

Д.В. СЕРДЕЧНЫЙ, к.т.н. (ГУУ)
Н.С. АКИНЬШИН, аспирант (ГУУ)
В.Д. КУТКОВ, аспирант (ГУУ)
г. Москва

ВИЗУАЛЬНАЯ ПРЕДИКТИВНАЯ АНАЛИТИКА В ЦИФРОВОЙ ТРАНСФОРМАЦИИ ЭНЕРГЕТИКИ АРКТИКИ

Введение

Цифровая трансформация энергетической отрасли направлена на переход от традиционной реактивной модели эксплуатации, основанной на устранении уже случившихся отказов, к проактивному управлению, базирующемуся на прогнозировании технического состояния активов. Данный переход приобретает особую актуальность для Арктической зоны РФ, где энергетическая инфраструктура функционирует в условиях экстремальных климатических нагрузок, геокриологической нестабильности и пространственной удалённости [1]. Огромные расстояния, низкая плотность населения и отсутствие развитой транспортной сети делают регулярное физическое присутствие персонала на объектах экономически нецелесообразным, а в периоды неблагоприятных погодных условий – невозможным. Традиционный подход, требующий периодических инспекций, не способен обеспечить должный уровень контроля над территориально распределённой инфраструктурой [2]. Внедрение систем, способных выполнять мониторинг в автономном режиме, становится не просто инструментом оптимизации, а необходимым условием для обеспечения надёжности энергоснабжения.

Фундаментальным барьером для построения точных прогнозных моделей является дефицит данных о реальном состоянии удалённых активов. Решение данной проблемы лежит в области применения технологий компьютерного зрения для анализа визуальных данных, получаемых с беспилотных авиационных систем (БАС) и стационарных камер. Визуальные образы содержат информативные паттерны – начальные стадии коррозии, микротрещины, динамику нарастания обледенения, деформацию опорных конструкций – которые являются ранними предикторами и количественными индикаторами развивающихся дефектов.

Концептуальная модель визуальной предиктивной аналитики

Переход от диагностической констатации дефекта к предиктивной оценке остаточного ресурса требует построения многоуровневой системы обработки данных. Система технического зрения на основе нейронных сетей в данной парадигме выступает не как конечный диагност, а как ин-

струмент извлечения количественных метрик, которые служат входными данными для моделей прогнозирования. Концептуальная модель такого процесса включает несколько последовательных этапов, представленных на рисунке 1.

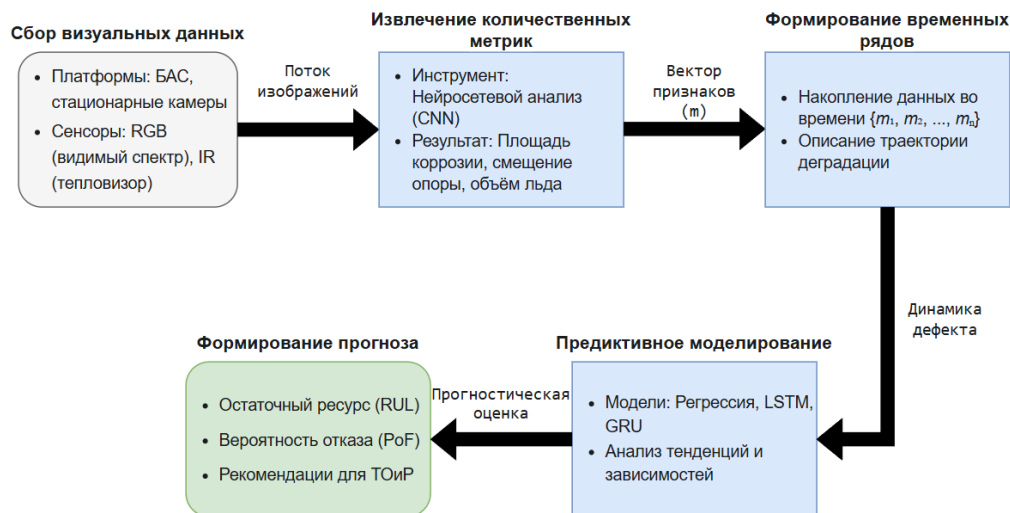


Рис. 1. Концептуальная модель процесса визуальной предиктивной аналитики

Этап 1. Сбор визуальных данных. На данном этапе формируется первичный поток информации. Для инспекции линейно-протяжённых объектов (ЛЭП, трубопроводы) применяются БАС, обеспечивающие пространственный охват. На критически важных узлах (трансформаторные подстанции, ДЭС) устанавливаются стационарные камеры. Для повышения информативности используется мультимодальный подход, сочетающий съёмку в видимом (RGB) и инфракрасном (IR) диапазонах. RGB-сенсоры позволяют идентифицировать структурные дефекты, в то время как IR-сенсоры выявляют тепловые аномалии (перегрев контактных соединений), являющиеся предикторами аварийных отказов.

Этап 2. Извлечение количественных метрик. Собранные изображения обрабатываются нейросетевыми моделями (CNN) [4]. Ключевая задача этапа – трансформация качественного визуального образа в объективный числовой показатель. Сегментационные модели (U-Net, Mask R-CNN) определяют точную площадь коррозии (в см^2) или объём ледовых отложений. Детекторы объектов, такие как YOLO [5], в связке с моделями определения ключевых точек (Keypoint Detection) фиксируют пространственное смещение опоры (в мм) относительно референсных значений. Таким образом, субъективная оценка "есть дефект" заменяется объективным измерением, пригодным для математического анализа.

Этап 3. Формирование временных рядов. Одиночное измерение является диагностическим; для прогнозирования необходим анализ динамики

ки. Последовательность количественных метрик, полученных в разные моменты времени $\{m_1, m_2, \dots, m_n\}$ с заданной периодичностью, формирует временной ряд. Данный ряд описывает траекторию деградации объекта. Частота сбора данных (дискретизация) определяется ожидаемой скоростью процесса: для медленной коррозии это могут быть месяцы, для нарастания обледенения – часы.

Этап 4. Предиктивное моделирование. Сформированные временные ряды поступают на вход математических моделей второго уровня. Для прогнозирования процессов с линейной или близкой к линейной динамикой (например, равномерный износ) могут применяться регрессионные модели. Для анализа сложных, нелинейных процессов, зависящих от множества внешних факторов (например, деформация опор из-за таяния мерзлоты под влиянием температуры), используются более сложные архитектуры, такие как рекуррентные нейронные сети (LSTM, GRU), способные улавливать долгосрочные зависимости в данных.

Этап 5. Формирование прогноза. Результатом работы предиктивной модели является прогностическая оценка, которая служит основой для принятия управленческих решений в системах ТОиР (техническое обслуживание и ремонт) [3]. Прогноз может быть выражен в нескольких формах:

- прогноз остаточного ресурса: оценка времени до достижения объектом предельного состояния;
- вероятность отказа: оценка вероятности отказа в заданном временном интервале;
- рекомендации для системы ТОиР: автоматическое формирование заявок на техническое обслуживание при превышении прогностическими показателями пороговых значений.

Выводы

Визуальная предиктивная аналитика является неотъемлемым компонентом цифровой трансформации энергетики, особенно в условиях Арктики. Данный подход позволяет решить проблему информационного дефицита для удалённых активов, преобразуя визуальные данные в основу для принятия проактивных управленческих решений.

Применение нейросетевых моделей для извлечения количественных метрик дефектов и последующий анализ их динамики во времени обеспечивают возможность перехода от планово-предупредительных и аварийно-восстановительных ремонтов к обслуживанию по фактическому состоянию и прогнозу. Данный подход напрямую способствует повышению надёжности энергоснабжения, снижению эксплуатационных затрат и обеспечению промышленной безопасности на стратегически важных территориях Российской Федерации. Дальнейшие перспективы развития данного направления связаны с созданием гибридных предиктивных моделей, интегрирую-

щих визуальные данные с телеметрией (SCADA), метеорологическими прогнозами и данными геокриологического мониторинга.

Благодарность

Статья подготовлена по результатам исследований, выполненных за счет средств федерального бюджета по государственному заданию «Научные, методологические и практические основы разработки и применения цифровых и интеллектуальных технологий в целях обеспечения устойчивого развития регионов Российской Федерации, включая удаленные и труднодоступные территории Сибири, Дальнего Востока и Арктической зоны»; код научной темы, присвоенной учредителем, – FZNW-2025-0021.

Список литературы:

1. Соловьев, Д. Климатические изменения и энергетическая инфраструктура в Российской Арктике / Д. Соловьев, Л. Шилова, О. Разоренова // Проект Байкал. – 2022. – Т. 19, № 71. – С. 50-57.
2. Биев, А. А. Формирование территориальной инфраструктуры обеспечения топливно-энергетическими ресурсами в Арктической зоне России / А. А. Биев // Север и рынок: формирование экономического порядка. – 2019. – № 3(65). – С. 43-51.
3. Повышение эффективности и обеспечение энергетической безопасности арктической инфраструктуры с применением программного обеспечения / Н. А. Бирюков, Ю. А. Бирюков, И. Н. Кравченко [и др.] // Строительные и дорожные машины. - 2020. – № 8. – С. 51-56.
4. Шабунин, А. С. Нейросетевые модели технологического оборудования в системе мониторинга и предиктивной аналитики / А. С. Шабунин, М. Ю. Чернецкий, Р. В. Осиповский // Электрические станции. – 2023. – № 11(1108). – С. 50-57.
5. Terven, Ju. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS / Ju. Terven, D. M. Córdova-Esparza, Ju. A. Romero-González // Machine Learning and Knowledge Extraction. – 2023. – Vol. 5, No. 4. – P. 1680-1716.

Информация об авторах:

Сердечный Денис Владимирович, к.т.н., начальник лаборатории цифровых и интеллектуальных технологий для развития территорий Российской Федерации, ГУУ, 109542, Москва, пр. Рязанский, д. 99, dv_serdechnyj@guu.ru

Акиншин Никита Сергеевич, аспирант, младший научный сотрудник лаборатории реверсивного инжиниринга, ГУУ, 109542, Москва, пр. Рязанский, д. 99, Email: ns_akinshin@guu.ru

Кутков Владимир Дмитриевич, аспирант, младший научный сотрудник лаборатории реверсивного инжиниринга, ГУУ, 109542, Москва, пр. Рязанский, д. 99,, Email: vd_kutkov@guu.ru