

УДК 004.896

DOI: [10.26102/2310-6018/2024.46.3.019](https://doi.org/10.26102/2310-6018/2024.46.3.019)

Особенности применения методов глубокого обучения для обнаружения небольших объектов на видео в условиях дождя

С.Е. Штехин, А.В. Стадник✉

*«Отраслевой центр разработки и внедрения информационных систем» Сириус,
филиал № 11, Сочи, Российская Федерация*

Резюме. В данной работе рассматриваются методы детектирования объектов небольшого размера на видео, при проведении распознавании технологических операций ручного труда, которые проходят вне помещений, на открытом воздухе и подвержены влиянию погодных условий. Рассмотрены подходы для улучшения точности детектирования таких объектов при неблагоприятных погодных условиях, таких как дождь. В данной работе был исследован двухэтапный подход. На первом этапе методами компьютерного зрения, такими методами глубокого обучения, как сверточные нейросети, производится выявление и классификация различных погодных условий на видео. На втором этапе, при обнаружении неблагоприятных погодных условий, проводится исследование различных методов глубокого обучения для фильтрация погодных условий на видео. Основное внимание уделено оценке влияния различных методов фильтрации на точность детектирования объектов небольшого размера. В работе рассмотрен вопрос применимости данного подхода для детектирования небольших инструментов на видеоданных, при распознавании технологических операций ручного труда, выполняемых при ремонте и обслуживании железнодорожного пути. Полученные результаты могут быть полезны при исследовании трудовых процессов, происходящих вне помещений, в алгоритмах распознавания технологических операций ручного труда на видеоданных.

Ключевые слова: глубокое обучение, трансформер, детектирование объектов, распознавание погодных условий на видео, фильтрация погодных условий, фильтрация шума на изображении, нейронные сети, технологические операции.

Для цитирования: Штехин С.Е., Стадник А.В. Особенности применения методов глубокого обучения для обнаружения небольших объектов на видео в условиях дождя. *Моделирование, оптимизация и информационные технологии.* 2024;12(3). URL: <https://moitvvt.ru/ru/journal/pdf?id=1640> DOI: 10.26102/2310-6018/2024.46.3.019

Features of application of deep learning methods for detection of small objects in rain video

S.E. Shtekhin, A.V. Stadnik✉

*"Industry center for the development and implementation of information systems" Sirius,
branch No. 11, Sochi, the Russian Federation*

Abstract. This paper discusses methods for detecting small objects in video when recognizing manual labor operations that take place outdoors, in the open air, and are affected by weather conditions. Approaches to improve the accuracy of detecting such objects in adverse weather conditions, such as rain, are considered. This paper explores a two-stage approach. At the first stage, computer vision methods and deep learning methods such as convolutional neural networks are used to identify and classify various weather conditions in video. At the second stage, when adverse weather conditions are detected, a study is conducted of various deep learning methods for filtering weather conditions in video. The main focus is on assessing the impact of various filtering methods on the accuracy of detecting small objects. The paper considers the applicability of this approach to detecting small tools in video data when recognizing manual labor operations performed during repair and maintenance of a railway

track. The obtained results can be useful in the study of labor processes occurring outdoors, in algorithms for recognizing manual labor operations in video data.

Keywords: deep learning, transformer, object detection, recognition of weather conditions on video, filtering of weather conditions, filtering of noise in the image, neural networks, technological operations.

For citation: Shtekhin S.E., Stadnik A.V. Features of application of deep learning methods for detection of small objects in rain video. *Modeling, Optimization and Information Technology*. 2024;12(3). URL: <https://moitvivr.ru/ru/journal/pdf?id=1640> DOI: 10.26102/2310-6018/2024.46.3.019 (In Russ.).

Введение

При работах на железной дороге стоит задача определения правильного порядка последовательности технологических операций ручного труда и определения времени каждой такой операции на видеоданных. Технологические операции, выполняемые сотрудником с помощью различных инструментов, относятся к работам, выполняемым при ремонте и обслуживании железнодорожного пути.

Для решения этого класса задач необходимо детектировать объекты на изображении и классифицировать тип их взаимодействия. При распознавании технологических операций ручного труда на видео необходимо детектировать сотрудника, выполняющего операцию, инструмент и определить взаимодействие сотрудника с инструментом. Методы распознавания таких технологических операций были исследованы [1] и реализованы в цифровой системе обработки видео.

Детектирование объектов на изображении – это одна из фундаментальных задач компьютерного зрения. В этой задаче необходимо найти объект на изображении, выделить его ограничивающим прямоугольником и классифицировать этот объект. Обзор [2] описывает методы детектирования объектов за последние 20 лет, включая как традиционные методы, так и методы глубокого обучения. В последние годы задача детектирования объектов успешно решается методами глубокого обучения, от сверточных сетей до трансформеров [3].

В технологических операциях применяются различные инструменты, которые необходимо распознавать [2]. Эти инструменты имеют различный размер и видны на изображениях под различными ракурсами и разным масштабом. Поэтому стоит задача детектировать на изображении объекты различного масштаба.

Высокая точность методами глубокого обучения достигается на средних и больших объектах. Существуют различные методы для улучшения точности распознавания, например, улучшение обобщающей способности моделей за счет использования метода стилизации изображений [4].

Однако детектирование небольших объектов, размером менее 20×20 пикселей, все еще остается проблемой, требующей решения. Это область активного исследования, и в последние годы было создано множество методов глубокого обучения, которые продемонстрировали многообещающие результаты. Обзор [5] фокусируется на методах глубокого обучения для детектирования небольших объектов за последние 5 лет. Некоторые исследования подчеркнули значимость объединения различных масштабов для обнаружения объектов, в то время как другие акцентировали внимание на полезности контекстной информации. Более того, методы увеличения точности классификации, такие как устранение дисбаланса примеров внутри классов и недостаточности обучения, также показали свою эффективность.

Работы, выполняемые при ремонте и обслуживании железнодорожного пути, происходят под открытым небом, когда работы производятся непосредственно на рельсовом полотне. Система распознавания технологических операций путевого хозяйства включает в себя обнаружение различных объектов на железнодорожных

путях, что подразумевает обнаружение работников и инструментов в различных погодных условиях. Обнаружение объектов на открытом воздухе, на видеоданных, осложняется из-за таких факторов, как изменяющаяся динамическая освещённость и погодные условия.

Погодные явления, такие как дождь, могут оказывать влияние на видео во многих аспектах [6]. Вот некоторые из них:

– Потеря качества изображения: погода может влиять на качество видео, в результате чего изображение может потерять четкость и ясность. Так, во время дождя на видео появляются брызги на камере.

– Искажение световых условий: изменение освещения на видео может быть вызвано как погодными явлениями, так и изменением времени суток. Так, при ночных условиях изображение на видео может стать темнее, а при ярком солнечном свете – ярче.

– Высокочастотный шум, вносимый погодными явлениями, особенно сильно сказывается на детектировании небольших объектов. Случайные искажения или размытие границ в случайном кадре может привести к искаженной классификации или отсутствию факта детекции объекта.

В настоящее время активно применяются различные способы повышения качества изображений и видео, которые были искажены погодными условиями. Например, в работе [7] рассматриваются разнообразные методы, включая нейронные сети, для улучшения визуального качества видеоматериалов. В работе [8] авторы исследовали влияние методов фильтрации погодных условий на обнаружение объектов разного размера. Но, в отличие от этих методов, в нашем исследовании мы сосредоточились на изучении влияния методов глубокого обучения на точность обнаружения небольших объектов.

В статье [9] проводится сравнительный анализ различных нейронных сетей для обнаружения объектов в условиях дождя в контексте беспилотного транспорта. Однако в нашей работе проведено исследование влияния дождя и методов фильтрации дождя на обнаружение небольших объектов.

В технологических операциях на железнодорожном пути применяются следующие инструменты небольшого размера: гаечный ключ, отвертка, кисть, лапка специальная для подрельсовых прокладок и другие. Целью данной работы является проверка гипотезы успешного применения методов распознавания и фильтрации погодных условий для детектирования таких инструментов небольшого размера.

Материалы и методы

Для улучшения точности и устойчивости модели при обнаружении объектов на видео в плохую погоду (дождь) используются различные подходы. В данном исследовании, основное внимание уделено построению алгоритма покадрового детектирования небольших объектов, который в независимости от погодных условий, выдавал максимальную точность (Рисунок 1).

Алгоритм состоит из двух этапов: детектирование погодных условий на видео и в зависимости от того, идет ли дождь, подключение на втором этапе модуля предварительной фильтрации изображений.

Для повышения точности детектирования небольших инструментов на кадре видео важно убедиться, что на нем нет дождя. Если дождь отсутствует, то методы фильтрации погоды могут снизить точность обнаружения небольших объектов. Поэтому в предлагаемом алгоритме сначала проверяется наличие дождя на видео, чтобы решить, нужно ли проводить фильтрацию погоды перед детектированием объектов небольшого размера.

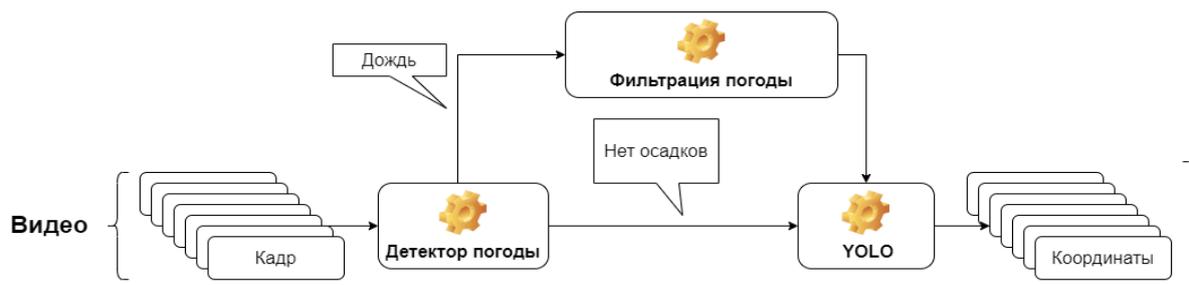


Рисунок 1 – Алгоритм обнаружения небольших объектов на видео при использовании моделей детекции и фильтрации дождя

Figure 1 – Algorithm detection of small objects in video using detection models and rain filtering

Детектирование погоды

Детекция погодных явлений на видео – это задача обработки и анализа видеопотока для выявления и классификации различных погодных условий, таких как дождь, снег, туман и т. д. Нейросетевые методы позволяют самостоятельно обучаться на основе набора данных. Нейронная сеть может обрабатывать большие объемы данных и использовать их для выявления определенных закономерностей и шаблонов. Нейросетевые методы также могут показывать лучшие результаты и более высокую точность в детекции погоды при обработке видео при сложных погодных условиях.

В обзоре [7] рассмотрены различные методы распознавания погодных условий. В нашей работе исследовались предобученные на датасете ImageNet [10] сверточные нейронные сети.

Датасеты

Предобученные модели с соответствующей архитектурой были дообучены на следующих наборах данных:

1. **DAWN: Vehicle Detection in Adverse Weather Nature Dataset**¹. Этот датасет содержит более 1 000 изображений, собранных в течение многих лет с целью создания системы распознавания погодных условий. DAWN сосредоточен на разнообразной транспортной среде (городской, шоссе и автострадной), а также включает в себя богатое разнообразие транспортных потоков. Набор данных DAWN включает в себя коллекцию из 1000 изображений реальной дорожной обстановки, которые разделены на четыре набора погодных условий: туман, снег, дождь и песчаные бури. Набор данных снабжен аннотациями с ограничивающими рамками объектов для сценариев автономного вождения и видеонаблюдения. Эти данные помогают интерпретировать влияние неблагоприятных погодных условий на работу систем обнаружения транспортных средств. Количество размеченных изображений с дождем в наборе данных равно 200.

2. **Weather Image Recognition @ Kaggle**². Этот набор данных содержит 6862 изображения различных типов погоды, его можно использовать для реализации классификации погоды на основе фотографии. Датасет содержит в том числе 500 изображений с дождем.

3. **Multi-class weather dataset(MWD) for image classification**³: Этот датасет содержит 1125 изображений, охватывающих различные аспекты погоды, такие как облака, дождь, солнце и туман [11].

¹ Naixia X. Weather phenomenon database (WEAPD). URL: <https://doi.org/10.7910/DVN/M8JQCR> (дата обращения: 29.07.2024).

² Gbeminiyi A. Multi-class Weather Dataset for Image Classification. URL: <https://data.mendeley.com/datasets/4drtyfjfy/1> (дата обращения: 29.07.2024).

³ Mourad K. DAWN. URL: <https://data.mendeley.com/datasets/766ygrbt8y/3> (дата обращения: 29.07.2024).

Из представленных датасетов был собран датасет, в котором были отобраны изображения с дождем. На этом датасете была дообучена классификационная нейросеть на архитектуре ResNet50 [12].

Фильтрация погоды и детектирование объектов небольшого размера

В последние годы, для фильтрации изображения от дождя широко используются методы глубокого обучения, позволяющие достичь значительной производительности, что важно для прикладного применения этих методов в различных областях. Данные методы позволяют устранить эффект дождя и восстановить изображение сцены, искаженное каплями или полосами дождя, сохраняя при этом важные визуальные детали. Как показано в обзоре [13], существует три вида таких методов. Методы, основанные на: сверточных нейронных сетях (CNN), генеративно-состязательных нейронных сетях (GAN) [14] и нейронных сетях на архитектуре трансформер [15].

Методы глубокого обучения, основанные на сверточных нейронных сетях рассмотрены в работах [16, 17], применение рекуррентных нейронных сетей предложено в работе [18], графовые сверточные нейронные сети рассмотрены в работах [19, 20].

Другим подходом является применение генеративно-состязательных нейронных сетей (GAN) для получения изображений без дождя. Этот подход рассмотрен в работах [21, 22], генеративно-состязательные модели, ограниченные физическими моделями дождя, рассмотрены в работах [23, 24], генеративно-состязательные модели, контролируемые интенсивность дождя, рассмотрены в [25].

В последние годы в области обработки изображений и видео стали широко применяться нейронные сети, основанные на архитектуре трансформер [26]. Применение этой архитектуры для фильтрации дождя на изображениях рассмотрено в работах [27–29].

Отдельно применяются гибридные нейронные сети, в которых используются элементы как архитектуры сверточных сетей, так и архитектуры трансформер. Применение этого подхода рассмотрено в работах [30, 31].

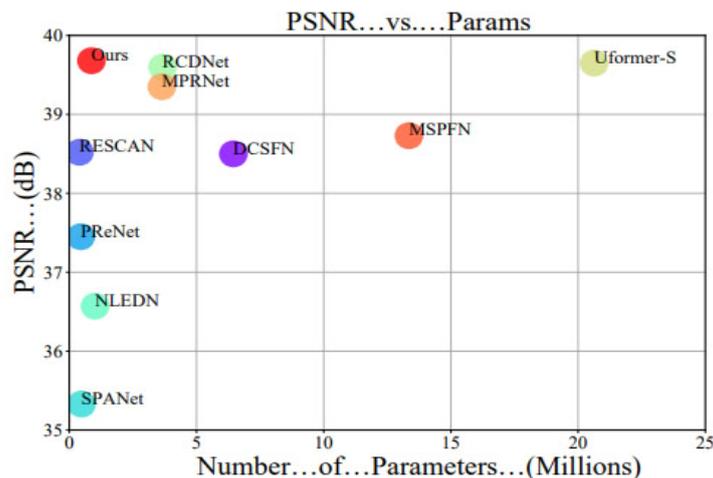


Рисунок 2 – Сравнительный анализ моделей фильтрации дождя для датасета Rain100L
Figure 2 – Comparative analysis of rain filtering models for the Rain100L dataset

Сравнение этих подходов показало, что достаточно высокая точность сочетается с высокой производительностью и небольшим размером модели в гибридном подходе, рассмотренном в работе [31], чем и обоснован выбор в нашей работе этого метода глубокого обучения для исследования фильтрации на детекцию объектов небольшого размера (Рисунок 2) [31].

В качестве модели, рассматриваемой для фильтрации дождя, была выбрана новая облегченная гибридная сеть CNN-Transformer Feature Fusion Network (HCT-FFN) [31], которая объединяет преимущества двух архитектур, CNN и Transformer, для восстановления изображений. Эта сеть состоит из последовательности модулей, учитывающих деградацию на этапе, основанном на CNN, и модуля background-aware vision Transformer (BaViT) на этапе на основе Transformer. Эти модули позволяют учитывать пространственно-изменяющиеся особенности распределения осадков и дополнять пространственно-временные зависимости изображений. Для улучшения взаимодействия между функциями CNN и функциями Transformer вводится интерактивная ветвь fusion на смежных этапах. Пример работы модели фильтрации дождя можно увидеть на Рисунке 3. Видно, что текстура и небольшие объекты довольно хорошо восстанавливаются. Применение данной нейросети при фильтрации дождя на видеоданных при работах на железнодорожном пути с такими же инструментами небольшого размера, как кисть на Рисунке 3 позволяет улучшить качество изображения для распознавания таких технологических операций.

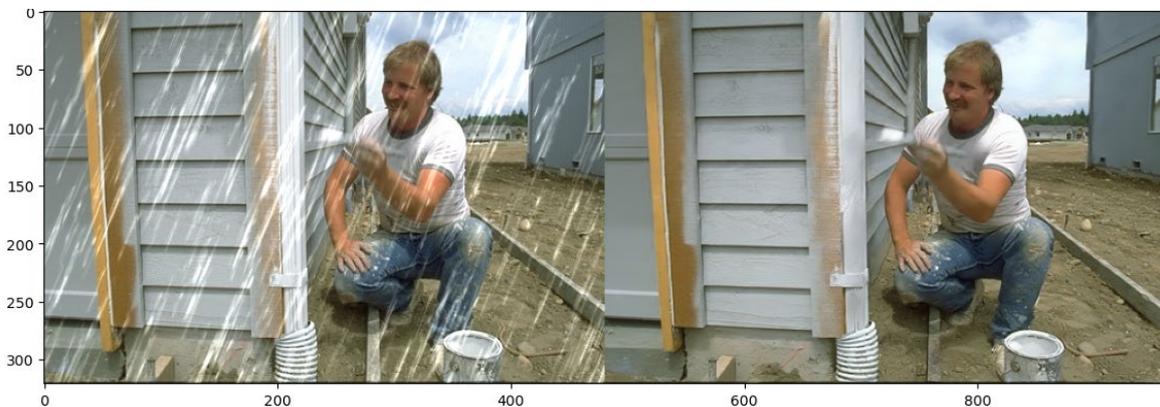


Рисунок 3 – Пример работы модели фильтрации дождя HCT-FFN
Figure 3 – Example of operation of the HCT-FFN rain filter model

В данной работе проводится оценка влияния фильтрации искажений от дождя на результаты детекции небольших объектов. Согласно обзору [9], модели семейства YOLO [32] показывают лучшие результаты для детектирования объектов небольшого размера, например сигналов светофора, чем другие модели детектирования объектов. Поэтому для тестирования влияния фильтрации на обнаружение объектов небольшого размера была выбрана модель семейства YOLO версии 8.

В качестве инструмента небольшого размера, сравнимого с кистью руки, для исследования поведения метрики детекции в случае наличия погодных эффектов и их фильтрации был выбран кухонный нож, который визуально похож на специальный инструмент небольшого размера – лапка специальная для подрельсовых прокладок, применяемый на работах на железнодорожном пути.

Для тестирования обнаружения небольших предметов был собран набор данных из сети Интернет, включающий два класса: изображения с ножом без дождя и изображения с ножом с дождем, всего 3000 изображений.

Результаты

Детектирование погоды

Для оценки возможностей покадровой классификации погоды на видеоданных, были проведены эксперименты на комбинированном датасете с использованием

следующих архитектур глубоких нейронных сетей: MobileNetV3 [33], ResNet-50 [15] и VGG11_BN [34]. В процессе обучения были использованы стандартные аугментации, такие как поворот на случайный угол до 30 градусов, отражение по горизонтали, изменение размера изображения до 224×224, преобразование в тензор и нормализация.

Для оценки качества классификации были использованы метрики precision, recall и f1-score, которые были рассчитаны на валидационном датасете, который включает в себя кадры из видеосъемки железнодорожного пути в солнечную и дождливую погоду.

Таблица 1 – Метрики классификации погодных условий на изображениях комбинированного датасета

Table 1 – Metrics for classifying weather conditions in combined dataset images

Метрика / Класс	precision			recall			F1-score		
	Mobile NetV3	ResNet 50	VGG11_BN	Модель / Класс	Mobile NetV3	ResNet 50	VGG11_BN	Модель / Класс	Mobile NetV3
Без осадков	0,84	0,82	0,85	Без осадков	0,84	0,82	0,85	Без осадков	0,84
Дождь	0,77	0,93	0,72	Дождь	0,77	0,93	0,72	Дождь	0,77

Анализ данных, представленных в Таблице 1, показывает, что использование ResNet50 является наиболее эффективным решением для обработки изображений в контексте определения наличия неблагоприятных погодных условий и последующей фильтрации. Таким образом, применение ResNet50 в рамках данного алгоритма представляется оптимальным выбором для детектирования дождя на видеоданных, на которых необходимо распознавать технологические операции при работах на железнодорожном пути.

Фильтрация погодных условий и детектирование объектов небольшого размера

Фильтрация изображения нейронной сетью может быть использована для устранения эффектов дождя на изображении. Это крайне полезно, когда нужно восстановить качество изображения, которое было сделано в плохую погоду. Нейронная сеть может анализировать изображение и определять, какие области изображения были затронуты дождем, частично восстановить исходное изображение, улучшив качество по отношению к зашумленной версии с дождем.

В качестве модели фильтрации дождя была применена предобученная модель – облегченная гибридная сеть НСТ-FFN [31]. Сеть содержит 0,9М параметров, и был использован вариант, предобученный на датасете с сильным дождем, чекпоинт ‘model_best_Rain100H.pt’.

Модель детекции YOLOv8s была обучена на 100 эпохах, с использованием параметров по умолчанию и стандартных аугментаций.

Сравнительный анализ проводился относительно полученных метрик на различных сценариях, в зависимости от наличия и отсутствия дождя на изображении и применения фильтрации на этом изображении. Результаты сведены в Таблицу 2.

Принимая во внимание метрики f1-score и mAP50 видно, что искажения, вызванные дождем, отрицательно сказываются на метриках обнаружения. Снижение f1-score составило около 18%. Использование фильтрации на изображениях с дождем позволяет улучшить на 14% обнаружение небольших объектов по сравнению с ситуацией, когда фильтрация не используется. Метрика f1-score снизилась на 4%, что гораздо меньше, чем 18%. Кроме того, обработка изображений без признаков дождя также снижает метрики обнаружения небольших объектов. Снижение f1-score составило 3%.

Таблица 2 – Результаты работы модели детекции небольших объектов на изображении для различных сценариев

Table 2 – Results of the small object detection model in the image for different scenarios

Наличие дождя на изображение	Применение фильтрации	precision	recall	f1-score	mAP50
нет	нет	0,902	0,950	0,925	0,941
да	нет	0,815	0,711	0,760	0,765
нет	да	0,918	0,877	0,897	0,899
да	да	0,884	0,887	0,885	0,905

Следовательно, можно сделать вывод, что предложенная в работе схема в целом повышает эффективность обнаружения небольших объектов при использовании системы в условиях, когда возможны осадки в виде дождя.

Обсуждение

Для того чтобы включать фильтрацию только в тех случаях, когда на видео идет дождь, были исследованы архитектуры классификационных сетей, которые определяют на видео есть дождь или нет. В случае, когда определяется дождь на видео, кадры с дождем фильтруются, чтобы на вход детектора попали кадры без дождя.

Выбор метода фильтрации может быть обусловлен различными мотивациями, в данном случае главной мотивацией является повышение точности детектирования объектов (в данном случае небольших инструментов) в условиях наличия дождя и производительность модели. Высокочастотные детали, присутствующие на изображении в условиях дождя, могут создавать шумы и искажения, что может приводить к ошибкам в детектировании объектов.

Для оценки влияния фильтрации на детектирование объектов было проведено исследование на сети YOLOv8. Было проанализировано, насколько меняется детекция при использовании фильтра и оценено влияние на детектирование.

Заключение

В данной работе была исследована и подтверждена гипотеза успешного применения методов распознавания и фильтрации погодных условий для детектирования инструментов небольшого размера, которые применяются в работах на железнодорожном пути. При распознавании технологических операций в работах на железнодорожном пути, в которых используются небольшие инструменты, важно, чтобы не снижалась точность обнаружения этих инструментов, когда нет дождя, и минимально возможно снижалась точность, когда идет дождь.

В данной работе было подтверждено, что при включении фильтрации дождя, когда дождя на видео нет, точность детектирования небольших объектов снижается на 3% по метрике f1-score. Проведенные исследования подтверждают важность определения дождя на видео. Для определения дождя используется отдельная классификационная нейросеть. Были исследованы различные архитектуры и выбрана архитектура нейросети Resnet50 с наибольшей точностью.

В случае обнаружения дождя на видео, кадры с дождем фильтруются отдельной нейросетью. В качестве модели для фильтрации дождя была выбрана новая облегченная гибридная нейронная сеть НСТ-FFN.

Когда на видео идет дождь, снижение f1-score составило около 18%. Использование фильтрации на изображениях с дождем позволяет улучшить на 14%

обнаружение объектов небольшого размера, по сравнению с ситуацией, когда фильтрация не используется.

Использование фильтра дождя и в качестве препроцессинга при инференсе нейросетевой модели YOLOv8 позволяет повысить метрики детекции инструментов небольшого размера. Принимая во внимание метрики f1-score и mAP50 видно, что искажения, вызванные дождем, отрицательно сказываются на метриках обнаружения.

Следовательно, можно сделать вывод о том, что предложенная в работе схема в целом повышает эффективность обнаружения небольших объектов при использовании системы в условиях, когда возможны осадки в виде дождя. Фильтрация справляется с достаточно сильными шумовыми эффектами дождя. Результаты проведенного исследования показывают, что предложенный подход применим для детектирования небольших инструментов на видеоданных, при распознавании технологических операций ручного труда, выполняемых при ремонте и обслуживании железнодорожного пути. Полученные результаты могут быть полезны при исследовании трудовых процессов, происходящих на открытом воздухе, в алгоритмах распознавания технологических операций ручного труда на видеоданных.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Штехин С.Е., Карачёв Д.К., Иванова Ю.К. Разработка алгоритма распознавания движений человека методами компьютерного зрения в задаче нормирования рабочего времени. *Труды Института системного программирования РАН*. 2020;32(1):121–136. [https://doi.org/10.15514/ISPRAS-2020-32\(1\)-7](https://doi.org/10.15514/ISPRAS-2020-32(1)-7)
Shtekhin S.E., Karachev D.K., Ivanova Yu.A. Computer vision system for Working time estimation by Human Activities detection in video frames. *Trudy Instituta sistemnogo programmirovaniya RAN = Proceedings of the Institute for System Programming of the RAS*. 2020;32(1):121–136. (In Russ.). [https://doi.org/10.15514/ISPRAS-2020-32\(1\)-7](https://doi.org/10.15514/ISPRAS-2020-32(1)-7)
2. Zou Zh., Chen K., Shi Zh., Guo Yu., Ye J. Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*. 2023;111(3):257–276. <https://doi.org/10.1109/jproc.2023.3238524>
3. Arkin E., Yadikar N., Xu X. et al. A survey: object detection methods from CNN to transformer. *Multimedia Tools and Applications*. 2023;82(14):21353–21383. <https://doi.org/10.1007/s11042-022-13801-3>
4. Карачев Д.К., Штехин С.Е., Тарасян В.С., Смолин И.Ю., Исаков М.В. Использование переноса стиля как способ улучшения обобщающей способности нейросети в задаче детекции объектов. *Труды Института системного программирования РАН*. 2023;35(6):247–264. [https://doi.org/10.15514/ISPRAS-2023-35\(6\)-16](https://doi.org/10.15514/ISPRAS-2023-35(6)-16)
Karachev D.K., Shtekhin S.E., Tarasyan V.S., Smolin I.U., Isakov M.V. Style transfer as a way to improve the generalization ability of a neural network in an object detection task. *Trudy Instituta sistemnogo programmirovaniya RAN = Proceedings of the Institute for System Programming of the RAS*. 2023;35(6):247–264. (In Russ.). [https://doi.org/10.15514/ISPRAS-2023-35\(6\)-16](https://doi.org/10.15514/ISPRAS-2023-35(6)-16)
5. Liu Y., Sun P., Wergeles N., Shang Y. A survey and performance evaluation of deep learning methods for small object detection. *Expert Systems with Applications*. 2021;172. <https://doi.org/10.1016/j.eswa.2021.114602>
6. Царук В.Б. Выделение искажений, вносимых атмосферными осадками на видеоизображения. В сборнике: *Актуальные проблемы авиации и космонавтики: Сборник материалов XIV Международной научно-практической конференции*,

- посвященной Дню космонавтики: Том 2, 09–13 апреля 2018 года, Красноярск, Россия. 2018. С. 176–178.
- Tsaruk V.B. Weather effects detection in video. In: *Aktual'nye problemy aviatsii i kosmonavтики: Sbornik materialov XIV Mezhdunarodnoi nauchno-prakticheskoi konferentsii, posvyashchenoi Dnyu kosmonavтики: Volume 2, 09–13 April 2018, Krasnoyarsk, Russia*. 2018. pp. 176–178. (In Russ.).
7. Ляхов П.А., Ионисян А.С., Лютова В.В., Оразаев А.Р. Обзор методов улучшения визуального качества изображений и видео в неблагоприятных погодных условиях. *Современная наука и инновации*. 2022;(4):8–24. <https://doi.org/10.37493/2307-910X.2022.4.1>
Lyakhov P.A., Ionisyan A.S., Liutova V.V., Orazhev A.R. Overview of methods for improving the visual quality of images and videos in adverse weather conditions. *Sovremennaya nauka i innovatsii = Modern Science and Innovations*. 2022;(4):8–24. (In Russ.). <https://doi.org/10.37493/2307-910X.2022.4.1>
 8. Shtekhin S., Karachev D., Stadnik A. Study of Filtering the Weather Adverse Effects to Object Detection. *Physics of Particles and Nuclei*. 2024;55:329–333. <https://doi.org/10.1134/S1063779624030766>
 9. Hnewa M., Radha H. Object Detection Under Rainy Conditions for Autonomous Vehicles: A Review of State-of-the-Art and Emerging Techniques. *IEEE Signal Processing Magazine*. 2021;38(1):53–67. <https://doi.org/10.1109/MSP.2020.2984801>
 10. Deng J., Dong W., Socher R., Li L.-J., Li K., Li F.-F. ImageNet: A large-scale hierarchical image database. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition, 20–25 June 2009, Miami, USA*. IEEE; 2009. pp. 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
 11. Gbeminiyi O., Zenghui W. Multi-Class Weather Classification from Still Image Using Said Ensemble Method. In: *2019 Southern African Universities Power Engineering Conference/Robotics and Mechatronics/Pattern Recognition Association of South Africa (SAUPEC/RobMech/PRASA), 28–30 January 2019, Bloemfontein, South Africa*. IEEE; 2019. pp. 135–140. <https://doi.org/10.1109/RoboMech.2019.8704783>
 12. He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27–30 June 2016, Las Vegas, USA*. IEEE; 2016. pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
 13. Chen X., Pan J., Dong J., Tang J. Towards Unified Deep Image Deraining: A Survey and A New Benchmark. URL: <https://arxiv.org/pdf/2310.03535> [Accessed 30th July 2024].
 14. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. Generative adversarial networks. *Communications of the ACM*. 2020;63(11):139–144. <https://doi.org/10.1145/3422622>
 15. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N. et al. Attention is All you Need. In: *Advances in Neural Information Processing Systems 30 (NIPS 2017): 31st Conference on Neural Information Processing Systems (NIPS 2017), 4–9 December 2017, Long Beach, USA*. Montreal: Curran Associates; 2017. pp. 5998–6008.
 16. Yang W., Tan R.T., Feng J., Liu J., Guo Z., Yan S. Deep Joint Rain Detection and Removal from a Single Image. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21–26 July 2017, Honolulu, USA*. IEEE; 2017. pp. 1685–1694. <https://doi.org/10.1109/CVPR.2017.183>
 17. Fu X., Huang J., Zeng D., Huang Y., Ding X., Paisley J. Removing Rain from Single Images via a Deep Detail Network. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 21–26 July 2017, Honolulu, USA*. IEEE; 2017. pp. 1715–1723. <https://doi.org/10.1109/CVPR.2017.186>

18. Li X., Wu J., Lin Z., Liu H., Zha H. Recurrent Squeeze-and-Excitation Context Aggregation Net for Single Image Deraining. In: *Computer Vision – ECCV 2018: 15th European Conference: Proceedings: Part VII, 8–14 September 2018, Munich, Germany*. Cham: Springer; 2018. pp. 262–277. https://doi.org/10.1007/978-3-030-01234-2_16
19. Fu X., Qi Q., Zha Z.-J., Zhu Y., Ding X. Rain Streak Removal via Dual Graph Convolutional Network. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2021;35(2):1352–1360. <https://doi.org/10.1609/aaai.v35i2.16224>
20. Fu X., Xiao J., Zhu Y., Liu A., Wu F., Zha Z.-J. Continual Image Deraining With Hypergraph Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2023;45(8):9534–9551. <https://doi.org/10.1109/TPAMI.2023.3241756>
21. Qian R., Tan R.T., Yang W., Su J., Liu J. Attentive Generative Adversarial Network for Raindrop Removal from A Single Image. In: *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 18–23 June 2018, Salt Lake City, USA*. IEEE; 2018. pp. 2482–2491. <https://doi.org/10.1109/CVPR.2018.00263>
22. Zhang H., Sindagi V., Patel V.M. Image De-Raining Using a Conditional Generative Adversarial Network. *IEEE Transactions on Circuits and Systems for Video Technology*. 2019;30(11):3943–3956. <https://doi.org/10.1109/TCSVT.2019.2920407>
23. Li R., Cheong L.-F., Tan R.T. Heavy Rain Image Restoration: Integrating Physics Model and Conditional Adversarial Learning. In: *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 15–20 June 2019, Long Beach, USA*. IEEE; 2019. pp. 1633–1642. <https://doi.org/10.1109/CVPR.2019.00173>
24. Pan J., Dong J., Liu Y., Zhang J., Ren J., Tang J. et al. Physics-Based Generative Adversarial Models for Image Restoration and Beyond. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2020;43(7):2449–2462. <https://doi.org/10.1109/TPAMI.2020.2969348>
25. Ni S., Cao X., Yue T., Hu X. Controlling the Rain: from Removal to Rendering. In: *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 20–25 June 2021, Nashville, USA*. IEEE; 2021. pp. 6324–6333. <https://doi.org/10.1109/CVPR46437.2021.00626>
26. Han K., Wang Y., Chen H., Chen X., Guo J., Liu Z. et al. A Survey on Vision Transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2022;45(1):87–110. <https://doi.org/10.1109/TPAMI.2022.3152247>
27. Xiao J., Fu X., Liu A., Wu F., Zha Z.-J. Image De-Raining Transformer. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2022;45(11):12978–12995. <https://doi.org/10.1109/TPAMI.2022.3183612>
28. Chen H., Wang Y., Guo T., Xu C., Deng Y., Liu Z. et al. Pre-Trained Image Processing Transformer. In: *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 20–25 June 2021, Nashville, USA*. IEEE; 2021. pp. 12294–12305. <https://doi.org/10.1109/CVPR46437.2021.01212>
29. Zamir S.W., Arora A., Khan S., Hayat M., Khan F.S., Yang M.-H. Restormer: Efficient Transformer for High-Resolution Image Restoration. In: *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 18–24 June 2022, New Orleans, USA*. IEEE; 2022. pp. 5718–5729. <https://doi.org/10.1109/CVPR52688.2022.00564>
30. Jiang K., Wang Z., Chen C., Wang Z., Cui L., Lin C.-W. Magic ELF: Image Deraining Meets Association Learning and Transformer. In: *MM '22: The 30th ACM International Conference on Multimedia, 10–14 October 2022, Lisboa, Portugal*. New York: Association for Computing Machinery; 2022. pp. 827–836. <https://doi.org/10.1145/3503161.3547760>

31. Chen X., Pan J., Lu J., Fan Z., Li H. Hybrid CNN-Transformer Feature Fusion for Single Image Deraining. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2023;37(1):378–386. <https://doi.org/10.1609/aaai.v37i1.25111>
32. Wang C.-Y., Bochkovskiy A., Liao H.-Y.M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. URL: <https://arxiv.org/abs/2207.02696v1> [Accessed 30th July 2024].
33. Howard A., Sandler M., Chen B., Wang W., Chen L.-C., Tan M., Chu G., Vasudevan V. Searching for MobileNetV3. In: *2019 IEEE/CVF International Conference on Computer Vision (ICCV), 27 October 2019 – 02 November 2019, Seoul, Korea (South)*. IEEE; 2019. pp. 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>
34. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. URL: <https://arxiv.org/abs/1409.1556> [Accessed 30th July 2024].

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Штехин Сергей Евгеньевич, руководитель группы компьютерного зрения, «Отраслевой центр разработки и внедрения информационных систем» Сириус, филиал № 11, Сочи, Российская Федерация.
e-mail: shs77@bk.ru
ORCID: [0000-0003-2866-4864](https://orcid.org/0000-0003-2866-4864)

Sergey E. Shtekhin, Head of the Computer Vision Group, "Industry center for the development and implementation of information systems" Sirius, branch No. 11, Sochi, the Russian Federation.

Стадник Алексей Викторович, кандидат физико-математических наук, старший специалист по анализу данных группы компьютерного зрения, «Отраслевой центр разработки и внедрения информационных систем» Сириус, филиал № 11, Сочи, Российская Федерация.
e-mail: i@lxstd.ru

Alexey V. Stadnik, Candidate of Physical and Mathematical Sciences, Senior Data Analysis Specialist of the Computer Vision Group, "Industry center for the development and implementation of information systems" Sirius, branch No. 11, Sochi, the Russian Federation.

Статья поступила в редакцию 07.08.2024; одобрена после рецензирования 19.08.2024; принята к публикации 28.08.2024.

The article was submitted 07.08.2024; approved after reviewing 19.08.2024; accepted for publication 28.08.2024.