

**Е.Г. Хитров, А.В. Андронов, А.С. Сухов, В.С. Никонов,
С.С. Петросян, В.Е. Божбов**

ИЗУЧЕНИЕ ВОЗМОЖНОСТЕЙ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ ОПРЕДЕЛЕНИЯ ОБОСОБЛЕННЫХ ПРЕПЯТСТВИЙ НА ГРУНТОВЫХ ЛЕСНЫХ ДОРОГАХ

Введение. Методы технического и компьютерного зрения (Computer Vision, CV) активно развиваются и находят все более широкое применение в различных гражданских областях промышленности. Инструменты CV используются в дефектоскопии и при определении качества продукции, такой как конструкционные материалы и изделия из древесины, предназначенной для деревянного домостроения и мебельного производства [Wang, Li et al., 2023; Wang, Liang et al., 2023; Wang et al., 2024; Han et al., 2023]. Возможное применение CV в лесоперерабатывающем комплексе и лесном хозяйстве не ограничивается лишь вопросами деревопереработки. Например, известны исследования [Shevtekar, 2024; Mohan Prakash&SrihariPriya, 2022], посвященные автоматическому распознаванию дефектов дорожных покрытий. Такие решения потенциально могут, после доработки, использоваться для повышения профильной проходимости и безопасности движения лесных и лесотранспортных машин за счет оперативного распознавания обособленных препятствий в виде корней, пней, кочек, ям и проч., встречающихся на пути лесной техники.

Современные модели CV распространяются с открытым исходным кодом [YOLOv8 Docs, 2024], со свободной лицензией для использования в научных целях, что является положительным моментом с точки зрения исследований и, далее, практики. С другой стороны, модели отличаются большим числом параметров (весов, рис. 1 по [YOLOv8 Docs, 2024]), а процесс их подбора (обучения моделей) [YOLOv8 Docs, 2024] и настройки для решения конкретной производственной задачи связан с ресурсоемкими компьютерными и вычислительными экспериментами [Hutter et al., 2019]. Результат эксперимента во многом определяется выбором стека методов эксперимента и гиперпараметров процесса обучения, а также качеством исходных данных.

К настоящему времени не представлено систематизированных результатов по использованию инструментов CV для выявления обособленных

препятствий на лесных дорогах, также не изложена методика эксперимента в указанной области.

Цель работы: апробация методики эксперимента и изучение возможностей инструментов компьютерного зрения для распознавания обособленных препятствий на лесных грунтовых дорогах.

Материалы и методы исследования. Для апробации методики эксперимента, ввиду ограниченного объема данных, на настоящем этапе исследований использован метод «zero-shot learning». Метод предполагает тестирование предобученной модели на данных из непосредственно предметной области [Hutter et al., 2019].

Эксперименты в работе проведены для различных версий предобученной искусственной нейронной сети (ИНС) YOLO: YOLOv8n.pt, YOLOv8s.pt, YOLOv8m.pt, YOLOv8l.pt. На рис. 1 для справки к последующим разработкам приведены сведения поставщика [YOLOv8 Docs, 2024] о числе весов различных моделей ИНС, включая версии 9-го и 10-го поколения.

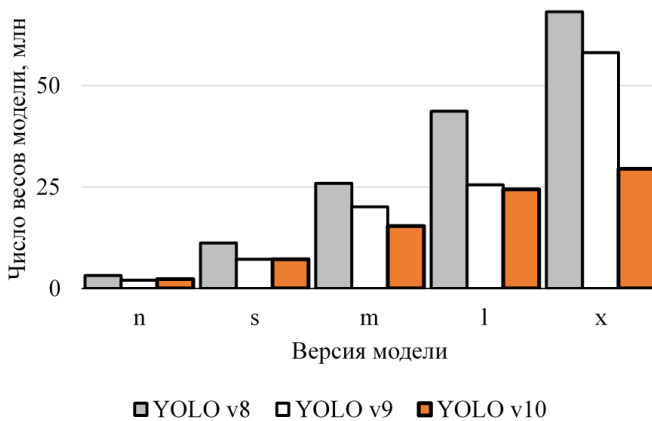


Рис. 1. Число весов различных версий ИНС YOLO
 Fig. 1. Various versions of YOLO ANN weights amount

Для повышения качества работы модели ИНС были дообучены на выборке данных [RDD2022 Dataset], содержащей цифровые снимки дефектов асфальтированных дорог. Снимки сопровождаются аннотациями с указанием областей, в которых экспертным путем выявлены дефекты дорожного покрытия. Обучающая выборка содержит 6962 снимка с разрешением 640×640 pсs. Выборка снимков, использованная при валидации моделей в

процессе дообучения, состоит из 271 аннотированного изображения. Для тестирования моделей использованы материалы, собранные авторами работы самостоятельно в полевых условиях.

Вычисления в процессе дообучения моделей и их тестирования проведены на стенде с параметрами, указанными в табл. 1. Программная часть подготовлена на языке Python, фреймворк Pytorch.

Таблица 1

Сведения об аппаратной и программной части экспериментального стенда

Experimental hardware and software setup

| Наименование | Характеристика |
|-----------------------|----------------------------------|
| Центральный процессор | Intel Core i7-12700KF 3,60 GHz |
| Графический процессор | NVIDIA GeForce RTX 4060 Ti 16 ГБ |
| Оперативная память | 32 ГБ DDR4 3200 МГц |
| Жесткий диск | 1 ТБ SSD NVMe |
| Материнская плата | ASUS ROG Strix Z590-E |
| Операционная система | Windows 10 22H2 |
| Версия Python | 3.11.7 |
| Версия CUDA | 11.1 |
| Версия PyTorch | 2.3.1 |

Для эксперимента использованы следующие гиперпараметры процесса дообучения: снимки масштабированы до разрешения 1280×1280 pсs (параметр $imgsz = 1280$), численный метод оптимизации при подборе весов моделей – Adam ($optimizer = Adam$), шаг численного метода 0,00001 ($lr = 0.00001$) с последующим уменьшением в 100 раз на завершающих итерациях процесса дообучения ($lrf = 0.01$), число эпох обучения модели (связано с числом итераций при реализации численной оптимизации весов) 100 ($epoch = 100$). Прочие гиперпараметры приняты по умолчанию в соответствии с документацией [YOLOv8 Docs, 2024].

В качестве оценок результативности дообучения моделей использованы стандартные метрики, связанные с функциями потерь при сегментации дефектов (box_loss) и классификации (cls_loss), точности ($precision, P$), полноты ($recall, R$) и усредненного значения точности ($mean\ average\ precision, mAP$). При тестировании моделей программными средствами поставщика измерено среднее время сегментации и классификации дефекта ($inference$) и выполнена экспертная оценка качества работы моделей на авторских данных.

Результаты исследования. На рис. 2 показана динамика функций потерь `box_loss` и `cls_loss` по мере дообучения моделей ИНС. Обратим внимание, что на завершающих эпохах дообучения ($\text{epoch} \geq 90$) для версий YOLOv8s, YOLOv8m, YOLOv8l не отмечается существенного изменения функций потерь, несмотря на уменьшение шага метода численной оптимизации ($\text{lr} = \text{lrf} \cdot \text{lr}_0 = 0,01 \cdot \text{lr}_0$); для модели YOLOv8n отмечается некоторое увеличение значений функций.

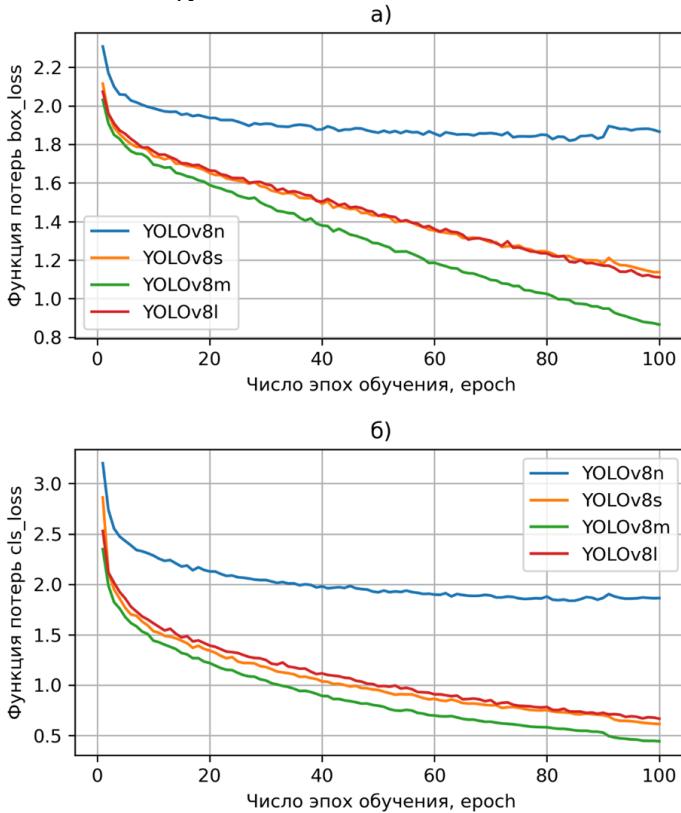


Рис. 2. Метрики качества определения области (а) и классификации (б) дефекта при дообучении моделей

Fig. 2. Segmentation (a) and classification (b) metrics scored during the models training

Экспериментальные данные, таким образом, показывают, что гиперпараметры скорости обучения lr_0 , lrf для метода Adam в данном случае подобраны рационально, дальнейшее уменьшение шага метода едва ли целе-

сообразно. Обратим внимание, что за выполненное число итераций лучшие результаты показала модель YOLOv8m.pt с числом весов меньшим, чем у версии YOLOv8l.pt (см. рис. 1); при этом функция потерь `box_loss`, связанная с качеством сегментации дефектов, убывает с большей скоростью, что видно по наклону условной линии тренда на рис. 2,а). Версия YOLOv8n.pt, с наименьшим числом весов среди рассмотренных моделей, отличается заметно худшими показателями.

На рис. 3 приведены результаты измерения метрик точности P и полноты R определения дефектов при обработке изображений из валидационной выборки данных.

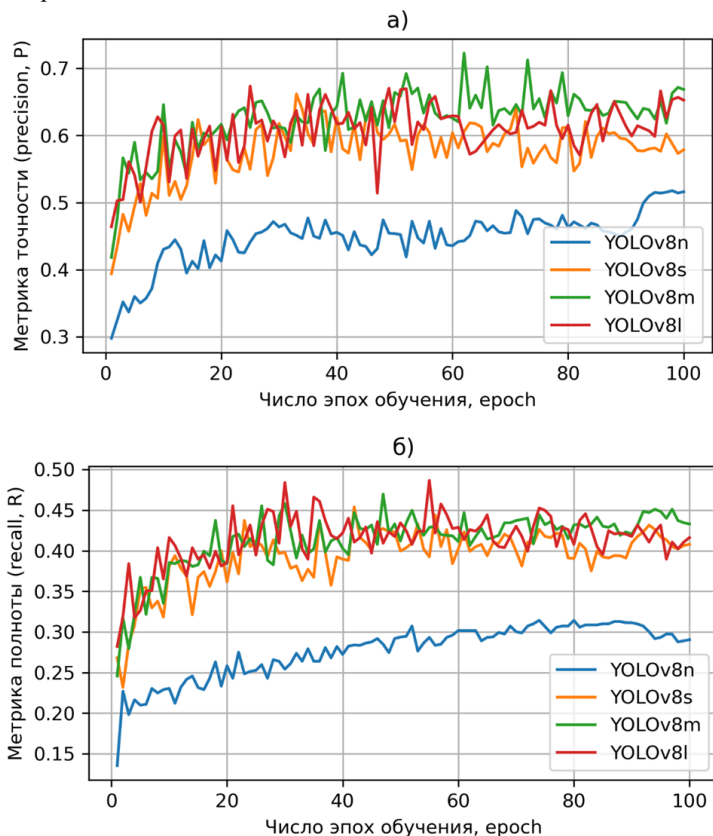


Рис. 3. Метрики точности (а) и полноты (б) распознавания дефектов при дообучении моделей

Fig. 3. Precision (a) and recall (b) metrics scored during the models training

Как и в случае с функциями потерь, в исследуемой задаче версия YOLOv8n.pt справляется с распознаванием дефектов дорожного покрытия хуже прочих рассмотренных. Версии ИНС YOLOv8s.pt, YOLOv8m.pt и YOLOv8l.pt показывают близкие друг к другу результаты, для версии YOLOv8m.pt можем отметить чуть более высокие оценки полноты и точности.

Результаты оценки моделей при валидации приведены на рис. 4.

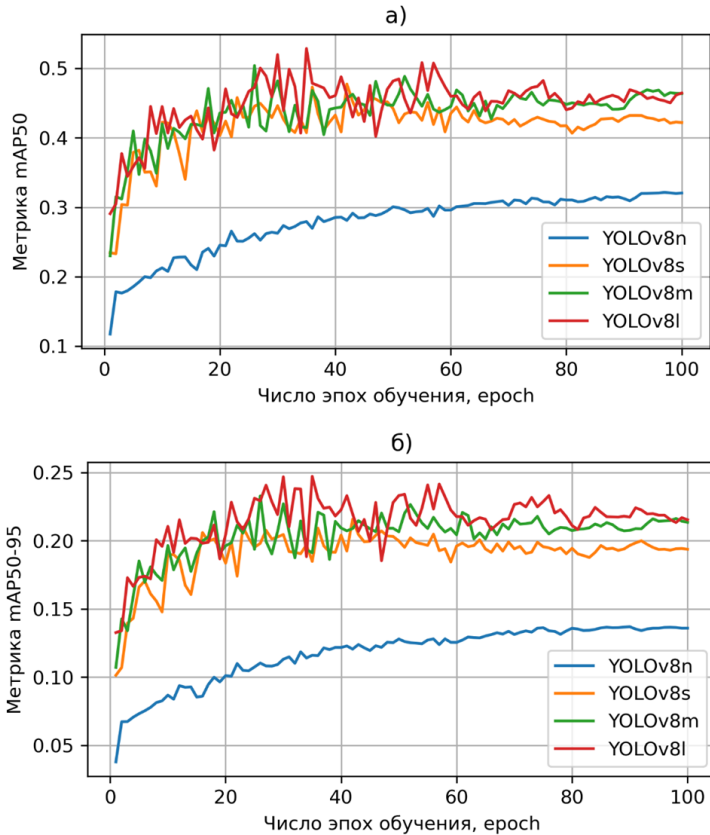


Рис. 4. Метрики усредненной точности mAP50 (а) и mAP50-95 (б) распознавания дефектов при валидации дообученных моделей

Fig. 4. Mean average precision mAP50 (a) and mAP50-95 (b) metrics scored during the models validation

В целом, тенденции, отмеченные при оценке моделей по мере дообучения на тренировочной выборке, сохраняются; несколько лучшие результаты достигаются моделью YOLOv8l.pt.

Функции потерь `box_loss` и `cls_loss` для рассматриваемых моделей при валидации приведены в виде графиков на рис. 5.

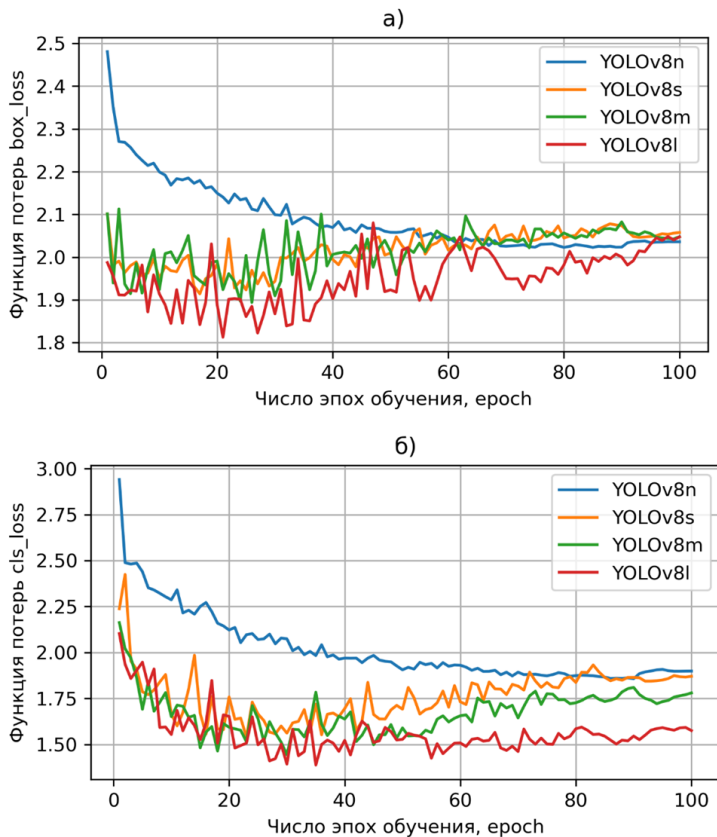


Рис. 5. Метрики качества определения области (а) и классификации (б) дефекта при валидации дообученных моделей

Fig. 5. Precision (a) and recall (b) metrics scored during the models validation

Можем заметить, что для модели YOLOv8n.pt отмечается стабильное снижение значений функций `box_loss` и `cls_loss`, а для модели YOLOv8l.pt при валидации, практически с самого начала дообучения, значения функ-

ций изменяются в сравнительно узком диапазоне. Таким образом, для двух указанных моделей не выявлено явления переобучения [Hutter et al., 2019] и значение гиперпараметра-регуляризатора $\text{weight_decay} = 0.0005$, принятое по умолчанию, не нуждается в корректировке. Для моделей YOLOv8s.pt и YOLOv8m.pt можем отметить некоторое увеличение функций box_loss , cls_loss при числе эпох $\text{epoch} \geq 50$, что, возможно, указывает на переобучение моделей; вопрос о настройке параметра регуляризации является предметом дальнейших исследований.

В табл. 2 приведены результаты оценки качества работы моделей, полученные при обработке изображений из всего набора данных (6976 + 271 изображение).

Таблица 2

Оценка моделей при обработке набора данных

Models performance during data set processing

| Модель | P | R | mAP50 | mAP50-95 | Время обработки одного дефекта на снимке, мс |
|---------|-------|-------|-------|----------|----------------------------------------------|
| YOLOv8n | 0,616 | 0,486 | 0,538 | 0,258 | 6,9 |
| YOLOv8s | 0,932 | 0,871 | 0,937 | 0,664 | 25,4 |
| YOLOv8m | 0,963 | 0,911 | 0,964 | 0,763 | 34,8 |
| YOLOv8l | 0,965 | 0,907 | 0,962 | 0,779 | 55,3 |

Проведенный эксперимент с набором данных [RDD2022 Dataset] показал, что модели ИНС YOLOv8.pt позволяют получить метрики качества распознавания выше либо сопоставимые с результатами, полученными в [Shevtekar, 2024; Mohan Prakash&Sriharipriya, 2022] при обучении моделей YOLO с использованием набора данных [Pothole Dataset], существенно меньшего по объему (400 снимков). Это обстоятельство показывает, что подготовленный экспериментальный стенд позволяет получать стабильные результаты и косвенно свидетельствует в пользу предположения, что модели YOLOv8.pt, дообученные с использованием [RDD2022 Dataset], результативны при сегментации и классификации дефектов дорог при тестировании.

Важно учесть скорость обработки дефектов, представленных на снимках: для моделей YOLOv8s и YOLOv8m оно составляет в среднем соответственно 25,4 и 34,8 мс для одного дефекта. Поскольку существенных различий в качестве работы моделей YOLOv8s.pt, YOLOv8m.pt, YOLOv8l.pt в эксперименте установлено не было, на настоящем этапе исследований мо-

жем рекомендовать модель ИНС YOLOv8m.pt в качестве перспективной версии для разработки технического решения по распознаванию одиночных препятствий на лесных дорогах; при этом следует дополнительно рассмотреть вопрос регуляризации весов модели (рис. 5).

В табл. 3 приведены результаты оценки моделей при тестировании, претендующие, на настоящем этапе, лишь на справочный характер ввиду ограниченного объема тестовой выборки данных (327 снимков грунтовых лесных дорог с 791 дефектом в виде ям).

Таблица 3

Результаты тестирования моделей

Results of YOLOv8m.pt model testing

| Модель | P | R | mAP50 | mAP50-95 | Время обработки одного дефекта на снимке, мс |
|---------|-------|-------|-------|----------|----------------------------------------------|
| YOLOv8n | 0,599 | 0,865 | 0,377 | 0,174 | 1,1 |
| YOLOv8s | 0,665 | 0,450 | 0,502 | 0,277 | 12,9 |
| YOLOv8m | 0,720 | 0,490 | 0,543 | 0,304 | 28,2 |
| YOLOv8l | 0,636 | 0,481 | 0,527 | 0,304 | 95,3 |

В целом, результаты тестирования подтверждают наши предварительные выводы о перспективности версии YOLOv8m.pt в качестве основы технического решения для определения обособленных препятствий, встречающихся на лесных дорогах. Дообученная модель способна определять обособленные препятствия в виде ям на лесных и грунтовых дорогах с приемлемой точностью. Пример результатов распознавания приведен на рис. 6.



Рис. 6. Пример распознавания препятствий в виде ям (YOLOv8m.pt)

Fig. 6. Obstacles recognition example (YOLOv8m.pt)

Выполненная нами экспертная оценка качества работы модели при тестирования повторяет предположения, сделанные выше. Дальнейшие разработки должны быть направлены на настройку модели и ее дообучение с использованием большего количества данных по обособленным препятствиям, встречающимся на лесных дорогах.

Заключение. В исследовании выполнена апробация методики эксперимента по изучению возможностей инструментов компьютерного зрения для последующего распознавания обособленных препятствий на лесных грунтовых дорогах. Установлено, что выбранные гиперпараметры процесса дообучения моделей ИНС YOLOv8n.pt, YOLOv8s.pt, YOLOv8m.pt, YOLOv8l.pt на большом наборе данных [RDD2022 Dataset] и стенд позволяют получать стабильные экспериментальные сведения по распознаванию и классификации дефектов дорог. Численный метод оптимизации Adam при дообучении с шагом минимизации 0,00001 целесообразно использовать и в дальнейшем.

В целом, тестирование и экспертная оценка результатов подтверждают предварительные выводы о перспективности версии YOLOv8m.pt в качестве основы технического решения для определения обособленных препятствий, встречающихся на лесных дорогах.

Таким образом, на настоящем этапе исследований в качестве перспективной версии для разработки технического решения по распознаванию одиночных препятствий на лесных дорогах рекомендуется модель ИНС YOLOv8m.pt (табл. 2 и 3); при этом следует дополнительно рассмотреть вопрос регуляризации весов модели (см. рис. 5).

Кроме того, в качестве направления дальнейших разработок отметим эксперименты с моделями ИНС YOLO v9, v10 для составления более полного и систематизированного научного представления о применимости моделей ИНС-трансформеров для определения обособленных препятствий на лесных дорогах. Полученные результаты, полагаем, будут способствовать накоплению научных сведений о современных моделях компьютерного зрения и машинного обучения, которые, на настоящем этапе развития области знания, рассматриваются как «черные ящики» [Hutter et al., 2019; Latour, 1987]

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Библиографический список

Han S., Jiang X., Wu Z. An Improved YOLOv5 Algorithm for Wood Defect Detection Based on Attention // IEEE Access. 2023. Vol. 11. P. 71800–71810. URL: <https://api.semanticscholar.org/CorpusID:259721127> (дата обращения: 10.08.2024).

Hutter F., Kotthoff L., Vanschoren J. (editors). *Automated Machine Learning: Methods, Systems, Challenges*. Springer, 2019. DOI: 10.1007/978-3-030-05318-5.

Latour B. *Science in Action: How to Follow Scientists and Engineers through Society*. Cambridge, MA: Harvard University Press, 1987.

Mohan Prakash B., Sriharipriya K.C. Enhanced pothole detection system using YOLOX algorithm // *Auton. Intell. Syst.* 2022. 2. 22. URL: <https://doi.org/10.1007/s43684-022-00037-z>

Pothole Dataset: Project on Realtime Potholes Detection. URL: <https://public.roboflow.com/object-detection/pothole> (дата обращения: 10.08.2024).

RDD2022 Dataset: The Multi-National Road Damage Dataset 2022. URL: <https://datasetninja.com/road-damage-detector> (дата обращения: 10.08.2024).

Shevtekar S. Enhanced Pothole Detection Using YOLOv8 Nano // *International Scientific Journal of Engineering and Management*. 2024. 03. P. 1–9. 10.55041/ISJEM01632. 2024

Wang M., Li M., Cui W., Xiang X., Duo H. TSW-YOLO-v8n: Optimization of detection algorithms for surface defects on sawn timber // *BioResources*. 2023. Vol. 18, no. 4. P. 8444–8457.

Wang R., Chen Y., Liang F., Wang B., Mou X., Zhang G. BPN-YOLO: A Novel Method for Wood Defect Detection Based on YOLOv7 // *Forests*. 2024. URL: <https://api.semanticscholar.org/CorpusID:270753559> (дата обращения: 10.08.2024).

Wang R., Liang F., Wang B., Mou X. ODCA-YOLO: An Omni-Dynamic Convolution Coordinate Attention-Based YOLO for Wood Defect Detection // *Forests*. 2023. T. 14, no. 9. 1885 p. DOI: <https://doi.org/10.3390/f14091885>.

YOLOv8 Docs: Ultralytics YOLO Docs. URL: <https://docs.ultralytics.com> (дата обращения: 10.08.2024).

References

Han S., Jiang X., Wu Z. An Improved YOLOv5 Algorithm for Wood Defect Detection Based on Attention. *IEEE Access*, 2023, vol. 11, pp. 71800–71810. URL: <https://api.semanticscholar.org/CorpusID:259721127> (accessed August 10, 2024).

Hutter F., Kotthoff L., Vanschoren J. (editors). *Automated Machine Learning: Methods, Systems, Challenges*. Springer, 2019. DOI: 10.1007/978-3-030-05318-5.

Latour B. *Science in Action: How to Follow Scientists and Engineers through Society*. Cambridge, MA: Harvard University Press, 1987.

Mohan Prakash B., Sriharipriya K.C. Enhanced pothole detection system using YOLOX algorithm. *Auton. Intell. Syst.*, 2022, 2, 22. URL: <https://doi.org/10.1007/s43684-022-00037-z>

Pothole Dataset: Project on Realtime Potholes Detection. URL: <https://public.roboflow.com/object-detection/pothole> (accessed August 10, 2024).

RDD2022 Dataset: The Multi-National Road Damage Dataset 2022. URL: <https://datasetninja.com/road-damage-detector> (accessed August 08, 2024).

Shevtekar S. Enhanced Pothole Detection Using YOLOv8 Nano. *International Scientific Journal of Engineering and Management*, 2024, 03, pp. 1–9. 10.55041/ISJEM01632. 2024

Wang M., Li M., Cui W., Xiang X., Duo H. TSW-YOLO-v8n: Optimization of detection algorithms for surface defects on sawn timber. *BioResources*, 2023, vol. 18, no. 4, pp. 8444–8457.

Wang R., Chen Y., Liang F., Wang B., Mou X., Zhang G. BPN-YOLO: A Novel Method for Wood Defect Detection Based on YOLOv7. *Forests*. 2024. URL: <https://api.semanticscholar.org/CorpusID:270753559> (access August 08, 2024).

Wang R., Liang F., Wang B., Mou X. ODCA-YOLO: An Omni-Dynamic Convolution Coordinate Attention-Based YOLO for Wood Defect Detection. *Forests*, 2023, vol. 14, no. 9, 1885 p. DOI: <https://doi.org/10.3390/f14091885>.

YOLOv8 Docs: Ultralytics YOLO Docs. URL: <https://docs.ultralytics.com> (accessed August 08, 2024).

Материал поступил в редакцию 15.06.2024

Хитров Е.Г., Андронов А.В., Сухов А.С., Никонов В.С., Петросян С.С., Божбов В.Е. Изучение возможностей компьютерного зрения для определения обособленных препятствий на грунтовых лесных дорогах // Известия Санкт-Петербургской лесотехнической академии. 2024. Вып. 250. С. 318–332. DOI: 10.21266/2079-4304.2024.250.318-332

Методы технического и компьютерного зрения активно развиваются и находят все более широкое применение в различных гражданских областях промышленности. Инструменты CV могут потенциально использоваться для повышения профильной проходимости и безопасности движения лесных и лесотранспортных машин за счет оперативного распознавания обособленных препятствий в виде корней, пней, кочек, ям и проч., встречающихся на пути лесной техники. В исследовании выполнена апробация методики эксперимента по изучению возможностей инструментов компьютерного зрения для распознавания обособленных препятствий на лесных грунтовых дорогах. Эксперименты в работе проведены для различных версий искусственной нейронной сети YOLO (YOLOv8n.pt, YOLOv8s.pt, YOLOv8m.pt, YOLOv8l.pt), дообученной на большом наборе данных Road Damage Detection 2022. Установлено, что экспериментальный стенд, включающий программную и аппаратную часть, а также подобранные гиперпараметры процесса обучения моделей позволяют получать стабильные экспериментальные сведения по распознаванию и классификации дефектов дорог, включая грунтовые и лесные. Результаты оценки моделей YOLO при дообучении и валидации показали, что в качестве перспективной версии для разработки технического решения по распознаванию одиночных препятствий на лесных дорогах можно рекомендовать модель ИНС YOLOv8m.pt; при этом следует дополнительно

рассмотреть вопрос регуляризации весов модели. Тестирование и экспертная оценка результатов подтвердили предварительные выводы о перспективности версии YOLOv8m.pt в качестве основы технического решения для определения обособленных препятствий, встречающихся на лесных дорогах. Отмечена целесообразность использования численного метода оптимизации Adam с шагом минимизации 0,00001 в дальнейших исследованиях, связанных с экспериментами с моделями искусственной нейронной сети YOLOv9, YOLOv9v10 для составления более полного и систематизированного научного представления о применимости моделей компьютерного зрения для определения обособленных препятствий на лесных дорогах.

Ключевые слова: профильная проходимость, движение лесных машин, zero-shot learning, сегментация, классификация.

Khitrov E.G., Andronov A.V., Sukhov A.S., Nikonov V.S., Petrosyan S.S., Bozhbov V.E. Study of computer vision methods for identifying obstacles on forest roads. *Izvestia Sankt-Peterburgskoj Lesotehniceskoy Akademii*, 2024, iss. 250, pp. 318–332 (in Russian with English summary). DOI: 10.21266/2079-4304.2024.250.318-332

Methods of technical and computer vision are developing and being increasingly used in various civil industries. Computer vision tools may be used to improve passability and traffic safety of forest machinery by promptly recognizing isolated obstacles in the form of roots, stumps, hummocks, potholes, etc. The study tested methodology of an experiment to study capabilities of computer vision tools for recognizing isolated obstacles on forest roads. The experiments in were carried out for various versions of the YOLO artificial neural network (YOLOv8n.pt, YOLOv8s.pt, YOLOv8m.pt, YOLOv8l.pt), retrained on a large dataset of Road Damage Detection 2022. It was found that the experimental setup, including software and hardware, as well as the selected hyperparameters of the model training process, make it possible to obtain stable experimental data on the recognition and classification of road defects, including forest ones. The results of scoring the YOLO models during retraining and validation showed that the YOLOv8m.pt artificial neural network model should be recommended as a promising version for developing a technical solution for recognizing single obstacles on forest roads; however, the issue of regularizing the model weights should be additionally considered. Testing and expert evaluation of the results confirmed the preliminary conclusions about the promise of the YOLOv8m.pt version as basis for the technical solution. The expediency of using the numerical optimization method Adam with a minimization step of 0.00001 in further studies related to experiments with the models of the artificial neural network YOLOv9, YOLOv9v10 is noted for the purpose of compiling a more complete and systematic scientific understanding of the applicability of computer vision models for identifying isolated obstacles on forest roads.

Keywords: profile passability, forest machinery locomotion, zero-shot learning, segmentation, classification.

ХИТРОВ Егор Германович – доцент высшей школы программной инженерии Санкт-Петербургского политехнического университета Петра Великого, доктор технических наук. SPIN-код: 4663-5944, ORCID: 0000-0003-4569-9508.

195251, ул. Политехническая, д. 29, Санкт-Петербург, Россия. E-mail: hitrov_eg@spbstu.ru

KHITROV Egor G. – DSc (Technical), Associate Professor of the Higher School of Software Engineering of Peter the Great St. Petersburg Polytechnic University, Associate Professor. SPIN-code: 4663-5944, ORCID: 0000-0003-4569-9508.

195251. Politekhnikeskaya str. 29. St. Petersburg. Russia. E-mail: hitrov_eg@spbstu.ru

АНДРОНОВ Александр Вячеславович – доцент кафедры лесного машиностроения, сервиса и ремонта Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова, кандидат технических наук, доцент. SPIN-код: 8345-3722, ORCID: 0000-0002-1035-9231.

194021, Институтский пер., д. 5У, Санкт-Петербург, Россия. E-mail: andronovalexandr@gmail.com

ANDRONOV Aleksandr V. – PhD (Technical), Associate Professor of the Department of Forestry Machinery, Service and Repair of St.Petersburg State Forest Technical University. SPIN-code: 8345-3722, ORCID: <https://orcid.org/0000-0002-1035-9231>.

194021. Institutsky per. 5U. St. Petersburg. Russia. E-mail: andronovalexandr@gmail.com

СУХОВ Артем Сергеевич – магистрант научно-образовательного центра математики ФГАОУ ВО «Национальный исследовательский университет ИТМО». ORCID: 0009-0002-2674-3884.

197101, Кронверкский пр., д. 49, Санкт-Петербург, Россия. E-mail: sukhovtema@gmail.com

SUKHOV Artem S. – Master's student of the Scientific and Educational Center of Mathematics of the National Research University ITMO. ORCID: 0009-0002-2674-3884.

197101. Kronverkskii av. 49. St. Petersburg. Russia. E-mail: sukhovtema@gmail.com

НИКОНОВ Виталий Сергеевич – аспирант кафедры лесного машиностроения, сервиса и ремонта Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова.

194021, Институтский пер., д. 5У, Санкт-Петербург, Россия. E-mail: nikonov99@outlook.com

NIKONOV Vitaliy S. – PhD student of the Department of Forestry Machinery, Service and Repair of the St.Petersburg State Forest Technical University.

194021. Institutsky per. 5U. St. Petersburg. Russia. E-mail: nikonov99@outlook.com

ПЕТРОСЯН Сурен Сергеевич – аспирант кафедры автоматизации, метрологии и управления в технических системах Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова. ORCID: <https://orcid.org/0009-0007-6224-9900>.

194021, Институтский пер., д. 5У, Санкт-Петербург, Россия. E-mail: surik1622@gmail.com

PETROSYAN Suren S. – PhD student of the Department of Automation, Metrology and Management in Technical Systems of the St.Petersburg State Forest Technical University. ORCID: <https://orcid.org/0009-0007-6224-9900>. 194021,

194021. Institutsky per. 5U. St. Petersburg. Russia. E-mail: surik1622@gmail.com

БОЖБОВ Владимир Евгеньевич – доцент кафедры геодезии, землеустройства и кадастров Санкт-Петербургского государственного лесотехнического университета имени С.М. Кирова, кандидат технических наук. SPIN-код: 1820-4686, ORCID: 0000-0003-0881-2911

194021, Институтский пер., д. 5У, Санкт-Петербург, Россия. E-mail: v-b@mail.ru

BOZHBOV Vladimir E. – PhD (Technical), Associate Professor of the Department of Geodesy, Land Management and Cadastre of the St.Petersburg State Forest Technical University. SPIN-code: 1820-4686, ORCID: 0000-0003-0881-2911.

194021. Institutsky per. 5U. St. Petersburg. Russia. E-mail: v-b@mail.ru