

Исследование современных глубоких сверточных нейросетевых моделей и алгоритмов аугментации данных в задаче распознавания изоляции электротехнического оборудования

И.В. Матвеев, А.И. Хальясмаа, П.В. Матренин

*Уральский федеральный университет имени первого Президента России
Б. Н. Ельцина, Екатеринбург*

Аннотация: Надежность работы электроэнергетических систем в значительной мере определяется состоянием изоляции электротехнического оборудования. Повреждения изоляции могут приводить к потерям электроэнергии, сокращению срока службы оборудования, а также к аварийным отключениям, поэтому диагностика изоляции приобретает критическое значение для предотвращения технологических нарушений. Однако традиционные подходы к контролю изоляции часто трудоемки и субъективны. В связи с этим возрастает роль методов компьютерного зрения и глубокого обучения, способных автоматически обнаруживать дефекты изоляции. В статье рассматривается применение современных архитектур глубоких сверточных нейронных сетей для задачи распознавания изоляционных элементов электрооборудования. В данной работе модели на основе глубоких сверточных нейронных сетей применяются вместе с алгоритмами аугментации изображений. Аугментация данных позволяет искусственно расширить ограниченные наборы обучающих изображений за счет различных преобразований, что особенно важно при небольшом объеме набора данных. Предлагаемый подход включает проведение сравнительного анализа точности моделей на наборе изображений с реальных энергетических объектов. Проведено сравнение по метрикам точности и полноты архитектур нейросетей при использовании различных алгоритмов аугментации, с целью повысить точность распознавания изоляторов. Результаты исследования позволят определить наиболее эффективные модели и алгоритмы аугментации, пригодные для условий реальной эксплуатации на энергетических объектах с учетом сложного фона, переменного освещения и различных ракурсов съемки оборудования. Практическая ценность работы заключается в повышении надежности и эффективности автоматизированного контроля изоляции электротехнического оборудования.

Ключевые слова: компьютерное зрение, сверточные нейронные сети, изоляция, дефект, аугментация данных, машинное обучение, энергетика, автоматизация анализа изображений.

Введение

Изоляторы являются важными элементами электроэнергетических систем, обеспечивая электрическую изоляцию между токоведущими частями и конструктивными элементами оборудования. Их надёжное распознавание на изображениях, полученных с беспилотных летательных аппаратов (БПЛА) или других средств визуального контроля, играет важную роль в задачах

технического мониторинга энергообъектов. Автоматическое определение местоположения и формы изоляторов на снимках в различных спектрах необходимо для анализа состояния оборудования и организации эффективного технического обслуживания. Распознавание изоляторов способствует повышению точности систем визуального контроля и снижает трудозатраты на обработку изображений. Задача сегментации изоляторов на изображениях является важным этапом создания интеллектуальных систем мониторинга состояния энергетической инфраструктуры.

Объём графических данных для диагностики электрооборудования значительно вырос из-за внедрения современных средств мониторинга.

Традиционные подходы к обработке изображений, включая визуальный контроль и классические алгоритмы компьютерного зрения, при таком объёме данных оказываются недостаточно эффективными [1]. Осмотр изоляторов, требующий подъёма сотрудников на опоры, крайне трудоёмок, отнимает много времени и сопряжён с риском производственного травматизма.

В этой ситуации перспективным решением становится применение методов глубокого обучения – свёрточных нейронных сетей (Convolutional neural network – CNN) совместно с аугментацией данных. Методы глубокого обучения широко используются в задачах контроля линий электропередачи и демонстрируют высокую эффективность в обнаружении изоляторов, существенно превосходя классические методы по точности. Например, модель на основе ResNet-101 достигла 80 % точности при обнаружении изоляторов [2].

Цель данной работы – исследовать и сопоставить эффективность различных архитектур CNN и методов аугментации данных для автоматизированного распознавания изоляторов на снимках видимого спектра с БПЛА. Рассматриваются архитектуры нейронных сетей вида

кодировщик-декодировщик (Encoder-Decoder, ED), а также каскад подобных сетей. Также анализируется влияние разнообразных приемов аугментации изображений на точность распознавания изоляторов. Определено оптимальное сочетание архитектуры нейронной сети и алгоритма аугментации, обеспечивающее наилучшую точность.

Особенности изображения изоляции электротехнического оборудования

Изоляторы линий электропередачи могут различаться по форме, материалу и классу напряжения, на котором они используются. В большинстве случаев изоляторы представляют собой стеклянные или фарфоровые диски, соединённые в гирлянды, либо композитные элементы с рёбрами.

Особенностью распознавания изоляторов является наличие повторяющихся элементов, которые могут сливаться друг с другом или с фоном. Кроме того, посторонние объекты, такие как металлическая арматура, провода, элементы опор и т.д. при большом отдалении предметов и недостаточной контрастности изображений могут распознаваться моделями как изоляторы. При различных ракурсах изоляторы могут частично перекрываться другими объектами, иметь искажения формы, сильные блики или тени, что усложняет задачу распознавания.

Нестабильное освещение может привести как к пересветам и насыщенным теням при ярком солнце, так и к снижению контрастности при облачной погоде. Атмосферные явления, такие как туман, дождь, пыль снижают резкость изображения [1]. Зашумленность изображений, возникающая из-за вибрации БПЛА, некачественной фокусировки или невысокого разрешения камер, дополнительно усложняет задачу [3-5].

Открытые размеченные датасеты электротехнического оборудования в настоящее время представлены только в видимом спектре. Сложность сбора

большого объема данных приводит к необходимости применять методы дополнения данных, в том числе алгоритмы аугментации.

Постановка задачи и общая схема обработки данных

Задача формализуется как задача семантической сегментации [6], целью которой является выделение на изображении пикселей, принадлежащих элементам изоляции. Учитывая разнообразие форм, ракурсов и условий съёмки, решение задачи требует использования современных методов глубокого обучения, то есть различных архитектур сверточных нейронных сетей, а также алгоритмов аугментации. Задача состоит из четырех этапов: сбор данных, их аннотирование для формирования датасета, обработка и анализ данных.

На этапе сбора данных было получено 480 снимков с БПЛА в видимом диапазоне при различных условиях: ярком дневном свете и в сумерках, с расстояний от 5 до 25 метров между БПЛА и изолятором, при разных углах съёмки.

На этапе аннотирования все изоляторы на снимках были размечены как полигональные контуры.

Этап обработки необходим для преобразования файлов изображений и аннотаций в формат для обучения нейронных сетей. Все изображения приведены к единому размеру и преобразованы в матрицы вещественных чисел от 0 до 1 для нормализации. Применение глубоких сверточных нейронных сетей и алгоритмов аугментации осуществляется на этапе анализа данных, которые подробно описаны ниже.

Метод

Алгоритмы аугментации данных служат для искусственного увеличения объема и разнообразия набора данных, что повышает способность модели обобщать выявленные зависимости [7].

В работе использовались следующие алгоритмы аугментации: повороты; зеркальные отражения; сдвиг; масштабирование; нелинейное перспективное искажение; изменение яркости; изменение контрастности; размытие фильтром Гаусса.

Аффинные преобразования делают модель инвариантной к положению объекта, улучшая её способность распознавать изоляторы в различных ракурсах. Нелинейные искажения повышают устойчивость модели к оптическим искажениям из-за особенностей камер. Аугментация по яркости и контрасту помогает сделать модель устойчивой к изменениям освещённости. Фильтр Гаусса имитирует снимки, сфокусированные не на изоляторах.

Для тестирования обнаружения объектов изоляции были выбраны модели, которые могли бы дополнять друг друга в будущем для создания каскадной модели. Именно этим обоснован выбор архитектур DeepLabV3+ [8] и U-Net++ [9, 10].

Архитектура DeepLabV3+ представляет собой современную модель сегментации, сочетающую в себе преимущества пространственно-пирамидальной обработки признаков и архитектуры ED. Использование пространственно-пирамидальной свертки позволяет избежать потерю разрешения, что особенно важно, так как изоляторы могут иметь различный размер на снимке. Модель одновременно обрабатывает признаки разных масштабов, что позволяет ей учитывать как мелкие детали, так и снимок в целом.

Архитектура U-Net++ является усовершенствованной версией классической архитектуры U-Net, адаптированной для более точного восстановления границ объектов. Основной особенностью U-Net++ является использование вложенных соединений между слоями кодировщика и декодировщика для передачи признаков между ними, что позволяет более

эффективно учитывать данные различного масштаба [9]. Благодаря плотной связи между слоями и возможности постепенного уточнения признаков при декодировании, модели архитектуры U-Net++ показывает высокую точность при ограниченном количестве обучающих данных [9, 10].

Также в работе предложена каскадная архитектура, которая заключается в применении к изображениям модели на основе DeepLabV3++ с последующей конкатенацией входного изображения и выхода модели DeepLabV3++ (сегментированного изображения) для получения входного тензора, обрабатываемого моделью U-Net++. Таким образом, модель архитектуры U-Net++ получает на вход три канала изображения в видимом спектре, а также один канал, содержащий 0 или 1 в зависимости от того, отнесла ли модель на основе DeepLabV3++ пиксель к изоляции.

В обеих моделях в качестве кодировщика использовалась предобученная модель ResNet34.

Результаты

Модели обучались и тестировались на описанном выше наборе данных. Обучение моделей проводилось в течение 20 эпох, с использованием минипакетов по 4 изображения. Для оценки работы моделей были использованы приведенные ниже метрики.

Точность отражает, какая доля всех пикселей, определенных моделью как принадлежащие к интересующему классу (P), действительно являются таковыми:

$$Pre = \frac{TP}{TP + FP}, \quad (1)$$

где TP – количество пикселей, правильно определенных как принадлежащие классу P ; FP – количество пикселей, ошибочно отнесённых к нему.

Высокое значение точности означает, что модель редко ошибочно классифицирует фон как изоляторы

Полнота показывает, какая доля пикселей, которые на самом деле относятся к интересующему классу, были правильно определены моделью:

$$Rec = \frac{TP}{TP + FN}, \quad (2)$$

где FN – количество пикселей класса P , которые модель не отнесла к нему.

Высокое значение полноты свидетельствует, что модель обнаруживает большую часть площади изоляторов на снимке.

Гармоническое среднее является агрегированием точности и полноты:

$$F1 = \frac{2 \cdot Pre \cdot Rec}{Pre + Rec} \quad (3)$$

IoU измеряет, насколько хорошо определенная моделью область совпадает с истинной (размеченной):

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

Результаты обучения моделей представлены в таблице №1.

Таблица № 1

Результаты работы моделей (без аугм. – аугментация не применялась, мин. и макс. аугм. – минимальная и максимальная аугментация, соответственно).

Метрики	DeepLabv3+			U-Net++			Каскадная модель		
	Без аугм.	Мин. аугм.	Макс. аугм.	Без аугм.	Мин. аугм.	Макс. аугм.	Без аугм.	Мин. аугм.	Макс. аугм.
<i>Pre</i>	0,62	0,63	0,7	0,76	0,76	0,66	0,73	0,7	0,62
<i>Rec</i>	0,74	0,76	0,7	0,77	0,75	0,84	0,75	0,78	0,81
<i>IoU</i>	0,51	0,52	0,54	0,62	0,61	0,59	0,57	0,59	0,55
F1	0,68	0,69	0,7	0,76	0,75	0,74	0,74	0,74	0,71

При минимальной аугментации использовались фильтр Гаусса сглаживание и повороты. При максимальной – все приведенные выше алгоритмы аугментации.

Наилучший результат показала модель U-Net++ без аугментации и с минимальным набором алгоритмов аугментации. Примеры результатов модели на основе U-Net++ приведены на рисунке 1.



Рис. 1. – Примеры результатов модели на основе U-Net++ (сверху вниз: без аугментации, с минимальной и максимальной аугментацией)

Можно отметить, что модель, обученная без применения аугментации, обладает более высокой точностью, так как смогла распознать близкие ряды изоляторов не как один целый объект, а как два отдельных. Результаты работы моделей при наилучшем для каждой наборе алгоритмов аугментации показаны на рисунке 2.




Рис. 2. – Примеры результатов моделей
(сверху вниз: U-Net++, каскадная, DeepLabV3+)

В целом, результаты показывают, что модель на основе DeepLabV3+ выделила контуры объектов интереса с меньшей точностью, как и каскадная модель, результаты представлены на рисунках 3 и 4, соответственно.



Рис. 3. – Примеры результатов модели на основе DeepLabV3+




Рис. 4. – Примеры результатов каскадной модели

Каскадная модель показала близкие результаты к U-Net++, проиграв ей в точности на больших расстояниях до изоляторов, но превзойдя на малых расстояниях.

Аугментация не дала значительного улучшения, а при множественном применении алгоритмов аугментации у всех моделей возросла чувствительность, но при этом упала точность. Таким образом, оптимальным вариантом среди рассмотренных оказалось использование небольшого количества алгоритмов аугментации.

Заключение

В работе рассмотрены возможности распознавания изоляции электротехнического оборудования по снимкам в видимом диапазоне, а также дана оценка влияния алгоритмов аугментации на качество моделей: наилучшим вариантом оказалось использование небольшого количества алгоритмов аугментации. Можно предположить, что причиной стало небольшое количество снимков в наборе данных.

Обоснована возможность распознавания изоляторов электротехнического оборудования на основе архитектур глубоких моделей семантической сегментации, в частности U-Net++. Результаты могут быть использованы в интеллектуальных системах автоматизированного мониторинга и диагностики оборудования в электроэнергетике.

Литература

1. Хальясмаа А.И. Метод автоматического анализа тепловизионных изображений высоковольтного оборудования с помощью алгоритмов компьютерного зрения и машинного обучения без учителя // Инженерный вестник Дона. 2025. №2. URL: ivdon.ru/ru/magazine/archive/n2y2025/9865

2. Zhang J., Xiao T., Li M., Zhou Y. Deep-learning-based detection of transmission line insulators // *Energies*. 2023. V. 16. Article 5560. DOI: 10.3390/en16145560
3. Zhaoyun Z., Shihong H., Yanxin L., Hui L., Zeng D., Houtang H. Image detection of insulator defects based on morphological detection and deep learning // *Energies*. 2022. Vol. 15. No. 7. Article 2465. DOI: 10.3390/en15072465
4. Wei D., Hu B., Shan C., Liu H. Insulator defect detection based on improved Yolov5s // *Frontiers in Earth Science*. 2023. Vol. 11. Article 1337982. DOI: 10.3389/feart.2023.1337982
5. Xu Z., Tang X. Transmission line insulator defect detection algorithm based on MAP-YOLOv8 // *Scientific Reports*. 2025. Vol. 15. Article 92445. DOI: 10.1038/s41598-025-92445-3
6. Csurka G., Volpi R., Chidlovskii B. Semantic image segmentation: two decades of research // *Arxiv*. 2023. DOI: 10.48550/arXiv.2302.06378
7. Shorten C., Khoshgoftaar T.M. A survey on image data augmentation for deep learning // *Journal of Big Data*. 2019. Vol. 6. Article 60. DOI: 10.1186/s40537-019-0197-0
8. Chen L.-C., Zhu Y., Papandreou G., Schroff F., Adam H. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation // *Arxiv*. 2018. DOI: 10.48550/arXiv.1802.02611
9. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // *Arxiv*. 2015. DOI: 10.48550/arXiv.1505.04597
10. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // *Lecture Notes in Computer Science*. 2018. Vol. 11045. DOI: 10.1007/978-3-030-00889-5_1

References

1. Khalyasmaa A.I. *Inzhenernyj vestnik Dona*. 2025. Vol. 2. URL: ivdon.ru/ru/magazine/archive/n2y2025/9865

2. Zhang J., Xiao T., Li M., Zhou Y. Energies. 2023. V. 16. Article 5560. DOI: 10.3390/en16145560
3. Zhaoyun Z., Shihong H., Yanxin L., Hui L., Zeng D., Houtang H. Energies. 2022. Vol. 15. No. 7. Article 2465. DOI: 10.3390/en15072465
4. Wei D., Hu B., Shan C., Liu H. Frontiers in Earth Science. 2023. Vol. 11. Article 1337982. DOI: 10.3389/feart.2023.1337982
5. Xu Z., Tang X. Scientific Reports. 2025. Vol. 15. Article 92445. DOI: 10.1038/s41598-025-92445-3
6. Csurka G., Volpi R., Chidlovskii B. Arxiv. 2023. DOI: 10.48550/arXiv.2302.06378
7. Shorten C., Khoshgoftaar T.M. Journal of Big Data. 2019. Vol. 6. Article 60. DOI: 10.1186/s40537-019-0197-0
8. Chen L.-C., Zhu Y., Papandreou G., Schroff F., Adam H. Arxiv. 2018. DOI: 10.48550/arXiv.1802.02611
9. Ronneberger O., Fischer P., Brox T. Arxiv. 2015. DOI: 10.48550/arXiv.1505.04597
10. Zhou Z., Siddiquee M.M.R., Tajbakhsh N., Liang J. Lecture Notes in Computer Science. 2018. Vol. 11045. DOI: 10.1007/978-3-030-00889-5_1.

Дата поступления: 6.06.2025

Дата публикации: 25.07.2025