедра кадастра и геоинженерии, Институт строительства и транспортной

инфраструктуры

🆔 0000-0002-7981-0895

Довгаль Владислав Витальевич

✉ d.vlad.recom@gmail.com

ФГБОУ ВО «Кубанский государственный технологический университет» (КубГТУ),

Краснодар, Россия

кафедра информационных систем и программирования, Институт компьютерных

систем и информационной безопасности

🆔 0000-0003-1046-3335

Поступила 04.12.2024. Принята к публикации 23.04.2025. Опубликовано 30.04.2025.



Selection of the optimal method for identifying agricultural land using neural networks

**Dmitry A. Gura^{1,2}✉, Roman A. Dyachenko^{1,3}, Alisa M. Barysheva¹,
Arseny A. Kolomytsev¹, Vladislav V. Dovgal¹**

¹ Kuban State Technological University, Krasnodar, Russia

² Kuban State Agrarian University, Krasnodar, Russia

³ Moscow Institute of Physics and Technology (National Research University),
Moscow, Russia

✉ gda-kuban@mail.ru

CITATION Gura DA, Dyachenko RA, Barysheva AM, Kolomytsev AA, Dovgal VV. Selection of the optimal method for identifying agricultural land using neural networks. *Izvestia vuzov. Geodesy and Aerophotosurveying*. 2025;69(2): 124–138. DOI:10.30533/GiA-2025-029.

KEYWORDS agricultural land plots, land plot identification, vineyards, neural networks (NN/ANN), image detection, artificial intelligence, Mask R-CNN, YOLOv8, YOLOv5, metrics, mAP, Precision, Recall

ABSTRACT The article presents the results of a study on the selection of an optimal neural network for identifying agricultural land plots, illustrated with vineyards, for updating the state agricultural land registry. The primary goal of the inventory is to detect any inconsistencies between the federal vineyard registry data and the vineyards' current condition. For the experiments, the YOLOv5, YOLOv8, and Mask R-CNN neural networks were selected as the most commonly used for the purposes of recognizing objects in images. Neural networks offer advanced methods of image analysis that can be used for automated identification of vineyards on agricultural land. Their performance in the detection task was determined by calculating the Precision, Recall, and mAP metrics on a validation data set. The results of the comparison of the YOLOv5, YOLOv8, and Mask R-CNN models are presented in the table, which can be used to track their effectiveness. A comparison of the models showed that for a set of agricultural land plot images with vineyards, the YOLOv5 model may be preferable for tasks that require gradual improvement with an increasing number of epochs, while Mask R-CNN provides consistent high results even with a small number of epochs. YOLOv8 lags significantly in all metrics, especially in the early stages, and demonstrates the lowest overall performance.

REFERENCES

1. Kuznetsov PN, Kotelnikov DYU. Avtomatizirovannyj tehnologicheskij kompleks monitoringa i diagnostiki vinogradnikov [Automated technological complex for monitoring and diagnostics of vineyards]. *Bulletin of agrarian science of the Don*. 2021;4(56): 16–23. (In Russian).
2. Studenkova NA, Dobrotvorskaya NI. Sovremennye problemy inventarizacii i kadaastrovogo ucheta zemel' sel'skhozajstvennogo naznachenija [Modern problems of inventory and cadastral registration of agricultural lands]. *Interexpo GEO-Siberia*. 2021;3(2): 198–204. (In Russian). DOI:10.33764/2618-981X-2021-3-2-198-204.
3. Kuznetsov PN, Kotelnikov DYU, Voronin DYU. Nejrosetevoe avtomatizirovannoe detektirovanie priznakov uhudshenija sostojanija vinogradnyh nasazhdenij [Neural network automated detection of signs of deterioration of grape plantations]. *Problems of scientific thought*. 2023;2(8): 48–55. (In Russian).
4. Kuznetsov PN, Kotelnikov DYU, Voronin DYU. Tehnologija avtomatizirovannogo monitoringa sostojanija vinogradnika. *Agrarian science*. 2023;3: 109–116. (In Russian). DOI:10.32634/0869-8155-2023-368-3-109-116.
5. Wang T, Gan VJ. Automated joint 3D reconstruction and visual inspection for buildings using computer vision and transfer learning. *Automation in Construction*. 2023;149: 104810. DOI:10.1016/j.autcon.2023.104810.
6. Gura DA, Markovsky IG, Pshidatok SK. Metodika monitoringa ob'ektov nedvizhimosti s pomoshh'ju trehmernogo lazernogo skanirovanija v specifikke gorodskih zemel' [Methodology for monitoring real estate objects using three-dimensional laser scanning in the specifics of urban lands]. *Geodesy and Cartography*. 2021;82(4): 45–53. (In Russian). DOI:10.22389/0016-7126-2021-970-4-45-53.
7. Dhanya VG, Subeesh A, Kushwaha NL, et al. Deep learning-based computer vision approaches for smart agricultural applications. *Artificial Intelligence in Agriculture*. 2022;6: 211–229. DOI:10.1016/j.aiia.2022.09.007.
8. Dyachenko RA, Dovgal VV, Gura DA. K voprosu sravnenija jeffektivnosti nejronnyh setej YOLOv8 i U-Net v zadachah segmentacii territorial'nyh ob'ektov [On the issue of comparing the efficiency of YOLOv8 and U-Net neural networks in the tasks of segmentation of territorial objects]. *Information technologies*. 2024;30(9): 480–485. (In Russian). DOI:10.17587/it.30.480-485.
9. Antyufeev VV, Ryabov VA. Opyt agroklimatologicheskogo obosnovanija proektov plodovyh nasazhdenij v Severnom Prichernomor'e v jepohu global'nogo poteplenija [Experience of agroklimatological substantiation of fruit planting projects in the northern Black Sea region in the era of global warming]. *Bulletin of the Orenburg State Agrarian University*. 2017;4(66): 252–256. (In Russian).
10. Filonova MA, Khoroshko MB. Primenenie sredstv mashinnogo zrenija v vinogradnyh hozhajstvah: podgotovka dannyh i obuchenie modeli [Application of machine vision tools in vineyards: data preparation and model training]. *Management of large systems: collection of scientific papers of the XIX All-Russian school-conference of young scientists (Voronezh, September 5–8, 2023)*. Voronezh: VSTU; 2023: 417–424. (In Russian).
11. Krizhevsky A, Sutskever I, Hinton GE. ImageNet Classification with Deep Convolutional Neural Networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems (Lake Tahoe, Nevada, Dec. 2012)*. 2012;1: 1097–1105.
12. Wang CY, Bochkovskiy A, Liao HYM. CSPNet: A new backbone that can enhance learning capability of CNN. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. Seattle, WA, USA; 2020: 1571–1580. DOI:10.1109/CVPRW50498.2020.00203.
13. Liu S, Qi L, Qin H, et al. Path Aggregation Network for Instance Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, UT, USA; 2018: 8759–8768. DOI:10.1109/CVPR.2018.00913.
14. Ren S, He K, Girshick R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence (June 1, 2017)*. 2017;39(6): 1137–1149. DOI:10.1109/TPAMI.2016.2577031.
15. Girshick R. Fast R-CNN. *Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*. Santiago, Chile; 2015: 1440–1448. DOI:10.1109/ICCV.2015.169.
16. He K, Gkioxari G, Dollár P, et al. Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. Venice, Italy; 2017: 2980–2988. DOI:10.1109/ICCV.2017.322.

17. Paletta Q, Terrén-Serrano G, Nie Y, et al. Advances in solar forecasting: Computer vision with deep learning. *Advances in Applied Energy*. 2023;11: 100150. DOI:10.1016/j.adapen.2023.100150.
18. Talaat FM, ZainEldin H. An improved fire detection approach based on YOLO-v8 for smart cities. *Neural Comput & Applic*. 2023;35: 20939–20954. DOI:10.1007/s00521-023-08809-1.
19. Lipilin DA, Evtushenko DD. Ocenka kachestva gorodskoj sredy s primeneniem geoinformacionnyh sistem na primere mikrorajonov goroda Krasnodara [Assessment of the quality of the urban environment using geographic information systems on the example of microdistricts of the city of Krasnodar]. *Geology and Geophysics of the South of Russia*. 2022;12(3): 195–210. (In Russian). DOI:10.46698/VNC.2022.72.93.013.
20. Pogorelov AV, Laguta AA, Natrebin PB, et al. Analysis of the bottom topography of the reservoir due to sediment trapping (according to the Krasnodar reservoir, Russia). *Geography, Environment, Sustainability*. 2023;16(3): 102–112.
21. Chengjun Chen, Chunlin Zhang, Jinlei Wang, et al. Semantic segmentation of mechanical assembly using selective kernel convolution UNet with fully connected conditional random field. *Measurement*. 2023; 209: 112499. DOI:10.1016/j.measurement.2023.112499.

AUTHORS Dmitry A. Gura

Kuban State Agrarian University named after I.T. Trubilin, Krasnodar, Russia;
 Kuban State Technological University, Krasnodar, Russia
 Department of Cadastre and Geoengineering, Institute of Construction and Transport Infrastructure
 PhD in Engineering, Associate Professor
 0000-0002-2748-9622

Roman A. Dyachenko

 djachenko.roman@kubstu.ru
 Moscow Institute of Physics and Technology (National Research University), Moscow, Russia;
 Kuban State Technological University, Krasnodar, Russia
 Department of Industrial Process Automation, Institute of Computer Systems and Information Security
 Dr. of Sci. (Engineering), Professor
 0000-0003-1244-1228

Alisa M. Barysheva

 alisa_barysheva03@mail.ru
 Kuban State Technological University, Krasnodar, Russia
 Department of Information Systems and Programming, Institute of Computer Systems and Information Security
 0009-0006-6163-0171

Arseny A. Kolomytsev

 mills@inbox.ru
 Kuban State Technological University, Krasnodar, Russia
 Department of Cadastre and Geoengineering, Institute of Construction and Transport Infrastructure
 0000-0002-7981-0895

Vladislav V. Dovgal

 d.vlad.recom@gmail.com
 Kuban State Technological University, Krasnodar, Russia
 Department of Information Systems and Programming, Institute of Computer Systems and Information Security
 0000-0003-1046-3335

Submitted: December 04, 2024. Accepted: April 23, 2025. Published: April 30, 2025.