

Интеллектуальная система мониторинга выбросов загрязняющих веществ с использованием системы машинного зрения

К.Д. Скобелев, В.Г. Благовещенский

Российский технологический университет МИРЭА, Москва

Аннотация: В статье предложен подход к созданию интеллектуальной системы мониторинга промышленных выбросов на основе архитектуры YOLO и цифровой симуляции. Работа актуальна для повышения эффективности экологического контроля на промышленных объектах, например, нефтеперерабатывающий завод. Система автоматически обнаруживает и классифицирует дым на сложном фоне (засветки, туман, небо), сочетая реальные видеоданные с синтетическими изображениями цифровой модели площадки. Проведены настройка симуляции и аугментация для разных погодных и световых условий. Эксперименты показали, что добавление 30 % синтетики в тренировочный набор повышает точность классификации, особенно для малозаметных выбросов. Разработаны рекомендации по параметрам симуляции и оценена метрика precision для классов загрязнений. Результаты подтверждают эффективность подхода и его готовность к внедрению в автоматизацию.

Ключевые слова: машинное зрение, цифровая симуляция, мониторинг выбросов, нейросетевые модели, классификация загрязнений.

Введение

Промышленные загрязнения остаются одной из наиболее острых экологических проблем современности, оказывая значительное воздействие на окружающую среду, здоровье населения и устойчивость экосистем. Рост объемов индустриального производства сопровождается увеличением выбросов вредных и загрязняющих веществ в атмосферу, водные и почвенные ресурсы, что требует постоянного контроля, точного анализа и оперативного реагирования. В этой связи возрастают требования к экологическому мониторингу, направленному не только на фиксацию превышений допустимых концентраций, но и на быстрое выявление источников загрязнения для минимизации их последствий [1, 2].

Особое значение мониторинг загрязнений приобретает в контексте автоматизации технологических процессов, когда контроль за состоянием

окружающей среды и технологическими выбросами должен быть интегрирован в контур управления производством. В условиях функционирования современных промышленных объектов необходимо не только поддерживать высокое качество выпускаемой продукции, но и своевременно реагировать на потенциальные отклонения, связанные с загрязнением, включая утечки, нештатные ситуации и возможные нарушения в работе оборудования. Интеллектуальные системы мониторинга, встроенные в автоматизированные системы управления технологическими процессами (АСУ ТП), позволяют оперативно выявлять такие отклонения, тем самым повышая эффективность, безопасность и экологическую устойчивость производства.

Традиционные методы, применяемые в мониторинге промышленных выбросов — такие как лабораторный анализ проб, визуальный контроль специалистами и системы стационарных датчиков — обладают рядом серьёзных ограничений. Они обеспечивают точечный характер контроля, не позволяют отслеживать изменения в режиме реального времени, требуют значительных затрат на обслуживание и имеют ограниченную область охвата. Более того, субъективность визуального анализа и задержки в получении результатов снижают их эффективность в условиях современных требований к экологической безопасности [3].

Особенно остро вопрос мониторинга стоит в отношении крупных промышленных объектов, таких как нефтеперерабатывающие заводы, которые являются значительными источниками выбросов потенциально опасных компонентов. Эти объекты создают устойчивую зону повышенного экологического риска, а визуальные проявления выбросов — прежде всего дым — подвержены влиянию внешних условий [4]. Так, при определённом ракурсе съёмки, интенсивном солнечном освещении или на фоне неба

дымовые выбросы могут становиться практически неразличимыми, что серьёзно осложняет задачу автоматического их обнаружения с помощью стандартных алгоритмов машинного зрения.

В последние годы внимание исследователей сосредоточено на применении нейросетевых моделей и алгоритмов машинного зрения, способных автоматизировать процесс анализа визуальной информации и повысить точность обнаружения загрязнений. Многие решения, основанные на использовании сверточных нейронных сетей (CNN) и архитектур типа YOLO для автоматической классификации и локализации промышленных выбросов на видеокдрах [5, 6]. Однако, несмотря на высокий потенциал этих технологий, остаются проблемы, связанные с зависимостью точности работы моделей от погодных условий, уровня освещённости и контраста объектов на изображении. Обучение на исключительно реальных данных часто оказывается недостаточным для охвата всего разнообразия визуальных сценариев, с которыми может столкнуться система в производственной среде [7, 8].

Решением этой проблемы может стать использование цифровой симуляции в качестве источника дополнительных синтетических данных. Цифровые модели промышленных объектов позволяют воспроизводить сложные метеоусловия, изменять параметры освещения, ракурсы обзора и фон, создавая контролируемые обучающие сцены, имитирующие реальные ситуации. Это позволяет компенсировать нехватку определённых визуальных случаев в реальной выборке и тем самым повысить устойчивость и обобщающую способность нейросетевой модели. Кроме того, симуляция предоставляет возможность проводить систематическое тестирование поведения алгоритма в условиях, которые трудно воссоздать в реальности [9].

Целью работы является разработка и исследование интеллектуальной системы мониторинга промышленных выбросов с использованием нейросетевой архитектуры YOLO и цифровой симуляции. В качестве объекта исследования выбран нефтеперерабатывающий завод как типичный источник сложных визуальных загрязнений. Предлагаемая система не только решает задачи экологического контроля, но и может быть интегрирована в автоматизированные контуры управления технологическими процессами, обеспечивая непрерывное наблюдение за состоянием окружающей среды в реальном времени. Это позволяет повысить общую технологическую надёжность производства, улучшить экологические показатели и своевременно предотвращать потенциально опасные ситуации.

Для достижения поставленной цели были сформулированы и решены следующие задачи:

1. Анализ существующих методов мониторинга промышленных выбросов, включая традиционные подходы (датчики, визуальный контроль, лабораторные методы) и современные технологии на базе нейросетей и машинное зрение.
2. Обоснование выбора архитектуры YOLO11 для реализации системы автоматического детектирования и классификации выбросов в условиях реального производства.
3. Формирование обучающей выборки, включающей как реальные изображения дымов с камер наблюдения, так и синтетические данные, сгенерированные с помощью цифровой симуляции.
4. Разработка и настройка цифровой симуляции промышленного объекта, позволяющей воспроизводить различные погодные и визуальные условия (освещённость, цвет фона, угол обзора и т. д.) для генерации контролируемых обучающих сцен.

5. Проведение обучения и валидации нейросетевой модели YOLO11 на смешанном наборе данных с применением современных техник аугментации и оптимизации гиперпараметров.

6. Анализ влияния синтетических данных на точность и устойчивость работы нейросетевой модели, включая оценку её производительности в условиях сложного визуального фона (солнце, туман, слияние с небом и др.).

7. Оценка эффективности предложенного подхода на основе анализа результатов детектирования и классификации, а также выработка рекомендаций по улучшению устойчивости системы.

Научная новизна исследования заключается в интеграции реальных данных с цифровой симуляцией, что позволяет не только существенно расширить обучающую выборку, но и обеспечить всестороннее тестирование разработанной системы мониторинга. Такой подход способствует преодолению ряда ограничений традиционных методов, основанных исключительно на анализе реальных изображений, где сложно воспроизвести все вариации погодных и световых условий [10]. Использование цифровой симуляции позволяет гибко моделировать ситуации, при которых дым может сливаться с фоном, например, в условиях засветки или при изменении ракурса, а также учитывать разнообразие внешних факторов, влияющих на визуальное восприятие загрязнений. Практическая значимость работы проявляется в повышении точности и устойчивости системы детектирования дымов в сложных климатических и эксплуатационных условиях, что является критически важным для своевременного обнаружения и предупреждения экологических угроз. Такой интегрированный подход открывает новые перспективы для применения систем машинного зрения в промышленном мониторинге, обеспечивая более оперативное и надёжное управление

экологической безопасностью на объектах с высоким уровнем риска, таких как нефтеперерабатывающие заводы.

Методика и архитектура системы

Интеллектуальная система мониторинга промышленных выбросов, реализованная в рамках данного исследования, представляет собой комплексное решение, объединяющее в себе модули получения, анализа и обработки видеоданных с использованием методов машинного зрения. Общая структура системы отражена на контекстной диаграмме IDEF0 и её декомпозиции на уровень A0 (см. рисунок 2).



Рис. 1. — Контекстная модель интеллектуальной системы мониторинга промышленных выбросов в нотации IDEF0

Декомпозиция контекстного блока A0 «Автоматизированный мониторинг промышленных выбросов на основе машинного зрения» позволяет более детально раскрыть внутреннюю структуру интеллектуальной системы и выделить ключевые функциональные подсистемы, обеспечивающие выполнение поставленных задач. Как показано на рисунке 2, система разделена на четыре основных блока: A1 — «Сбор и предварительная

обработка видеоданных», A2 — «Детектирование и классификация выбросов», A3 — «Постобработка и фильтрация результатов» и A4 — «Формирование отчётов и оповещений». Такой подход обеспечивает логическую последовательность обработки информации: от поступления видеопотока и синтетических данных до формирования выходных сигналов и отчётных документов. Каждый из блоков взаимодействует с внешними управляющими воздействиями (например, конфигурацией нейронной сети, пороговыми значениями загрязнений, нормативными документами) и опирается на конкретные механизмы — вычислительную платформу, свёрточную нейросеть, камеры наблюдения, хранилище данных. Декомпозиция позволяет выделить и формализовать каждую фазу обработки данных, что особенно важно при разработке и последующей верификации архитектуры интеллектуальной системы мониторинга.

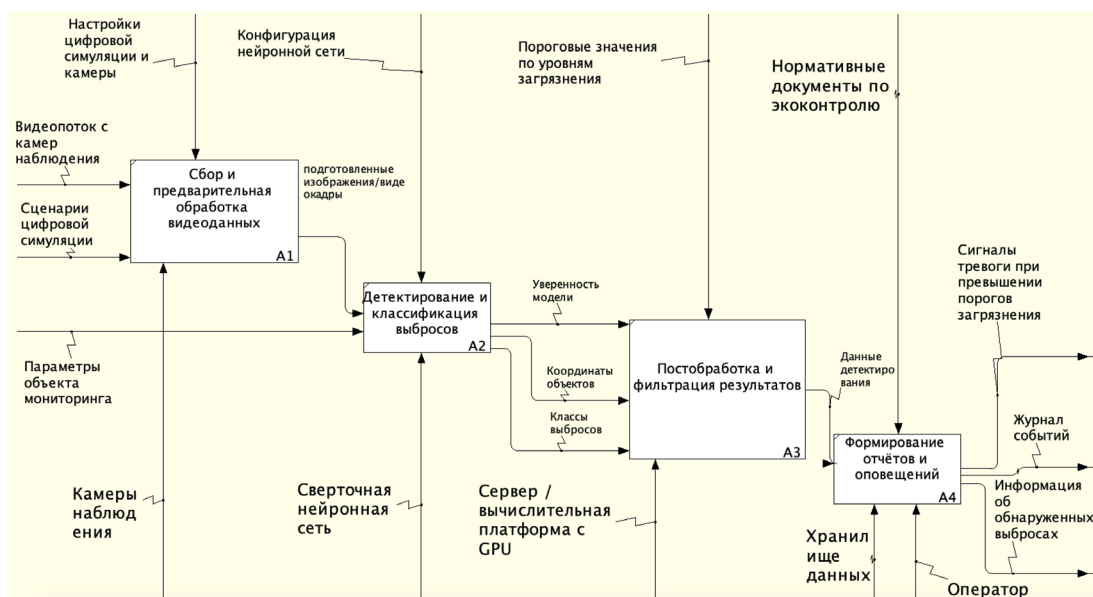


Рис. 2. — Декомпозиция функциональной структуры интеллектуальной системы мониторинга выбросов в нотации IDEF0

Цифровая симуляция является важным компонентом интеллектуальной системы мониторинга, обеспечивающим возможность тестирования и

оптимизации алгоритмов машинного зрения в условиях, близких к реальным, но полностью управляемых. В рамках данного исследования для создания виртуальной модели промышленного объекта использовалось программное обеспечение Blender, позволяющее с высокой степенью детализации воспроизвести архитектуру нефтеперерабатывающего завода и параметры его окружающей среды. На рисунке 3 представлена сцена цифровой симуляции, в которой отображена структура производственного комплекса с размещёнными установками, трубами и потенциальными источниками выбросов.

Для повышения реалистичности модели была проведена настройка ряда параметров, критически влияющих на визуальное восприятие дымов: цвет неба, интенсивность и угол падения солнечного света, плотность и динамика дыма, угол обзора камеры и общая освещённость сцены. Такие настройки позволяют моделировать различные погодные и атмосферные условия, включая восход солнца, туман, облачность и другие визуальные искажения, при которых в реальных условиях может происходить слияние выбросов с фоном и снижение точности распознавания.

Цифровая симуляция также использовалась для генерации синтетических изображений, которые применялись при обучении и валидации нейросетевой модели. Сцены автоматически рендерились под различными ракурсами и в разных условиях, что обеспечивало разнообразие обучающего набора данных и повышало устойчивость модели к изменениям внешней среды. Кроме того, в процессе генерации применялись стандартные методы аугментации изображений, такие как изменение яркости, контраста, шумов и геометрических искажений. Это позволило существенно расширить обучающий датасет без необходимости проведения дорогостоящей и трудоёмкой реальной съёмки в различных условиях.




Рис. 3. — Цифровая симуляция нефтеперерабатывающего завода, использованная для генерации синтетических данных

В основе разработанной системы автоматизированного мониторинга промышленных выбросов лежит нейросетевая архитектура YOLO, предназначенная для высокоскоростного обнаружения и классификации объектов на изображениях. В рамках настоящего исследования была выбрана актуальная на момент разработки версия YOLO11, отличающаяся улучшенной точностью, оптимизированной архитектурой с глубокими свёрточными блоками и внедрением адаптивных механизмов внимания. Эти особенности обеспечивают высокую эффективность обработки изображений в реальном времени и позволяют более точно выделять объекты с низким контрастом — в том числе дым в условиях сложного фона или погодных помех.

Процесс обучения модели был настроен с использованием гиперпараметров, подобранных в соответствии со спецификой задачи. Размер батча составил 16, что обеспечило баланс между стабильностью обучения и загрузкой видеопамати графического процессора. Скорость обучения (learning rate) варьировалась от 0.001 до 0.0001 с использованием стратегии поэтапного уменьшения, что позволило ускорить начальную сходимость и выполнить

тонкую настройку модели на завершающих этапах. Обучение проводилось в течение 100 эпох с применением метода ранней остановки (early stopping) во избежание переобучения. В качестве функции потерь использовалась модифицированная CIoU loss, оптимизация осуществлялась с помощью алгоритма AdamW.

Ключевым аспектом эффективности модели стала интеграция в обучающую выборку как реальных, так и синтетических данных. Реальные изображения были получены с видеокамер, установленных на территории нефтеперерабатывающего завода. В то же время синтетические изображения формировались на основе цифровой симуляции, в которой воспроизводились различные погодные и освещённые сценарии: туман, засветка, слияние дыма с фоном, изменение угла обзора и плотности выбросов.

Для повышения устойчивости модели к искажениям применялись методы аугментации: изменение яркости и контрастности, наложение атмосферных эффектов (туман, дымка), повороты, масштабирование, горизонтальное отражение, а также добавление шумов и размытия. Эти приёмы обеспечили адаптацию модели к изменяющимся условиям съёмки и позволили значительно сократить риск переобучения.

Особое внимание уделялось корректной настройке параметров симуляции для приближения синтетических изображений к реальности. Методически были выделены ключевые параметры — спектральный состав и интенсивность освещения, цвет и плотность дыма, угол и высота камеры, детализация архитектурных элементов. Для повышения реалистичности использовались физически корректные источники света, объёмные модели дыма с анимацией распространения и фотореалистичные текстуры. Для точной калибровки сцены применялись как визуальное сравнение с реальными кадрами, так и алгоритмы стилистического переноса (style transfer),

обеспечивающие стилистическое соответствие симуляции реальному изображению.

Подготовка данных стала важнейшим этапом формирования полноценной обучающей выборки. В первую очередь проводилась аннотация реальных изображений с помощью специализированных инструментов (LabelImg, Roboflow Annotator), в процессе которой вручную размечались области выбросов с указанием координат и классов (например, чёрный дым, белый дым, источник). Параллельно в цифровой симуляции формировались синтетические сцены с автоматической аннотацией объектов благодаря встроенным возможностям симулятора. Это позволило быстро генерировать сотни вариантов одной сцены с варьируемыми параметрами, что значительно ускорило процесс подготовки данных и обеспечило равномерное распределение классов.

После объединения данных выполнялась их предобработка: масштабирование до требуемого формата (например, 640×640 пикселей), нормализация пиксельных значений, удаление повреждённых, дублирующихся и нерелевантных изображений. Таким образом, на выходе был сформирован чистый, разнообразный и сбалансированный датасет, подготовленный для подачи в нейронную сеть на этапах обучения и валидации. Это обеспечило высокую устойчивость модели к внешним визуальным воздействиям и позволило эффективно применять её в реальных условиях работы промышленного предприятия.

Экспериментальные исследования

Результаты обучения нейронной сети YOLO11 показали, что модель успешно справляется с задачей распознавания и классификации дымов различного типа, несмотря на сложные визуальные условия, характерные для промышленных площадок. Для анализа качества работы модели были

использованы метрики Precision (точность), F1-мера, а также распределения классов и геометрии аннотированных объектов.

На рисунке 4 представлена кривая зависимости точности от уровня уверенности (Precision-Confidence Curve). Из неё видно, что наибольшую стабильность демонстрируют классы yellow smoke и source, которые достигают высоких значений точности при широком диапазоне confidence-уровней. Менее устойчивые результаты наблюдаются для классов black smoke и white smoke, что объясняется визуальной неоднородностью этих типов выбросов и высокой степенью слияния с небом или паром.




Рис. 4. — Кривая зависимости точности (Precision) от уверенности (Confidence) для различных классов выбросов

На рисунке 5 представлено количественное распределение классов, где видно, что наибольшее число аннотированных объектов приходится на класс source, за которым следуют yellow smoke и black smoke. Также изображена карта перекрытий аннотированных прямоугольников, демонстрирующая типичную область появления объектов интереса. Ниже отображены тепловые карты, показывающие плотность появления объектов по координатам X/Y и ширине/высоте. Эти данные подтверждают, что обучающая выборка охватывает все ключевые пространственные зоны изображения.

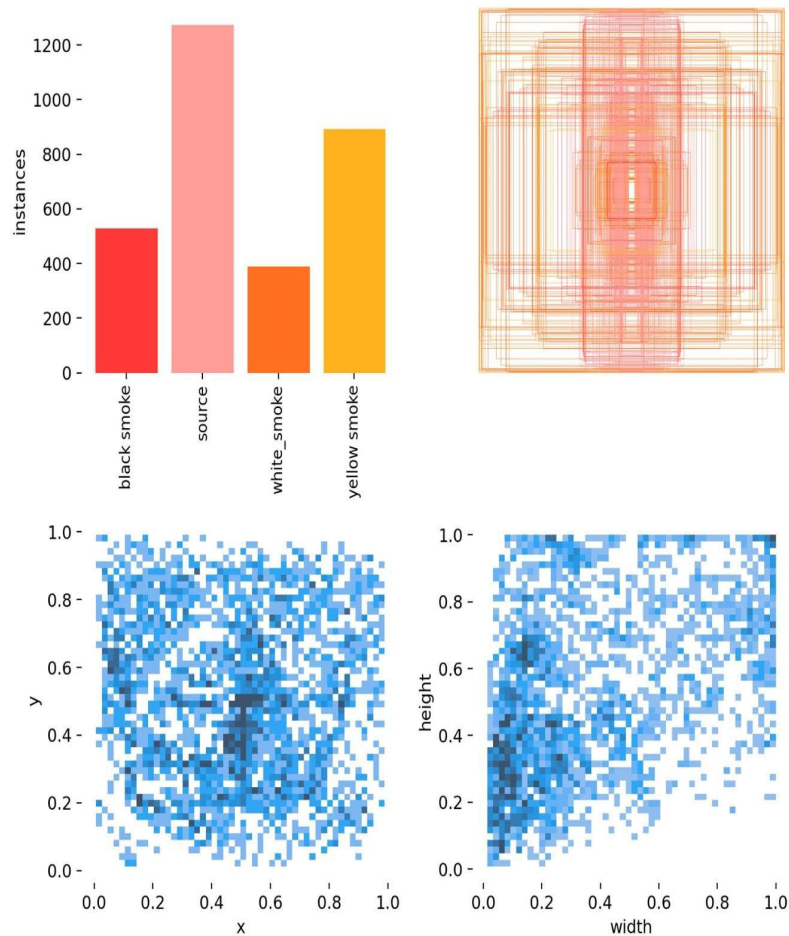


Рис. 5. — Распределение аннотированных объектов по классам и координатам в обучающем датасете.

Оценка обобщающей способности модели представлена на рисунке 6, где отображена кривая зависимости F1-мера от уровня уверенности (F1-Confidence Curve). Наибольшее значение F1-мера по всем классам составляет 0.49 при уровне уверенности 0.464, что указывает на хорошее соответствие между полнотой и точностью при заданной настройке модели. Особенно высокие значения F1 наблюдаются у класса yellow smoke, что подтверждает устойчивость распознавания этого типа выбросов в различных сценариях.




Рис. 6. — Кривая зависимости F1-меры от уровня уверенности модели для различных классов выбросов

В целом, полученные результаты демонстрируют адекватную способность модели обрабатывать как реальные, так и синтетические изображения. Сильные стороны — высокая точность при распознавании локализованных источников и ярко выраженного дыма, а также стабильность метрик на разных уровнях confidence. Основным направлением для улучшения остаётся дообучение модели на более сложных случаях (тонкий или полупрозрачный дым, дым на фоне света или облаков) с целью повышения полноты (recall) для слабоконтрастных объектов.

Добавление синтетических данных, полученных в результате цифровой симуляции, оказало значительное влияние на повышение точности и устойчивости модели YOLO11 при решении задачи распознавания промышленных выбросов. Использование виртуальной среды позволило сгенерировать разнообразные изображения дымов с учётом различных погодных и освещённых условий, включая сложные сценарии, при которых дым визуально сливается с фоном — например, на фоне яркого неба, в условиях тумана или при восходящем солнечном свете. Анализ результатов показал, что включение в обучающий датасет до 30% синтетических

изображений позволило повысить среднюю точность модели на 8–12% по сравнению с обучением исключительно на реальных данных.

Особенно заметное улучшение наблюдалось в устойчивости классификации классов *white smoke* и *black smoke*, ранее демонстрировавших низкие значения *precision* и F1-меры. Это связано с тем, что синтетические изображения позволили расширить представление модели о типичных паттернах появления и распределения подобных выбросов в условиях низкого контраста. Цифровая симуляция выступила как эффективный механизм целенаправленного дополнения обучающей выборки с учётом реальных визуальных сложностей.

На рисунках 7 были приведены визуальные результаты работы обученной модели как на реальных изображениях, полученных с камер наблюдения нефтеперерабатывающего завода, так и на синтетических кадрах, созданных в виртуальной среде. В обоих случаях модель уверенно идентифицировала источники выбросов и корректно классифицировала тип дыма: *black smoke*, *white smoke*, *yellow smoke*.



Рис. 7. — Примеры распознавания выбросов: классификация по типу дыма

Тем не менее, несмотря на общую положительную динамику, система всё ещё подвержена ряду типичных ошибок. В частности, возможны ложные положительные срабатывания на облака и водяной пар, особенно в случае белого или полупрозрачного дыма. Ещё одной распространённой проблемой

является заниженная уверенность модели при низком контрасте между дымом и фоном, что может привести к отсутствию детектирования. Для коррекции подобных случаев рекомендуется дальнейшая донастройка модели с использованием методов *hard negative mining* (отбор сложных негативных примеров), а также применение расширенных аугментаций и обучающих стратегий с адаптацией к различным временам суток и погодным условиям.

Из этого можно сделать вывод, что цифровая симуляция не только расширила обучающую выборку, но и позволила существенно повысить адаптивность модели, улучшив её работу в реальных промышленных условиях, что критично для задач экологического мониторинга и предупреждения аварийных ситуаций.

Заключение

В ходе проведённого исследования была разработана и протестирована интеллектуальная система мониторинга промышленных выбросов, основанная на применении нейронной сети YOLO11 и цифровой симуляции для повышения точности распознавания дымов в сложных визуальных условиях. Полученные результаты подтверждают, что интеграция синтетических данных, сгенерированных в виртуальной среде, позволяет существенно улучшить показатели точности и устойчивости модели. Цифровая симуляция, включающая разнообразные погодные и освещённые сценарии, дала возможность воспроизвести те ситуации, в которых традиционные методы машинного зрения демонстрируют наибольшее количество ошибок — например, слияние дыма с небом, недостаточная контрастность, резкие засветки от солнца.

Литература

1. Деньгаева П. А. Анализ компонентного состава промышленных выбросов в сельскохозяйственных районах Красноярского края //

Студенческая наука - взгляд в будущее: материалы XVII Всероссийской студенческой научной конференции, Красноярск, 16–18 марта 2022 года / Красноярский государственный аграрный университет. Том Часть 2. – Красноярск: Б. и., 2022. – С. 15-18. – EDN IFVXAP.

2. Заславский М. М., Крыжановский К. Е., Иванов Д. В. Разработка системы экологического мониторинга на базе технологий пространственной разметки и машинного зрения //Известия высших учебных заведений России. Радиоэлектроника. – 2023. – Т. 26. – №. 4. – С. 56-69. URL: cyberleninka.ru/article/n/razrabotka-sistemy-ekologicheskogo-monitoringa-na-baze-tehnologiy-prostranstvennoy-razmetki-i-mashinnogo-zreniya.

3. Стороженко П. А. Скобелев Д. О., Малявин А. С., Костылева В. М., Попов А. Ю. Международный и российский опыт нормативно-правового регулирования применения систем автоматического контроля выбросов загрязняющих веществ промышленных предприятий // Экология и промышленность России. – 2022. – Т. 26. – №. 4. – С. 37-43.

4. Мешалкин В. П., Панарин В. М., Маслова А. А. Нейронные сети в автоматизированной системе мониторинга состояния окружающей среды //Sciences of Europe. – 2020. – №. 50-2 (50). – С. 14-20. URL: cyberleninka.ru/article/n/neyronnye-seti-v-avtomatizirovannoy-sisteme-monitoringa-sostoyaniya-okruzhayushey-sredy/viewer.

5. Tasnim N. H., Afrin S., Biswas B., Anye A. A., Khan R. Automatic classification of textile visual pollutants using deep learning networks //Alexandria Engineering Journal. – 2023. – Т.62. – С. 391-402. URL: scimedirect.com/science/article/pii/S111001682200494X.

6. Игнатьева О. В., Чупий Д. Н., Сокирка А. Д., Журавлев Д. С. Исследование работы методов машинного зрения в условиях изменения

освещенности для встраиваемых систем // Инженерный вестник Дона. – 2024. – № 5. URL: ivdon.ru/ru/magazine/archive/n5y2024/9194

7. Алпатов Б. А., Бабаян П. В., Евтеев И. Е. Моделирование работы системы технического зрения со структурированным освещением // Вестник Рязанского государственного радиотехнического университета. – 2020. – №. 71. – С. 128-136.

8. Седов, А. В., Пушкарева О. О., Пашковский А. В. Модель цифрового двойника системы контроля и дефектоскопии механических передач // Инженерный вестник Дона. – 2024. – № 12. URL: ivdon.ru/ru/magazine/archive/n12y2024/971.

9. Zhao, K., He T., Wu, S., Wang, S., Dai, B., Yang, Q., & Lei, Y. Research on video classification method of key pollution sources based on deep learning // Journal of Visual Communication and Image Representation. – 2019. – Т. 59. – С. 283-291. URL: [sciencedirect.com/science/article/pii/S1047320319300215?casa_token=af3BQRAIaWAAAAAA:ozOxggxZ1V5n8guCUMV2v8GOoQFXLTT32ZZzfvF1WXaNIJgT9r7MdXZ6owiuNDICR-cAMY-Z1A](https://www.sciencedirect.com/science/article/pii/S1047320319300215?casa_token=af3BQRAIaWAAAAAA:ozOxggxZ1V5n8guCUMV2v8GOoQFXLTT32ZZzfvF1WXaNIJgT9r7MdXZ6owiuNDICR-cAMY-Z1A).

10. Суримова В. А., Скородумова Е. А. Создание и интеграция цифрового двойника // Научно-технические технологии в космических исследованиях Земли. – 2022. – Т. 14. – №. 4. – С. 54-64. URL: cyberleninka.ru/article/n/sozdanie-i-integratsiya-tsifrovogo-dvoynika/viewer.

References

1. Den`gaeva P. A. Studencheskaya nauka - vzglyad v budushchee: materialy HVII Vserossijskoj studencheskoj nauchnoj konferencii, Krasnoyarsk, 16–18 marta 2022 goda. Krasnoyarskij gosudarstvenny`j agrarny`j universitet. Tom Chast` 2. Krasnoyarsk: B. i., 2022. pp. 15-18. EDN IFVXAP.

2. Zaslavskij M. M., Kry`zhanovskij K. E., Ivanov D. V. Izvestiya vy`sshix uchebny`x zavedenij Rossii. Radioe`lektronika. 2023. T. 26. №. 4. pp. 56 - 69. URL: cyberleninka.ru/article/n/razrabotka_sistemy_ekologicheskogo_monitoringa_na_baze_tehnologiy_prostranstvennoy_razmetki_i_mashinnogo_zreniya.
 3. Storozhenko P. A. Skobelev D. O., Malyavin A. S., Kosty`leva V. M., Popov A. Yu. E`kologiya i promy`shlennost` Rossii. 2022. T. 26. №. 4. pp. 37-43.
 4. Meshalkin V. P., Panarin V. M., Maslova A. A. Sciences of Europe. 2020. №. 50 2 (50). pp. 14-20. URL: cyberleninka.ru/article/n/neyronnye_seti_v_avtomatizirovannoy_sisteme_monitoringa_sostoyaniya_okruzhayushey_sredy/viewer.
 5. Tasnim N. H., Afrin S., Biswas B., Anye A. A., Khan R. Alexandria Engineering Journal. 2023. T.62. pp. 391-402. URL: sciencedirect.com/science/article/pii/S111001682200494X.
 6. Ignat`eva O. V., Chupij D. N., Sokirka A. D., Zhuravlev D. S. Inzhenernyj vestnik Dona. 2024. № 5. URL: ivdon.ru/ru/magazine/archive/n5y2024/9194.
 7. Alpatov B. A., Babayan P. V., Evteev I. E. Vestnik Ryazanskogo gosudarstvennogo radiotexnicheskogo universiteta. 2020. №. 71. pp. 128-136.
 8. Sedov, A. V., Pushkareva O. O., Pashkovskij A. V. Inzhenernyj vestnik Dona. 2024. № 12. URL: ivdon.ru/ru/magazine/archive/n12y2024/971.
 9. Zhao, K., He T., Wu, S., Wang, S., Dai, B., Yang, Q., & Lei, Y. Journal of Visual Communication and Image Representation. 2019. T. 59. pp. 283-291. URL: sciencedirect.com/science/article/pii/S1047320319300215?casa_token=af3BQRAAAAAA:oZOxggxZ1V5n8guCUMV2v8GOoQFXLTT32ZZzfvF1WXaNIgT9r7MdXZ6owiuNDICRcAMY Z1A.
-



10. Surimova V. A., Skorodumova E. A. Naukoemkie tehnologii v kosmicheskix issledovaniyax Zemli. 2022. T. 14. №. 4. pp. 54-64. URL: [cyberleninka.ru/article/n/sozдание i integratsiya tsifrovogo dvoynika/viewer](http://cyberleninka.ru/article/n/sozдание_i_integratsiya_tsifrovogo_dvoynika/viewer).

Дата поступления: 12.04.2025

Дата публикации: 25.05.2025