

УДК 004.932; 621.3.051

DOI: [10.26102/2310-6018/2020.31.4.036](https://doi.org/10.26102/2310-6018/2020.31.4.036)

## Обзор подходов к детектированию дефектов элементов ЛЭП на изображениях в инфракрасном, ультрафиолетовом и видимом спектрах

М.А. Астапова, И.В. Лебедев

*Федеральное государственное бюджетное учреждение науки «Санкт-Петербургский Федеральный исследовательский центр Российской академии наук» (СПб ФИЦ РАН), Санкт-Петербургский институт информатики и автоматизации Российской академии наук, Санкт-Петербург, Российская Федерация*

**Резюме:** В работе представлен обзор современных методов мониторинга состояния элементов конструкции линий электропередач (ЛЭП) посредством обработки изображений в инфракрасном, ультрафиолетовом и видимом спектрах. Рассмотрены методы распознавания основных элементов конструкции ЛЭП и детектирования наиболее характерных для них дефектов, основанные на определении отличительных признаков (цвет, форма, границы, градиент яркости и текстура). В качестве основных элементов ЛЭП были рассмотрены изоляторы, провода, опоры и арматура. Анализ эффективности рассмотренных методов и подходов проводился на основе сравнения представленных в источниках метрик: значений доли верных распознаваний (accuracy), точности (precision) и полноты (recall). Особый интерес представляет анализ методов мониторинга элементов конструкции ЛЭП на основе изображений, полученных не только в видимом, но также в ультрафиолетовом и инфракрасном спектрах. Методы, предназначенные для обработки изображений в видимом спектре, основываются на алгоритмах глубокого и машинного обучения. Ультрафиолетовый спектр (УФ) используется для выявления коронных разрядов на проводах и изоляторах. Съемка в инфракрасном спектре (ИК) позволяет выявить дефекты элементов ЛЭП, которые не могут быть детектированы на изображениях в видимом спектре, например, горячие точки (hotspot). В результате проведенного анализа были рассмотрены методы детектирования дефектов ЛЭП. Методы с наибольшей эффективностью для видимого спектра: GVN, HOG + SVM, SSD, Grab cut, cascading CNN, LBP-NF + SVM, DMNN, VGG - 19, LBP + ULBP, YOLO v3, DELM + LRF, SVM, Faster R - CNN, CNN, стереозрение + PLAMEC. Методом детектирования с наибольшей эффективностью для ИК-спектра является «оцу + пороговая обработка», а для УФ-спектра метод – SVR.

**Ключевые слова:** беспилотный летательный аппарат, обследование высоковольтных линий электропередач, обнаружение неисправностей, определение дефектов, спектральный анализ изображений

**Для цитирования:** Астапова М.А., Лебедев И.В. Обзор подходов к детектированию дефектов элементов ЛЭП на изображениях в инфракрасном, ультрафиолетовом и видимом спектрах. *Моделирование, оптимизация и информационные технологии*. 2020;8(4). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=883> DOI: 10.26102/2310-6018/2020.31.4.036

## Review of approaches to the detection of defects in power transmission line elements in images in the infrared, ultraviolet and visible spectra

M.A. Astapova, I.V. Lebedev

*St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS), St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, , St. Petersburg, Russian Federation*

**Abstract:** The paper presents an overview of modern methods for monitoring of the state of structural elements of power transmission lines (PTL) by processing images in the infrared, ultraviolet and visible spectra. Methods for recognizing of the main structural elements of power transmission lines and detecting the most characteristic defects for them, based on the determination of distinctive structural features (color, shape, borders, brightness gradient and texture), are considered. Insulators, wires, supports and fittings are considered as the main elements of power transmission lines. The analysis of the efficiency of the considered methods and approaches was performed based on the comparison of the metrics presented in the source data: values of the proportion of correct recognitions (accuracy), accuracy (precision) and recall (recall). Particularly relevant is the analysis of methods for monitoring structural elements of power transmission lines based on images obtained not only in the visible, but also in the ultraviolet and infrared spectra. Methods for image processing in the visible spectrum are based on deep and machine learning algorithms. The ultraviolet spectrum (UV) is used to detect corona discharges on wires and insulators. Imaging in the infrared spectrum (IR) enables to identify defects in power transmission lines that cannot be revealed in images in the visible spectrum, for example, hotspots. As a result of the analysis, the methods for detecting power line defects with the highest efficiency for the visible spectrum were considered: GVN, HOG + SVM, SSD, Grab cut, cascading CNN, LBP-HF + SVM, DMNN, VGG-19, LBP + ULBP, YOLO v3, DELM + LRF, SVM, Faster R-CNN, CNN, stereo vision + PLAMEC. The detection method with the highest efficiency for the IR spectrum is "Otsu + Threshold Processing", and the SVR method shows the highest efficiency for the UV spectrum.

**Keywords:** unmanned aerial vehicle, inspection of high-voltage power lines, fault detection, defect detection, spectral image analysis

**For citation:** Astapova M.A., Lebedev I.V. Review of approaches to the detection of defects in power transmission line elements in images in the infrared, ultraviolet and visible spectra. *Modeling, optimization and information technology*. 2020;8(4). Available from: <https://moitvvt.ru/ru/journal/pdf?id=883> DOI: 10.26102/2310-6018/2020.31.4.036 (In Russ).

## Введение

В настоящее время около 60% существующих распределительных линий в значительной мере изношены [1]. Наблюдаемое ухудшение состояния линий электропередачи (ЛЭП) влечет за собой снижение их пропускной способности и, как следствие, снижение эффективности процессов производства, передачи, распределения и потребления электроэнергии (ЭЭ), ускоренное старение изоляции электрооборудования, ложное срабатывание устройств релейной защиты и автоматики и пр. Сегодня 90% воздушных линий электропередач (ВЛ) не оборудованы системами мониторинга, поэтому контроль за состоянием проводящих линий ведется визуальным способом оперативно-выездными бригадами сетевых компаний, а передача полученной ориентировочной информации осуществляется по имеющимся телекоммуникационным каналам. Такая организация работы по контролю ЛЭП является низкоэффективной, что объясняет необходимость разработки современных автоматизированных систем мониторинга. Кроме того, повсеместное внедрение подобных систем позволило бы контролировать уровень тока и температуру проводов по всей трассе, что создает предпосылки к созданию «умной» электрической сети с динамическими параметрами [2,3].

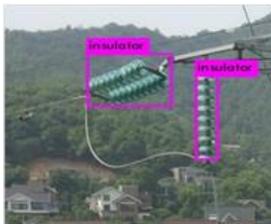
На сегодня наиболее перспективным направлением в области инспектирования и мониторинга состояния распределительных сетей является использование беспилотных летательных аппаратов (БПЛА) [4]. При мониторинге ВЛ при помощи БПЛА могут быть использованы следующие устройства: камеры различных спектров видимости, лидары,

магнитометры, датчики обнаружения химикатов и газов и пр. Наиболее популярным подходом к дистанционному инспектированию ЛЭП при помощи БПЛА является техническое зрение на основе камер высокого разрешения [5,6] и оптических датчиков, которые позволяют получить изображения в видимом спектре и затем применить к ним специализированные методы обработки. Кроме того, для определения температурных режимов работы элементов конструкции ВЛ и детектирования коронных разрядов используются инфракрасная термография и ультрафиолетовая съемка соответственно [7].

Целью данной работы является обзор и анализ методов детектирования дефектов элементов ЛЭП. Отдельно рассмотрены методы детектирования повреждений на изображениях в видимом, ультрафиолетовом (УФ) и инфракрасном (ИК) спектрах. Статья организована следующим образом. В разделе 2 кратко описаны элементы конструкции ЛЭП и наиболее характерные для них дефекты. Третий раздел содержит описание подхода к мониторингу ЛЭП при помощи БПЛА. В четвертом и пятом разделах представлен обзор методов распознавания элементов ВЛ и их дефектов соответственно. Пятый и шестой разделы содержат обзоры методов детектирования дефектов на УФ и ИК-изображениях соответственно. Седьмой раздел содержит обсуждение полученных результатов и сводную таблицу методов детектирования дефектов.

#### Элементы конструкции ЛЭП и их дефекты

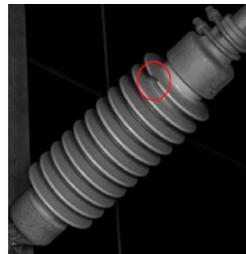
В данной работе в качестве основных компонентов конструкции ЛЭП рассматриваются провода (в том числе грозозащитный трос), изолятор, опора и арматура. Провода обеспечивают передачу энергии от источника. В зависимости от класса напряжения может быть от одного до восьми проводов в каждой фазе. Наиболее распространенные дефекты компонентов ЛЭП представлены на Рисунке 1.



Изолятор



Отсутствие тарелки



Сколы



Коронный разряд



Опора



Падение



Коррозия



Гнездо

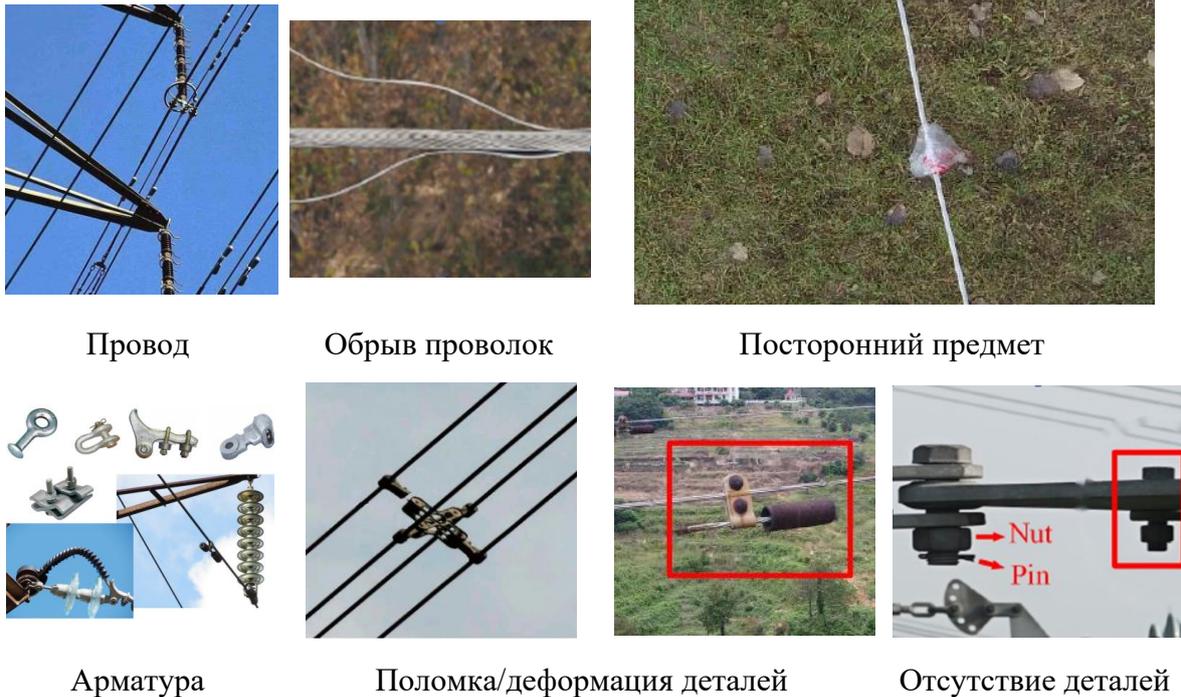


Рисунок 1 – Наиболее распространенные дефекты компонентов ЛЭП  
Figure 1 – The most common defects in power transmission line components

Мониторинг состояния элементов ВЛ при помощи ИК и УФ камер позволяет выявить неисправности элементов конструкций линии, которые не заметны при визуальном осмотре. Для дистанционного выявления коронного разряда на проводах применяется методы обработки УФ-изображений [8,9]. Для обнаружения дефектов изоляции, измерения температуры проводов ЛЭП с целью выявления сверхнормативных потерь энергии используется инфракрасная термография. Термограммы представляют собой изображения в инфракрасных лучах, показывающие картину распределения температурных полей. Трещины, загрязнение и следы перекрытия изоляторов, нарушение целостности провода, а также ослабление арматуры представлены на ИК-снимках горячими точками, что позволяет использовать методы обработки изображений для выявления дефектов [10]. В данном разделе были кратко описаны элементы конструкции ЛЭП и наиболее характерные для них дефекты. Далее рассмотрим подход к мониторингу ЛЭП при помощи БПЛА.

### Подход к мониторингу ЛЭП при помощи БПЛА

Детектирование дефектов элементов ЛЭП позволяет оценить состояние проводящей линии и на основании результатов анализа составить план технического обслуживания по ликвидации повреждений. Предполагается, что БПЛА автономно совершает полет по заранее рассчитанным ключевым точкам [11,12] и выполняет мультиспектральную съемку. Полученные изображения отправляются на наземную базовую станцию по каналу беспроводной связи (Рисунок 2).

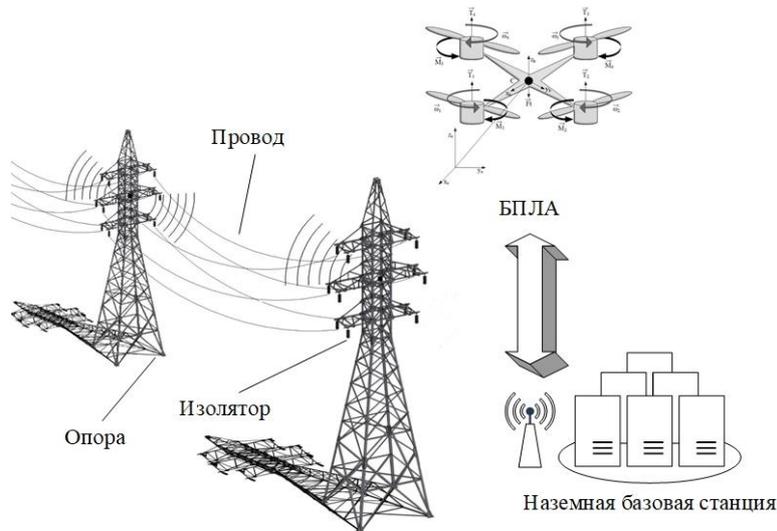


Рисунок 2 – Схема системы мониторинга ЛЭП  
Figure 2 – Power transmission line monitoring system diagram

Далее детектирование дефектов элементов проводится в два этапа: распознавание элементов ЛЭП на изображении и распознавание повреждений выявленных элементов [13–16]. Рассмотрим подробнее используемые для этого методы распознавания различных элементов конструкции ЛЭП.

### Методы распознавания элементов ЛЭП

С развитием технологий управления БПЛА и обработки изображений проверка состояния элементов ЛЭП сводится к разработке специализированных методов анализа аэрофотоснимков. Наиболее перспективными для использования в целях мониторинга ЛЭП представляются методы извлечения и анализа отличительных признаков объектов (feature-based methods), в частности, при помощи методов машинного обучения, включая методы глубокого обучения [17]. В качестве визуальных признаков для этой цели, как правило, используют: цвет [18,19], форму [20], границы (edge) [21], градиент яркости [13,19], текстуру [22], так называемые ключевые признаки (keypoint features) [23,24] и др. Кроме того, для детектирования компонентов линии могут использоваться преобразования Хафа [25], модели нечеткой логики [26] и рецептивного поля [27]. Показатели эффективности рассмотренных методов приведены в Таблице 1.

#### *Детектирование изоляторов на изображениях*

Для детектирования изолятора на изображении может применяться гистограмма направленных градиентов (Histogram of Oriented Gradients, HOG) [28], которая представляет собой дескрипторы особых точек. Дескрипторы подсчитывают количество направлений градиента в локальных областях изображения. Для фильтрации яркостной составляющей изображения используется фильтр, скрытые переменные (latent variable) которого определяются при помощи машины опорных векторов (support vector machine, SVM). Совместное использование HOG и SVM позволяет достичь полноты детектирования 93,81% [13].

Детектор Deformable Part Model (DPM) [29] расширяет возможности HOG, так как позволяет работать с объектами, которые имеют высокую степень изменчивости по внешнему виду внутри одного класса, благодаря комбинации нескольких подмоделей. Оригинальный DPM основан на методе скользящего окна и имеет высокую

вычислительную сложность, поскольку применяется ко всему изображению, а не к его части. Для уменьшения вычислительной сложности метода сначала осуществляется поиск фрагментов изображений, содержащих опоры, затем на полученных фрагментах детектируются изоляторы. По результатам тестирования [13], полнота улучшенного метода составила 98,97%.

Для детектирования изолятора, который частично заслонен другим изолятором, авторы работы [19] разработали метод на основе расчета салиентности (saliency value). Салиентность рассчитывается для двух признаков: цвета и градиента. Для этого сначала пространства признаков разделяются на 12 (для цвета) и 8 (для градиента) областей при помощи метода k-средних. Затем рассчитывается салиентность для обоих признаков и их суммарная салиентность, после чего полученное значение сравнивается с пороговой величиной для локализации фона и изолятора. В работе [30] для локализации стеклянных и керамических изоляторов авторы разработали алгоритм определения признаков цвета и ключевых точек. После построения гистограмм распределения цветов и нахождения ключевых точек к полученным данным применялась пороговая обработка. Результаты экспериментов подтверждают эффективность и надежность алгоритма. Средний показатель обнаружения дефектов в керамике может достигать более 91%, а средний показатель обнаружения дефектов стекла более 92%. В Предлагаемое решение может быть использовано в системе контроля крупномасштабных инфраструктур, например, высоковольтных линий электропередачи электроэнергетических предприятий.

В работе [31] для бинаризации изображения использовался метод Оцу [32], который позволил получить области изображения, в которых расположены изоляторы. После чего для выделения границ применялся метод максимумов модулей вейвлет-преобразования (Wavelet transform modulus maxima method) [33] и преобразование Хафа. Такое решение характеризуется простотой реализации и малой временной сложностью  $O(n)$  (где  $n$  – количество пикселей). Однако пороговая обработка чувствительна к неравномерной яркости изображения, что может затруднить распознавание изоляторов на сложном фоне. Разработанный метод может использоваться для выявления неисправностей изоляторов, но не способен локализовать их дефекты.

Низкая эффективность методов, основанных на определении признаков цвета, объясняется сложностью определения диапазона цветов при работе со сложным фоном. Кроме того, цветовые признаки в большей степени содержат информацию о глобальных областях, нежели о локальных.

Признаки текстуры изображения были использованы в работах [34,35]. Предложенные решения позволяют локализовать изоляторы с учетом изменения их ориентации. Так метод [35] включает в себя три этапа: корректировку положения изолятора в горизонтальной плоскости, извлечение признака текстуры при помощи дескриптора Local Directional Pattern (LDP) и классификацию полученных признаков на основе SVM. При тестировании предложенного метода значение полноты достигло 94,24%. В последующем исследовании [34] авторы разработали дескриптор RI-LDP (rotation invariant local directional pattern), который инвариантен к вращению изолятора. При этом сократилось количество шагов метода в связи с отсутствием необходимости в корректировке ориентации изолятора. Использование разработанного дескриптора позволило повысить полноту до 95,74%.

В качестве ключевых признаков в работах [23,24] использовались SURF (Speeded up robust features) и разность гауссианов (Difference of Gaussians, DoG) соответственно. Алгоритм локализации изоляторов [24] состоит из трех этапов: обнаружение локальных объектов, описание локальных объектов и сопоставление объектов. Для обнаружения и

описания объектов использовался детектор Харриса (Harris affine region detector), после чего полученные признаки сравнивались с признаками из визуального словаря изоляторов (visual vocabulary of insulator), который был сгенерирован на основе обучающей выборки при помощи метода k-средних. Точность распознавания достигла 87%.

Для повышения точности распознавания изоляторов авторы [36] использовали комбинацию нескольких признаков: цвета, формы и текстуры. Однако такое решение привело к высокой вычислительной сложности алгоритма, что не позволяет использовать его в системах инспектирования реального времени. Кроме того, данный алгоритм применим для распознавания только соседних изоляторов.

Помимо вышеперечисленных, для распознавания изоляторов используются классификаторы на основе AdaBoost [37], SVM [38], каскадного классификатора (Cascade classifier) [39] и метода k-ближайших соседей (k-nearest neighbors algorithm, k-NN) [15]. В [37] перед применением классификатора на основе AdaBoost для улучшения изображения проводится выравнивание гистограммы (histogram equalization), после чего изображение преобразуется в бинарное при помощи оптимального порога энтропии (optimal entropy threshold, ОЕТ). ОЕТ позволяет выделить изолятор на изображении, однако после обработки изображение остается зашумленным. Для уменьшения шума на изображении применяются стандартные морфологические операции: эрозия, наращивание, замыывание и размыкание.

В работе [38] авторы предложили метод обнаружения изоляторов, основанный на слиянии признаков (feature-fusion) при помощи HOG и локальных бинарных паттернов (local binary pattern). После извлечения признаков размерность данных уменьшается при помощи метода главных компонент (principal component analysis), затем для классификации используется SVM. Тестирование на 500 изображениях показало точность классификации 89,1%, что выше, чем при использовании признаков по отдельности: 75,3% и 76,9% для HOG и LBP соответственно.

В работе [39] признаки Хаара (Haar-like feature), интегрального графа (integral graph feature) и признак гистограммы направленного градиента (directional gradient histogram feature) были объединены для обучения каскадного классификатора и SVM. Затем две модели классификаторов использовались для определения местоположения изоляторов на изображении.

Авторы статьи [15] используют в качестве ключевых признаков DoG. На основании DoG определяется круговой (Circular GLOH-like, CGL) дескриптор. Данный дескриптор основан на градиентах изображения, которые вычисляются при помощи оператора Шарра (Scharf operator). После этого размерность данных уменьшается при помощи метода главных компонент. Дескрипторы DoG используются для обучения классификатора k-NN.

Популярным решением в области распознавания образов является использование сверточных нейронных сетей (СНС), например, R-CNN [40], Fast R-CNN [41], Faster R-CNN [42], YOLO [43], R-FCN [44], SSD [45], в сочетании с классификаторами VGG-Net [46] и Inception-V4 [47]. Такие методы осуществляют поиск объектов на изображении путем извлечения многомерных семантических признаков. Например, СНС для распознавания изоляторов, представленная в [48], состоящая из 7 слоев (1 входного, 2 слоев свертки, 2 пулинга, 1 полносвязного слоя и 1 выходного слоя) позволила достичь доли верных распознаваний 89,04%.

Авторы работы [49] предложили оригинальный метод детектирования изоляторов на изображении. Помимо камеры, БЛА, инспектирующий ЛЭП, оснащен лазером, который генерирует пучок определенной длины волны. Предложенный метод основан

на анализе кривых интенсивности пикселей, считываемой между парами спроецированных на изолятор лазерных точек/маркеров (laser spots). В качестве исходных данных используются RGB-изображения с лазерными точками и без них. Локализация лазерных точек на изображении осуществляется при помощи бинаризации. Классификация выполняется посредством обработки кривых интенсивности: усреднения сигнала, удаления линейного тренда, поиска максимума и минимума. Точность распознавания изоляторов при использовании данного метода составляет 98,982%.

Для повышения эффективности СНС в задаче инспектирования ЛЭП авторы [14] разработали специализированную каскадную архитектуру СНС, которая содержит три ветви, предназначенные для извлечения карты признаков, изменения канала свертки и обеспечения взаимодействия между каналами. По результатам экспериментов, предложенное решение превосходит по точности YOLOv2 (89,83%) и YOLOv3-tiny (52,78%), однако не достигает точности YOLOv3 (90,05%)

В [50] представлен метод детектирования изоляторов на основе сети Faster R-CNN, которая состоит из двух СНС: Region Proposal Network (RPN) и Fast R-CNN. Для предварительного обучения сети использовалась модель Цайлера и Фергуса (Zeiler and Fergus net) [51]. Исходное изображение поступает на вход RPN для определения областей, в которых расположены изоляторы. Полученные области являются входными данными Faster R-CNN, которая рассчитывает вероятность нахождения изолятора в каждой области. По результатам тестирования, время работы предложенного метода составило 0,131 с, средняя точность детектирования – 92,6%. Сеть Faster R-CNN также использовалась в [52] для обнаружения дефектов поверхности изоляторов на высокоскоростной железной дороге и в [53] для обнаружения самопроизвольно взрывающихся стеклянных изоляторов.

В целом, методы на основе СНС не требуют корректировки параметров поиска компонент на изображении после обучения сети, однако для обучения СНС необходимо сформировать репрезентативную выборку, которая содержит изображения различных масштабов и ракурсов, снятые при различных условиях освещения. Создание таких наборов данных является отдельной достаточно трудоемкой задачей.

#### *Детектирование элементов опор на изображениях*

Распознавание опор является, пожалуй, наиболее сложной задачей при автоматизированном инспектировании ЛЭП, поскольку конструкции опор отличаются по типу и внешнему виду, что требует разработки специализированных подходов для каждого вида, и могут быть спутаны с похожими на них элементами окружения. Так, например, метод, представленный в [54], применим для распознавания только одностоечных опор типа «Свечка». Для последующего распознавания исходное RGB-изображение конвертируется в пространства HSI и YCbCr. После преобразования снимка каналы цветовых пространств B, S и Cr передаются на вход искусственной нейронной сети, которая выполняет классификацию цветовых признаков на четыре группы: стойка опоры (pole), траверса (crossarm), древесно-кустарниковая растительность. По результатам тестирования, предложенное решение достигло 70% верных распознаваний.

Детектирование металлических опор на изображении может быть основано на определении признаков формы ввиду их характерной конструкции. Так, для детектирования опор воздушных линий электропередач в [55] авторы использовали оператор Кэнни обнаружения границ на изображении и преобразования Хафа для поиска

прямых линий. Метод также был дополнен специализированными правилами, которые позволили сократить число ложных распознаваний.

Рассмотрим некоторые методы детектирования опор при помощи машинного обучения. В частности, авторы метода на основе бустинга [56,57] предложили для локализации и сегментации опоры сильный классификатор, полученный в результате обучения 2048 слабых деревьев решений. Для обучения и объединения деревьев решений применялись алгоритмы Aggregate Channel Features (ACF), AdaBoost и RealBoost [58]. Разработанный алгоритм был обучен и протестирован на 1400 кадрах. Средняя ошибка детектирования опор составила 3,25%, а доля ложных распознаваний – 1,5%, что означает, что 3 из 200 фоновых изображений были детектированы как опоры. При этом 4 из 200 изображений опор были детектированы как фон.

Метод распознавания опор, представленный в [59], состоит из трех шагов: предварительной обработки изображения, классификации и постобработки. Предобработка, как и в [55] заключается в бинаризации и обнаружении вертикальных линий при помощи преобразования Хафа. Для классификации используется алгоритм Region Proposal, основанный на методе скользящего окна, гистограмма направленных коэффициентов HOG и многослойный перцептрон (Multi-Layer Perceptron).

Метод распознавания опор на основе глубокого обучения представлен в [60]. Авторы использовали YOLO v3. На вход сети подается RGB-изображение, из которого извлекается карта признаков. Далее изображение делится на квадратные ячейки. В случае, если ячейка имеет координаты центра объекта, которые входят в контрольной набор данных, она является кандидатом для потенциального детектирования опоры. В ней строятся три рамки (bounding boxes) размером 13×13, 26×26 и 52×52, для каждой из которых при помощи коэффициента Жаккара (Jaccard index) определяется вероятность присутствия опоры. Точность обнаружения этого алгоритма составляет 90%. Этот метод может быть применен для быстрой оценки потерь электросети после аварии, а также для быстрого обнаружения опор ЛЭП.

### *Детектирование проводов на изображениях*

При детектировании проводов ЛЭП часто вводится допущение, что они представляют собой прямые, которые параллельны друг другу. Это приводит к ограничению, накладываемому на ракурс съемки: съемка должна провалиться только верху.

Метод, основанный на определении признаков формы, показан в работе [61]. Для выделения границ авторы использовали алгоритм Edge Drawing, который позволили определить прямые линии. Затем для окончательного детектирования применялся набор правил/шагов (hand-craft rules): разделение изображения на вертикальные и горизонтальные сегменты, удаление малых сегментов, группировка сегментов и определение сегментов, на которых присутствует требуемое число параллельных прямых. Новый алгоритм обнаружения линии электропередачи на основе технического зрения (PLineD), способен повысить надежность обнаружения даже при наличии фонового шума. Алгоритм протестирован на изображениях набора данных с различными фонами и погодными условиями. Результаты экспериментов показали, что данный подход успешно идентифицирует линии электропередачи даже при наличии опор.

В работе [62] для распознавания опор использовались операторы Кэнни и Собеля для выделения границ, а также преобразования Хафа для поиска прямых линий. Кроме того, авторы представили формулы для расчета оптимальных параметров выделения границ, которые позволяют ослабить фоновые помехи. Система обеспечила полностью

автоматизированное отслеживание линий электропередач в Далласе протяженностью 15 км со скоростью до 30 км/ч.

Метод детектирования грозозащитных тросов на основе глубокого обучения представлен в [63]. Авторы разработали генеративно-сопоставительную сеть с условием (Conditional Generative Adversarial Network, cGAN). Использование генеративной сети позволило увеличить обучающую выборку до 1000 изображений. Доля верных распознаваний решения составила 94,8%, при этом cGAN превзошла по точности сети PCANet (86,8%) и ENet (95,4%).

Таким образом, существующие методы детектирования проводов ЛЭП позволяют автоматически в реальном времени отслеживать и обнаруживать их на изображениях.

#### *Детектирование элементов арматуры на изображениях*

В современных исследованиях зачастую в качестве арматуры рассматриваются распорки проводов в расщепленной фазе и виброгасители. Метод распознавания арматуры на основе определения признаков формы описан в [64]. Данный метод содержит три уровня обработки изображения: сегментацию, поиск параллельных и перпендикулярных линий для распознавания проводов и опоры, а также локализация арматуры. Участок разрыва двух прямых линий считался местом расположения виброгасителя или распорки. Результат распознавания изолятора показывает, что он в значительной степени достигается за счет ограничения положения и локального контура.

Авторы [65] разработали метод локализации виброгасителя на основе определения признаков текстуры интегрального изображения. Для извлечения признаков Хаара из скользящего окна использовался классификатор Adaboost. Обучающая выборка включала в себя 1518 изображений с виброгасителями и 2999 фоновых изображений. По результатам тестирования на 100 изображениях, доля истинно-положительных классификаций составила 92,48%.

К методам глубокого обучения относится решение, представленное в работе [66]. Сверточная нейронная сеть (CNN) превосходно работает в области распознавания объектов. При обнаружении объектов сверточные нейронные сети на основе областей (RCNN) извлекают область, которая может содержать объект, из изображений. Однако вычисления такие вычисления являются весьма дорогостоящими, что не могут использоваться в практических проектах. С помощью Fast R-CNN и Faster R-CNN можно решить эту проблему, изменяя способ поиска объекта. Fast R-CNN и Faster R-CNN экономят много времени и могут выполнять обнаружение объектов в реальном времени. Для детектирования виброгасителей, распорок и дугогасящих колец (arcing ring) на изображениях авторы использовали Faster R-CNN. Также в данном исследовании были проанализированы такие методы, как SPPNet и DPM. Результаты тестирования показали, что метод Faster R-CNN может одновременно обнаруживать различные электрические устройства на одном изображении в течение 80 мс и достигать точности 92,7% на стандартном тестовом наборе, что имеет большое преимущество при проверке ЛЭП. Тестирование, проведенное на 1500 изображениях, показало полноту метода 84,03%.

В качестве показателей эффективности представленных решений используется несколько показателей: доля верных детектирований (accuracy), полнота (recall), точность (precision), среднее значение точности (mAP) доля истинно-положительных классификаций (false positive per image).

Таблица 1 – Сравнительная таблица методов детектирования различных элементов ЛЭП  
Table 1 – Comparative table of methods for detecting various elements of power transmission lines

Метод	Выборка	Accuracy, %	Recall, %	Precision, %	False positive per image, %
Изолятор					
HOG+SVM [13]	Test: 1755		93,81		0,84
DPM [29]	Test: 1755		98,97		2,72
[35]	Test: 325		92,24		
[34]	Test: 395		95,74		
[24]	Test: 100 Train: 300		92	87	
HOG+LPB [38]	Test: 500 Train: 2800	83,5		89,1	2,1
[15]	Test: 400			92,6	99,7
[49]	Test: 2386	96,101	96,317	98,982	
[43]	Test: 1166	86,667	89,412	89,412	
SSD [45]	Test: 1166	89,629	92,941	90,804	
CNN [48]	Test: 1305 Train: 1220	89,04	89,25	71,35	
CNN [14]	Test: 1356 Train: 2675	mAP:89,96			
Faster R-CNN [43]	Test: 1166	94,074	98,823	90,308	
Faster R-CNN [50]	Test: 300 Train: 1000			mAP: 92,6	
Faster R-CNN [52]	Test: 12000 Train: 6000			mAP: 99,8	
Faster R-CNN [53]	Test: 208 Train: 412		96,6	97,1	
Опора					
[57]	Test: 1400	96,75			1,5
[54]	Test: 700			70	
Canny [55]	Test: 2 videos			100	
[Martinez C. et al.]	Test: 3655 Train: 14620	95,63			59
YOLO v3 [59]	Test: 1478 Train: 11951			mAP: 90,45	
Провода					
PLineD [61]	Test: 82				
cGAN [63]	Test: 1000 Train: 5000	94,8			
Арматура					
MLP [64]	Test: 2000	80,42			0,934
Harr+AdaBoost [65]	Test: 100 Train: 4517			True positive rate:92,48%	
Faster R-CNN [66]	Test: 1500 Train: 4500		84,03		

В данном разделе были проанализированы различные методы распознавания элементов ЛЭП на основе машинного и глубокого обучения. Использование методов

машинного обучения позволяет повысить точность детектирования элементов ЛЭП по сравнению с методами, основанными на определении признаков. Методы глубокого обучения обеспечивают высокие показатели точности распознавания по сравнению с альтернативными методами. Далее рассмотрим методы детектирования дефектов элементов ЛЭП.

### Методы детектирования дефектов элементов ЛЭП

Детектирование дефектов элементов ЛЭП позволяет оценить их состояние и на основании результатов анализа составить план технического обслуживания по устранению повреждений. В соответствии с используемым двухэтапным подходом к мониторингу ЛЭП, фрагменты изображений, содержащие компоненты линии, используются для выявления дефектов данного компонента. Задача разработки методов детектирования дефектов более сложная по сравнению с распознаванием элементов ВЛ, поскольку каждый элемент может иметь несколько разных характерных дефектов. Характеристики методов детектирования дефектов показаны в Таблице 2.

Таблица 2 – Методы детектирования дефектов элементов ЛЭП

Table 2 – Methods for detecting defects in power transmission lines

Метод	Выборка	Accuracy, %	Recall, %	Precision, %	Average runtime/s
Отсутствие тарелки изолятора					
Computer vision+ DPM [13]	Test: 480			false alarm rate: 9,63%	
ML+Mathematical morphology [19]	Test: 100	92,4	43	67,2	0,525
ML+Mathematical morphology [30]	Test: 100	90,6	52,1	77,8	0,677
Grab cut	Test: 90		91,7	95,6	0,127
U-net	Test: 55 Train: 165		95,5		
R-FCN	Test: 822 Train: 2626			mAP: 90,5	
cascading CNN	Test: 264 Train: 7092		96	91	
Сколы изолятора					
LBP-HF+SVM	Test: 80	93,33			
VGG-19	Test: 2080 Train: 50560	92,69			
Inception-v3	Test: 2080 Train: 50560	83,41			
ResNet-50	Test: 2080 Train: 50560	26,01			
DMNN	Test: 1000 Train:		98,6	92,2	
Обледенение изолятора					
LBP+ULBP					0,015
Падение опоры					
YOLO v3	Test: 1478 Train: 11951		91	90 mAP: 90,45	
Faster RCNN	Test: 1478 Train: 11951		67	75 mAP: 71,94	

Коррозия опоры					
DELM+LRF	Test: 560 Train: 2237			F1 score: 79,6	
DELM+LRF	Test: 603 Train: 2414			F1 score: 88,8	
Гнезда птиц на опоре					
SVM	Test: 200 Train: 2972	97,33	96	98,63	
Повреждение/обрыв проводок провода					
[78]	Test: 100			Recognition rate: 100%	
GVN	Test: 400	85,5			
Посторонний предмет на проводе					
HOG+SVM	Test: 335 Train: 301	84,3			0,539
SSD	Test: 1500 Train: 4500			mAP: 85,2	
Деформация арматуры					
Faster R-CNN	Test: 500 Train: 1000		83,4		
Отсутствие деталей арматуры					
CNN	Test: 752 Train: 1900	96,54			
Растительность на трассе					
PLAMEC		93,2			

### *Детектирование дефектов изоляторов*

Разрушения тарелки изолятора и наличие постороннего предмета между тарелками является наиболее распространенными дефектами. Поверхность фарфорового изолятора имеет высокую отражающую способность, что позволяет анализировать яркость пикселей на изображении в оттенках серого. Так авторы работы [13] исследовали период функции изменения яркости пикселей (local intensity period estimation) для детектирования двух упомянутых ранее дефектов. В зависимости от значения изменения периода яркости можно определить отсутствие тарелки изолятора или наличия постороннего. Метод оценки показал наилучшие результаты с самым низким уровнем ложных срабатываний на уровне 9,63% (44 из 457 хороших изоляторов были ошибочно классифицированы как детективные).

Метод детектирования отсутствия тарелки (стеклянного) изолятора представлен в [19]. Для определения расстояния между тарелками и локализации дефекта авторы использовали операции математической морфологии (Mathematical morphology): эрозию (Erosion), наращивание (dilation) и замыкание (closing). Изменение расстояния между тарелками свидетельствовало о наличии дефекта. Операции математической морфологии также использовались в работе [30]. Такое решение позволило достичь точности детектирования 90,6% и может применяться для инспектирования стеклянных и фарфоровых изоляторов.

Морфологические операторы применялись в работе [14]. Авторы представили метод, который состоит из трех этапов. На первом этапе используется алгоритм Grab cut для сегментации изображения и локализации изолятора. Затем для выделения границ предположительно поврежденных изоляторов применяются морфологические операторы. Последний этап заключается в окончательной проверке кандидатов на

наличие дефектов при помощи метода k-средних. Предложенный метод показывает результаты обнаружения неисправностей, которые достигают показателя точности 98,3%. Таким образом, метод обеспечивает более высокую точность и меньшее время работы в отличие от работ [30] и [19].

В [53] отсутствие тарелки изолятора основано на использовании полностью сверточной нейронной сети (Fully Convolutional Network, FCN). Авторы разработали сеть U-net, которая представляет собой усовершенствованную модель VGGNet-16. Тестирование на 55 изображениях показало полноту метода 95,5%.

Авторы [67] для детектирования данного дефекта использовали сеть Region-based Fully Convolutional Networks (R-FCN). R-FCN состоит из двух моделей RPN для поиска областей и FCN Resnet101 для получения карты признаков. Для тестирования метода была сформирована выборка размеров 822 изображений разного размера. Среднее значение доли верных распознаваний составило 90,5%.

Для детектирования отсутствия тарелки изолятора авторы [16] разработали каскадную нейронную сеть. Первая СНС предназначена для локализации изолятора на изображении и основана на VGGNet. Вторая сеть используется для распознавания дефекта и использует модель ResNet. Точность предложенного решения достигает 96%.

Другим распространенным дефектом изоляторов является наличие сколов на поверхности тарелок. Для оценки состояния изоляторов со сколами авторы [68] разработали метод на основе многоцелевого программирования (МОП). Метод k-средних применялся для поиска изоляторов на изображении ЛЭП. Затем осуществлялось извлечение признаков при помощи гистограммы локальных бинарных шаблонов (Local Binary Pattern Histogram Fourier, LBP-HF). Далее для классификации полученных признаков использовался МОП. Предложенное решение предназначено для классификации изоляторов на три группы: без повреждений, с незначительными и опасными повреждениями. Эффективность данного метода составляет 93,33%.

В работе [69] для классификации изоляторов и распознавания сколов на поверхности изолятора использовались СНС. Были рассмотрены четыре класса штыревых изоляторов ЛЭП 15 кВ: фарфоровый одноцветный, фарфоровый двухцветный, полимерный и стеклянный. Обучающая выборка состояла из 2560 изображений изоляторов, полученных в реальных условиях и лаборатории. Для расширения выборки был использован генератор, который позволили увеличить количество изображений на 48 000. Процесс генерации синтетических данных включал в себя сегментацию изображения для выделения изолятора, провода и спиральной вязки (спиральных зажимов) и детализацию изображения, которая заключалась в наложении масок зажимов и проводов, изменении яркости, масштаба, угла наклона и смещении. С целью определения наиболее подходящей СНС для работы с изоляторами были протестированы три модели: VGG-19 [70], Inception-v3 [71] и ResNet-50 [72]. VGG-19 имеет 19 полносвязных слоев и малую размерность фильтров сверточных слоев (3×3), что позволяет уменьшить количество параметров и, соответственно, время из обработки. Inception-v3 также характеризуется уменьшенной размерностью фильтра, а также наличием пакетной нормализацией (batch normalization) для предобработки подаваемых в слой данных. ResNet-50 построена по аналогии с архитектурой VGG-19, но имеет короткие пути (пропуски соединений), которые позволяют решить проблемы исчезающего градиента (vanishing gradient) и взрывающегося градиента (exploding gradient) при обучении. По результатам тестирования, наибольшую точность распознавания имеет СНС VGG-19. При решении задачи классификации изолятора точность данной модели составила 92%, при классификации изолятора и детектирования его дефектов – 85%.

С целью повышения точности детектирования СНС авторы статьи [52] объединили глубокий классификатор материалов (deep material classifier, DMC) и глубокий шумоподавляющий автокадировщик (deep denoising autoencoder, DDAE), которые были интегрированы в многозадачную глубокую нейронную сеть (deep multitask neural network, DMNN). DMC предназначен для распознавания изолятора на изображении. Далее автокадировщик восстанавливает сегменты изображения и рассчитывает карту ошибок восстановления. На основе карты ошибок восстановления и ошибок классификации определяются аномалии. Повреждения изолятора выявляются путем сравнения результатов работы классификатора и полученных аномалий. По словам авторов, при обучении DMNN не требуются изображения поврежденных изоляторов.

Наличие гололеда на изоляторах приводит к дополнительным механическим нагрузкам. В результате увеличения массы изоляторов повышается риск деформации арматуры, кроме того ухудшаются защитные свойства изоляторов. В [73] представлен метод детектирования обледенения изолятора на основе определения признаков текстуры. Для извлечения признаков использовались унифицированные (Uniform Local Binary Patterns) и усовершенствованные локальные бинарные шаблоны (Improved Uniform Local Binary Patterns). Метод позволяет определить шесть типов обледенения: прозрачный лед, непрозрачный лед, сильная, средняя и слабая изморозь, а также иней и снег. Для определения типа обледенения рассчитывался коэффициент корреляции между гистограммами признаков текстуры изображения тестовой выборки и изображения контрольной выборки. При применении IULBP результаты коэффициента корреляции определили определенные типы льда. Результаты показали, что IULBP больше подходит для распознавания типов льда на изоляторах, чем ULBP, так как обеспечивает большую точность.

Авторы [74] для детектирования наледи использовали алгоритм сегментации GrabCut. Детектирование дефекта основано на расчете геометрических параметров изолятора: расстояния между тарелками и расстояния от крайней точки до шапки изолятора. Тестирование проводилось с использованием метеорологических данных и показало работоспособность решения.

### *Детектирование дефектов опор*

Падение опоры приводит к обрыву проводов ВЛ и отключению потребителей от электросети. Падение опоры может служить последствием развития других неисправностей, например, загнивания деревянных частей, коррозии металла. В [63] для детектирования упавших опор использовались две модели нейронных сетей YOLO v3 и Faster RCNN. Тестирование на 1478 изображениях показало, что YOLO v3 превосходит Faster RCNN по точности на 15%.

Предотвратить падение опоры возможно путем своевременного распознавания коррозии металлических элементов опоры. Для решения данной задачи авторы работ [75,76] разработали метод на основе экстремального глубокого машинного обучения (Deep Extreme Learning Machine). Извлечение признаков осуществляется при помощи локального рецепиентного поля (Local Receptive Field), которое сочетает свойства слоев свертки и пулинга. Такое решение позволяет использовать небольшие обучающие выборки. Результаты экспериментов показывают, что эффективность DELM-LRF была выше, чем у других сравнительных методов ELM-LRF, DELM, KELM, ELM, SVM и CaffeNet-CNN. В [76] авторы добавили в модель скрытый слой, который позволил помимо изображений использовать для обучения текстовые данные инспектирования.

Также к дефектам опор ЛЭП относят наличие птичьих гнезд. Контакты птиц или материала гнезд с элементами ВЛ могут являться причиной короткого замыкания, которые приводят к отключению потребителей. В [77] описан алгоритм детектирования гнезд, который состоит из нескольких этапов. Первый этап заключается в бинаризации изображения путем применения динамического порога. Далее извлекаются признаки: доля белых областей, доля белых пикселей, признаки проекции и улучшенные признаки неровностей. После полученные признаки классифицируются при помощи SVM. Выбранные признаки обеспечивают большую точность детектирования по сравнению с методом на основе HOG (65,91% precision).

#### *Детектирование дефектов проводов*

В современных исследованиях освещены методы детектирования двух дефектов проводов: повреждение проволок и наличие постороннего предмета на проводах. Зачастую данные методы основаны на сегментации изображения и последующего определения аномального сегмента при помощи правил (handcraft rules). Так, в [78] для обнаружения границ использовался оператор Кэнни. Затем при помощи улучшенного правила Фримена (Improved Freeman Rule, IFR) детектировались оборванные проволоки провода. Метод был протестирован на 100 изображениях. Процент правильно распознанных дефектов составил 100%.

Метод, представленный в [79], основан на определении признаков текстуры изображения. Исходное изображение преобразуется в изображение в оттенках серого при помощи нормализации (Grayscale Variance Normalization, GVN). Затем провод локализуется на основе адаптивной пороговой сегментации с морфологическими операторами. Детектирование обрыва проволок проводов осуществляется путем анализа формы кривых распределения уровня яркости (Gray value distribution). Изображение провода без повреждений имеет кривую прямоугольной формы. При наличии дефекта кривая становится пилообразной. Средняя точность обнаружения неисправностей при идентификации обрыва проводника может достигать 90,45%, в то время как средняя точность обнаружения неисправностей при идентификации дефектов поверхности проводника 92,05%.

Для детектирования постороннего предмета на проводе авторы [80] разработали метод на основе HOG и SVM. Для предварительной обработки изображения использовался медианный фильтр. Затем извлекались и классифицировались признаки HOG при помощи построения ориентированного ациклического графа (Directed Acyclic Graph) и SVM. С помощью экспериментальных результатов было определено, что пиксельные ячейки HOG имеют размер  $32 \times 32$ , при этом скорость обработки каждого изображения составила 0,539 с, а средняя точность распознавания составила 84,3%.

Авторы [81] для обнаружения постороннего предмета на проводе использовали СНС SSD. Результаты экспериментов показывают, что метод SSD может достигать точности 85,2% при скорости 26 кадров в секунду.

#### *Детектирование дефектов арматуры*

Существует несколько работ, посвященных детектированию дефектов арматуры. Основными дефектами являются поломка и отсутствие деталей. В для обнаружения деформированных деталей распорок проводов авторы [82] разработали метод на основе оператора Кэнни и преобразования Хафа. После выделения границ определялись области-кандидаты при помощи скользящего окна. Определение поврежденной детали основано на правиле: если количество частей распорки больше 1, то деталь считается

поврежденной. Результаты экспериментов успешно продемонстрировали эффективность предложенного метода.

В работе [83] для детектирования поврежденных виброгасителей авторы использовали Faster R-CNN. По результатам тестирования на 500 изображениях, полнота предложенного решения составила 83,4%.

Для детектирования отсутствия соединительных деталей арматуры (болтов) авторы [84] разработали метод на основе СНС. Для локализации арматуры на изображении применялся классификатор Adaboost. Затем полученные фрагменты использовались в качестве входных данных восьмислойной СНС для классификации их по трем категориям: арматура с повреждениями, арматура без повреждений и фон. Разработанный метод имеет точность детектирования 96,54%.

#### *Детектирование древесно-кустарниковой растительности на трассе*

При вводе ВЛ в эксплуатацию и периодически в процессе работы на трассе ЛЭП проводится измерение ширины просеки, высоты деревьев и кустарников под проводами, расстояний от элементов линии до стволов деревьев и их кроны. Зачастую для детектирования деревьев в качестве исходных данных используется стереопара. Методы детектирования растительности [85,86] включают несколько шагов: предобработки изображений, распознавания проводов линии и обнаружение растительности (фона). После обнаружения растительности вычисляется расстояние от проводов до деревьев на основании трехмерной реконструкции окружения. Главным недостатком такого решения является потребность в дополнительной камере, что приводит к утяжелению аппаратной части БПЛА и повышает стоимость системы мониторинга.

Таким образом, в данном разделе были рассмотрены методы детектирования дефектов элементов ЛЭП в видимом спектре. Далее приведем методы детектирования дефектов элементов ЛЭП на УФ-изображениях.

#### **Методы детектирования дефектов элементов ЛЭП на УФ-изображениях**

Изображения в УФ-спектре используются для выявления коронных разрядов на проводах и изоляторах. Излучаемые коронным разрядом частицы имеют длину волны, характерную для УФ-части спектра света 230–405 нм [87]. Солнечное излучение вызывает помехи, поэтому пригодна только часть спектрального диапазона для получения чистого сигнала в диапазоне 240–280 нм. Однако в данной части спектра интенсивность излучения короны слабее, чем в диапазоне 290–400 нм, поэтому для получения высококонтрастных изображений используются УФ-усилители (UV solar blind image intensifiers), а также солнечно-слепой полосный фильтр (solar blind band pass filter) [88]. Высокий коэффициент усиления (обычно 106 ph/ph) значительно затрудняет обработку изображения, поскольку приводит представлению всех разрядов в виде ярких белых пятен одинакового размера (blobs), что не позволяет оценить интенсивность излучения и степень повреждения [89]. Кроме того, усиление сигнала не гарантирует отсутствие фонового шума, в том числе темного тока (dark current) и утечки фотонов (leakage photons) [90].

Тем не менее существуют методы классификации повреждений элементов ЛЭП, вызывающих коронный заряд. Данные методы зачастую основаны на извлечении признаков из серии изображений короны при помощи алгоритмов машинного обучения. Так в работе [91] представлен алгоритм детектирования разрядов, основанный на модифицированном преобразовании Хафа (modified Hough transform) и предназначенный для мониторинга тяговых электросетей при помощи поездов (railway inspection) [92]. В качестве входных данных использовалось изображение короны в

градациях серого. Так как размер ярких пятен (blobs) не позволяет отличить излучение короны от фонового шума, проводится предобработка изображения в виде расчета центров (centroids) данных пятен. Детектирование коронных разрядов основано на сравнении положений центров пятен на изображениях и отслеживании их траекторий при помощи преобразования Хафа. Пятна с прямолинейными траекториями помечаются как коронный разряд. Для уменьшения вероятности ложного распознавания вводятся ограничения на расстояние от начала координат до прямой, угол между х-осью и нормальную к прямой, а на направление движения центра пятна. Разработанный алгоритм позволил сократить в 5 раз число ложных распознаваний короны (в час) по сравнению со стандартным распознаванием Хафа. Главным недостатком предложенного решения является возможность его применения только при прямолинейном движении камеры вдоль трассы ЛЭП.

Аналогично преобразованию Хафа алгоритм детектирования разрядов на УФ-изображении [89] содержит процедуру голосования точек. На вход алгоритма поступает серия изображений в оттенках серого с обнаруженными пятнами, а также информация о калибровке камеры. Точки пятен проецируются на трехмерное пространство как отрезки с фиксированной depth of interest. Затем точки полученных отрезков проецируются обратно на изображение, сопоставляются с исходные точками с заданной точностью (допустимым отклонением) и накапливают голоса по всем кадрам серии. Такое решение позволяет отследить развитие короны во времени. Однако полученный результат зависит от величины допустимого отклонения, принятой при сопоставлении проекций и исходного изображения.

В исследовании [93] авторы также разработали алгоритм обнаружения разрядов на УФ-изображении. Исходный кадр был преобразован в изображение в оттенках серого, после чего для устранения фонового шума использовался медианный фильтр (median filter). Далее к полученному изображению применялась бинаризация, что позволило определить критерий детектирования разряда. Данный критерий представляет собой отношение суммарного числа пикселей со значением «1» (светящаяся область УФ-разряда) к общей наблюдаемой площади (в пикселях). При превышении критерия порогового значения разряд считался дефектом оборудования. Эффективность использования данного критерия для выявления дефекта объясняется его согласованностью с амплитудным значением тока разряда.

Помимо отношения числа пикселей (UV image area ratio) для диагностики неисправностей по УФ-изображению могут использоваться площадь и диаметр разряда (ultraviolet flare area and flare diameter) [94]. В этом случае как и ранее представленных алгоритмах исходное изображение преобразуется в изображение в оттенках серого при помощи адаптивной пороговой сегментации (dynamic threshold segmentation), а затем в бинарное изображение. При этом для выделения границ и повышения резкости изображения был использован дискретный оператор Лапласа (Laplacian image enhancement / Discrete Laplace operator). Кроме того, были определены пороговые значения площади разряда, которые позволяют определить состояние изоляции: нормальное, хорошее, наличие микротрещин, деградация, старение (normal good Micromark, degradation Serious aging).

Также в качестве показателя интенсивности короны может применяться число фотонов излучения в минуту, которое измеряется УФ-камерой [95]. Число фотонов до 1000 (1 класс) свидетельствует о необходимости наблюдения за будущей активностью каждые два года. При числе фотонов 1000-5000 необходима постоянная проверка. Число фотонов свыше 5000 говорит о потребности в срочном ремонте или замене поврежденных элементов. Однако результат регистрации фотонов зависит от влажности

воздуха, температуры окружающей среды, давления, расстояния обнаружения и коэффициента усиления камеры. Главным недостатком представленных исследований является отсутствие количественной оценки работы алгоритмов и методов, что не позволяет выбрать наиболее предпочтительное решение.

В работе [96] авторы анализируют состояние изоляторов и проводов на основе величины интенсивности разряда. Для оценки данного параметра была разработана модель регрессии опорных векторов (support vector regression, SVR), которая учитывает параметры УФ-камеры. Для оптимизации параметров ядер и величины вознаграждения использовался генетический алгоритм. Погрешность оценки интенсивности разряда составила менее 9%.

БПЛА могут служить платформой для автономного обнаружения и определения местоположения высоковольтного коронного разряда. Например, при помощи обработки изображений можно автоматизировать локализацию разряда и своевременно устранять серьезные последствия. Методы обработки УФ-изображений представлены в небольшом количестве. Тем не менее, инспектирование состояния ЛЭП с помощью данной технологии является многообещающей и перспективной областью исследования. Методом детектирования с наибольшей эффективностью для УФ-спектра является метод SVR. Рассмотрим также детектирование дефектов элементов ЛЭП на ИК-изображениях.

### **Методы детектирования дефектов элементов ЛЭП на ИК-изображениях**

Съемка в ИК-спектре позволяет выявить дефекты элементов ЛЭП, которые не могут быть детектированы на изображениях в видимом спектре. Обработка таких изображений является важным инструментом для прогнозирования и предотвращения дефекта ЛЭП в виде горячей точки. Наличие горячих точек свидетельствует о нарушении температурных режимов работы провода, изоляторов и соединительных деталей (Рисунок 3).

В [97] для детектирования горячих точек использовалось пороговая обработка. При этом метод позволяет определить поврежденный элемент и тип дефекта.

Метод поиска горячих точек на ИК-изображении, предложенный в [98], включает в себя несколько этапов. Первый этап заключается в преобразовании исходного изображения в изображение в оттенках серого. Далее для ослабления действия фоновых помех используется фильтр Гаусса. Затем осуществляется бинаризация полученного изображения при помощи метода Оцу с целью выделения элементов ЛЭП. Последний этап заключается в пороговой обработке для локализации горячих точек. Метод на основе бинаризации и пороговой обработки также показан в [99]. Для тестирования алгоритма использовался набор ИК-изображений, полученных при обследовании ЛЭП. Из полученных результатов можно сделать вывод, что в большинстве случаев горячие точки были обнаружены правильно.

Приведенные методы могут сочетаться с методом распознавания элементов ЛЭП на ИК-изображении на основе модели СНС YOLO [18]. Представленный подход определяет координаты, угол ориентации и тип класса каждой части оборудования. Эксперименты с набором данных показывают, что метод устойчив к шуму, а средняя точность распознавания такого решения достигает 93,7% (mAP).

Метод распознавания изоляторов на термограммах показан в работе [100]. Авторы использовали метод скользящего окна для поиска регионов-кандидатов. Из каждого региона извлеклись признаки при помощи пулинга бинарных признаков (Binary Feature Pooling). После этого проводилась классификация признаков с использованием SVM. Окончательный выбор регионов, в которых расположены изоляторы,

осуществлялся на основании проверки отношений геометрических параметров изоляторов. Точность (precision) предложенного метода составила 89,1%.

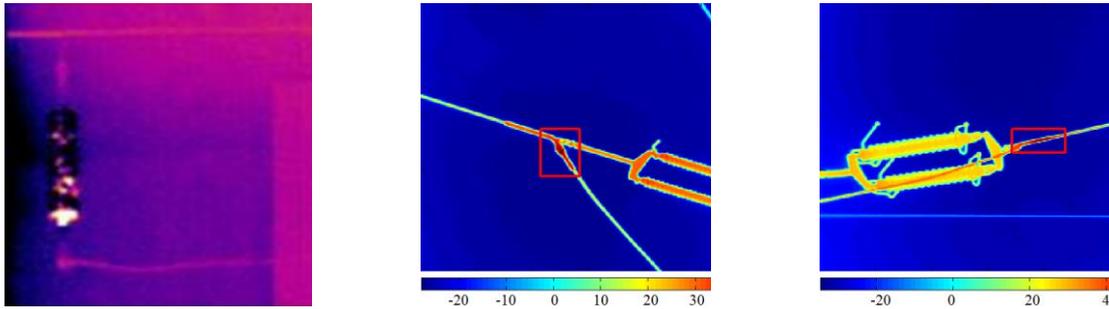


Рисунок 3 – Примеры визуализации дефектов на ИК-изображениях  
Figure 3 – Examples of visualization of defects in IR images

Для детектирования горячих точек, первым делом необходимо определить линии электропередач. Для этого можно использовать видимые изображения для извлечения ЛЭП и проржавевших изоляторов, а следующим шагом при помощи ИК-изображений выявлять горячие точки.

### Обсуждение результатов

На основе анализа всех рассмотренных подходов к детектированию дефектов элементов ЛЭП были выбраны наиболее эффективные из них на основе приведенных в источниках данных о показателях их эффективности (Таблица 3).

Таблица 3 – Наиболее эффективные методы детектирования дефектов ЛЭП.

Table 3 – Methods for detecting power transmission line defects, selected on the basis of maximum efficiency indicators.

Дефект	Спектр съемки	Метод/подход к детектированию	Причины возникновения дефекта
Коронный разряд на проводах и изоляторах	УФ	SVR	Атмосферные перенапряжения, атмосферные осадки,
Провода и тросы			
Обрыв проводов и тросов	В	GVN	Сильный ветер, гололед, падение деревьев
Оплавление проволок провода	ИК	Оцу + пороговая обработка	Коммутационные перенапряжения
Нарушение целостности провода	ИК	Оцу + пороговая обработка	Усталость металла вследствие вибраций
Наличие посторонних объектов	В	HOG+SVM, SSD	Природный и человеческий факторы
Изоляторы			
Загрязнение поверхности изоляторов	УФ	SVR	Продукты отработки промышленных предприятий, пыль почвы и морской воздух,
	ИК	Оцу + пороговая обработка	
Отсутствие тарелки	В	Grab cut, cascading CNN	Атмосферные перенапряжения, коммутационные
Сколы	В	LBP-HF+SVM, DMNN, VGG-19	

Обледенение	В	LBP+ULBP	Погодные условия
Опоры			
Наклон, смещение в грунте, падение	В	YOLO v3	Ветровые нагрузки, гололед
Коррозия металла	В	DELM+LRF	Высокая влажность воздуха, примеси и твердые частицы в атмосфере
Птичьи гнезда	В	SVM	–
Арматура			
Трещины, перетирания и деформация отдельных частей	В	Faster R-CNN	Износ, старение металла, ветровые нагрузки
	ИК	Оцу + пороговая обработка	
Отсутствие деталей	В	CNN	
Трасса			
Наличие посторонних объектов: строений, стогов сена, деревьев	В	Стереозрение+PLAMEC	Посторонние воздействия, стихийные явления

Проведенный обзор методов детектирования элементов ЛЭП на изображениях в видимом спектре показал, что большинство методов, основанных на определении признаков, и методов машинного обучения чувствительны к сложным фоновым помехам, ракурсу и дальности съемки. Такие решения характеризуются высокой трудоемкостью реализации, однако не они не требуют больших обучающих выборок. Методы глубокого обучения имеют большую точность распознавания, тем не менее, данные методы также имеют ограничения в применении, поскольку в открытом доступе представлено мало наборов данных аэрофотоснимков.

Среди методов распознавания элементов ВЛ преобладают исследования, посвященные детектированию изоляторов. Это связано с тем, что вне зависимости от класса напряжения линии и материала все изоляторы имеют одинаковую форму. Кроме того длина гирлянды изоляторов высоковольтной ЛЭП превышает 1 м, поэтому в отличие от крепежных элементов данный элемент конструкции можно распознать на большом расстоянии. Детектирование опор ЛЭП существенно осложняется многообразием их форм и материалов. В пределах одного участка линии используются опоры различных типов. Поэтому большинство существующих методов детектирования опор основаны на поиске пересечений вертикальных (стоек) и горизонтальных (траверсы) линий. Такое решение не позволяет распознавать металлические и композитные опоры сложных форм. Методы распознавания проводов также основаны на их представлении в виде параллельных прямых. Таким образом, для успешного детектирования съемка ВЛ должна проводиться только сверху.

Число исследований, посвященных детектированию дефектов ВЛ, меньше количества работ по обнаружению элементов. Во-первых, это связано с недостатком изображений неисправностей. Во-вторых, несколько типов дефектов соответствуют одному элементу. В-третьих, один и тот же дефект может проявляться по-разному. Упомянутые причины ограничивают использование методов глубокого обучения и делают предпочтительным использование методов машинного обучения или методов на основе определения признаков. Все рассмотренные работы нацелены на распознавание только одного дефекта. При этом многие повреждения элементов ЛЭП не освещены в современной литературе, например, недопустимые изменения стрелы провеса и

расстояний между проводами, недопустимое отклонение стоек опор и изоляторов от оси, ожоги изолятора, обгорание деревянных деталей опоры и пр.

Недостаток в методах детектирования некоторых дефектов может компенсировать обработка УФ и ИК-изображений. Однако исследований в данном направлении представлено мало. Большинство методов построено на простых принципах и не имеют количественных показателей эффективности, что не позволяет оценить их эффективность.

Кроме того, для некоторых рассмотренных исследований характерно отсутствие единой системы оценки эффективности методов. В качестве показателей эффективности разработанных решений используется несколько показателей: доля верных детектирований, полнота, точность, среднее значение точности (mAP) доля истинно-положительных классификаций, F-мера, что затрудняет сравнительный анализ методов. Помимо этого, для оценки разработанных решений авторы использовали собственный набор данных.

На основе анализа всех рассмотренных подходов к детектированию дефектов элементов ЛЭП были выбраны наиболее эффективные, на основе максимальных показателей эффективности.

### Заключение

Данная работа посвящена анализу современных методов детектирования неисправностей ЛЭП на изображениях трех спектров. Показан подход к воздушному инспектированию ВЛ при помощи БПЛА, который состоит из двух этапов: детектирования элементов линии и детектирования дефектов элементов.

Методы, предназначенные для обработки изображений в видимом спектре, основываются на алгоритмах глубокого и машинного обучения. Ультрафиолетовый спектр (УФ) используется для выявления коронных разрядов на проводах и изоляторах. Методы обработки УФ и ИК-изображений представлены в небольшом количестве работ и не имеют количественной оценки эффективности. Тем не менее, инспектирование состояния ЛЭП является многообещающей и перспективной областью исследования. Съемка в инфракрасном спектре (ИК) позволяет выявить дефекты элементов ЛЭП, которые не могут быть детектированы на изображениях в видимом спектре, например, горячие точки (hotspot). Проанализированные методы обработки УФ- и ИК-изображений не имеют количественной оценки эффективности. В результате проведенного анализа были выбраны методы детектирования дефектов ЛЭП с наибольшей эффективностью для видимого спектра: GVN, HOG+SVM, SSD, Grab cut, cascading CNN, LBP-HF+SVM, DMNN, VGG-19, LBP+ULBP, YOLO v3, DELM+LRF, SVM, Faster R-CNN, CNN, стереозрение+PLAMEC. Методом детектирования с наибольшей эффективностью для ИК-спектра является «оцу + пороговая обработка», а для УФ-спектра метод – SVR.

К нерешенным задачам выявления дефектов ЛЭП можно отнести формирование репрезентативных выборок изображений различных спектров, распознавание элементов конструкции малого размера и разработку единообразной системы оценки эффективности работы методов.

### БЛАГОДАРНОСТИ

*Работа выполнена при финансовой поддержке РФФИ в рамках научного проекта №20-08-01056 А*

### ЛИТЕРАТУРА

1. Кудряков А.Г., Сазыкин В.Г., Кравченко И.И. Способ повышения надёжности воздушных линий электропередачи. *Успехи Современной Науки*. 2016;2(10):73-75.

2. Colak I., Sagirolu S., Fulli G., Yesilbudak M., Covrig C.-F. A survey on the critical issues in smart grid technologies. *Renewable and Sustainable Energy Reviews*. 2016;54:396-405.
3. Peng F.Z. Flexible AC transmission systems (FACTS) and resilient AC distribution systems (RACDS) in smart grid. *Proceedings of the IEEE*. 2017;105(11):2099-2115.
4. Zormpas A., Moirogiorgou K., Kalaitzakis K., Plokamakis G.A., Partsinevelos P., Giakos G., Zervakis M. Power transmission lines inspection using properly equipped unmanned aerial vehicle (UAV). *2018 IEEE International Conference on Imaging Systems and Techniques (IST)*. 2018;1-5.
5. Tragulnuch P., Kasetkasem T., Isshiki T., Chanvimaluang T., Ingprasert S. High voltage transmission tower identification in an aerial video sequence using object-based image classification with geometry information. *2018 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*. 2018;473-476.
6. Bian J., Hui X., Zhao X., Tan M. A novel monocular-based navigation approach for UAV autonomous transmission-line inspection. *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2018;1-7.
7. Menendez O., Cheein F.A.A., Perez M., Kouro S. Robotics in power systems: Enabling a more reliable and safe grid. *IEEE Industrial Electronics Magazine*. 2017;11(2):22-34.
8. Nguyen P., Dudkin S., Kong C. Automatic diagnostic of transmission lines based on ultraviolet inspection. *E3S Web of Conferences*. 2019;140:07008.
9. Juergen B., Fernando P.L., Thomas L. OCM 2017 - Optical Characterization of Materials - conference proceedings. *KIT Scientific Publishing*. 2017;248.
10. Han S., Hao R., Lee J. Inspection of insulators on high-voltage power transmission lines. *IEEE transactions on power delivery*. 2009;24(4):2319-2327.
11. Шабанова А.Р., Толстой М.И., Лебедев И.В. Способ построения безопасных траекторий движения беспилотного летательного аппарата при мониторинге линий электропередач в условиях влияния электромагнитных полей. *Проблемы региональной энергетики*. 2019;3(44).
12. Князь В.А., Вишняков Б.В., Визильтер Ю.В., Горбачевич В.С., Выголов О.В. Технологии интеллектуальной обработки информации для задач навигации и управления беспилотными летательными аппаратами. *Труды СПИИРАН*. 2016;2(45):26-44.
13. Han Y., Liu Z., Lee D., Liu W., Chen J., Han Z. Han Y. et al. Computer vision-based automatic rod-insulator defect detection in high-speed railway catenary system. *International Journal of Advanced Robotic Systems*. 2018;15(3):1729881418773943.
14. Han J., Yang Z., Zhang Q., Chen C., Li H., Lai S., Hu G., Xu C., Xu H., Wang D., Chen R. A method of insulator faults detection in aerial images for high-voltage transmission lines inspection. *Applied Sciences*. 2019;9(10):2009.
15. Oberweger M., Wendel A., Bischof H. Visual recognition and fault detection for power line insulators. *19th computer vision winter workshop*. 2014;1-8.
16. Tao X., Zhang D., Wang Z., Liu X., Zhang H., Xu D. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2018;1-13.
17. Bian J., Hui X., Zhao X., Tan M. A monocular vision-based perception approach for unmanned aerial vehicle close proximity transmission tower inspection. *Int J Adv Robot Syst*. 2019 Jan 1;16(1):1729881418820227.
18. Gong X., Yao Q., Wang M., Lin Y. A deep learning approach for oriented electrical equipment detection in thermal images. *IEEE Access*. 2018;6:41590-41597.

19. Zhai Y., Wang D., Zhang M., Wang J., Guo F. Fault detection of insulator based on saliency and adaptive morphology. *Multimedia Tools and Applications*. 2017;76(9):12051-12064.
20. Wang X, Guo K, Wang Y. Detection algorithm of cracked insulator based on statistical shape models. *Comput. Meas. Control*. 2018;26:26-28.
21. Yin J., Lu Y., Gong Z., Jiang Y., Yao J. Edge detection of high-voltage porcelain insulators in infrared image using dual parity morphological gradients. *IEEE Access*. 2019;7:32728-32734.
22. Zhang J., Liu L., Wang B., Chen X., Wang Q., Zheng T. High speed automatic power line detection and tracking for a UAV-based inspection. *2012 International Conference on Industrial Control and Electronics Engineering*. 2012;266-269.
23. Tomaszewski M., Osuchowski J., Debita Ł. Effect of spatial filtering on object detection with the surf algorithm. *International Scientific Conference BCI 2018 Opole. Springer, Cham*. 2018;121-140.
24. Liao S., An J. A robust insulator detection algorithm based on local features and spatial orders for aerial images. *IEEE Geoscience and Remote Sensing Letters*. 2014;12(5):963-967.
25. Cheng H., Zhai Y., Chen R., Wang D., Dong Z., Wang Y. Self-Shattering defect detection of glass insulators based on spatial features. *Energies*. 2019;12(3):543.
26. Ke H., Wang H., Li B. Image Segmentation Method of Insulator in Transmission Line Based on Weighted Variable Fuzzy C-Means. *Journal of Engineering Science & Technology Review*. 2017;10(4):115–123.
27. Guo L., Liao Y., Yao H., Chen J., Wang M. An electrical insulator defects detection method combined human receptive field model. *Journal of Control Science and Engineering*. 2018;1-9.
28. Dalal N., Triggs B. Histograms of oriented gradients for human detection. *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. 2005;1:886-893.
29. Felzenszwalb P.F., Girshick R.B., McAllester D., Ramanan D. Object detection with discriminatively trained part-based models. *IEEE transactions on pattern analysis and machine intelligence*. 2009;32(9):1627–1645.
30. Zhai Y., Chen R., Yang Q., Li X., Zhao Z. Insulator fault detection based on spatial morphological features of aerial images. *IEEE Access*. 2018;6:35316-35326.
31. Hao-ran J, Lin-jun J, Shu-jia Y. Recognition and fault diagnosis of insulator string in aerial images. *Journal of Mechanical & Electrical Engineering*. 2015;32(2).
32. Otsu N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*. 1979;9(1):62-66.
33. Mallat S., Hwang W.L. Singularity detection and processing with wavelets. *IEEE transactions on information theory*. 1992;38(2):617-643.
34. Jabid T., Ahsan T. Insulator detection and defect classification using rotation invariant local directional pattern. *Int. J. Adv. Comput. Sci. Appl.* 2018;9(2):265-272.
35. Jabid T., Uddin M.Z. Rotation invariant power line insulator detection using local directional pattern and support vector machine. *2016 International Conference on Innovations in Science, Engineering and Technology (ICISSET)*. 2016;1–4.
36. Jiang Y. T., Han J., Ding J. The identification and diagnosis of self-blast defects of glass insulators based on multi-feature fusion. *Electr. Power*. 2015;50(5):52-58.
37. Zhai Y., Wang D., Guo Y., Zhang M., Liu Y. Recognition of Aerial Insulator Image Based on Structural Model and the Optimal Entropy Threshold Segmentation. *DEStech Transactions on Engineering and Technology Research*. 2016;iceta.

38. Tiantian Y., Guodong Y., Junzhi Y. Feature fusion based insulator detection for aerial inspection. *2017 36th Chinese Control Conference (CCC)*. 2017;10972-10977.
39. Zuo D., Hu H., Qian R., Liu Z. An insulator defect detection algorithm based on computer vision. *2017 IEEE International Conference on Information and Automation (ICIA)*. 2017;361-365.
40. He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2017;2961–2969.
41. Girshick R. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2015;1440–1448.
42. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*. 2016;39(6):1137–1149.
43. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016;779-788.
44. Pál D., Póczos B., Szepesvári C. Estimation of Rényi Entropy and Mutual Information Based on Generalized Nearest-Neighbor Graphs. *Advances in neural information processing systems*. 2010;1849-1857.
45. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single shot multibox detector. *European conference on computer vision*. Springer, Cham. 2016;21-37.
46. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.2014.
47. Szegedy C., Ioffe S., Vanhoucke V., Alemi A.A. Inception-v4, inception-resnet and the impact of residual connections on learning. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2017;31(1).
48. Yang Y., Wang L. Insulator recognition based on convolution neural network. *MATEC Web of Conferences*. 2017;139:00035.
49. Tomaszewski M., Michalski P., Ruszczak B., Zator S. Detection of power line insulators on digital images with the use of laser spots. *IET Image Processing*. 2019;13(12):2358-2366.
50. Ma L., Xu C., Zuo G., Bo B., Tao F. Detection method of insulator based on faster r-cnn. *2017 IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*. 2017. p. 1410–1414.
51. Zeiler M.D., Fergus R. Visualizing and understanding convolutional networks. *European conference on computer vision*. Springer, Cham. 2014;818-833.
52. Kang G., Gao S., Yu L., Zhang D. Deep architecture for high-speed railway insulator surface defect detection: Denoising autoencoder with multitask learning. *IEEE Transactions on Instrumentation and Measurement*. 2018;68(8):2679-2690.
53. Ling Z., Qiu R.C., Jin Z., Zhang Y., He X., Liu H., Chu L. An accurate and real-time self-blast glass insulator location method based on faster R-CNN and U-net with aerial images. *arXiv preprint arXiv:1801.05143*. 2018.
54. Castellucci P.B., Lucca L.C., SantAnna M., Tralalle G., Mustacio V.H., da Silva J.F.R., Vallin S. Pole and crossarm identification in distribution power line images. *2013 Latin American Robotics Symposium and Competition*. 2013;2-7.
55. Tragulnuch P., Chanvimaluang T., Kasetkasem T., Ingprasert S., Isshiki T. High Voltage Transmission Tower Detection and Tracking in Aerial Video Sequence using Object-Based Image Classification. *2018 International Conference on Embedded Systems and Intelligent*

- Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES)*. 2018;1-4.
56. Han B., Wang X. Learning for tower detection of power line inspection. *DEStech Transactions on Computer Science and Engineering*. 2016;iccae.
  57. Han B., Wang X. Detection for power line inspection. *MATEC Web of Conferences. EDP Sciences*. 2017;100:03010.
  58. Friedman J., Hastie T., Tibshirani R. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*. 2000;28(2):337-407.
  59. Martinez C., Sampedro C., Chauhan A., Collumeau J.F., Campoy P. The Power Line Inspection Software (PoLIS): A versatile system for automating power line inspection. *Engineering applications of artificial intelligence*. 2018;71:293-314.
  60. Chen B., Miao X. Distribution Line Pole Detection and Counting Based on YOLO Using UAV Inspection Line Video. *J Electr Eng Technol*. 2020 Jan 1;15(1):441–8.
  61. Santos T., Moreira M., Almeida J., Dias A., Martins A., Dinis J., Formiga J., Silva E. PLineD: Vision-based power lines detection for Unmanned Aerial Vehicles. *2017 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*. 2017;253–259.
  62. Zhou G., Yuan J., Yen I., Bastani F. Robust real-time UAV based power line detection and tracking. *2016 IEEE International Conference on Image Processing (ICIP)*. 2016;744-748.
  63. Chang W., Yang G., Li E., Liang Z. Toward a Cluttered Environment for Learning-Based Multi-Scale Overhead Ground Wire Recognition. *Neural Processing Letters*. 2018;48(3):1789-1800.
  64. Liu Y., Li J., Xu W., Liu M. A method on recognizing transmission line structure based on multi-level perception. *International Conference on Image and Graphics. Springer, Cham*. 2017;512-522.
  65. Jin L. J., Yan S. J., Liu Y. Vibration damper recognition based on Haar-like features and cascade AdaBoost classifier. *Journal of System Simulation*. 2012;24(09):1806-1809.
  66. Wang W., Tian B., Liu Y., Li, J. Study on the electrical devices detection in UAV images based on region based convolutional neural networks. *Journal of Geo-information Science*. 2017;19(2):256-263.
  67. Li S., Zhou H., Wang G., Zhu X., Kong L., Hu Z. Cracked insulator detection based on R-FCN. *Journal of Physics: Conference Series*. 2018; 1069(1):012147.
  68. Prasad P.S., Rao B.P. LBP-HF features and machine learning applied for automated monitoring of insulators for overhead power distribution lines. *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. 2016;808-812.
  69. Prates R.M., Cruz R., Marotta A.P., Ramos R.P., Simas Filho E.F., Cardoso J.S. Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *Computers & Electrical Engineering*. 2019;78:343–355.
  70. Wan S., Liang Y., Zhang Y. Deep convolutional neural networks for diabetic retinopathy detection by image classification. *Computers & Electrical Engineering*. 2018;72:274-282.
  71. Szegedy C., Wei Liu, Yangqing Jia, Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015;1–9.
  72. Wu Z., Shen C., van den Hengel A. Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*. 2019;90:119–133.

73. Yang L., Jiang X., Hao Y., Li L., Li H., Li R., Luo B. Recognition of natural ice types on in-service glass insulators based on texture feature descriptor. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2017;24(1):535-542.
74. Hao Y., Wei J., Jiang X., Yang L., Li L., Wang J., Li H., Li R. Icing condition assessment of in-service glass insulators based on graphical shed spacing and graphical shed overhang. *Energies*. 2018;11(2):318.
75. Maeda K., Takahashi S., Ogawa T., Haseyama M. Automatic estimation of deterioration level on transmission towers via deep extreme learning machine based on local receptive field. *2017 IEEE International Conference on Image Processing (ICIP)*. 2017;2379-2383.
76. Maeda K., Takahashi S., Ogawa T., Haseyama M. Estimation of deterioration levels of transmission towers via deep learning maximizing canonical correlation between heterogeneous features. *IEEE Journal of Selected Topics in Signal Processing*. 2018;12(4):633-644.
77. Lu J., Xu X., Li X., Li L., Chang C., Feng X., Zhang S. Detection of bird's nest in high power lines in the vicinity of remote campus based on combination features and cascade classifier. *IEEE Access*. 2018;6:39063-39071.
78. Liu K. P., Wang B. H., Chen X. G., Jin L. J. Damaged cables recognition based on improved Freeman rule. *Jidian Gongcheng/ Mechanical & Electrical Engineering Magazine*. 2012;29(2):211-214.
79. Zhang Y., Huang X., Jia J., Liu X. A recognition technology of transmission lines conductor break and surface damage based on aerial image. *IEEE Access*. 2019;7:59022-59036.
80. Mao T., Ren L., Yuan F., Li C., Zhang L., Zhang M., Chen Y. Defect recognition method based on HOG and SVM for drone inspection images of power transmission line. *2019 International Conference on High Performance Big Data and Intelligent Systems (HPBD&IS)*. 2019;254-257.
81. Wang B., Wu R., Zheng Z., Zhang W., Guo J. Study on the method of transmission line foreign body detection based on deep learning. *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*. 2017;1-5.
82. Song Y., Wang L., Jiang Y., Wang H., Jiang W., Wang C., Chu J., Han D. A vision-based method for the broken spacer detection. *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*. 2015;715-719.
83. Tang Y., Han J., Wei, W. Research on part recognition and defect detection of transmission line in deep learning. *Electronic Measurement Technology*. 2018;41(6):60-65.
84. Wang Z. Applied research on deep learning in defect detection of key components on transmission towers. *Master's thesis, Civil Aviation University of China*. 2018.
85. Li Q., Ma Y., He F., Xi S., Xu J. Bionic vision-based intelligent power line inspection system. *Computational and mathematical methods in medicine*. 2017;2017:4964287.
86. Zhang Y., Yuan X., Li W., Chen S. Automatic power line inspection using UAV images. *Remote Sensing*. 2017;9(8):824.
87. Grum F., Costa L. F. Spectral emission of corona discharges. *Applied Optics*. 1976;15(1):76-79.
88. Lindner M., Elstein S., Lindner P., Topaz J.M., Phillips A. J. Daylight corona discharge imager. *Eleventh International Symposium on High Voltage Engineering*. 1999;4:349-352.
89. Komar G., Pischler O., Schichler U., Vieriu R.-L. Performance of UV and IR Sensors for Inspections of Power Equipment. *Proceedings of the Nordic Insulation Symposium*. 2019;26:82-87.

90. Jianwen Ding, Xiang Li, Xi Zhu, Xun Cao, Feng Yan, Bian X. Solar-irradiated leakage of UV camera for daytime corona inspection. *2015 IEEE Conference on Electrical Insulation and Dielectric Phenomena (CEIDP)*. 2015;298-301.
91. Li J., Zhou Y., Yi X., Zhang M., Chen X., Cui M., Yan F. An Automatic Corona-discharge Detection System for Railways Based on Solar-blind Ultraviolet Detection. *Current Optics and Photonics*. 2017;1(3):196-202.
92. Duda R.O., Hart P.E. Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*. 1972;15(1):11-15.
93. Zhou W., Li H., Yi X., Tu J., Yu J. A criterion for UV detection of AC corona inception in a rod-plane air gap. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2011;18(1):232-237.
94. Lv F., Dai R., Li H., Jin H. Comparison of Two UV Imaging Parameters's in the Insulator Fault Diagnosis. *2012 Second International Conference on Intelligent System Design and Engineering Application*. 2012;1400-1403.
95. Chen Q., Li Y., Yang G., Jin T., Zhang Z., Zhang S. Detection and Analysis of Ultraviolet Corona Discharge for Earth Switch Grading Ring. *2019 IEEE International Conference on Computational Electromagnetics (ICCEM)*. 2019;1-3.
96. Li X., Jin L., Xu Z., Jiang T., Jin H. Surface discharge detection method of contaminated insulators based on ultraviolet images' parameters. *2017 1st International Conference on Electrical Materials and Power Equipment (ICEMPE)*. 2017;155-158.
97. Anbalagan S., Sudhakar T.D. Protection of Power Transmission Lines Using Intelligent Hot Spot Detection. *2019 Fifth International Conference on Electrical Energy Systems (ICEES)*. 2019;1-6.
98. Zaripova A.D., Zaripov D.K., Usachev A.E. Automatic condition monitoring method to find defects in high-voltage insulators using infrared images. *E3S Web of Conferences*. 2019;124:03003.
99. Wronkowicz A. Approach to automated hot spot detection using image processing for thermographic inspections of power transmission lines. *Diagnostyka*. 2016;17.
100. Zhao Z., Xu G., Qi Y. Representation of binary feature pooling for detection of insulator strings in infrared images. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2016;23(5):2858-2866.

## REFERENCES

1. Kudryakov A.G., Sazykin V.G., Kravchenko I.I. Sposob povysheniya nadyozhnosti vozdushnyh linij elektroperedachi. *Uspekhi Sovremennoj Nauki*. 2016;2(10):73-75. (In Russ.).
2. Colak I., Sagiroglu S., Fulli G., Yesilbudak M., Covrig C.-F. A survey on the critical issues in smart grid technologies. *Renewable and Sustainable Energy Reviews*. 2016;54:396-405.
3. Peng F.Z. Flexible AC transmission systems (FACTS) and resilient AC distribution systems (RACDS) in smart grid. *Proceedings of the IEEE*. 2017;105(11):2099-2115.
4. Zormpas A., Moirogiorgou K., Kalaitzakis K., Plokamakis G.A., Partsinevelos P., Giakos G., Zervakis M. Power transmission lines inspection using properly equipped unmanned aerial vehicle (UAV). *2018 IEEE International Conference on Imaging Systems and Techniques (IST)*. 2018;1-5.
5. Tragulnuch P., Kasetkasem T., Isshiki T., Chanvimaluang T., Ingprasert S. High voltage transmission tower identification in an aerial video sequence using object-based image classification with geometry information. *2018 15th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*. 2018;473-476.

6. Bian J., Hui X., Zhao X., Tan M. A novel monocular-based navigation approach for UAV autonomous transmission-line inspection. *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2018;1-7.
7. Menendez O., Cheein F.A.A., Perez M., Kouro S. Robotics in power systems: Enabling a more reliable and safe grid. *IEEE Industrial Electronics Magazine*. 2017;11(2):22-34.
8. Nguyen P., Dudkin S., Kong C. Automatic diagnostic of transmission lines based on ultraviolet inspection. *E3S Web of Conferences*. 2019;140:07008.
9. Juergen B., Fernando P.L., Thomas L. OCM 2017 - Optical Characterization of Materials - conference proceedings. *KIT Scientific Publishing*. 2017;248.
10. Han S., Hao R., Lee J. Inspection of insulators on high-voltage power transmission lines. *IEEE transactions on power delivery*. 2009;24(4):2319-2327.
11. Shabanova A.R., Tolstoj M. I., Lebedev I. V. Sposob postroeniya bezopasnyh traektorij dvizheniya bespilotnogo letatel'nogo apparata pri monitoringe linij elektroperedach v usloviyah vliyaniya elektromagnitnyh polej. *Problemy Regional'noj Energetiki*. 2019;3(44). (In Russ.).
12. Knyaz' V.A., Vishnyakov B.V., Vizil'ter YU.V., Gorbacevich V.S., Vygolov O.V. Tekhnologii intellektual'noj obrabotki informacii dlya zadach navigacii i upravleniya bespilotnymi letatel'nymi apparatami. *Trudy SPIIRAN*. 2016;2(45):26-44.
13. Han Y., Liu Z., Lee D., Liu W., Chen J., Han Z. Han Y. et al. Computer vision-based automatic rod-insulator defect detection in high-speed railway catenary system. *International Journal of Advanced Robotic Systems*. 2018;15(3):1729881418773943.
14. Han J., Yang Z., Zhang Q., Chen C., Li H., Lai S., Hu G., Xu C., Xu H., Wang D., Chen R. A method of insulator faults detection in aerial images for high-voltage transmission lines inspection. *Applied Sciences*. 2019;9(10):2009.
15. Oberweger M., Wendel A., Bischof H. Visual recognition and fault detection for power line insulators. *19th computer vision winter workshop*. 2014;1-8.
16. Tao X., Zhang D., Wang Z., Liu X., Zhang H., Xu D. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2018;1-13.
17. Bian J., Hui X., Zhao X., Tan M. A monocular vision-based perception approach for unmanned aerial vehicle close proximity transmission tower inspection. *Int J Adv Robot Syst*. 2019 Jan 1;16(1):1729881418820227.
18. Gong X., Yao Q., Wang M., Lin Y. A deep learning approach for oriented electrical equipment detection in thermal images. *IEEE Access*. 2018;6:41590-41597.
19. Zhai Y., Wang D., Zhang M., Wang J., Guo F. Fault detection of insulator based on saliency and adaptive morphology. *Multimedia Tools and Applications*. 2017;76(9):12051-12064.
20. Wang X, Guo K, Wang Y. Detection algorithm of cracked insulator based on statistical shape models. *Comput. Meas. Control*. 2018;26:26-28.
21. Yin J., Lu Y., Gong Z., Jiang Y., Yao J. Edge detection of high-voltage porcelain insulators in infrared image using dual parity morphological gradients. *IEEE Access*. 2019;7:32728-32734.
22. Zhang J., Liu L., Wang B., Chen X., Wang Q., Zheng T. High speed automatic power line detection and tracking for a UAV-based inspection. *2012 International Conference on Industrial Control and Electronics Engineering*. 2012;266-269.
23. Tomaszewski M., Osuchowski J., Debita Ł. Effect of spatial filtering on object detection with the surf algorithm. *International Scientific Conference BCI 2018 Opole. Springer, Cham*. 2018;121-140.

24. Liao S., An J. A robust insulator detection algorithm based on local features and spatial orders for aerial images. *IEEE Geoscience and Remote Sensing Letters*. 2014;12(5):963-967.
25. Cheng H., Zhai Y., Chen R., Wang D., Dong Z., Wang Y. Self-Shattering defect detection of glass insulators based on spatial features. *Energies*. 2019;12(3):543.
26. Ke H., Wang H., Li B. Image Segmentation Method of Insulator in Transmission Line Based on Weighted Variable Fuzzy C-Means. *Journal of Engineering Science & Technology Review*. 2017;10(4):115–123.
27. Guo L., Liao Y., Yao H., Chen J., Wang M. An electrical insulator defects detection method combined human receptive field model. *Journal of Control Science and Engineering*. 2018;1-9.
28. Dalal N., Triggs B. Histograms of oriented gradients for human detection. *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. 2005;1:886-893.
29. Felzenszwalb P.F., Girshick R.B., McAllester D., Ramanan D. Object detection with discriminatively trained part-based models. *IEEE transactions on pattern analysis and machine intelligence*. 2009;32(9):1627–1645.
30. Zhai Y., Chen R., Yang Q., Li X., Zhao Z. Insulator fault detection based on spatial morphological features of aerial images. *IEEE Access*. 2018;6:35316-35326.
31. Hao-ran J, Lin-jun J, Shu-jia Y. Recognition and fault diagnosis of insulator string in aerial images. *Journal of Mechanical & Electrical Engineering*. 2015;32(2).
32. Otsu N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*. 1979;9(1):62-66.
33. Mallat S., Hwang W.L. Singularity detection and processing with wavelets. *IEEE transactions on information theory*. 1992;38(2):617-643.
34. Jabid T., Ahsan T. Insulator detection and defect classification using rotation invariant local directional pattern. *Int. J. Adv. Comput. Sci. Appl.* 2018;9(2):265-272.
35. Jabid T., Uddin M.Z. Rotation invariant power line insulator detection using local directional pattern and support vector machine. *2016 International Conference on Innovations in Science, Engineering and Technology (ICISSET)*. 2016;1–4.
36. Jiang Y. T., Han J., Ding J. The identification and diagnosis of self-blast defects of glass insulators based on multi-feature fusion. *Electr. Power*. 2015;50(5):52-58.
37. Zhai Y., Wang D., Guo Y., Zhang M., Liu Y. Recognition of Aerial Insulator Image Based on Structural Model and the Optimal Entropy Threshold Segmentation. *DEStech Transactions on Engineering and Technology Research*. 2016;iceta.
38. Tiantian Y., Guodong Y., Junzhi Y. Feature fusion based insulator detection for aerial inspection. *2017 36th Chinese Control Conference (CCC)*. 2017;10972-10977.
39. Zuo D., Hu H., Qian R., Liu Z. An insulator defect detection algorithm based on computer vision. *2017 IEEE International Conference on Information and Automation (ICIA)*. 2017;361-365.
40. He K., Gkioxari G., Dollar P., Girshick R. Mask R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2017;2961–2969.
41. Girshick R. Fast R-CNN. *Proceedings of the IEEE international conference on computer vision*. 2015;1440–1448.
42. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*. 2016;39(6):1137–1149.

43. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016;779-788.
44. Pál D., Póczos B., Szepesvári C. Estimation of Rényi Entropy and Mutual Information Based on Generalized Nearest-Neighbor Graphs. *Advances in neural information processing systems*. 2010;1849-1857.
45. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A.C. SSD: Single shot multibox detector. *European conference on computer vision*. Springer, Cham. 2016;21-37.
46. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.2014.
47. Szegedy C., Ioffe S., Vanhoucke V., Alemi A.A. Inception-v4, inception-resnet and the impact of residual connections on learning. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2017;31(1).
48. Yang Y., Wang L. Insulator recognition based on convolution neural network. *MATEC Web of Conferences*. 2017;139:00035.
49. Tomaszewski M., Michalski P., Ruszczak B., Zator S. Detection of power line insulators on digital images with the use of laser spots. *IET Image Processing*. 2019;13(12):2358-2366.
50. Ma L., Xu C., Zuo G., Bo B., Tao F. Detection method of insulator based on faster r-cnn. *2017 IEEE 7th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*. 2017. p. 1410–1414.
51. Zeiler M.D., Fergus R. Visualizing and understanding convolutional networks. *European conference on computer vision*. Springer, Cham. 2014;818-833.
52. Kang G., Gao S., Yu L., Zhang D. Deep architecture for high-speed railway insulator surface defect detection: Denoising autoencoder with multitask learning. *IEEE Transactions on Instrumentation and Measurement*. 2018;68(8):2679-2690.
53. Ling Z., Qiu R.C., Jin Z., Zhang Y., He X., Liu H., Chu L. An accurate and real-time self-blast glass insulator location method based on faster R-CNN and U-net with aerial images. *arXiv preprint arXiv:1801.05143*. 2018.
54. Castellucci P.B., Lucca L.C., SantAnna M., Traballe G., Mustacio V.H., da Silva J.F.R., Vallin S. Pole and crossarm identification in distribution power line images. *2013 Latin American Robotics Symposium and Competition*. 2013;2-7.
55. Tragulnuch P., Chanvimaluang T., Kasetkasem T., Ingprasert S., Isshiki T. High Voltage Transmission Tower Detection and Tracking in Aerial Video Sequence using Object-Based Image Classification. *2018 International Conference on Embedded Systems and Intelligent Technology & International Conference on Information and Communication Technology for Embedded Systems (ICESIT-ICICTES)*. 2018;1-4.
56. Han B., Wang X. Learning for tower detection of power line inspection. *DEStech Transactions on Computer Science and Engineering*. 2016;iccae.
57. Han B., Wang X. Detection for power line inspection. *MATEC Web of Conferences. EDP Sciences*. 2017;100:03010.
58. Friedman J., Hastie T., Tibshirani R. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*. 2000;28(2):337-407.
59. Martinez C., Sampedro C., Chauhan A., Collumeau J.F., Campoy P. The Power Line Inspection Software (PoLIS): A versatile system for automating power line inspection. *Engineering applications of artificial intelligence*. 2018;71:293-314.

60. Chen B., Miao X. Distribution Line Pole Detection and Counting Based on YOLO Using UAV Inspection Line Video. *J Electr Eng Technol*. 2020 Jan 1;15(1):441–8.
61. Santos T., Moreira M., Almeida J., Dias A., Martins A., Dinis J., Formiga J., Silva E. PLineD: Vision-based power lines detection for Unmanned Aerial Vehicles. *2017 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC)*. 2017;253–259.
62. Zhou G., Yuan J., Yen I., Bastani F. Robust real-time UAV based power line detection and tracking. *2016 IEEE International Conference on Image Processing (ICIP)*. 2016;744-748.
63. Chang W., Yang G., Li E., Liang Z. Toward a Cluttered Environment for Learning-Based Multi-Scale Overhead Ground Wire Recognition. *Neural Processing Letters*. 2018;48(3):1789-1800.
64. Liu Y., Li J., Xu W., Liu M. A method on recognizing transmission line structure based on multi-level perception. *International Conference on Image and Graphics*. Springer, Cham. 2017;512-522.
65. Jin L. J., Yan S. J., Liu Y. Vibration damper recognition based on Haar-like features and cascade AdaBoost classifier. *Journal of System Simulation*. 2012;24(09):1806-1809.
66. Wang W., Tian B., Liu Y., Li, J. Study on the electrical devices detection in UAV images based on region based convolutional neural networks. *Journal of Geo-information Science*. 2017;19(2):256-263.
67. Li S., Zhou H., Wang G., Zhu X., Kong L., Hu Z. Cracked insulator detection based on R-FCN. *Journal of Physics: Conference Series*. 2018; 1069(1):012147.
68. Prasad P.S., Rao B.P. LBP-HF features and machine learning applied for automated monitoring of insulators for overhead power distribution lines. *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. 2016;808-812.
69. Prates R.M., Cruz R., Marotta A.P., Ramos R.P., Simas Filho E.F., Cardoso J.S. Insulator visual non-conformity detection in overhead power distribution lines using deep learning. *Computers & Electrical Engineering*. 2019;78:343–355.
70. Wan S., Liang Y., Zhang Y. Deep convolutional neural networks for diabetic retinopathy detection by image classification. *Computers & Electrical Engineering*. 2018;72:274-282.
71. Szegedy C., Wei Liu, Yangqing Jia, Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015;1–9.
72. Wu Z., Shen C., van den Hengel A. Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*. 2019;90:119–133.
73. Yang L., Jiang X., Hao Y., Li L., Li H., Li R., Luo B. Recognition of natural ice types on in-service glass insulators based on texture feature descriptor. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2017;24(1):535-542.
74. Hao Y., Wei J., Jiang X., Yang L., Li L., Wang J., Li H., Li R. Icing condition assessment of in-service glass insulators based on graphical shed spacing and graphical shed overhang. *Energies*. 2018;11(2):318.
75. Maeda K., Takahashi S., Ogawa T., Haseyama M. Automatic estimation of deterioration level on transmission towers via deep extreme learning machine based on local receptive field. *2017 IEEE International Conference on Image Processing (ICIP)*. 2017;2379-2383.
76. Maeda K., Takahashi S., Ogawa T., Haseyama M. Estimation of deterioration levels of transmission towers via deep learning maximizing canonical correlation between heterogeneous features. *IEEE Journal of Selected Topics in Signal Processing*. 2018;12(4):633-644.

77. Lu J., Xu X., Li X., Li L., Chang C., Feng X., Zhang S. Detection of bird's nest in high power lines in the vicinity of remote campus based on combination features and cascade classifier. *IEEE Access*. 2018;6:39063-39071.
78. Liu K. P., Wang B. H., Chen X. G., Jin L. J. Damaged cables recognition based on improved Freeman rule. *Jidian Gongcheng/ Mechanical & Electrical Engineering Magazine*. 2012;29(2):211-214.
79. Zhang Y., Huang X., Jia J., Liu X. A recognition technology of transmission lines conductor break and surface damage based on aerial image. *IEEE Access*. 2019;7:59022-59036.
80. Mao T., Ren L., Yuan F., Li C., Zhang L., Zhang M., Chen Y. Defect recognition method based on HOG and SVM for drone inspection images of power transmission line. *2019 International Conference on High Performance Big Data and Intelligent Systems (HPBD&IS)*. 2019;254–257.
81. Wang B., Wu R., Zheng Z., Zhang W., Guo J. Study on the method of transmission line foreign body detection based on deep learning. *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*. 2017;1-5.
82. Song Y., Wang L., Jiang Y., Wang H., Jiang W., Wang C., Chu J., Han D. A vision-based method for the broken spacer detection. *2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*. 2015;715–719.
83. Tang Y., Han J., Wei, W. Research on part recognition and defect detection of transmission line in deep learning. *Electronic Measurement Technology*. 2018;41(6):60-65.
84. Wang Z. Applied research on deep learning in defect detection of key components on transmission towers. *Master's thesis, Civil Aviation University of China*. 2018.
85. Li Q., Ma Y., He F., Xi S., Xu J. Bionic vision-based intelligent power line inspection system. *Computational and mathematical methods in medicine*. 2017;2017:4964287.
86. Zhang Y., Yuan X., Li W., Chen S. Automatic power line inspection using UAV images. *Remote Sensing*. 2017;9(8):824.
87. Grum F., Costa L. F. Spectral emission of corona discharges. *Applied Optics*. 1976;15(1):76-79.
88. Lindner M., Elstein S., Lindner P., Topaz J.M., Phillips A. J. Daylight corona discharge imager. *Eleventh International Symposium on High Voltage Engineering*. 1999;4:349-352.
89. Komar G., Pischler O., Schichler U., Vieriu R.-L. Performance of UV and IR Sensors for Inspections of Power Equipment. *Proceedings of the Nordic Insulation Symposium*. 2019;26:82-87.
90. Jianwen Ding, Xiang Li, Xi Zhu, Xun Cao, Feng Yan, Bian X. Solar-irradiated leakage of UV camera for daytime corona inspection. *2015 IEEE Conference on Electrical Insulation and Dielectric Phenomena (CEIDP)*. 2015;298-301.
91. Li J., Zhou Y., Yi X., Zhang M., Chen X., Cui M., Yan F. An Automatic Corona-discharge Detection System for Railways Based on Solar-blind Ultraviolet Detection. *Current Optics and Photonics*. 2017;1(3):196-202.
92. Duda R.O., Hart P.E. Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*. 1972;15(1):11-15.
93. Zhou W., Li H., Yi X., Tu J., Yu J. A criterion for UV detection of AC corona inception in a rod-plane air gap. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2011;18(1):232-237.
94. Lv F., Dai R., Li H., Jin H. Comparison of Two UV Imaging Parameters's in the Insulator Fault Diagnosis. *2012 Second International Conference on Intelligent System Design and Engineering Application*. 2012;1400-1403.

95. Chen Q., Li Y., Yang G., Jin T., Zhang Z., Zhang S. Detection and Analysis of Ultraviolet Corona Discharge for Earth Switch Grading Ring. *2019 IEEE International Conference on Computational Electromagnetics (ICCEM)*. 2019;1-3.
96. Li X., Jin L., Xu Z., Jiang T., Jin H. Surface discharge detection method of contaminated insulators based on ultraviolet images' parameters. *2017 1st International Conference on Electrical Materials and Power Equipment (ICEMPE)*. 2017;155-158.
97. Anbalagan S., Sudhakar T.D. Protection of Power Transmission Lines Using Intelligent Hot Spot Detection. *2019 Fifth International Conference on Electrical Energy Systems (ICEES)*. 2019;1-6.
98. Zaripova A.D., Zaripov D.K., Usachev A.E. Automatic condition monitoring method to find defects in high-voltage insulators using infrared images. *E3S Web of Conferences*. 2019;124:03003.
99. Wronkowicz A. Approach to automated hot spot detection using image processing for thermographic inspections of power transmission lines. *Diagnostyka*. 2016;17.
100. Zhao Z., Xu G., Qi Y. Representation of binary feature pooling for detection of insulator strings in infrared images. *IEEE Transactions on Dielectrics and Electrical Insulation*. 2016;23(5):2858-2866.

#### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Астапова Марина Алексеевна, Marina S. Astapova**, Programmer Of программист лаборатории автономных Laboratory Of Autonomous Robotic робототехнических систем, Санкт- Systems, St. Petersburg Federal Research Петербургский Федеральный Center Of The Russian Academy Of исследовательский центр Российской Sciences (SPC RAS), St. Petersburg Institute академии наук (СПб ФИЦ РАН), Санкт- For Informatics And Automation Of The Петербургский институт информатики и Russian Academy Of Sciences, St. автоматизации Российской академии наук, Petersburg, Russian Federation Санкт-Петербург, Российская Федерация  
*e-mail:* [marinaastapova55@gmail.com](mailto:marinaastapova55@gmail.com)  
ORCID: [0000-0002-9121-894X](https://orcid.org/0000-0002-9121-894X)

**Лебедев Игорь Владимирович, младший Igor V. Lebedev**, Junior Researcher Of научный сотрудник лаборатории Laboratory Of Autonomous Robotic автономных робототехнических систем, Systems, St. Petersburg Federal Research Санкт-Петербургский Федеральный Center Of The Russian Academy Of исследовательский центр Российской Sciences (SPC RAS), St. Petersburg Institute академии наук (СПб ФИЦ РАН), Санкт- For Informatics And Automation Of The Петербургский институт информатики и Russian Academy Of Sciences, St. автоматизации Российской академии наук, Petersburg, Russian Federation Санкт-Петербург, Российская Федерация  
*e-mail:* [igorlebedev@gmail.com](mailto:igorlebedev@gmail.com)