

УДК 004.032.26

ИСПОЛЬЗОВАНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ДЕТЕКЦИИ ПЫЛЕВОГО ОБЛАКА В ПРОИЗВОДСТВЕННОМ ПОМЕЩЕНИИ

Васильев Н.А., Зарубин К.А., Лаута О.С., Ситдилов Д.С.
Военная академия связи
г. Санкт-Петербург

Одним из примеров задачи компьютерного зрения является мониторинг производственного процесса на предприятии порошковой металлургии, где в процессе работы размольной установки существует риск утечки алюминиевой пудры (пыли, мелкодисперсного порошка), и, как следствие, возникновения аварийной ситуации.

Актуальность работы обусловлена отсутствием систем, позволяющих своевременно информировать о возникновении аварийной ситуации на предприятии. Используемые температурные датчики и газоанализаторы не позволяют вовремя принять меры по устранению утечки пыли.

В данной статье рассматривается реализация задачи детекции пылевого облака в режиме реального времени с использованием нейронных сетей.

Подходы к обнаружению объектов разделяются на две группы: классические алгоритмы (на основе вручную спроектированных признаков) и обнаружение объектов на основе применения сверточных нейронных сетей.

Среди классических алгоритмов выделяются: алгоритм VJ, алгоритм HOG, алгоритм DPM. Представленные алгоритмы неэффективны для решения поставленных задач [1-4] так, как их точность ниже по сравнению с алгоритмами, основанными на сверточных нейронных сетях. Кроме того, данные алгоритмы сложно переобучить на новый класс объектов.

Двухэтапные алгоритмы – подход, где сначала выделяются области с высокой вероятностью содержащие объекты, а затем эти области подвергаются анализу классификатором и регрессором. Среди двухэтапных алгоритмов выделяются: R-CNN, SPPNet, Fast R-CNN и Faster R-CNN, который объединяет в себе преимущества остальных алгоритмов.

Одноэтапные алгоритмы – подход, где обнаружение объектов и предсказание их границ осуществляется на одном шаге. Среди одноэтапных алгоритмов выделяются: одна из наиболее развивающихся моделей семейства Yolo, YOLOv5, SSD, RetinaNet.

Проведено множество работ с использованием данных архитектур сетей, которые позволяют наиболее точно оценить их применимость для работы в режиме реального времени. В статье [5] производилось обучение моделей SSD на базе MobileNet-1, MobileNet-2; YOLOv3; Faster R-CNN на базе Resnet-101, InceptionResnet-2. Скорость работы SSD MobileNet-1 составила 25 fps, Faster R-CNN 8 fps, YOLOv3 17 fps. Более современные исследования архитектуры CHC

для задачи обнаружения полипов [6] указывают на то, что наиболее оптимальным алгоритмом с точки зрения скорости работы и точности является алгоритм YOLOv4. В статье [7] сравниваются алгоритмы SSD и YOLOv5 на базе Kvasir-SEG (содержащий 1000 изображений полипов), выявлено преимущество YOLOv5, как по точности 0.92, так и по скорости работы 55 fps. В задаче обнаружения аэрокосмических снимков преимущество по скорости обработки данных показала модель YOLOv5 [8].

Результаты проведенного анализа показали, что модель нейронной сети YOLOv5 обладает оптимальным соотношением скорости работы и точности для работы в режиме реального времени.

Ввиду отсутствия доступных баз изображения пылевого облака, а также с учетом ограничений в сборе данных принято решение использовать синтетические данные. Подобный подход хорошо показал себя во многих исследованиях, в частности, большой интерес для настоящей работы представляет исследование авторов работы [10], согласно которым синтетические данные позволяют достичь приемлемой точности на изображениях реального мира, преодолев тем самым проблему нехватки данных. В основе обучения модели нейронной сети лежит метод Transfer Learning [9], применение знаний, полученных на одной задаче, к другой целевой задаче.

Процесс подготовки данных включает в себя перевод разметки изображений в требуемый формат для датасета выбросов пыли на строительных площадках, используемого для первого этапа обучения модели, создание, аугментирование и разметка синтетических изображений пылевого облака на фоне размытой установки, используемые для второго этапа обучения модели.

Выделено двести изображений пылевых облаков с использованием графического редактора, которые объединены с исследуемым объектом. Пример получившихся пылевых облаков представлен на рис. 1.




Рис. 1. Пример изображений пылевых облаков с помощью графического редактора

Для выделенных изображений применялись следующие методы аугментации: масштабирование изображения, повороты, сдвиги, изменение яркости, контраста и насыщенности, регулировка альфа-канала изображения. Значение альфа-канала изменялось в зависимости от изображения от 205 до

250. Изображение с регулировкой альфа-канала и без регулировки представлены на рис. 2.



Рис. 2. Изображение без регулировки альфа-канала, с регулировкой

Всего создано 500 изображений для второго этапа обучения модели.

Для первого этапа обучения модели использовался датасет, содержащий 3860 изображений выбросов пыли на различных строительных площадках (данные получены синтетически на движке Unity 3D), которые были разделены на обучающую и проверочную выборки в соотношении: 3158 – 702. Зависимости приведенные на рис. 3 позволяют сделать вывод о достижении моделью нейронной сети оптимальных результатов на 23 эпохе обучения, после которой заметно снижение значений представленных метрик, что является показателем переобучения. Значение метрик на 23 эпохе обучения: $mAP@0.5=99.5$, $precision=99.5$, $recall=99.5$.




Рис. 3. Графики метрик mAP , $precision$, $recall$ для первого этапа обучения модели

Для второго этапа модели нейронной сети использовались веса с первого этапа и датасет, состоящий из 500 созданных и размеченных синтетических изображений пылевого облака. Зависимости приведенные на рис. 4 позволяют сделать вывод о достижении моделью нейронной сети оптимальных результатов на 30 эпохе обучения, значение метрики mAP составило 99,5 %, значение метрик $precision$, $recall$ составило 99,9%.




Рис. 4. Графики метрик mAP, precision, recall для второго этапа обучения модели

Для тестирования модели использовался видеоматериал, отснятый на предприятии. Необходимо отметить, что использование аугментации, а именно изменение альфа-канала изображения, дало существенный прирост confidence внутри bbox объектов на тестовых данных. Окончательные результаты тестирования модели представлены на рис. 5.



Рис. 5. Результаты работы модели на тестовых данных

Тестирование модели после второго этапа обучения проводилось на видеопотоке реальных изображений пылевого облака. Результаты показали, что модель надежно определяет начало процесса пыления, точность составила в среднем 98 %.

Созданная модель будет служить основой для формирования системы автоматизированного контроля за уровнем пыли на рабочих местах. Применение нейронных сетей в системе видеонаблюдения предоставляет возможность обнаружения процессов пыления, что в свою очередь приводит к достижению следующих результатов:

- 1) Принятие оперативных мер по устранению утечек пыли и возгорания, что, в конечном итоге, предотвращает возникновение аварийных ситуаций и потенциальных взрывов.
- 2) Повышение уровня защиты технологического процесса.
- 3) Сокращение времени восстановления работы мельницы, уменьшение простоя и, как следствие, повышение эффективности производства.

Список литературы:

1. Viola P., Jones M. Rapid object detection using a boosted cascade of simple features // Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. – 2001. – pp. I–I.
2. Viola P., Jones M. Robust real-time face detection // International Journal of Computer Vision. – 2004. – vol. 57(2). – pp. 137 – 154.
3. Dalal N., Triggs B. Histograms of oriented gradients for human detection // IEEE Computer Society Conference on Computer Vision and Pattern Recognition. – 2005. – vol. 1. – pp. 886 – 893.
4. Felzenszwalb P., Girshick R., McAllester D. Cascade object detection with deformable part models // IEEE Computer Society Conference on Computer Vision and Pattern Recognition. – 2010. – pp. 2241 – 2248.
5. Ерохин Д.Ю., Ершов М.Д. Современные сверточные нейронные сети для обнаружения и распознавания объектов// Цифровая обработка сигналов. – 2018. – №3. – С. 64 – 69.
6. Jha D., Ali S., Tomar N. K., Johansen H.D., Johansen D., Rittscher J., Riegler M.A., Halvorsen P. Real-Time Polyp Detection, Localization and Segmentation in Colonoscopy Using Deep Learning // Computer Vision and Pattern Recognition. – 2021. – pp. 40496 – 4051.
7. Лебедев А.А. Разработка алгоритма детектирования полипов на видеопотоке с эндоскопической системы с использованием методов глубокого машинного обучения//Перспективные технологии в средствах передачи информации. – 2021. – С.400 – 403.
8. Скрипачев В.О., Гуйда М.В., Гуйда Н.В., Жуков А.О. Исследование сверточных нейронных сетей для обнаружения объектов на аэрокосмических снимках// International Journal Of Open Information Technologies. – 2022. – №7. – С. 54 – 64.
9. Богатырева А.А., Виноградова А.Р., Тихомирова С.А. Исследование способности к Transfer Learning сверточных нейронных сетей, обученных на ImageNet //Международный журнал прикладных и фундаментальных исследований. – 2019. – № 7 – С. 106 – 111.
10. Xiong R., Tang P. Machine learning using synthetic images for detecting dust emissions on construction sites // Smart and Sustainable Built Environment. – 2021. – Vol. 10. – № 3. – pp. 487 – 503.