

УДК 005, 004.021, 004.932:621.391+519.876.5
DOI: 10.18799/29495407/2024/4/77
Шифр специальности ВАК: 2.3.5

Тенденции в современных системах мониторинга промышленной безопасности и охраны труда

К.В. Чумаков✉

Национальный исследовательский Томский политехнический университет, Россия, г. Томск

✉chumakovk@tpu.ru

Аннотация. Представлены результаты использования видеоаналитики, основанной на алгоритмах искусственного интеллекта и компьютерного зрения, для мониторинга нештатных ситуаций и повышения безопасности технологических процессов. В условиях быстрого развития промышленности и усложнения производственных систем традиционные методы контроля безопасности становятся менее эффективными. Предложены инновационные подходы к анализу видеоданных, которые позволяют в реальном времени отслеживать соблюдение правил безопасности во время выполнения работ, выявлять нестандартные события и предотвращать потенциальные аварийные ситуации.

Ключевые слова: безопасность технологических процессов, производственная безопасность, мониторинг, повышение эффективности, видеоаналитика, компьютерное зрение, машинное обучение, искусственный интеллект

Для цитирования: Чумаков К.В. Тенденции в современных системах мониторинга промышленной безопасности и охраны труда // Известия Томского политехнического университета. Промышленная кибернетика. – 2024. – Т. 2. – № 4. – С. 34–40. DOI: 10.18799/29495407/2024/4/77

UDC 005, 004.021, 004.932:621.391+519.876.5
DOI: 10.18799/29495407/2024/4/77

Application of video analytics to monitor and improve the safety of technological processes

K. V. Chumakov✉

National Research Tomsk Polytechnic University, Tomsk, Russian Federation

✉chumakovk@tpu.ru

Abstract. The article presents the results of using video analytics based on artificial intelligence and computer vision algorithms to monitor compliance with safety rules during production work, as well as to monitor emergency situations. The author has developed the approach that allows real-time detection of non-standard events and prevention of potential emergency situations. The paper describes the key artificial intelligence algorithms used to process and interpret the video data stream.

Keywords: process safety, industrial safety, monitoring, increasing efficiency, video analytics, computer vision, machine learning, artificial intelligence

For citation: Chumakov K.V. Application of video analytics to monitor and improve the safety of technological processes. Bulletin of the Tomsk Polytechnic University. Industrial Cybernetics, 2024, vol. 2, no. 4, pp. 34–40. DOI: 10.18799/29495407/2024/4/77

Введение

В последние годы наблюдается стремительное развитие технологий, что привело к значительным изменениям в подходах к обеспечению безопасности на производстве [1–3]. Сложные производственные процессы и увеличение числа работников требуют применения более совершенных систем мониторинга и контроля за соблюдением норм охраны труда. Традиционные методы, основанные на ручных проверках и инспекциях, постепенно заменяются современными решениями, включающими в себя автоматизацию и использование технологий искусственного интеллекта (ИИ). Современные системы мониторинга промышленной безопасности стали важным инструментом для обеспечения безопасности работников и предотвращения несчастных случаев на производстве. На рис. 1 приведены статистические данные несчастных случаев на производстве.

В условиях повышения требований к безопасности и ужесточения законодательных норм предприятия вынуждены внедрять новые технологии, которые позволяют в режиме реального времени отслеживать работу оборудования, контролировать соблюдение правил техники безопасности и выявлять потенциальные риски. Одним из ключевых направлений в развитии этих систем является интеграция видеоаналитики и ИИ для повышения точности мониторинга и минимизации человеческого фактора.



Рис. 1. Статистические данные по несчастным случаям по данным Федеральной службы государственной статистики за 2020–2023 гг. [1]

Fig. 1. Static data on accidents according to the Federal State Statistics Service for 2020–2023

Современные технологии в системах мониторинга безопасности

Одной из главных тенденций в области промышленной безопасности является внедрение технологий компьютерного зрения и видеоаналитики

для автоматизации мониторинга. Эти системы позволяют в реальном времени контролировать поведение сотрудников, обнаруживать потенциальные угрозы и предотвращать аварийные ситуации. Например, видеоаналитика, основанная на алгоритмах ИИ, может выявлять отсутствие средств индивидуальной защиты (СИЗ) у работников, таких как каски или защитные очки, а также следить за их передвижениями в опасных зонах.

Также значительное внимание уделяется разработке систем, способных анализировать данные с множества камер наблюдения и датчиков. Такие системы могут автоматически обнаруживать утечки газа, нарушения в работе оборудования или нестандартные ситуации на производстве. Кроме того, современные системы охраны труда могут интегрироваться с умными СИЗ, которые уведомляют работников и администрацию о необходимости замены или исправления защитного оборудования.

С развитием технологий интернета вещей (IoT) на промышленных предприятиях устанавливаются интеллектуальные датчики [4], отслеживающие перемещение работников и состояние оборудования. Это позволяет минимизировать вероятность аварий и повысить эффективность мониторинга за счёт автоматизированных уведомлений о потенциальных угрозах.

Применение искусственного интеллекта для предсказания угроз

Одной из значимых тенденций является использование алгоритмов машинного обучения для анализа данных о травматизме и предсказания потенциальных угроз. Алгоритмы ИИ позволяют изучать исторические данные и выявлять скрытые закономерности, которые могут указывать на повышенные риски на производстве. Например, на предприятиях нефтегазовой промышленности внедряются системы, которые в реальном времени анализируют работу оборудования и предотвращают аварии благодаря раннему выявлению потенциальных проблем.

Алгоритмы компьютерного зрения также используются для мониторинга производственных процессов. Они способны автоматически распознавать нарушения в соблюдении техники безопасности [5], такие как отсутствие защитной одежды или нахождение работников в опасных зонах. Технологии анализа видеоизображений с использованием нейронных сетей позволяют значительно повысить точность и скорость выявления нарушений.

Технические решения и проблемы внедрения

Современные системы промышленной безопасности включают в себя множество технических решений. Например, камеры с высоким разрешением, установленные на производственных площад-

ках, позволяют вести детальный мониторинг даже при ограниченной видимости или неблагоприятных погодных условиях. Алгоритмы обработки видеоданных могут автоматически анализировать сотни камер, позволяя операторам быстро реагировать на инциденты.

Однако одним из вызовов при внедрении таких систем является необходимость их адаптации под конкретные условия предприятия. Например, в зависимости от типа производственного процесса может потребоваться настройка алгоритмов ИИ для улучшения распознавания объектов в кадре. Важно учитывать и такие факторы, как освещённость, удалённость объектов и погодные условия.

Ещё одна проблема заключается в высоких требованиях к вычислительным ресурсам. Обработка видеопотоков в реальном времени и обучение моделей машинного обучения требуют мощных серверов и высокопроизводительного оборудования. Это увеличивает затраты на внедрение подобных решений, однако с течением времени они оправдываются за счёт снижения уровня травматизма и повышения общей безопасности.

Материалы и методы решения

Для решения поставленной задачи – разработка нового подхода к анализу видеоданных, позволяющего в режиме реального времени отслеживать соблюдение правил техники безопасности при выполнении работ, выявлять аномалии и предотвращать потенциальные аварийные ситуации на примере производства газотранспортной компании, была выбрана модель YOLOv8, которая является частью обширного семейства алгоритмов компьютерного зрения под названием YOLO (You Only Look Once). Эти алгоритмы известны своей высокой эффективностью при обнаружении объектов в реальном времени, что делает их идеальными для

различных приложений, требующих быстрой и точной обработки изображений

Перед использованием модели YOLOv8 необходимо провести тщательную подготовку набора данных, который включает аннотированные изображения объектов. Этот процесс состоит из нескольких ключевых этапов: подготовка обучающей выборки, аннотирование изображений, обучение модели и оценка её точности на валидационном наборе данных. В процессе подготовки обучающей выборки рассматривались два типа моделей нейронных сетей: детекция и сегментация. Эти модели отличаются от классификационных подходов тем, что они не только идентифицируют объекты на изображении, но и выделяют их границы, а также определяют местоположение. В частности, при детекции объекты отображаются в виде ограничительных рамок, тогда как сегментация предоставляет семантические маски (рис. 2). Модели классификации обычно применяются для задач, где необходимо присвоить изображению один класс без разметки отдельных объектов или их позиций.

Важно отметить, что выбор типа нейронной сети для обнаружения нестандартных ситуаций зависит от специфики технологического процесса. Ключевыми факторами являются условия видимости, расстояние до объекта и погодные условия. Для первой версии системы мониторинга была выбрана модель детекции YOLOv8 для отслеживания следующих объектов: «персона», «голова», «каска». Эти объекты были выбраны с целью контроля соблюдения требований безопасности на промышленном объекте, особенно для идентификации наличия СИЗ у работников. Основными причинами выбора модели детекции стали простота аннотирования объектов на кадрах, легкость реализации алгоритма, высокая скорость обработки данных и низкие требования к вычислительным ресурсам.



а/а



б/б

Рис. 2. Разметка объектов на изображении для обучения модели: а) ограничительная рамка (детекция); б) семантическая маска (сегментация)

Fig. 2. Object annotation in an image for model training: a) bounding box (detection); b) semantic mask (segmentation)

После выбора модели нейронной сети проводилось аннотирование изображений. Этот процесс включает добавление меток и метаданных к изображениям, что придает им структуру и смысл, понятный алгоритмам машинного обучения. В качестве обучающих изображений были выбраны наиболее типичные сцены производственных процессов в области ремонта магистральных газопроводов повышенной опасности. Все изображения размечались вручную с основным критерием – наличие хотя бы одного из целевых объектов: «персона», «голова», «каска». В результате была сформирована обучающая выборка с разметкой детекции объектов, состоящая из 500 изображений для обучения модели, 100 изображений для валидации и 100 изображений для тестирования. Главная цель тестовой выборки заключается в оценке точности работы обученной модели на новых данных и определении основных метрик её производительности.

Обучение модели проводилось с использованием видеокарты NVIDIA GeForce RTX 4080 с архитектурой CUDA, обладающей следующими характеристиками: 1040 ядер, 320 тензорных ядер и 80 RT-ядер для трассировки лучей. Модель обучалась на протяжении 1000 эпох – полного прохода через весь набор данных. Процесс обучения нейронной сети осуществлялся методом «train», который позволяет корректировать ошибки и постепенно повышать точность предсказаний на основе предоставленных данных. На первом этапе обучения загружались изображения из ранее сформированного набора данных. Для увеличения разнообразия обучающего набора не использовались техники аугментации (например, вращение или изменение яркости). Вместо этого изображения группировались по 32 случайных изображения для одновременной обработки. Модель выполняла прямой проход (Forward Pass) для каждого изображения из группы и генерировала предсказания о местопо-

ложении объектов и их классах. Прямой проход позволяет преобразовать входные данные в целевые значения без обратной связи или коррекции ошибок.

На выходе модель возвращает координаты ограничивающих рамок, классы объектов и точность предсказаний. Затем предсказания сравниваются с истинными аннотациями объектов на изображениях. Вычисляется функция потерь, которая измеряет расхождение между предсказаниями и реальными метками (например, потери по координатам ограничивающих рамок). На основе этой функции выполняется обратное распространение ошибки: модель обновляет свои веса с помощью алгоритма оптимизации для минимизации потерь. Процесс повторяется для всех изображений в обучающем наборе на протяжении заданного количества эпох. После каждой итерации модель тестировалась на валидационном наборе данных для оценки её производительности. По завершении обучения модель сохраняется для дальнейшего использования или развертывания у пользователя.

Результаты и обсуждение

Результаты работы модели приведены на рис. 3. Видно, что часть людей не детектирована моделью. На рис. 4 показано, что при использовании модели она неверно идентифицирует объект в кадре. Таким образом, предварительные результаты детекции объектов можно считать неудовлетворительными. Для устранения установленной неточности идентификации объектов к изображениям была применена аугментация: вращение на произвольный угол от -30 до 30 и зеркальное отражение. В результате обучающая выборка с разметкой детекции объектов состояла из 6000 изображений для обучения модели, 1200 изображений для валидации модели и 100 изображений для тестирования. Однако подход с изменением значений параметров обучения не улучшил результат.




Рис. 3. Метрики обучения модели на 1000 повторений: а) детекция; б) сегментация
Fig. 3. Model training metrics for 1000 iterations: a) detection; b) segmentation




Рис. 4. Пример детекции объектов в кадре на объекте газотранспортной инфраструктуры

Fig. 4. Object detection in a frame at gas transportation infrastructure facilities

Для повышения достоверности идентификации объектов в кадре была выбрана модель сегментации. Аннотирование обучающего набора изображений выполнялось вручную в программном обеспечении AnyLabel Software (рис. 5). Затем размеченные изображения загружались в программное обеспечение Roboflow для экспорта в формат YOLO8. В результате обучающая выборка с разметкой сегментации объектов состояла из 6000 изображений для обучения модели, 1200 изображений для валидации модели, 100 изображений для тестирования. После обучения модели на протяжении 1000 итераций результаты предсказания модели существенно улучшились. Однако применение данного подхода привело к появлению большого количества ложных срабатываний. Например, участки леса сегментировались как «персона». Для повышения точности и устранения ложных срабатываний проведена сегментация и аннотирование 400 объектов, отмеченных на изображениях как «ложное срабатывание»: уличные фонари, отражение солнца от блестящих поверхностей, участки густого леса, напоминающие силуэт человека, головные уборы, похожие на каску. Затем модель переобучалась. После этого точность предсказания модели составила более 90 % (рис. 6).

Для обобщения полученных результатов на рис. 3 приведены оценочные метрики обучения модели с детекцией и сегментацией. К оценочным метрикам обучения относятся:

- метрика $\text{precision}(B)$ (точность для ограничивающих рамок) измеряет долю истинно положительных предсказаний к общему числу положительных предсказаний (истинно положительные и ложно положительные) и показывает, насколько точно модель определяет объекты;
- метрика $\text{recall}(B)$ (полнота для ограничивающих рамок) измеряет долю истинно положительных

предсказаний к фактическим положительным (истинно положительные и ложно отрицательные) и отражает способность модели находить все релевантные объекты.



Рис. 5. Аннотирование изображений в программном обеспечении AnyLabel Software

Fig. 5. Image annotation in software AnyLabel Software




Рис. 6. Результат сегментации объектов в кадре

Fig. 6. Object frame segmentation result

Одной из мер качества работы нейронной сети для идентификации объектов является численная метрика mAP (mean average precision). Метрика mAP в зависимости от граничного значения показателя IoU (Intersection over Union) разделяется на два вида. Наиболее часто используемыми являются граничные значения 0,5 и 0,95:

- $\text{mAP}_{50}(B)$ – средняя точность при пороге IoU 0,5. Эта метрика оценивает точность модели по нескольким классам, считая обнаружение правильным, если IoU с истинным значением составляет не менее 0,5;
- $\text{mAP}_{50-95}(B)$ – средняя точность по нескольким порогам IoU (от 0,5 до 0,95). Эта метрика дает более полное представление о производительности модели при различных уровнях точности обнаружения.

Порог IoU 0,5 означает, что для того, чтобы предсказание модели считалось правильным, об-

ласть перекрытия между предсказанным ограничивающим прямоугольником и истинным значением должна составлять не менее 50 %.

По метрикам модели на рис. 3 видно, что модель сегментации значительно превосходит модель детекции по точности (Precision (B)) и полноте (Recall (B)). Высокая точность и полнота модели сегментации указывают на её надежность и способность эффективно обнаруживать объекты без значительного количества ошибок. Модель сегментации также демонстрирует лучшие результаты по обоим метрикам mAP по сравнению с моделью детекции. Это говорит о том, что она более эффективна в задачах обнаружения объектов как при стандартных условиях (mAP50), так и при более строгих критериях (mAP50-95).

Перспективы и преимущества внедрения систем мониторинга

Внедрение систем мониторинга промышленной безопасности на основе ИИ и видеоаналитики открывает множество преимуществ для предприятий [6]. Во-первых, они позволяют значительно сократить затраты на физические проверки и инспекции, автоматизируя контроль за соблюдением норм безопасности. Во-вторых, такие системы помогают минимизировать человеческий фактор, который часто является причиной ошибок и аварий.

С точки зрения экономики, внедрение современных технологий безопасности позволяет сократить расходы на страхование, компенсации за травмы и убытки, связанные с авариями. Более того, улучшение условий труда приводит к повышению производительности работников и снижению текучести кадров.

Социальный аспект также играет важную роль. Создание более безопасной рабочей среды способствует повышению морального духа сотрудников,

улучшает их здоровье и снижает уровень стресса на производстве. Это, в свою очередь, положительно сказывается на репутации компании и её конкурентоспособности на рынке.

Заключение

Современные системы мониторинга промышленной безопасности и охраны труда играют ключевую роль в обеспечении безопасности сотрудников и предотвращении аварий на производственных объектах. Основными тенденциями, которые определяют развитие этой области, являются использование искусственного интеллекта, видеоаналитики и умных технологий. Эти инновационные подходы позволяют автоматизировать процессы контроля за соблюдением норм безопасности, снизить зависимость от человеческого фактора и повысить оперативность реагирования на потенциальные угрозы.

Однако с ростом использования цифровых технологий в сфере охраны труда возникает необходимость соблюдать законодательные требования [7], касающиеся защиты персональных данных и конфиденциальности. Это требует от предприятий не только внедрения высокотехнологичных решений, но и обеспечения их соответствия правовым нормам.

Таким образом, современные тенденции в системах мониторинга промышленной безопасности направлены на создание более безопасной и предсказуемой рабочей среды, что способствует повышению эффективности производства и снижению рисков для здоровья и жизни сотрудников. Внедрение таких систем становится не просто рекомендованным, но необходимым шагом для предприятий, стремящихся к созданию безопасных условий труда при высоких требованиях современной промышленности.

СПИСОК ЛИТЕРАТУРЫ

1. Автоматизированная система управления безопасностью труда на предприятиях с опасными производственными объектами / С.Ю. Ксандопуло, С.Ю. Маринин, В.В. Новиков, Г.В. Яковенко, С.А. Асадов, А.Г. Саенко // Современные наукоемкие технологии. – 2006. – № 6. – С. 82–84. EDN JRGQKL.
2. Шарафутдинов Д.К., Бадрутдинов М.Н., Сибатуллин Р.Р. Дидактические средства по охране труда при ремонте и реконструкции магистральных трубопроводов на основе графического дизайна и информационных технологий // Безопасность труда в промышленности. – 2011. – № 9. – С. 61–68.
3. Сведения о травматизме на производстве и профессиональных заболеваниях // Федеральная служба государственной статистики. URL: https://rosstat.gov.ru/working_conditions (дата обращения 26.09.2024).
4. Семенова А.Г., Данилова Е.В. Инновационные технологии как эффективные инструменты снижения производственного травматизма // Инновации и инвестиции. – 2019. – № 8. – С. 19–21.
5. An approach to progress monitoring of industrial manual processes based on camera recordings and object interactions / M. Mühlbauer, K. Kutzner, A. Sommer, H. Würschinger, N. Hanenkamp // Procedia CIRP. – 2022. – Vol. 107. – P. 582–587. DOI: <https://doi.org/10.1016/j.procir.2022.05.029>
6. Казиханов Б.Р. Цифровизация и автоматизация в системах охраны труда: преимущества, вызовы и перспективы // Охрана труда и техносферная безопасность на объектах промышленности, транспорта и социальных инфраструктур: Сборник статей III Всероссийской научно-практической конференции. – Пенза, 26–27 февраля 2024. – Пенза: Пензенский государственный аграрный университет, 2024. – С. 61–64.
7. Седова Ж.И. Требования законодательства при переходе на цифровые технологии в деятельности опасных производственных объектов // Пермский юридический альманах. – 2019. – № 2. – С. 128–137.

Информация об авторах

Константин Владимирович Чумаков, заведующий лабораторией искусственного интеллекта в промышленности, Национальный исследовательский Томский политехнический университет, Россия, 634050, г. Томск, пр. Ленина, 30, chumakovk@tpu.ru

Поступила в редакцию: 10.11.2024

Поступила после рецензирования: 17.12.2024

Принята к публикации: 28.12.2024

REFERENCES

1. Ksandopulo S.Yu., Marinin S.Yu., Novikov V.V., Yakovenko G.V., Asadov S.A., Saenko A.G. Automatic labor safety management system of industrial hazardous objects. *Modern science-intensive technologies*, 2006, no. 6, pp. 82–84. (In Russ.) EDN JRGQKL.
2. Sharafutdinov D.K., Badrutdinov M.N., Sibagatullin R.R. Didactic tools for labor protection during repair and reconstruction of main pipelines based on graphic design and information technology. *Labor Safety in Industry*, 2011, no. 9, pp. 61–68. (In Russ.)
3. Information on industrial injuries and occupational diseases. *Federal State Statistics Service*. (In Russ.) Available at: https://rosstat.gov.ru/working_conditions (accessed 26 September 2024).
4. Semenova A.G., Danilova E.V. Innovative technologies as effective tools to reduce industrial injuries. *Innovations and Investments*, 2019, no. 8, pp. 19–21. (In Russ.)
5. Mühlbauer M., Kutzner K., Sommer A., Würschinger H., Hanenkamp N. An approach to progress monitoring of industrial manual processes based on camera recordings and object interactions. *Procedia CIRP*, 2022, vol. 107, pp. 582–587. DOI: <https://doi.org/10.1016/j.procir.2022.05.029>
6. Kazikhanov B.R. Digitalization and automation in labor protection systems: advantages, challenges and prospects. *Labor protection and technosphere safety at industrial, transport and social infrastructure facilities. Collection of articles of the III All-Russian scientific and practical conference*. Penza, February 26–27, 2024. Penza, Penza State Agrarian University Publ., 2024. pp. 61–64. (In Russ.)
7. Sedova Zh.I. Legislation requirements for the transition to digital technologies in the activities of hazardous production facilities. *Perm Legal Almanac*, 2019, no. 2, pp. 128–137. (In Russ.)

Information about the authors

Konstantin V. Chumakov, Head of the Laboratory of Artificial Intelligence in Industry, National Research Tomsk Polytechnic University, 30, Lenin ave., Tomsk, 634050, Russian Federation, Россия, chumakovk@tpu.ru

Received: 10.11.2024

Revised: 17.12.2024

Accepted: 28.12.2024