

Математические, информационные и интеллектуальные технологии в энергетике

УДК 621.311.25-047.36:004.032.26:004.932

DOI:10.25729/ESI.2026.42.2.009

Обучение сверточной нейросетевой модели методом Active learning для мониторинга безопасности объектов теплоэнергетики

Кулагина Людмила Владимировна, Шефер Эдуард Артурович

Сибирский федеральный университет, Россия, Красноярск, shefer.eduardov-119sp@list.ru

Аннотация. Обеспечение промышленной безопасности объектов теплоэнергетики сопряжено с необходимостью применения эффективных и надежных средств раннего обнаружения потенциально пожароопасных и аварийных ситуаций. Эта задача осложняется специфическими условиями эксплуатации, характеризующимися широким диапазоном рабочих режимов, высоким уровнем электромагнитных помех и вибраций, а также, зачастую, ограниченным объемом размеченных данных, пригодных для обучения и верификации систем мониторинга и прогнозирования. Целью данной работы является разработка и экспериментальная валидация комплексного подхода к повышению точности и надежности систем компьютерного зрения для мониторинга безопасности теплоэнергетических объектов на основе методологии активного обучения. В качестве основных методов используются сверточные нейросетевые модели детекции объектов архитектуры YOLOv8, эвристический механизм отбора информативных данных по метрике неопределенности, а также инструменты объяснимого искусственного интеллекта и отказоустойчивого принятия решений с участием эксперта. Научная новизна работы заключается в адаптации методов Active Learning к однопроходным детекторам для задач промышленной безопасности, а также в интеграции цикла целевой доразметки сложных примеров с механизмами интерпретации и гибридной верификации результатов (что позволяет минимизировать затраты на разметку (за счёт выборочного запроса «сложных» примеров); оперативно адаптироваться к новым типам аномалий (например, нестандартным утечкам, локальным перегревам)); тогда как в большинстве публикаций по безопасности теплоэнергетических объектов используются классические методы машинного обучения (SVM, случайные леса) либо предобученные CNN без адаптации под специфику отрасли. В выполненной работе экспериментальные исследования на специализированном датасете изображений объектов теплоэнергетики показали, что применение активного обучения обеспечивает прирост показателя mAP@0.5:0.95 на 28,32 % и увеличение полноты обнаружения на 7,82 % по сравнению со стандартным обучением. Полученные результаты подтверждают перспективность предложенного подхода для практического применения в системах мониторинга и раннего оповещения, способных обеспечить своевременное выявление отклонений от нормальных параметров функционирования оборудования и предотвращение развития аварийных сценариев.

Ключевые слова: активное обучение, сверточные нейросети, YOLOv8, промышленная безопасность, объекты теплоэнергетики

Цитирование: Кулагина Л.В. Обучение сверточной нейросетевой модели методом Active learning для мониторинга безопасности объектов теплоэнергетики / Л.В. Кулагина, Э.А. Шефер // Информационные и математические технологии в науке и управлении, 2026. – № 2(42). – С. 117-127. – DOI:10.25729/ESI.2026.42.2.009.

Введение. Объекты теплоэнергетики, включая котельные установки, теплоэлектроцентрали, системы теплогенерации и теплообменное оборудование, относятся к категории потенциально опасных производственных объектов. Их эксплуатация осуществляется в условиях высоких температур, давления и непрерывных технологических процессов, что предъявляет повышенные требования к системам мониторинга и раннего обнаружения нештатных ситуаций. Современные тенденции модернизации теплоэнергетических объектов, направленные на повышение энергетической эффективности и автоматизацию управления, приводят к усложнению режимов эксплуатации и росту требований к надежности средств промышленной безопасности. Одним из перспективных направлений повышения уровня безопасности является применение методов искусственного

интеллекта и компьютерного зрения для автоматического обнаружения пожароопасных ситуаций, таких, как возгорание, задымление и аномальные тепловые режимы. Сверточные нейросетевые модели продемонстрировали высокую эффективность в задачах распознавания визуальных образов, однако их практическое внедрение в промышленную сферу сталкивается с рядом ограничений.

Ключевой проблемой является дефицит специализированных размеченных данных, отражающих реальную специфику теплоэнергетических объектов, включая особенности визуального проявления дыма и пламени на фоне технологического оборудования, влияние инфракрасного и видимого спектров, а также редкость аварийных событий и выраженный дисбаланс классов, в отличие от задач общего компьютерного зрения, для которых доступны крупные открытые датасеты. В области промышленной безопасности теплоэнергетики универсальные наборы данных оказываются недостаточно репрезентативными, что обуславливает необходимость разработки методов, позволяющих эффективно использовать ограниченные объемы данных и целенаправленно повышать качество моделей за счет привлечения экспертных знаний. В этом контексте особый интерес представляет методология активного обучения (Active Learning), предполагающая итеративный отбор наиболее информативных примеров для последующей разметки и дообучения модели.

Значительный массив исследований по применению методов искусственного интеллекта для распознавания аварийных ситуаций накоплен в смежных областях промышленной безопасности. В частности, активно развиваются методы компьютерного зрения для раннего обнаружения лесных пожаров, основанных на анализе динамики дыма и пламени, а также системы мониторинга аварий на объектах химической и горнодобывающей промышленности, где используются модели для выявления утечек, взрывов и разрушений оборудования.

Существенный опыт также накоплен в задачах визуального и сенсорного контроля транспортных систем и объектов хранения горючих сред, вместе с тем прямой перенос указанных решений на объекты теплоэнергетики оказывается затруднительным вследствие отличий в характере визуального фона, преобладания технологического пара, высокотемпературного пара, высокотемпературных поверхностей и специфике режимов эксплуатации [1-5].

Целью данной работы является разработка комплексного подхода к обучению сверточной нейросетевой модели детекции пожароопасных ситуаций на объектах теплоэнергетики с использованием активного обучения, а также экспериментальная оценка эффективности предложенного решения по сравнению со стандартным обучением [6-8].

1. Специфика визуального мониторинга объектов теплоэнергетики и подготовка данных. Визуальный мониторинг объектов теплоэнергетики обладает рядом специфических особенностей, существенно отличающих его от задач общего назначения. Во-первых, целевые признаки аварийных ситуаций, такие, как дым и пламя, часто имеют размытые границы и неустойчивую форму, а их визуальное проявление зависит от условий освещения, ракурса съемки и спектрального диапазона. Во-вторых, на изображениях присутствуют интенсивные фоновые помехи, связанные с нагретыми поверхностями, парообразованием, отражениями и вибрациями оборудования. В-третьих, аварийные события являются редкими, что приводит к сильному дисбалансу между классами «норма» и «опасная ситуация».

Указанные факторы существенно осложняют применение стандартных подходов к обучению нейросетевых моделей и делают недостаточным использование универсальных датасетов, сформированных для общих задач детекции огня или дыма. В рамках данной работы исходные данные формировались на основе изображений объектов теплоэнергетики,

включая котельные и теплогенерирующие установки, в видимом спектре и с учетом характерных условий эксплуатации.

Подготовка входных данных включает в себя поиск качественных материалов, а также их предобработку, которая включает в себя разметку боксов и присвоение классов объектам. Зачастую практика такова, что большинство обучений происходит на заранее сформированном наборе данных [9-11] взятом из интернет-ресурсов, таких, как: «Roboflow», «Github», «HugginFace». Здесь преимуществом является быстрый доступ к обучению модели без долгой консолидации входных данных, однако универсальный характер этих платформ становится недостатком при решении узкоспециализированных прикладных задач (например, таких, как мониторинг безопасности объектов теплоэнергетики), для которых характерны специфические условия видеофиксации, уникальные ракурсы технологического оборудования, особая визуальная природа целевых объектов (дым, пламя в инфракрасном и видимом спектрах), а также выраженный дисбаланс классов. В результате готовых, качественно размеченных наборов данных, которые могут использоваться для подобной специализации, практически не существует.

Отмеченное противоречие между потребностью в больших объемах размеченных данных и их фактическим отсутствием для специфичных индустриальных сценариев формирует основную проблему на старте разработки. Решение лежит не в поиске готовых решений, а в создании собственного цикла формирования и улучшения датасета. Такой цикл должен начинаться с первичного сбора сырых данных и их ручной экспертной разметки с помощью специализированных инструментов. Для подготовки обучающей выборки был разработан специализированный десктопный инструмент ручной разметки изображений с графическим интерфейсом. Приложение обеспечивает создание и редактирование ограничивающих рамок, присвоение классов и экспорт аннотаций в формате YOLOv8. Использование собственного инструмента разметки позволило сформировать первичный датасет, отражающий реальную визуальную специфику теплоэнергетических объектов, однако его объем оказался недостаточным для достижения высокой надежности модели при стандартном обучении, что обусловило необходимость применения активного обучения.

2. Метод обучения «Active learning». Активное обучение представляет собой итеративный подход к машинному обучению, в котором модель самостоятельно определяет наиболее информативные данные для последующей разметки экспертом. В отличие от пассивного обучения на фиксированном наборе данных, Active Learning позволяет целенаправленно концентрировать усилия на примерах, вызывающих наибольшую неопределенность в предсказаниях модели.

Классические стратегии активного обучения разрабатывались преимущественно для задач классификации и требуют адаптации при применении к задачам детекции объектов, где модель одновременно предсказывает координаты ограничивающих рамок и вероятности классов. В нашей работе предложен эвристический механизм оценки неопределенности для однопроходного детектора YOLOv8, основанный на анализе распределения уверенности детекций и отборе предсказаний с промежуточными значениями confidence. Такие примеры, находящиеся вблизи решающей границы, обладают наибольшей информационной ценностью для последующего дообучения модели.

Итеративный цикл активного обучения включает следующие этапы: начальное обучение модели на первичном размеченном датасете; инференс на пуле неразмеченных данных с пониженным порогом уверенности; вычисление метрики неопределенности и отбор сложных примеров; экспертную разметку отобранных изображений; дообучение модели и повторную

валидацию. Данный цикл повторяется до достижения требуемых показателей качества [11-14].

В контексте подготовки данных для нейросетевых моделей в компьютерном зрении, активное обучение успешно применяется для задач семантической сегментации [11, 12], классификации медицинских изображений и детекции объектов в беспилотных системах. Например, в работе по обнаружению дефектов на производственных линиях этот метод позволил сократить объем ручной разметки на 40%, сохранив прирост точности. Подход в принципе остается единым: после начального обучения на небольшом размеченном датасете модель оценивает неразмеченные данные, выявляет среди них наиболее «проблемные» случаи, которые затем отправляются эксперту для разметки и добавляются в обучающую выборку. Цикл повторяется до достижения требуемых метрик качества, однако прямое применение классических подходов активного обучения к современным однопроходным детекторам, таким, как YOLOv8 [15], используемым в предлагаемой работе, сопряжено с техническими и методологическими сложностями. Пример «проблемного» случая детекции объекта представлен на рисунке 1.



Рис. 1. Пример «проблемного» случая детекции объекта

Стандартные стратегии, разработанные для моделей классификации, требуют адаптации к архитектуре, которая одновременно предсказывает координаты bounding boxes и вероятности классов, более того, для промышленных систем безопасности критически важны не только точность, но и интерпретируемость решений модели, а также отказоустойчивость в условиях неопределенности, следовательно, необходима комплексная реализация активного обучения, которая интегрирует механизм интеллектуального отбора данных и инструменты для анализа ошибок модели и системы безопасности для принятия решений в гибридном режиме «автоматика-эксперт».

Выполненное исследование направлено на преодоление указанных ограничений путем разработки и внедрения специализированного инструментария, реализующего полный цикл активного обучения для задачи детекции пожароопасных ситуаций для теплоэнергетических объектов.

3. Разработанные инструменты для использования «Active learning». Разработанная система программных инструментов образует комплексное решение полного цикла работ с системами компьютерного зрения, первым компонентом которой является интерактивный инструмент ручной разметки, реализованный как десктопное приложение с графическим интерфейсом на базе Tkinter, что обеспечивает кроссплатформенность и простоту развертывания без дополнительных зависимостей.

Архитектурно программа следует принципам объектно-ориентированного проектирования, где класс `AnnotationData` инкапсулирует логику хранения и преобразования аннотаций, а `InteractiveLabelingTool` объединяет управление состоянием и визуальное представление. Ключевой особенностью инструмента являются двунаправленные конвертации между абсолютными координатами ограничивающих рамок и нормализованным форматом YOLOv8, что обеспечивает совместимость с современными конвейерами обучения нейронных сетей. Вид графического интерфейса представлен на рисунке 2.

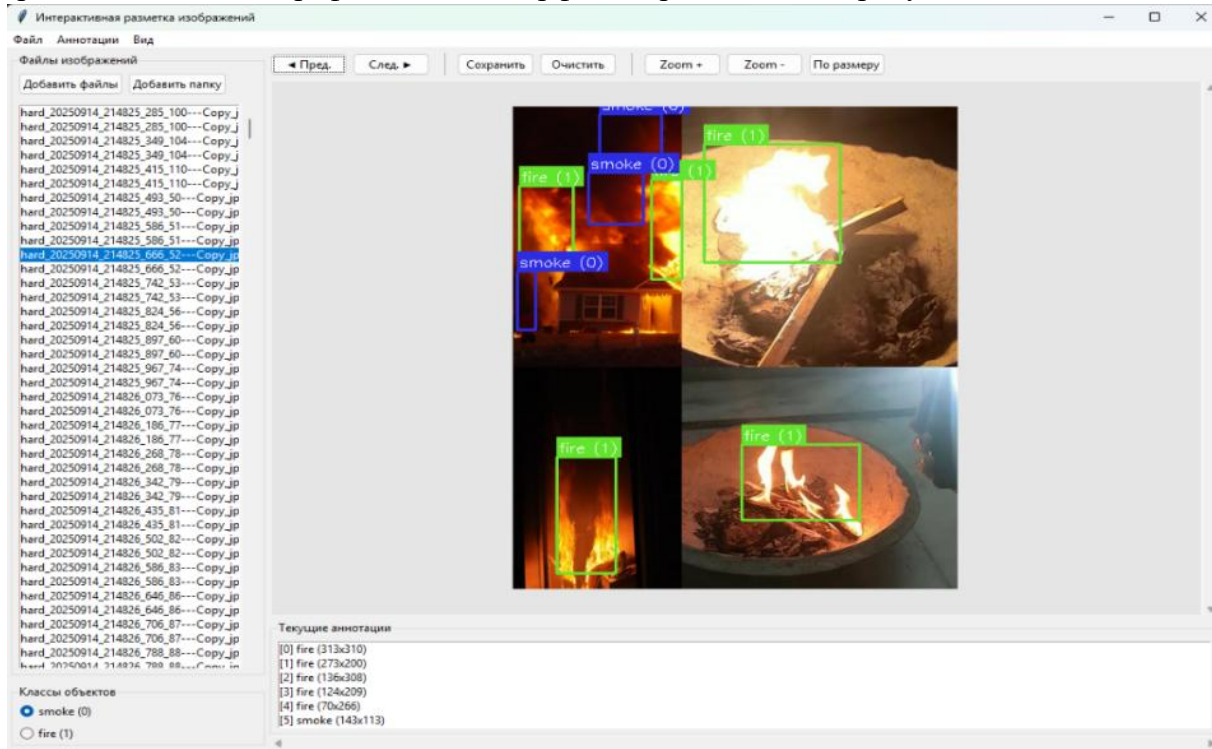


Рис. 2. Вид графического интерфейса

Графическая оболочка спроектирована с учетом эргономики длительной работы оператора, реализуя интуитивную модель взаимодействия через сочетания мыши и «горячих» клавиш, двухпанельная компоновка разделяет область навигации по файлам и выбор классов объектов от основной рабочей зоны просмотра и разметки изображений, механизм bounding boxes использует событийно-ориентированную парадигму с визуальной обратной связью. На всех этапах работы система адаптирует масштабирование с алгоритмом подгонки изображений под размер окна просмотра, интеллектуальное управление состоянием аннотаций с предотвращением потери данных при переходе между изображениями и экспорт результатов в структурированном виде с метаданными проекта.

Второй компонент системы – набор посттренинговых инструментов для YOLOv8, представляет собой концептуально более сложный модуль, реализующий три современных подхода к улучшению промышленных систем компьютерного зрения.

Движок активного обучения построен на принципе неопределенности семплирования, где вместо случайного выбора данных для дополнительной разметки система идентифицирует примеры, в которой модель демонстрирует промежуточную уверенность; сомнительные предсказания, находящиеся вблизи решающей границы классификатора, обладают максимальной информационной ценностью для дообучения модели. Алгоритм выполняет сканирование датасета с автоматическим определением структуры каталогов, инференс с пониженным порогом уверенности для захвата всех гипотез модели, количественную оценку неопределенности через специальную метрику и фильтрацию артефактов по минимальной

площади bounding box. Результатом работы является набор сложных примеров, готовых к целевой доразметке, с полным аннотированием и структурированными метаданными.

Модуль объяснимого искусственного интеллекта [16, 17] решает задачу интерпретации решений модели детекции, что критически важно для повышения доверия к системе и ее отладки, несмотря на архитектурные ограничения YOLOv8, изначально не предназначенной для градиентных методов атрибуции. Разработан эвристический алгоритм генерации карт внимания на основе пространственного распределения bounding boxes. Для каждого обнаруженного объекта создается тепловая карта, где пиксели внутри ограничивающей рамки получают значение, пропорциональное уверенности детекции, а окружающей области – затухающее значения по экспоненциальному закону, моделирующему гауссово распределение внимания, данные визуализации, преобразованные в псевдоцветное представление, позволяют анализировать фокусные области модели и выявлять потенциальные источники ошибок.

Отказоустойчивая система реализует трехуровневую иерархию доверия к предсказаниям модели, что особенно важно для критически важных применений, таких, как системы пожарной безопасности. Архитектура принятия решений разделяет все детекции на три категории:

- автоматически принимаемые при высокой уверенности
- отправляемые на экспертную проверку при промежуточных значениях
- отклоняемые как ненадежные при низкой уверенности

Данный подход позволяет создать гибридную систему, где рутинные случаи обрабатываются автоматически, а сложные и неоднозначные ситуации передаются человеку-эксперту для окончательного решения; процессный workflow включает инференс с расширенной чувствительностью, анализ максимальной уверенности по изображению, категоризацию и маршрутизацию результатов с формированием очереди экспертизы, содержащей полный контекст для принятия взвешенного решения.

Интеграционные аспекты системы обеспечивают формирование замкнутого цикла обработки данных компьютерного зрения, начиная с первичной разметки через интерактивный инструмент, обучения модели YOLOv8 [18, 19], посттренингового анализа для идентификации “слабых” мест, целевой доразметки сложных примеров и итеративного улучшения модели с валидацией через механизмы explainable AI и fail-safe. Научная новизна разработки заключается в практической реализации активного обучения для однопроходных детекторов, области менее исследованной по сравнению с двухпроходными архитектурами, а также в создании эвристических методов explainable AI для black-box моделей детекции, обеспечивающих баланс между интерпретируемостью и вычислительной эффективностью.

Практическая значимость системы наиболее выражена в задачах промышленного мониторинга и безопасности, особенно в детекции пожароопасных ситуаций в видимом и инфракрасном диапазонах. Инструменты оптимизированы для работы с несбалансированными наборами данных, где критические события редки, но требуют максимальной надежности обнаружения. Система активного обучения позволяет существенно сократить временные затраты на подготовку данных за счет концентрации усилий операторов на наиболее информативных примерах, а отказоустойчивые механизмы обеспечивают необходимый уровень надежности в системах автоматического принятия решений [20-23].

4. Сравнительный анализ использования стандартного обучения и метода «Active learning». Для оценки эффективности предложенного подхода был проведен сравнительный эксперимент между базовой моделью YOLOv8, обученной стандартным способом, и моделью, прошедшей итеративный цикл активного обучения. Эксперимент проводился на

специализированном датасете, содержащем 2457 изображений объектов теплоэнергетики. Данные были разделены на обучающую, валидационную и тестовую выборки в соотношении 70/15/15. Обе модели обучались при идентичных гиперпараметрах и условиях вычислительного эксперимента.

Эксперимент проводился на специализированном, подготовленном вручную, датасете и видеоданных с объектов теплоэнергетики, содержащем 2457 изображений в формате 640×640 пикселей. Датасет был разделен на обучающую (70%), валидационную (15%) и тестовую (15%) выборки. Для обеих моделей использовалась идентичная архитектура YOLOv8, идентичные гиперпараметры обучения (100 эпох, batch size=16, SGD optimizer) и условия аппаратного обеспечения (NVIDIA GeForce RTX 5070, 16 ГБ VRAM).

Качество моделей оценивалось по стандартным для задач детекции объектов метриками [15]:

- mAP@0.5 (mean Average Precision при IoU=0.5) – основная метрика качества детекции;
- mAP@0.5:0.95 – усредненная точность при различных порогах IoU от 0.5 до 0.95;
- Precision – доля верно-обнаруженных объектов среди всех обнаружений;
- Recall – доля верно-обнаруженных объектов среди всех существующих в данных;
- F1-Score – гармоническое среднее precision и recall.

После проведения валидации обеих моделей на идентичном тестовом наборе данных были получены количественные оценки их производительности [23-28]. Результаты сравнительного анализа представлены в таблице 1.

Таблица 1. Сравнительный анализ качества моделей детекции

| Метрика | Базовая модель | Модель с активным обучением | Абсолютное улучшение | Относительное улучшение, % |
|--------------|----------------|-----------------------------|----------------------|----------------------------|
| mAP@0.5 | 0.9062 | 0.9420 | +0.0358 | +3.95 |
| mAP@0.5:0.95 | 0.5137 | 0.6591 | +0.1454 | +28.32 |
| Precision | 0.8985 | 0.9052 | +0.0067 | +0.74 |
| Recall | 0.8461 | 0.9123 | +0.0662 | +7.82 |
| F1-Score | 0.8715 | 0.9087 | +0.0372 | +4.27 |

Анализ результатов демонстрирует устойчивое превосходство модели, дообученной с применением активного обучения, по всем ключевым метрикам. Наиболее значительный прирост наблюдается в показателе mAP@0.5:0.95 (+28,32%), что свидетельствует о существенном повышении качества детекции в сложных условиях при различных порогах перекрытия. Это указывает на эффективность метода в улучшении работы модели именно на тех примерах, которые представляют наибольшую трудность для классификации.

Не менее важным является рост полноты обнаружения (recall) на 7,82% при сохранении высокого уровня точности (precision), что для систем безопасности является критически значимым достижением. Улучшение F1-Score на 4,27% подтверждает сбалансированное повышение общего качества детекции. Полученные количественные результаты убедительно доказывают, что предложенный метод активного обучения позволяет целенаправленно улучшать модель за счёт итеративного добавления в обучение наиболее информативных сложных примеров.

Предложенный метод активного обучения решает проблемы технологического пара, высокотемпературных поверхностей за счет: целевой идентификации сложных случаев (алгоритм выявляет примеры, где модель демонстрирует минимальную уверенность, именно те ситуации, где визуальные признаки аварийной ситуации (дым, пламя) наиболее схожи с

нормальными технологическими процессами); адаптации к специфическому визуальному фону (итеративное добавление проблемных примеров позволяет научить модель различать технологический пар и дым, тепловое излучение оборудования и очаги возгорания, блики, отражения и пламя); компенсации дисбаланса классов, в условиях, где аварийные ситуации редки, но критически важны, активное обучение целенаправленно отбирает для доразметки именно те кадры, которые содержат слабовыраженные признаки опасности; интеграции экспертных знаний (разработанная система позволяет работать в гибридном режиме «машина-человек», это позволяет привлекать специалистов для доразметки наиболее неоднозначных случаев), что обеспечивает учет предметной специфики теплоэнергетических процессов.

Заключение. В работе предложен и экспериментально подтвержден комплексный подход к повышению точности и надежности систем компьютерного зрения для обеспечения безопасности объектов теплоэнергетики на основе методологии активного обучения. Адаптация Active Learning к однопроходным детекторам YOLOv8 и интеграция механизмов объяснимости и экспертной верификации позволили эффективно решить проблему дефицита специализированных размеченных данных. Полученные результаты демонстрируют, что целенаправленный отбор и доразметка наиболее информативных примеров обеспечивают существенное улучшение качества детекции пожароопасных ситуаций. Практическая значимость работы заключается в возможности внедрения предложенного подхода в системы промышленного мониторинга и раннего оповещения, где критически важны надежность и интерпретируемость автоматических решений. Перспективы дальнейших исследований связаны с расширением спектра обнаруживаемых аварийных событий и адаптацией подхода к другим классам промышленных объектов.

Список источников

1. Guang W., Yuan Y., Huang S. et al. Application of large AI models in safety and emergency management of the power industry in China. *Processes*, 2025, vol. 13, no. 8, p. 2569, DOI: 10.3390/pr13082569.
2. Xie J., Sun K., Lei X. Risk assessment method of power plant industrial control information security based on Bayesian attack graph. *Journal of Electrical Systems*, 2021, vol. 17, pp. 529-541.
3. Zhu G., Hu Y., Zhang X. et al. Applying deep learning and automated machine learning for enhanced state monitoring and health assessment of high-pressure heater in thermal power units. *Engineering Applications of Artificial Intelligence*, 2025, vol. 141, p. 109805, DOI: 10.1016/j.engappai.2024.109805.
4. Wang Y., Chung S.H. Artificial intelligence in safety-critical systems: a systematic review. *Industrial Management & Data Systems*, 2022, vol. 122, no. 2, pp. 442-470, DOI: 10.1108/IMDS-07-2021-0419.
5. Alotaibi N., Dursun S. Vision inspection of power lines with deep learning. *SPE Conference at Oman Petroleum & Energy Show*, 2024, DOI: 10.2118/218663-MS.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436-444, DOI:10.1038/nature14539.
7. Рассел С., Норвиг П. Искусственный интеллект: современный подход – 3-е изд. / С. Рассел, П. Норвиг. – М.: Вильямс, 2021. – 1408 с.
8. Гудфеллоу Я. Глубокое обучение. – 2-е изд / Я. Гудфеллоу, И. Бенджио, А. Курвилль; пер. А.А. Слинкин. – М.: ДМК Пресс, 2018. – 652 с.
9. Мёрфи К. Машинное обучение: вероятностный подход / К. Мёрфи. – М.: ДМК Пресс, 2013. – 1067 с.
10. Гонсалес Р.С. Цифровая обработка изображений. – 3-е изд. / Р.С. Гонсалес, Р.Е. Вудс //– М.: Техносфера, 2012. – 1104 с.
11. Прэтт У. Цифровая обработка изображений / У. Прэтт. – М.: Мир, 2014. – 736 с.
12. Сзелиски Р. Компьютерное зрение: алгоритмы и приложения / Р. Сзелиски. – М.: Бином. Лаборатория знаний, 2016. – 812 с.
13. Дуда Р. Распознавание образов / Р. Дуда, П. Харт, Д. Сторк. – М.: Мир, 2010. – 680 с.
14. Gal Y., Islam R., Ghahramani Z. Deep Bayesian active learning with image data. In: D. Precup, Y.W. Teh (eds.). *Proceedings of the 34th International Conference on Machine Learning*. PMLR, 2017, vol. 70, pp. 1183-1192. Available at: <https://proceedings.mlr.press/v70/gal17a.html> (accessed: 05/15/2026).
15. Sener O., Savarese S. Active learning for convolutional neural networks: a core-set approach. *International Conference on Learning Representations (ICLR)*, 2018, DOI: 10.48550/arXiv.1708.00489.
16. Yoo D., Kweon I.S. Learning loss for active learning. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, DOI:10.48550/arXiv.1905.03677.

17. Redmon J., Farhadi A. YOLOv3: an incremental improvement. arXiv preprint, 2018, DOI: 10.48550/arXiv.1804.02767.
18. Ribeiro M.T., Singh S., Guestrin C. "Why should I trust you?" Explaining the predictions of any classifier. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'16), 2016, pp. 1135–1144, DOI: 10.1145/2939672.2939778.
19. Selvaraju R.R. et al. Grad-CAM: visual explanations from deep networks via gradient-based localization. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, DOI: 10.48550/arXiv.1610.02391.
20. Raschka S., Mirjalili V. Python machine learning. 2nd ed. Birmingham, Packt Publishing Ltd., 2017.
21. Chollet F. Deep learning with Python. Manning Publications. Available at: <https://soureestdeeds.github.io/pdf/Deep%20Learning%20with%20Python.pdf> (accessed: 05.16.2026).
22. Кулагина Л.В. Прототип системы раннего оповещения о пожаре на основе интеллектуального нейросетевого распознавания / Л.В. Кулагина, Э.А. Шефер // IV Международный Косыгинский Форум «Проблемы инженерных наук: формирование технологического суверенитета»: сборник научных трудов Международного научно-технического симпозиума «Современные инженерные проблемы ключевых отраслей экономики страны». – М.: РГУ им. А.Н. Косыгина, 2024. – С. 128-130. – EDN: DSEIXZ.
23. Кулагина Л.В. Подход к повышению надежности противопожарных технологий промышленного предприятия / Л.В. Кулагина, Э.А. Шефер // Сахаровские чтения 2024 года: экологические проблемы XXI века: материалы 24-й международной научной конференции. – Минск: ИВЦ Минфина Республики Беларусь, 2024. – С. 241-244. – DOI: 10.46646/SAKH-2024-2-241-244. – EDN: SOJANQ.
24. Кулагина Л.В. Совершенствование систем пожарной безопасности объектов теплоэнергетики / Л.В. Кулагина, Э.А. Шефер // Журнал Сибирского федерального университета. Серия: Техника и технологии, 2025. – Т. 18, № 6(127). – С. 778-789. – EDN: ZIOIEO.
25. Бычков А.Г., Киселёва Т.В., Маслова Е.В. Использование сверточных нейросетей для классификации изображений // Вестник Сибирского государственного индустриального университета, 2023, № 1(43), С. 39-49. – DOI: 10.57070/2304-4497-2023-1(43)-39-49.
26. Свидетельство о государственной регистрации программы для ЭВМ № 2024611904 Российская Федерация. Программный комплекс мониторинга теплового режима в производственных помещениях: № 2024610862: заявл. 22.01.2024: опублик. 25.01.2024 / Л.В. Кулагина, Э.А. Шефер; заявитель СФУ. – EDN: GESTOA.
27. Свидетельство о государственной регистрации программы для ЭВМ № 2023616496 Российская Федерация. Программа для прогнозирования качества воздуха на основе модели машинного обучения: № 2023611680: заявл. 01.02.2023: опублик. 28.03.2023 / Л.В. Кулагина; заявитель СФУ. – EDN: DMHFIE.
28. Свидетельство о государственной регистрации программы для ЭВМ № 2023665492 Российская Федерация. Программа для прогнозирования и мониторинга термоточек, в том числе техногенного происхождения (объекты теплоэнергетики): № 2023664095: заявл. 05.07.2023: опублик. 17.07.2023 / Л.В. Кулагина, И.В. Кириллова; заявитель СФУ. – EDN: JYMXXP.

Кулагина Людмила Владимировна. Канд. техн. наук, доцент, доцент кафедры «Техносферная и экологическая безопасность» Политехнического института СФУ, AuthorID: 596975, SPIN: 1325-9320, ORCID: 0000-0003-4406-5060. klvation@gmail.com. 660074, г. Красноярск, ул. Ак. Киренского, д. 26.

Шефер Эдуард Артурович. Аспирант кафедры «Техносферная и экологическая безопасность» Политехнического института СФУ, AuthorID: 1286852, SPIN: 1454-4289, ORCID: 0009-0000-3073-8821. shefer.eduardov-119sp@list.ru. 660074, г. Красноярск, ул. Ак. Киренского, д. 26.

UDC 621.311.25-047.36:004.032.26:004.932

DOI:10.25729/ESI.2026.42.2.009

Training a convolutional neural network model using the Active Learning method for monitoring the safety of thermal power plants

Ludmila V. Kulagina, Eduard A. Shefer

Siberian Federal University, Russia, Krasnoyarsk, shefer.eduardov-119sp@list.ru

Abstract. Ensuring industrial safety at thermal power facilities requires effective and reliable early detection of potentially fire-hazardous and emergency situations. This task is complicated by specific operating conditions characterized by a wide range of operating modes, high levels of electromagnetic interference and vibration, and

often a limited amount of labeled data suitable for training and verifying monitoring and forecasting systems. The goal of this study is to develop and experimentally validate a comprehensive approach to improving the accuracy and reliability of computer vision systems for monitoring thermal power facility safety based on an active learning methodology. The primary methods utilized include convolutional neural network models for object detection based on the YOLOv8 architecture, a heuristic mechanism for selecting informative data based on an uncertainty metric, and tools for explainable artificial intelligence and fault-tolerant decision-making with expert participation. The scientific novelty of the work lies in the adaptation of Active Learning methods to single-pass detectors for industrial safety tasks, as well as in the integration of a cycle of targeted additional labeling of complex examples with mechanisms for interpretation and hybrid verification of results (which allows for minimizing labeling costs (due to a selective request for "complex" examples); prompt adaptation to new types of anomalies (e.g., non-standard leaks, local overheating)); whereas most publications on the safety of thermal power facilities use classical machine learning methods (SVM, random forests) or pre-trained CNNs without adaptation to the specifics of the industry. In the completed work, experimental studies on a specialized dataset of images of thermal power facilities showed that the use of active learning provides an increase in the mAP@0.5:0.95 indicator by 28.32% and an increase in the detection recall by 7.82% compared to standard learning. The obtained results confirm the potential of the proposed approach for practical application in monitoring and early warning systems capable of ensuring the timely detection of deviations from normal operating parameters of equipment and preventing the development of emergency scenarios.

Keywords: active learning, convolutional neural networks, YOLOv8, industrial safety, thermal power plants

References

1. Guang W., Yuan Y., Huang S. et al. Application of large AI models in safety and emergency management of the power industry in China. *Processes*, 2025, vol. 13, no. 8, p. 2569, DOI: 10.3390/pr13082569.
2. Xie J., Sun K., Lei X. Risk assessment method of power plant industrial control information security based on Bayesian attack graph. *Journal of Electrical Systems*, 2021, vol. 17, pp. 529-541.
3. Zhu G., Hu Y., Zhang X. et al. Applying deep learning and automated machine learning for enhanced state monitoring and health assessment of high-pressure heater in thermal power units. *Engineering Applications of Artificial Intelligence*, 2025, vol. 141, p. 109805, DOI: 10.1016/j.engappai.2024.109805.
4. Wang Y., Chung S.H. Artificial intelligence in safety-critical systems: a systematic review. *Industrial Management & Data Systems*, 2022, vol. 122, no. 2, pp. 442-470, DOI: 10.1108/IMDS-07-2021-0419.
5. Alotaibi N., Dursun S. Vision inspection of power lines with deep learning. *SPE Conference at Oman Petroleum & Energy Show*, 2024, DOI: 10.2118/218663-MS.
6. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, vol. 521, pp. 436-444, DOI:10.1038/nature14539.
7. Russell S., Norvig P. *Iskusstvennyy intellekt: sovremennyy podkhod [Artificial intelligence: a modern approach]*. 3rd ed. Moscow, Williams Publ., 2021, 1408 p.
8. Goodfellow I., Bengio Y., Courville A. *Glubokoye obucheniye [Deep learning]*. Trans. by A.A. Slinkin. 2nd ed. Moscow, DMK Press Publ., 2018, 652 p.
9. Murphy K. *Mashinnoye obucheniye: veroyatnostnyy podkhod [Machine learning: a probabilistic approach]*. Moscow, DMK Press Publ., 2013, 1067 p.
10. Gonzalez R.C., Woods R.E. *Tsifrovaya obrabotka izobrazheniy [Digital image processing]*. 3rd ed. Moscow, Tekhnosfera Publ., 2012, 1104 p.
11. Pratt W. *Tsifrovaya obrabotka izobrazheniy [Digital image processing]*. Moscow, Mir Publ., 2014, 736 p.
12. Szeliski R. *Kompyuternoye zreniye: algoritmy i prilozheniya [Computer vision: algorithms and applications]*. Moscow, Binom. Laboratory of Knowledge Publ., 2016, 812 p.
13. Duda R., Hart P., Stork D. *Raspoznavaniye obrazov [Pattern recognition]*. Moscow, Mir Publ., 2010, 680 p.
14. Gal Y., Islam R., Ghahramani Z. Deep Bayesian active learning with image data. In: *Proceedings of the 34th International Conference on Machine Learning*. PMLR, 2017, vol. 70, pp. 1183-1192 (accessed: 05/15/2026)
15. Sener O., Savarese S. Active learning for convolutional neural networks: a core-set approach. In: *Proceedings of the International Conference on Learning Representations (ICLR)*, 2018.
16. Yoo D., Kweon I.S. Learning loss for active learning. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, DOI:10.48550/arXiv.1905.03677.
17. Redmon J., Farhadi A. YOLOv3: an incremental improvement. *arXiv preprint*, 2018, DOI: 10.48550/arXiv.1804.02767.
18. Ribeiro M.T., Singh S., Guestrin C. "Why should I trust you?" Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD'16)*, 2016, pp. 1135-1144, DOI: 10.1145/2939672.2939778.

19. Selvaraju R.R. et al. Grad-CAM: visual explanations from deep networks via gradient-based localization. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017, DOI: 10.48550/arXiv.1610.02391.
20. Raschka S., Mirjalili V. Python machine learning. 2nd ed. Birmingham, Packt Publishing Ltd., 2017.
21. Chollet F. Deep learning with Python. Manning Publications. Available at: <https://soureestdeeds.github.io/pdf/Deep%20Learning%20with%20Python.pdf> (accessed: 05.16.2026).
22. Kulagina L.V., Shefer E.A. Prototip sistemy rannego opoveshcheniya o pozhare na osnove intellektual'nogo neyrosetevogo raspoznavaniya [Prototype of an early fire warning system based on intelligent neural network recognition]. IV Mezhdunarodnyy Kosygin'skiy Forum "Problemy inzhenernykh nauk: formirovaniye tekhnologicheskogo suvereniteta": sbornik nauchnykh trudov Mezhdunarodnogo nauchno-tekhnicheskogo simpoziuma "Sovremennyye inzhenernyye problemy klyuchevykh otrasley ekonomiki strany" [IV International Kosygin Forum "Problems of Engineering Sciences: Formation of Technological Sovereignty": Proceedings of the International Scientific and Technical Symposium "Modern Engineering Problems of Key Sectors of the Country's Economy"]. Moscow, Kosygin University Publ., 2024, pp. 128-130, EDN: DSEIXZ.
23. Kulagina L.V., Shefer E.A. Podkhod k povysheniyu nadezhnosti protivopozharnykh tekhnologiy promyshlennogo predpriyatiya [An approach to improving the reliability of fire protection technologies at an industrial enterprise]. Sakharovskiye chteniya 2024 goda: ekologicheskiye problemy XXI veka: materialy 24-y mezhdunarodnoy nauchnoy konferentsii [Sakharov Readings 2024: Environmental Problems of the 21st Century: Proceedings of the 24th International Scientific Conference]. Minsk, Information and Computing Center of the Ministry of Finance of the Republic of Belarus Publ., 2024, pp. 241-244, DOI: 10.46646/SAKH-2024-2-241-244, EDN: SOJANQ.
24. Kulagina L.V., Shefer E.A. Sovershenstvovaniye sistem pozharной bezopasnosti ob'yektov teploenergetiki [Improving fire safety systems for thermal power facilities]. Zhurnal Sibir'skogo federal'nogo universiteta. Seriya: Tekhnika i tekhnologii [Journal of Siberian Federal University. Series: Engineering and Technologies], 2025, vol. 18, no. 6(127), pp. 778-789, EDN: ZIOIEO.
25. Bychkov A.G., Kiseleva T.V., Maslova E.V. Ispol'zovaniye svertochnykh neyrosetey dlya klassifikatsii izobrazheniy [Using convolutional neural networks for image classification]. Vestnik Sibir'skogo gosudarstvennogo industrial'nogo universiteta [Bulletin of Siberian State Industrial University], 2023, no. 1(43), pp. 39-49, DOI: 10.57070/2304-4497-2023-1(43)-39-49.
26. Kulagina L.V., Shefer E.A. Programmnyy kompleks monitoringa teplovogo rezhima v proizvodstvennykh pomeshcheniyakh [Software complex for monitoring thermal conditions in industrial premises]. State registration certificate of computer program No. 2024611904 Russian Federation: No. 2024610862, appl. 01.22.2024, publ. 01.25.2024, EDN: GESTOA.
27. Kulagina L.V. Programma dlya prognozirovaniya kachestva vozdukha na osnove modeli mashinnogo obucheniya [Program for air quality forecasting based on a machine learning model]. State registration certificate of computer program No. 2023616496 Russian Federation: No. 2023611680, appl. 02.01.2023, publ. 03.28.2023, EDN: DMHFIE.
28. Kulagina L.V., Kirillova I.V. Programma dlya prognozirovaniya i monitoringa termotochek, v tom chisle tekhnogennogo proiskhozhdeniya (ob'yekty teploenergetiki) [Program for forecasting and monitoring thermal points, including man-made ones (thermal power facilities)]. State registration certificate of computer program No. 2023665492 Russian Federation: No. 2023664095, appl. 07.05.2023, publ. 07.17.2023, EDN: JYMXXP.

Kulagina Liudmila Vladimirovna. PhD (candidate of technical sciences), Assistant Professor, Assistant Professor of the Chair «Technospheric and Ecological Safety» in SibFU, AuthorID: 596975, SPIN: 1325-9320, ORCID: 0000-0003-4406-5060. klvation@gmail.com. 26 Kirenskogo str., Krasnoyarsk, Russia, 660074.

Shefer Eduard Arturovich. PhD student at the Chair «Technospheric and Ecological Safety» in SibFU. AuthorID: 1286852, SPIN: 1454-4289, ORCID: 0009-0000-3073-8821. shefer.eduardov-119sp@list.ru. 26 Kirenskogo str., Krasnoyarsk, Russia, 660074.

Статья поступила в редакцию 21.05.2025; одобрена после рецензирования 04.10.2025; принята к публикации 10.02.2026.

The article was submitted 05/21/2025; approved after reviewing 10/04/2025; accepted for publication 02/10/2026.