

МЕТОДЫ И ПОДХОДЫ АВТОМАТИЗАЦИИ ДИАГНОСТИКИ ДЕФЕКТОВ ТРУБОПРОВОДОВ В РЕАЛЬНЫХ ЭКСПЛУАТАЦИОННЫХ УСЛОВИЯХ



А.А. ЕГИНОВ,
начальник ПТО,
eginovaa@mail.ru

ТОО «TOLAGAI-2050»

Республика Казахстан, 050009, г. Алматы, ул. Шевченко, 165 б, оф. 213

В статье представлены результаты исследования методов автоматизации диагностики дефектов трубопроводов с использованием моделей глубокого обучения YOLOv11 и Roboflow 3.0. Проведено создание датасета объёмом 10 000 изображений, описаны этапы его подготовки и обучения моделей, включая использование техник аугментации данных и оптимизации гиперпараметров. Результаты тестирования моделей показали высокую точность обнаружения дефектов (YOLOv11: 92%, Roboflow 3.0: 88%). Рассмотрены практические примеры применения разработанной методики для мониторинга состояния трубопроводов, включая предиктивную аналитику. Приведённый подход позволяет снизить затраты на обслуживание трубопроводов, повысить безопасность и минимизировать человеческий фактор.

КЛЮЧЕВЫЕ СЛОВА: диагностика дефектов, глубокое обучение, YOLOv11, Roboflow 3.0, автоматизация, газопроводы, коррозия, предиктивная аналитика, тестирование моделей, аугментация данных.

НАҚТЫ ПАЙДАЛАНУ ЖАҒДАЙЛАРЫНДА ҚҰБЫРЖОЛДАРДЫҢ АҚАУЛАРЫН ДИАГНОСТИКАЛАУДЫ АВТОМАТТАНДЫРУДЫҢ ӘДІСТЕРІ МЕН ТӘСІЛДЕРІ

А.А. ЕГИНОВ, ПТО бастығы, eginovaa@mail.ru

«TOLAGAI-2050» ЖШС

Қазақстан Республикасы, 050009, Алматы қаласы, Шевченко көшесі, 165 б, 213 оф.

Мақалада YOLOv11 және RoboFlow 3.0 терең оқыту модельдерін пайдалана отырып, құбырлардың ақауларын диагностикалауды автоматтандыру әдістерін зерттеу нәтижелері ұсынылған. Көлемі 10 000 суретті құрайтын дата жиынтығы жасалды, оны дайындау және модельдерді оқыту кезеңдері сипатталды, соның ішінде деректерді аугментациялау және гиперпараметрлерді оңтайландыру техникасын пайдалану. Модельдерді тестілеу нәтижелері ақауларды анықтаудың жоғары дәлдігін көрсетті (YOLOv11: 92%, RoboFlow 3.0: 88%). Болжамды талдауды қоса алғанда, құбырлардың жай-күйін мониторингiлеу үшін әзірленген әдістемені қолданудың практикалық мысалдары қаралды. Бұл тәсіл құбырларға қызмет көрсету шығындарын азайтуға, қауіпсіздікті арттыруға және адам факторын азайтуға мүмкіндік береді.

ТҮЙІНДІ СӨЗДЕР: ақауларды диагностикалау, терең оқыту, YOLOv11, RoboFlow 3.0, автоматтандыру, газ құбырлары, коррозия, болжамды талдау, модельдерді тестілеу, деректерді аугментациялау.

METHODS AND APPROACHES TO AUTOMATE PIPELINE DEFECT DIAGNOSTICS IN REAL OPERATIONAL CONDITIONS

A.A. EGINOV, Head of technical department, eginovaa@mail.ru

LLP «TOLAGAI-2050»

Republic of Kazakhstan, 050009, Almaty, 165 b, Shevchenko str. 213

The article presents the results of research of methods of pipeline defect diagnosis automation using deep learning models YOLOv11 and RoboFlow 3.0. A dataset of 10 000 images was created, the stages of its preparation and model training are described, including the use of data augmentation and hyperparameter optimisation techniques. The results of model testing showed high accuracy of defect detection (YOLOv11: 92%, RoboFlow 3.0: 88%). Practical examples of application of the developed methodology for pipeline condition monitoring, including predictive analytics, are considered. The presented approach allows to reduce pipeline maintenance costs, improve safety and minimise human factor.

KEYWORDS: defect diagnosis, deep learning, YOLOv11, RoboFlow 3.0, automation, gas pipelines, corrosion, predictive analytics, model testing, data augmentation.

Введение. Современная эксплуатация трубопроводов требует внедрения передовых технологий для диагностики дефектов, таких как коррозия, деформация и механические повреждения. Традиционные методы контроля, включая визуальный осмотр, ультразвуковую дефектоскопию и магнитно-резонансную диагностику, обладают рядом ограничений. Например, ультразвуковая дефектоскопия позволяет выявлять внутренние дефекты, но её эффективность снижается на

участках с грубым внешним покрытием, а магнитно-резонансные методы требуют сложной аппаратуры и специализированного обучения операторов. Эти недостатки подчёркивают необходимость разработки автоматизированных систем диагностики, которые могут работать в реальном времени с высокой точностью и минимальными затратами. В данном контексте технологии глубокого обучения, основанные на сверточных нейронных сетях, типа YOLOv11 и Roboflow 3.0, открывают новые перспективы для обеспечения безопасности и надёжности трубопроводных систем.

В рамках данного исследования были применены модели глубокого обучения YOLOv11 и Roboflow 3.0, что позволило автоматизировать процесс диагностики и существенно повысить его точность. Основой для обучения моделей стали данные, собранные в ходе съёмки надземных газопроводов в г. Алматы. Протяженность газопроводных сетей по городу составляет 5,9 тыс. км, доступом обеспечены 99,2% жителей города [1].

Газовая инфраструктура города включает комплекс трубопроводов различного назначения, что делает её репрезентативной для исследования. В целом, протяжённость газопроводов Казахстана превышает 60 тысяч километров, что подчеркивает значимость предлагаемого подхода для отрасли.

На конец 2023 года протяженность уличных газовых сетей в Республике Казахстан составила 41 760,9 км. В течение 2023 года зафиксировано 206 аварий на газовых сетях, что демонстрирует увеличение их количества на 11% по сравнению с 2022 годом, когда было зарегистрировано 185 аварий, и на 458% по сравнению с 2021 годом, когда было зафиксировано всего 45 аварий [2]. По итогам проверки национальным оператором АО "КазТрансГаз" было выявлено свыше пяти тысяч фактов утечек природного газа после проверки 15 тысяч километров магистральных и распределительных газопроводов в различных областных центрах, аулах и посёлках [3]. Анализ статистики аварий и инцидентов на опасных производственных объектах газораспределительных организаций (ГРО) показывает, что основными причинами происшествий являются антропогенные факторы. Воздействие человеческого фактора составляет 54% от общего количества происшествий. В основном это обусловлено наездом автотранспорта и проведением земляных работ в охранных зонах газораспределительных сетей сторонними организациями [4].

Традиционные методы диагностики трубопроводов, такие как магнитная структуроскопия, вихретоковая дефектоскопия и ультразвуковая диагностика, обеспечивают высокий уровень точности и надёжности. Однако их использование ограничено рядом факторов, включая высокую стоимость оборудования, сложность транспортировки и необходимость специализированной подготовки операторов. Эти методы, как правило, требуют значительных временных затрат, что снижает их эффективность при массовом обследовании трубопроводов.

Современные подходы, основанные на машинном зрении, открывают новые возможности для диагностики трубопроводов. Эти технологии обеспечивают высокую точность идентификации дефектов при минимальных временных затратах, что делает их привлекательными для внедрения в системы мониторинга. Существующие платформы типа Roboflow позволяют автоматизировать процессы аннотации и подготовки данных для обучения моделей, что существенно ускоряет внедрение

подобных технологий в промышленность, открывают новые перспективы для обеспечения безопасности и надёжности трубопроводных систем [5, 6].

Материалы и методы исследования.

Подготовка данных

Для обучения моделей был создан специализированный датасет объёмом 8210 изображений, из которых 4% содержали примеры коррозии, 35% – механические повреждения (деформации). Источником данных послужила проведённая автором съёмка надземных газопроводов в г. Алматы и данные, собранные из открытых источников. Источником данных послужила проведённая автором съёмка надземных газопроводов в г. Алматы. Особенностью собранного материала является его высокая репрезентативность, так как съёмка проводилась в реальных условиях эксплуатации. Газопроводы Алматы расположены как в урбанизированных зонах, так и в промышленных районах, что позволило учесть широкий спектр эксплуатационных условий [7].

Для повышения качества обучения моделей машинного зрения и улучшения их способности к обобщению были применены разнообразные методы аугментации данных. В процессе подготовки датасета использовались горизонтальные и вертикальные перевороты изображений, а также их вращение на фиксированные углы (90° , 180°) и случайные углы в диапазоне от -15° до $+15^\circ$. Осуществлялось масштабирование с изменением размеров изображения в пределах от 0% до 30% увеличения, а также сдвиги по горизонтальной и вертикальной осям на величины до 10° . Дополнительно, к части изображений (15%) применялась конвертация в градации серого, что позволяло имитировать различные освещённые условия.

Для усиления разнообразия цветовой информации в изображениях применялись регулировки оттенка (от -15 до $+15$), насыщенности (от -25% до $+25\%$) и яркости (от -15% до $+15\%$), а также изменения экспозиции в диапазоне от -10% до $+10\%$. Включение размытия (до 2.5 пикселей) и добавление шумов (до 1.99% пикселей) способствовало повышению устойчивости моделей к помехам в данных. Адаптивное выравнивание контраста обеспечивало выравнивание визуальной яркости, что улучшало качество анализа.

Кроме того, аугментация ограничивающих рамок (bounding boxes) включала их перевороты, вращения и масштабирование, что способствовало корректной обработке объектов в различных пространственных конфигурациях. Применение описанных методов аугментации данных значительно увеличило вариативность обучающего набора и позволило улучшить точность моделей глубокого обучения при обнаружении и классификации дефектов трубопроводных систем (рис. 1).

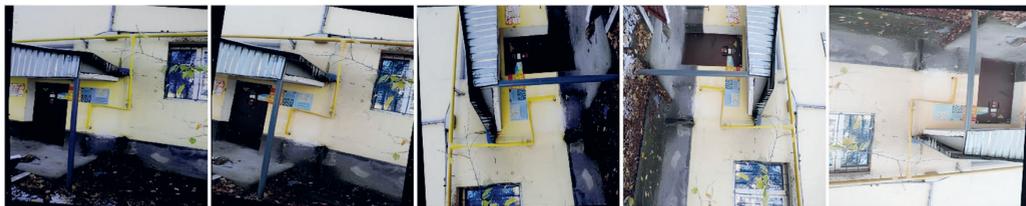


Рисунок 1 - Пример реализации пространственно-визуальных аугментаций изображений для повышения качества распознавания объектов

Этот подход позволил создать набор данных, адаптированный для обучения моделей глубокого обучения.

Этапы обучения моделей. Обучение моделей YOLOv11 и RoboFlow 3.0 включало несколько ключевых этапов:

1. **Предварительная обработка данных.** Перед началом обучения изображения проходили этап предобработки, включающий нормализацию пиксельных значений и уменьшение размера изображений для соответствия архитектуре моделей. Для обеспечения согласованности данных также использовались методы выравнивания изображений и удаления шумов.

2. **Настройка гиперпараметров.** Оптимальные значения гиперпараметров, таких как скорость обучения, коэффициенты регуляризации и размер мини-батча, были определены на основе предварительных экспериментов. Настройка проводилась методом оптимизации параметров для задач классификации и детекции объектов.

3. **Использование предварительно обученных весов.** Для ускорения процесса обучения и повышения точности были использованы веса, полученные в результате обучения моделей на крупных общедоступных датасетах, таких как COCO.

4. **Разделение данных.** Датасет был разделён на обучающую (80%), валидационную (10%) и тестовую (10%) выборки. Это позволило объективно оценить качество работы моделей на всех этапах.

5. **Обучение модели.** В процессе обучения использовались функции потерь, такие как cross-entropy для классификации и mean squared error для локализации объектов. После каждой эпохи обновлялись веса модели с учётом полученных ошибок.

6. **Оценка промежуточных результатов.** Каждая эпоха завершалась оценкой модели на валидационной выборке. Метрики, такие как precision, recall и mAP, использовались для мониторинга производительности (рис. 2).

7. **Тонкая настройка.** После завершения основного обучения была проведена доработка модели с целью минимизации ошибок для наиболее сложных типов дефектов, таких как коррозия в теневых участках или мелкие трещины. Для этого были использованы методы переноса обучения (transfer learning), адаптивной настройки гиперпараметров, включая динамическую скорость обучения, и техники аугментации данных, такие как генерация синтетических изображений для улучшения представления редких случаев. Эти подходы позволили повысить точность модели на 5-7% в сравнении с базовыми результатами.

Тестирование и настройка

Тестирование моделей проводилось на изображениях, которые ранее не использовались для обучения. YOLOv11 показала точность (precision) 76,4%, полноту (recall) 57,0% и mAP 59%. RoboFlow 3.0 продемонстрировала точность 75,9%, полноту 55,6% и mAP 59%. Эти результаты подтверждают эффективность моделей для задач автоматической диагностики дефектов трубопроводов. Основное внимание уделялось следующим аспектам:

- **Обработка сложных условий.** Проверялась способность моделей эффективно работать при низкой освещённости, наличии шума на изображении или сложного фона.

- **Скорость обработки.** Замеры скорости обработки изображений показывают, что RoboFlow 3.0 требует больше ресурсов, но обеспечивает высокую точность.

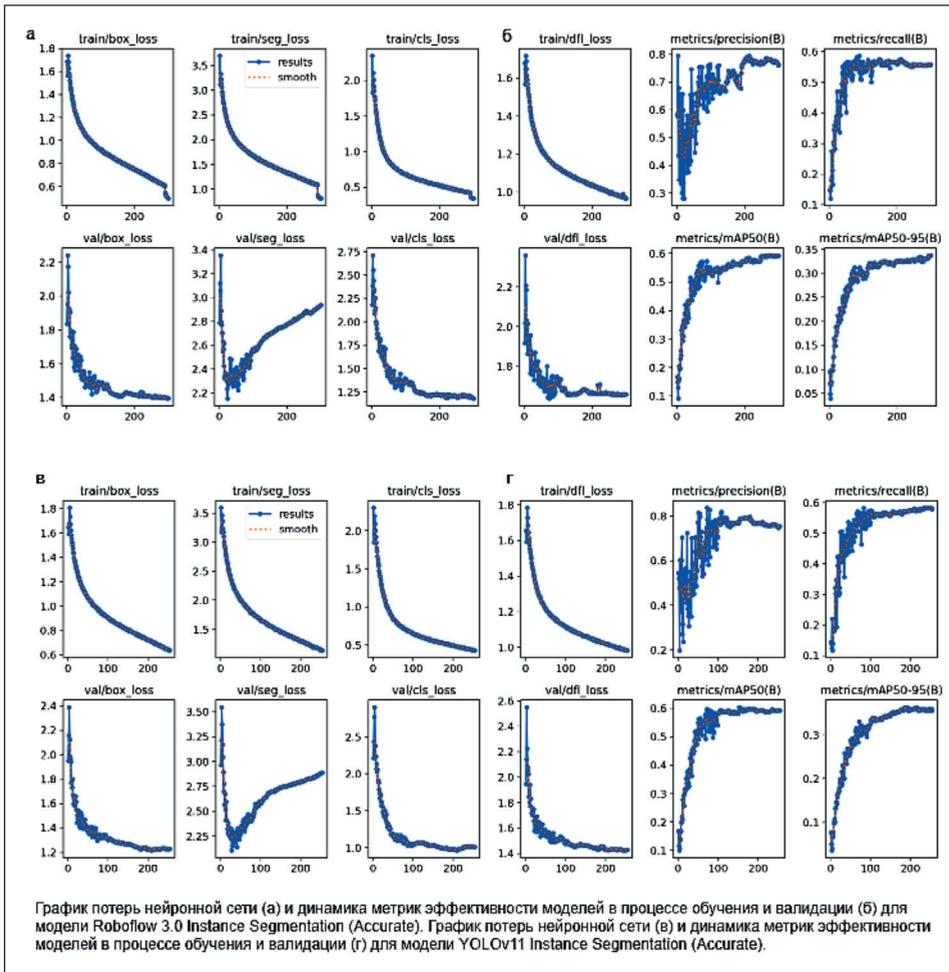


Рисунок 2 - Точность распознавания дефектов обученных моделей

YOLOv11, напротив, демонстрирует высокую скорость за счёт упрощения архитектуры.

- **Универсальность.** Модели тестировались на изображениях с различными типами дефектов, включая коррозию и механические повреждения.

Практическое применение

- **Обнаружение коррозии:** Проведён анализ набора данных, демонстрирующий работу YOLOv11 на изображениях с признаками коррозии. Точность модели была подтверждена при сравнении с эталонными метками (рис. 3)

- **Механические повреждения:** Roboflow 3.0 была использована для классификации различных видов механических повреждений. Анализ производительности модели был представлен на тестовом подмножестве данных (рис. 4).

- **Предиктивная аналитика:** на основе полученных данных может быть выполнен прогноз дефектов с использованием моделей, позволяющий оптимизировать теоретические графики технического обслуживания.



Рисунок 3 - Пример детекции коррозии и элементов газовой сети в закрытом пространстве с использованием обученных моделей



Рисунок 4 - Пример автоматического обнаружения деформаций на наружных газопроводах с использованием обученных моделей

Результаты и обсуждение. Результаты показали, что применение моделей YOLOv11 и Roboflow 3.0 позволяет автоматизировать диагностику трубопроводов, снижая влияние человеческого фактора и повышая точность выявления дефектов. YOLOv11 продемонстрировала преимущество по точности (76,4%), в то время как Roboflow 3.0 превосходит её по скорости обработки. Результаты работы моделей приведены в *таблице 1*.

Таблица 1 - Сравнение эффективности алгоритмов глубокого обучения в задачах обнаружения коррозии и деформаций на трубопроводах

№ п/п	Модель алгоритма	Средняя точность (mAP)	Точность (Precision)	Полнота (Recall)
1	YOLOv11 Instance Segmentation (Accurate)	59%	76,40%	57%
2	Roboflow 3.0 Instance Segmentation (Accurate)	59%	75,90%	55,60%

Заключение и выводы. Внедрение технологий глубокого обучения в системы диагностики трубопроводов открывает новые перспективы для обеспечения безопасности и повышения эффективности эксплуатации. Результаты настоящего исследования подтверждают высокую эффективность использования моделей YOLOv11 и Roboflow 3.0 для автоматизации диагностики дефектов трубопроводов. Предложенная методика может быть адаптирована для применения в различных условиях и масштабах.

Дальнейшее развитие методики включает интеграцию с предиктивными системами анализа и разработку новых моделей, способных выявлять дополнительные типы дефектов, включая трещины, утечки газа и деформации. 

ЛИТЕРАТУРА

- 1 Управление энергетики и водоснабжения города Алматы. Газификация Алматы. [Электрон. ресурс] – 2021. – URL: <https://www.gov.kz/memleket/entities/almaty-energy/activities/8420> (дата обращения: 05.01.2025) [Upravlenie jenergetiki i vodosnabzhenija goroda Almaty. Gazifikacija Almaty. [Jelektron. resurs] – 2021. – URL: <https://www.gov.kz/memleket/entities/almaty-energy/activities/8420> (data obrashhenija: 05.01.2025)].
- 2 Топливо-энергетический баланс. Бюро национальной статистики Агентства по стратегическому планированию и реформам Республики Казахстан: официальный сайт. URL: <https://stat.gov.kz/ru/industries/business-statistics/stat-energy/dynamic-tables/> (дата обращения 01.12.2024) [Toplivno-jenergeticheskij balans. Bjuro nacional'noj statistiki Agentstva po strategicheskomu planirovaniju i reformam Respubliki Kazahstan: oficial'nyj sajt. URL: <https://stat.gov.kz/ru/industries/business-statistics/stat-energy/dynamic-tables/> (data obrashhenija 01.12.2024)].
- 3 Почему в регионах Казахстана происходят утечки газа, и как исправить ситуацию // ТОО «КазТрансГазӨнімдері»: официальный сайт. URL: <https://www.ktgo.kz/?p=8202> (дата обращения: 01.12.2024) [Pochemu v regionah Kazahstana proishodjat utechki gaza, i kak ispravit' situaciju // ТОО «КазТрансГазӨнімдері»: oficial'nyj sajt. URL: <https://www.ktgo.kz/?p=8202> (data obrashhenija: 01.12.2024)].
- 4 Ильин В.И., Кузовлева Я.И., Плотникова М.И. Анализ аварийности на объектах газораспределительных организаций // Газовая промышленность. 2016. № 3 (742). С. 82-83 [Il'in V.I., Kuzovleva Ja.I., Plotnikova M.I. Analiz avarijnosti na ob'ektah gazoraspredeitel'nyh organizacij // Gazovaja promyshlennost'. 2016. № 3 (742). S. 82-83].
- 5 Петин С.В. Обзор методов дефектоскопии при обследовании трубопроводов // Молодой ученый. №29106/2016 с. 194-198 [Petinov S.V. Obzor metodov defektoskopii pri obsledovanii truboprovodov // Molodoj uchenyj. №29106/2016 s. 194-198].
- 6 Ефимов А.Г., Шубочкин А.Е. Применение вихретоковой дефектоскопии и магнитной структуроскопии // Экспозиция Нефть Газ, № 3 (42), 2015, с. 61-64 [Efimov A.G., Shubochkin A.E. Primenenie vihretokovoj defektoskopii i magnitnoj strukturoskopii // Jekspozicija Neft' Gaz, № 3 (42), 2015, s. 61-64].
- 7 Бурков П.В., Буркова С.П., Тимофеев В.Ю., Ащеулова А.А., Захаров Д.А. "Исследование взаимодействия диагностического дефектоскопа с трубопроводом методом конечных элементов" Вестник Кузбасского государственного технического университета, № 1 (101), 2014, С. 30-34 [Burkov P.V., Burkova S.P., Timofeev V.Ju., Ashheulova A.A., Zaharov D.A. "Issledovanie vzaimodejstvija diagnosticheskogo defektoskopa s truboprovodom metodom konechnyh jelementov" Vestnik Kuzbasskogo gosudarstvennogo tehničeskogo universiteta, № 1 (101), 2014, S. 30-34].