

**СОЛОВЬЕВ Е. С., КУНЦЕВ В. Е., ГРЕСЮК А. Н.
КОМПЬЮТЕРНОЕ ЗРЕНИЕ ДЛЯ АНАЛИЗА НЕФТЕПРОВОДОВ В
АРКТИЧЕСКИХ УСЛОВИЯХ**

УДК 004.932, ГРНТИ 28.23.15

Статья поступила в редакцию 25.11.2025

Компьютерное зрение для анализа
нефтепроводов в арктических условиях

Computer vision for analysis of oil
pipelines in arctic conditions

**Е. С. Соловьев, В. Е. Кунцев,
А. Н. Гресюк**

**E. S. Solovyov, V. E. Kuntsev,
A. N. Gresyuk**

Ухтинский государственный технический
университет, г. Ухта

Ukhta State Technical University,
Ukhta

В работе рассматривается применение технологий компьютерного зрения (Computer Vision, CV) для расшифровки видеопотока с целью автоматизации контроля состояния нефтепроводов. Проведен сравнительный анализ классических и современных архитектур нейронных сетей. Предложено решение для мониторинга в условиях Арктики, позволяющее минимизировать экологические риски и экономические потери, а также повысить безопасность персонала.

The paper discusses the use of computer vision (CV) technologies for decoding video streams to automate the monitoring of oil pipeline conditions. A comparative analysis of classical and modern neural network architectures is presented. A solution for monitoring in Arctic conditions is proposed, which minimizes environmental risks and economic losses, as well as improves personnel safety.

Ключевые слова: компьютерное зрение, анализ видеопотока, нейронные сети, YOLO, мониторинг нефтепроводов, Арктика, промышленная безопасность

Keywords: computer vision, video stream analysis, neural networks, YOLO, oil pipeline monitoring, Arctic, industrial safety

Введение

Арктическая зона России является ключевым регионом для национальной энергетической стратегии [1] и основой для поддержания экономической стабильности страны. Эксплуатация обширной сети магистральных нефтепроводов в условиях Крайнего Севера – это задача исключительной сложности, требующая внедрения передовых, полностью отечественных технологических решений.



Рисунок 1. Работа в арктических условиях

Компьютерное зрение (CV), как одно из наиболее динамичных направлений развития искусственного интеллекта, предоставляет уникальные возможности для решения этой задачи, наделяя российские вычислительные системы способностью к автоматическому анализу видео- и фоторяда с целью непрерывного мониторинга критической инфраструктуры.

Современное состояние диагностики трубопроводов

На сегодняшний день, система диагностики и технического обслуживания (ТО) магистральных нефтепроводов базируется на комплексе традиционных методов [2], которые можно разделить на три основные группы: внутритрубная инспекция, неразрушающий контроль (НК) с поверхности и визуальный мониторинг.

Внутритрубная Диагностика (ВИД)

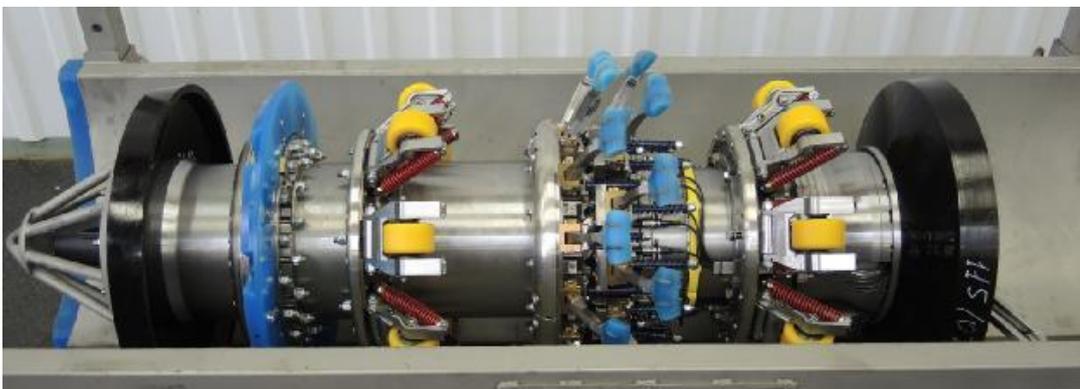


Рисунок 2. Внутритрубный дефектоскоп

Внутритрубная инспекция (ВИД) является золотым стандартом для обнаружения внутренних дефектов трубопровода. Она выполняется с помощью интеллектуальных снарядов (PIGs), которые перемещаются по трубе вместе с потоком нефти.

- **Магнитные методы (MFL, TFI):** Интеллектуальные снаряды, оснащенные сильными магнитами, создают в стенке трубы магнитное поле. Обнаружение потерь магнитного потока (MFL) позволяет выявлять коррозию, раковины и трещины.

- **Ультразвуковые методы (UT):** Снаряды используют ультразвуковые волны для измерения толщины стенки и обнаружения дефектов. UT-методы обеспечивают высокую точность определения глубины и размеров дефектов.



Рисунок 3. Ультразвуковой прибор диагностики

Наземный Неразрушающий Контроль и Спектральный Анализ

Методы наземного контроля применяются для локальной диагностики или обследования участков, недоступных для ВИД.

- **Ультразвуковой контроль с поверхности (УЗК):** Используется для точного измерения толщины стенки и поиска дефектов сварных швов. Это ручной, высокоточный, но точечный метод.

- **Вихретоковый контроль (ВТК):** Применяется для обнаружения поверхностных трещин и дефектов в зонах сварки.

- **Акустическая эмиссия (АЭ):** Пассивный метод, регистрирующий акустические волны, возникающие при росте дефекта (трещины) или утечке.

- **Спектральный и Тепловизионный Анализ (для утечек):** Тепловизоры, установленные на вертолётах или БПЛА, регистрируют аномалии температуры, вызванные выходом продукта из трубы. Однако этот метод чувствителен к погодным условиям и малоэффективен для ранней детекции небольших дефектов.

Традиционные методы инспекции, разработанные в 20 веке, оказались неэффективными и неприемлемо рискованными в уникальных климатических и геологических условиях Арктики:

- **Угроза национальной экологической безопасности:** Аварии в Арктике имеют катастрофические последствия. Разлив 1 литра нефти загрязняет до 1 миллиона литров воды, а ликвидация последствий в зоне вечной мерзлоты обходится для государства в 5 раз дороже стандартных условий.

- **Экономические потери для ТЭК России:** Длительный простой трубопровода может стоить стратегическим компаниям до 1 миллиона долларов США в сутки. Увеличение стоимости ремонтных работ в Арктике на 300% требует превентивных, высокоточных методов диагностики.

- **Сохранение человеческого ресурса:** Обеспечение безопасности персонала, работающего в условиях -50°C и полярной ночи, является приоритетом. Тяжелые условия ведут к росту травматизма на 40%, что требует полной автоматизации опасных инспекционных работ.

Целью данного исследования является разработка и обоснование выбора оптимальной архитектуры компьютерного зрения для обеспечения технологического суверенитета в области мониторинга нефтепроводов, путем достижения максимального баланса между точностью детекции и скоростью обработки данных в режиме реального времени [3].

Технологические ограничения и пути их преодоления

Ключевая научно-техническая проблема заключается в сложности одновременного анализа пространственных (визуальный дефект) и временных (динамика развития дефекта, движение техники) признаков в видеопотоке. Это требует поиска компромисса между точностью и скоростью работы, который критичен для быстрого принятия решений операторами.

Несоответствие традиционных методов проектам

Существующие подходы не отвечают требованиям по масштабу и частоте, необходимым для контроля тысяч километров стратегических трубопроводов:

- **Визуальный осмотр:** Проводится всего 1-2 раза в год и занимает 2-3 недели на 100 км, что оставляет огромные временные "окна" для развития аварийных ситуаций [2].

- **Ультразвуковой контроль (УЗК):** Применим только локально и не подходит для сплошного мониторинга протяженных магистралей.

- Внутритрубные дефектоскопы: Требуют высоких капитальных затрат и сложны в эксплуатации в арктических условиях.

Подробное описание архитектуры YOLOv8

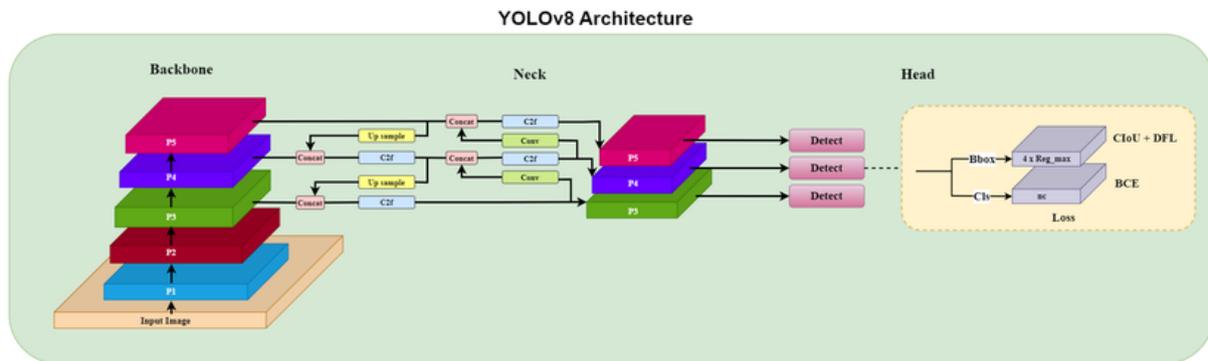


Рисунок 4. Схема работы архитектуры YOLOv8

Для обеспечения быстрой инференции (предсказания) на борту мобильных беспилотных летательных аппаратов (БПЛА), которые обладают ограниченными вычислительными ресурсами, в качестве основного детектора предполагается использовать архитектуру YOLOv8 (You Only Look Once, версия 8). Данная архитектура, являясь одноэтапным детектором (single-stage detector), демонстрирует наилучший баланс между скоростью обработки (до 60 FPS) и точностью детекции (mAP 0.75) среди существующих решений.

Выбор YOLOv8 перед предшественниками (v5, v7) обоснован следующими ключевыми улучшениями:

- Усовершенствованный Backbone (Основная Сеть): В основе YOLOv8 лежит модифицированная сеть, развившая концепцию CSPDarknet (Cross Stage Partial Network). Эта структура потенциально может быть оптимизирована для арктических условий, поскольку она минимизирует количество вычислений, сохраняя при этом богатую извлекаемую признаковую информацию.
- Архитектура Neck (Шейка): В YOLOv8 используется структура, подобная PAFPN (Path Aggregation Feature Pyramid Network), которая эффективно объединяет признаки из разных уровней основной сети. Это позволяет обнаруживать как крупные объекты (например, участки проседания грунта), так и мелкие (например, начальные микротрещины) с высокой точностью.
- Декомпозированная Детекционная Голова (Decoupled Head): В отличие от ранних версий YOLO, где классификация и локализация выполнялись в одной ветви, YOLOv8 предлагает раздельное выполнение этих задач. Это ускоряет сходимость обучения и повышает точность локализации критических дефектов.

Предполагаемая Функция Потерь (Loss Function): Для обучения сети предполагается использовать передовую функцию потерь, например, Distance IoU loss (DIoU) или ее улучшенную версию Complete IoU loss (CIoU). Эти функции не только учитывают площадь пересечения объектов, но и расстояние между их центрами, а также соотношение сторон. Это критически важно для точной локализации продолговатых дефектов, таких как продольные трещины и линейная коррозия.

Обоснование и применение 3D-CNN [4] для временного анализа

Для повышения надежности системы и верификации критических инцидентов, обнаруженных YOLOv8, на стационарных серверах будет рассмотрена возможность использования 3D-сверточных нейронных сетей (3D-CNN). Ключевое отличие 3D-CNN заключается в том, что она применяет сверточные ядра не только в двух пространственных измерениях (x, y), но и в третьем – временном (t).

Концепция 3D-свертки: Ядро 3D-свертки имеет размерность $K*K*D$, где D – размерность по времени (количество кадров). Вместо обработки каждого кадра видео независимо, как это делает 2D-CNN (включая YOLO), 3D-CNN позволяет сети одновременно захватывать пространственные и временные признаки из последовательности кадров.

Преимущества для арктического мониторинга:

1. Учет Динамики Дефектов: 3D-CNN позволяет отслеживать динамическое развитие дефекта (например, увеличение длины трещины или скорость смещения трубы) или подтверждать, что обнаруженный объект не является временным артефактом (тень, пролетающая птица, случайный снежный комок).

2. Верификация Аномалий: 3D-CNN будет использоваться как второй контур верификации. Если YOLOv8 детектирует просадку грунта, 3D-CNN анализирует последовательность кадров (например, за последние 5 секунд) для подтверждения, что это не оптическое искажение, а реальное, устойчивое во времени смещение.

3. Повышенная Устойчивость: В условиях низкой видимости (метель, туман) или недостаточной освещенности, 3D-свертка, объединяя информацию из нескольких последовательных кадров, может обеспечить более надежное извлечение признаков по сравнению с анализом одного кадра.

Сравнительный анализ нейросетевых архитектур

В рамках исследования был проведен детальный анализ возможностей современных архитектур глубокого обучения (Deep Learning), которые базируются на сверточных нейронных сетях (CNN) [10]. Основной фокус был сделан на детекторах, применимых для анализа видеопотока, критически важного для быстрого реагирования.

Таблица 1. Результаты сравнительного анализа

| Метод / Архитектура | Точность (mAP) | Скорость (FPS) | Память (GB) | Устойчивость к Окклюзии | Актуальность для РФ |
|---------------------|----------------|----------------|-------------|-------------------------|---|
| Faster R-CNN [5] | 0.78 | 7-10 | 2-3 | Средняя | Низкая скорость для Real-Time |
| YOLOv8 [6] | 0.75 | 45-60 | 1-2 | Средняя | Оптимальный баланс для БПЛА |
| CNN + LSTM | 0.72 | 20-30 | 2-3 | Высокая | Хорошая для анализа временных рядов |
| 3D-CNN | 0.81 | 10-15 | 3-4 | Высокая | Высокая точность, учет динамики |
| ViT (Video) | 0.85 | 5-8 | 8-12 | Очень высокая | Высокие требования к отечественным Edge-устройствам |

Техническое обоснование выбора

- **Приоритет Скорости:** Для систем раннего оповещения на мобильных платформах (дроны) критична скорость. YOLO (You Only Look Once), демонстрируя 45-60 FPS при mAP 0.75, является идеальной одноэтапной архитектурой для быстрого развертывания.

- **Точность с Учетом Времени:** Для стационарных систем, где требуется высокая надежность верификации, 3D-CNN является предпочтительным. Эта архитектура, используя трехмерные свертки, эффективно улавливает пространственно-временные особенности (например, проседание грунта или изменение геометрии трубы), обеспечивая точность 0.81.

- **Перспективы Квантования:** Хотя Трансформеры (ViT) [7] обладают высочайшей точностью (0.85), их ресурсоемкость требует дальнейшей оптимизации, в частности, через квантование нейросетей. Это направление является ключевым для создания энергоэффективных отечественных решений.

Предлагаемое решение

Одним из наиболее критических этапов, определяющих успешность внедрения системы компьютерного зрения в Арктике, является создание репрезентативного и сбалансированного датасета. В условиях Крайнего Севера, где получение «чистых» данных затруднено, предполагается активное использование синтетической генерации и продвинутых методов аугментации.

Для обучения нейросетевых моделей необходимо будет собрать и разметить видео- и фотоматериалы из трех ключевых источников: архивные данные российских компаний ТЭК, материалы, полученные с БПЛА, и данные с установленных термокожухов.

Таблица 2. Предполагаемые классы дефектов для детекции

| Класс Дефекта | Описание и Актуальность для Арктики | Сенсорный Признак |
|--|---|---|
| Продольная/Поперечная Трещина | Ключевой признак механического напряжения, критичный в условиях промерзания грунта. | Визуальный (высокое разрешение) |
| Коррозия | Детекция следов коррозии, особенно под изоляцией (Corrosion Under Insulation, CUI), часто маскируется. | Визуальный, Тепловизионный (аномалии температуры) |
| Смещение/Проседание Трубы | Геометрическое отклонение от нормы, вызванное термокарстом или пучением грунта (вечная мерзлота). | Визуальный, Лидар/Стереокамера |
| Наличие Посторонней Техники (FOD) | Обнаружение несанкционированных работ или техники в охранной зоне трубопровода – критично для безопасности. | Визуальный |
| Наледь/Обледенение | Факт обледенения камеры, требующий немедленного технического обслуживания. | Визуальный (размытие, низкий контраст) |

Наибольшая сложность заключается в том, что в реальных арктических условиях большинство данных будут содержать окклюзии (частичное перекрытие объекта) и низкий контраст. Предлагается разработать специальную стратегию подготовки данных для преодоления этих уникальных вызовов:

1. Синтетическая Генерация Снежной Окклюзии:

- В связи с недостатком реальных данных о дефектах, частично перекрытых снегом или льдом, будет применена технология синтетической аугментации. Это включает наложение масок снега и льда на «чистые» изображения дефектов, обучая модель детектировать объект даже при 30-50% перекрытии.

Моделирование Полярной Ночи и Тумана:

- Для обеспечения работоспособности в условиях низкой освещенности планируется использовать методы аугментации, имитирующие работу сенсоров: Гамма-коррекция и случайное изменение яркости/контраста для имитации полярного дня и ночи.

- Добавление цифрового шума и Гауссовского размытия для имитации помех и оптических искажений, вызванных туманом и метелью.

Балансировка Классов:

- Поскольку дефекты (трещины, коррозия) являются редкими событиями в сравнении с «чистой» трубой, будет необходимо активно применять методы сэмплирования и копирования/вставки (Copy-Paste Augmentation) для увеличения количества редких классов в датасете, предотвращая смещение модели в сторону детектирования только посторонних объектов.

Заключение

Таким образом, успешность CV-системы в Арктике напрямую зависит от качества и репрезентативности обучающей выборки, которая должна быть адаптирована к экстремальным климатическим и операционным условиям.

Список использованных источников и литературы

1. Грязнов, М. С. и др. Анализ перспектив применения технологий компьютерного зрения при эксплуатации объектов нефтегазовой инфраструктуры в Арктическом регионе // Арктика: экология и экономика. – 2022. – № 3 (47). – С. 104–115.
2. Сенсорные системы мониторинга нефтегазового оборудования в условиях Крайнего Севера: монография / В. Л. Козлов [и др.]. – Санкт-Петербург : Изд-во Политехн. ун-та, 2021. – 230 с.
3. Ван З. и др. Глубокое обучение для промышленного контроля: обзор // IEEE Transactions по промышленной информатике. – 2021. – Том. 17, № 6. – С. 3816–3829.
4. Тран Д. и др. Изучение пространственно-временных особенностей с помощью 3D-сверточных сетей // Международная конференция IEEE по компьютерному зрению (ICCV). – 2015. – С. 4489–4497.
5. Рен С. и др. Более быстрый R-CNN: к обнаружению объектов в реальном времени с помощью сетей предложений регионов // Транзакции IEEE по анализу шаблонов и машинному интеллекту. – 2017. – Том. 39, № 6. – С. 1137–1149.
6. Редмон Дж., Фархади А. YOLOv3: Постепенное улучшение // Препринт arXiv arXiv:1804.02767. – 2018. – 6 с.
7. Досовицкий А. и др. Изображение стоит 16x16 слов: преобразователи для масштабного распознавания изображений // Международная конференция по обучению представлений (ICLR). – 2021. – 22 с.
8. Хохрайтер С., Шмидхубер Дж. Долговременная кратковременная память // Нейронные вычисления. – 1997. – Вып. 9, № 8. – С. 1735–1780.
9. Бараметов, Ю. Л., Коробова, Е. А. Применение нейронных сетей для прогнозирования остаточного ресурса нефтегазопроводов // Нефтегазовое дело. – 2020. – № 5. – С. 15–23.
10. Брадски, Г. Библиотека OpenCV // Журнал программных инструментов доктора Добба. – 2000. – [Электронный ресурс]. – Режим доступа: URL: <https://www.drdoobs.com/open-source/the-opencv-library/184404169> (дата обращения: 20.11.2025).

List of references

1. Gryaznov, M. S. et al. Analysis of the prospects for the use of computer vision technologies in the operation of oil and gas infrastructure facilities in the Arctic region // *Arktika: Ekologiya i Ekonomika [Arctic: Ecology and Economics]*. – 2022. – № 3 (47). – P. 104–115.
2. Kozlov, V. L. et al. Sensor systems for monitoring oil and gas equipment in the Far North: Monograph. – Saint Petersburg : Izd-vo Politekhn. un-ta [Publishing House of Peter the Great St. Petersburg Polytechnic University], 2021. – 230 p.
3. Wang, Z. et al. Deep Learning for Industrial Inspection: A Survey // *IEEE Transactions on Industrial Informatics*. – 2021. – Vol. 17, № 6. – P. 3816–3829.
4. Tran, D. et al. Learning Spatiotemporal Features with 3D Convolutional Networks // *IEEE International Conference on Computer Vision (ICCV)*. – 2015. – P. 4489–4497.
5. Ren, S. et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 2017. – Vol. 39, № 6. – P. 1137–1149.
6. Redmon, J., Farhadi, A. YOLOv3: An Incremental Improvement // *arXiv preprint arXiv:1804.02767*. – 2018. – 6 p.
7. Dosovitskiy, A. et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale // *International Conference on Learning Representations (ICLR)*. – 2021. – 22 p.
8. Hochreiter, S., Schmidhuber, J. Long Short-Term Memory // *Neural Computation*. – 1997. – Vol. 9, № 8. – P. 1735–1780.
9. Barametov, Yu. L., Korobova, E. A. Application of neural networks for predicting the residual life of oil and gas pipelines // *Neftegazovoe Delo [Oil and Gas Business]*. – 2020. – № 5. – P. 15–23.
10. Bradski, G. The OpenCV Library // *Dr. Dobb's Journal of Software Tools*. – 2000. – [Electronic resource]. – Available at: URL: <https://www.drdobbs.com/open-source/the-opencv-library/184404169> (accessed: 20.11.2025).